



Харківський національний університет радіоелектроніки  
Державне підприємство  
"Південний державний  
проектно-конструкторський та науково-дослідний  
інститут авіаційної промисловості"



Kharkiv National University of Radio Electronics  
State Enterprise  
"Southern National Design & Research Institute of Aerospace Industries"

## Сучасний стан наукових досліджень та технологій в промисловості

## Innovative technologies and scientific solutions for industries

*Щоквартальний науковий журнал*

**№ 1 (31), 2025**

Затверджений до друку  
Науково-технічною Радою  
Харківського національного університету радіоелектроніки  
(Протокол № 2 від 20 березня 2025 р.)

### **ЗАСНОВНИКИ**

Харківський національний університет радіоелектроніки,  
Державне підприємство "Південний державний  
проектно-конструкторський та науково-дослідний інститут  
авіаційної промисловості"

### **АДРЕСА РЕДАКЦІЇ:**

Україна, 61166, м. Харків, проспект Науки, 14  
Інформаційний сайт: <http://itssi-journal.com>  
<https://journals.uran.ua/itssi>  
E-mail редколегії: [journal.itssi@gmail.com](mailto:journal.itssi@gmail.com)

*Quarterly scientific journal*

**No. 1 (31), 2025**

Approved for publication  
by the Scientific and Technical Council  
of the Kharkiv National University of Radio Electronics  
(Protocol No. 2 d.d. 220 March 2025)

### **ESTABLISHERS**

Kharkiv National University of Radio Electronics,  
State Enterprise  
"National Design & Research Institute  
of Aerospace Industries"

### **EDITORIAL OFFICE ADDRESS:**

14 Nauky Ave., Kharkiv, Ukraine, 61166  
Information site: <http://itssi-journal.com>  
<https://journals.uran.ua/itssi>  
E-mail of the editorial board: [journal.itssi@gmail.com](mailto:journal.itssi@gmail.com)

Ідентифікатор медіа R30-03878

Витяг з реєстру суб'єктів у сфері медіа – реєстрантів від 25.04.2024 № 1410

*Журнал включено до Переліку наукових фахових видань України, в яких можуть публікуватися результати дисертаційних робіт на здобуття наукових ступенів доктора і кандидата наук наказом Міністерства освіти і науки України від 16.07.2018 №775 (додаток 7)*

Харків – 2025

© Харківський національний університет радіоелектроніки,  
Державне підприємство "Південний державний проектно-конструкторський  
та науково-дослідний інститут авіаційної промисловості"

## РЕДАКЦІЙНА КОЛЕГІЯ

### Головний редактор

**Бодянський Євгеній Володимирович,**  
д-р техн. наук, професор

### Заступник головного редактора

**Айзенберг Ігор Наумович,**  
канд. техн. наук, професор (США);  
**Шекер Серхат,** д-р техн. наук, професор (Туреччина)

### Члени редколегії:

**Артюх Роман Володимирович,** канд. техн. наук;  
**Бабенко Віталіна Олексіївна,**  
д-р екон. наук, канд. техн. наук, професор;  
**Безкоровайний Володимир Валентинович,**  
д-р техн. наук, професор;  
**Гасімов Юсіф,** д-р мат. наук, професор (Азербайджан);  
**Гопєєнко Віктор,** д-р техн. наук, професор (Латвія);  
**Го Цян,** д-р техн. наук, професор (КНР);  
**Зайцева Єлена,** д-р техн. наук, професор (Словаччина);  
**Зачко Олег Богданович,** д-р техн. наук, професор;  
**Коваленко Андрій Анатолійович,** д-р техн. наук, професор;  
**Косенко Віктор Васильович,** д-р техн. наук, професор;  
**Костін Юрій Дмитрович,** д-р екон. наук, професор;  
**Левашенко Віталій,** д-р техн. наук, професор (Словаччина);  
**Лемешко Олександр Віталійович,** д-р техн. наук, професор;  
**Малєєва Ольга Володимирівна,** д-р техн. наук, професор;  
**Момот Тетяна,** д-р екон. наук, професор (США);  
**Музика Катерина Миколаївна,** д-р техн. наук, професор;  
**Назарова Галина Валентинівна,** д-р екон. наук, професор;  
**Невлюдов Ігор Шакирович,** д-р техн. наук, професор;  
**Опанасюк Анатолій Сергійович,**  
д-р фіз.-мат. наук, професор;  
**Павлов Сергій Володимирович,** д-р техн. наук, професор;  
**Паржнн Юрій,** д-р техн. наук, професор (США);  
**Перова Ірина Геннадіївна,** д-р техн. наук, професор;  
**Петленков Едуард,** канд. техн. наук (Естонія);  
**Петришин Любомир,** д-р техн. наук, професор (Польща);  
**Рубан Ігор Вікторович,** д-р техн. наук, професор;  
**Семенець Валерій Васильович,** д-р техн. наук, професор;  
**Семенов Сергій,** д-р техн. наук, професор (Польща);  
**Сетлак Галина,** д-р техн. наук, професор (Польща);  
**Терзіян Ваган,** д-р техн. наук, професор (Фінляндія);  
**Телєтов Олександр Сергійович,** д-р екон. наук, професор;  
**Тімофєєв Володимир Олександрович,**  
д-р техн. наук, професор;  
**Філатов Валентин Олександрович,** д-р техн. наук, професор;  
**Чумаченко Ігор Володимирович,** д-р техн. наук, професор;  
**Чухрай Наталія Іванівна,** д-р екон. наук, професор;  
**Юн Джин,**  
канд. фіз.-мат. наук, професор (КНР);  
**Ястремська Олена Миколаївна,** д-р екон. наук, професор.

## EDITORIAL BOARD

### Editor in Chief

**Bodyanskiy Yevgeniy,**  
Dr. Sc. (Engineering), Professor, Ukraine

### Deputy Chief Editor

**Igor Aizenberg,**  
PhD (Computer Science), Professor (United States)  
**Serhat Seker,** Dr. Sc. (Engineering), Professor (Turkey)

### Editorial Board Members:

**Artiukh Roman,** PhD (Engineering Sciences) (Ukraine);  
**Babenko Vitalina,**  
Dr. Sc. (Economics); PhD (Engineering Sciences), Professor (Ukraine);  
**Bezkorovainyi Volodymyr,**  
Dr. Sc. (Engineering), Professor (Ukraine);  
**Gasimov Yusif,** Dr. Sc. (Mathematical), Professor (Azerbaijan);  
**Gopeyenko Victors,** Dr. Sc. (Engineering), Professor (Latvia);  
**Guo Qiang,** Dr. Sc. (Engineering), Professor (P.R. of China);  
**Zaitseva Elena,** Dr. Sc. (Engineering), Professor (Slovak Republic);  
**Zachko Oleh,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Kovalenko Andrey,** Dr. Sc. (Engineering), Professor, (Ukraine);  
**Kosenko Viktor,** Dr. Sc. (Engineering), Professor, (Ukraine);  
**Kostin Yuri,** Dr. Sc. (Economics), Professor (Ukraine);  
**Levashenko Vitaly,** Dr. Sc. (Engineering), Professor (Slovakia);  
**Lemeshko Oleksandr,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Malyeyeva Olga,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Momot Tatiana,** Dr. Sc. (Economics), Professor (USA);  
**Muzyka Kateryna,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Nazarova Galina,** Dr. Sc. (Economics), Professor (Ukraine);  
**Nevliudov Igor,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Opanasyuk Anatoliy,**  
Dr. Sc. (Physical and Mathematical), Professor (Ukraine);  
**Pavlov Sergii,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Parzhyn Yurii,** Dr. Sc. (Engineering), Professor (USA);  
**Perova Iryna,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Petlenkov Eduard,** PhD (Engineering Sciences) (Estonia);  
**Petryshyn Lubomyr,** Dr. Sc. (Engineering), Professor (Poland);  
**Ruban Igor,** Dr. Sc. (Engineering), Professor, (Ukraine);  
**Semenets Valery,** Dr. Sc. (Engineering), Professor, (Ukraine);  
**Semenov Serhii,** Dr. Sc. (Engineering), Professor (Poland);  
**Setlak Galina,** Dr. Sc. (Engineering), Professor (Poland);  
**Terziyan Vagan,** Dr. Sc. (Engineering), Professor, (Finland);  
**Teletov Aleksandr,** Dr. Sc. (Economics), Professor (Ukraine);  
**Timofeyev Volodymyr,**  
Dr. Sc. (Engineering), Professor (Ukraine);  
**Filatov Valentin,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Chumachenko Igor,** Dr. Sc. (Engineering), Professor (Ukraine);  
**Chukhray Nataliya,** Dr. Sc. (Economics), Professor (Ukraine);  
**Yu Zheng,**  
PhD (Physico-Mathematical Sciences), Professor (P.R. of China);  
**Iastremska Olena,** Dr. Sc. (Economics), Professor (Ukraine)

## ЗМІСТ

### Інформаційні технології

- 5 *Герасимук Д.В., Поляков А.О., Федорченко В.М.*  
Виявлення компромісів між справедливістю, стабільністю і точністю  
для відповідального вибору моделі машинного навчання (ua)
- 20 *Дашенков Д. С., Смеляков К. С.*  
Розширення набору даних *ImageNET* для мультимодального навчання  
з текстом та зображеннями (ua)
- 32 *Долгий А. І., Шубін І. Ю.*  
Дослідження сучасних методів та інструментів онтологічного інжинірингу  
в контексті створення інтелектуальних систем (ua)
- 49 *Єна М. В.*  
Розроблення алгоритмів оброблення даних у реальному часі  
для оптимізації трафіку (ua)
- 61 *Каргін А. О., Кузьменко Р. С.*  
Модель ймовірно-нечіткого актуатора  
в контурі м'якого управління автономною безлюдною системою (ua)
- 73 *Ляшенко О. С., Михайліченко І. В.*  
Модель автономної системи моніторингу та оптимізації ІТ-інфраструктури  
з використанням трансформерів (ua)
- 83 *Мацелюх Ю. Р., Литвин В. В.*  
Метод *K*-середніх для аналізу даних  
з організації пасажирських перевезень у розумному місті (ua)
- 102 *Поддубний В. О., Сєвєрінов О. В., Непокритов Д. М.*  
Дослідження ефективності алгоритмів оброблення зображень  
у схемах нульового водяного (ua)
- 115 *Сітнікова О. О., Мельник М. О., Сирота О. П., Семенов С. Г.*  
Інтелектуальний метод підтримки ухвалення  
рішення про безпеку програмного забезпечення з використанням гібридних моделей (en)
- 127 *Усачов В. О., Шубін І. Ю.*  
Структурно-функціональна модель навчання в комп'ютеризованих системах навчання (ua)
- 143 *Чернишов Д. В.*  
Порівняльна система для аналізу метрик відстані у високовимірному просторі (en)

### Телекомунікаційні системи та комп'ютерні мережі

- 151 *Кирсанов О. О., Кривенко С. А.*  
Модель *ML* для аналізу властивостей речовини  
на основі її фізико-хімічних особливостей (ua)
- 166 *Невлюдов І. Ш., Новоселов С. П., Сичова О. В.*  
Метод децентралізованого управління технологічними процесами  
на інтелектуальному виробництві (ua)
- 180 *Пастушенко Г. О.*  
Розроблення методу підвищення точності локалізації бездротових сенсорних мереж (ua)
- 190 **Алфавітний покажчик**

## CONTENTS

### Information Technology

- 5 ***Herasymuk D., Poliakov A., Fedorchenko V.***  
Detecting trade-offs between fairness, stability, and accuracy  
for responsible machine learning model selection (ua)
- 20 ***Dashenkov D., Smelyakov K.***  
Extending the *ImageNET* dataset for multimodal text and image learning (ua)
- 32 Dolhyi A., Shubin I. Research of modern methods  
and tools of ontological engineering in the context of creating intellectual systems (ua)
- 49 ***Yena M.***  
Development of real time data processing algorithms for UAV traffic optimization (ua)
- 61 ***Kargin A., Kuzmenko R.***  
Probabilistic-fuzzy actuator model in the soft control circuit  
of an autonomous unmanned system (ua)
- 73 ***Liashenko O., Mykhailichenko I.***  
Autonomous monitoring and optimization system for IT infrastructure using transformers (ua)
- 83 ***Matseliukh Y., Lytvyn V.***  
Application of the K-means clustering method  
in the organisation of passenger transport in a smart city (ua)
- 102 ***Poddubnyi V., Sievierinov O., Nepokrytov D.***  
Research the efficiency of image processing algorithms in zero watermark schemes (ua)
- 115 ***Sitnikova O., Melnyk M., Syrota O., Semenov S.***  
Intelligent method for supporting decision-making on software security using hybrid models (en)
- 127 ***Usachov V., Shubin I.***  
A structural-functional model of learning in computerized learning systems (ua)
- 143 ***Chernyshov D.***  
Comparative framework for analyzing distance metrics in high-dimensional spaces (en)

### Telecommunication Systems & Computer Network

- 151 ***Kyrsanov O., Kryvenko S.***  
Machine learning model for predicting substance properties based  
on its physicochemical properties (ua)
- 166 ***Nevlyudov I., Novoselov S., Sychova O.***  
Method of decentralized control of technological processes in intelligent manufacturing (ua)
- 180 ***Pastushenko H.***  
Development of the method for increasing the accuracy  
of localization of wireless sensor networks (ua)
- 190 **Alphabetical index**

Д. ГЕРАСИМУК, А. ПОЛЯКОВ, В. ФЕДОРЧЕНКО

## ВИЯВЛЕННЯ КОМПРОМІСІВ МІЖ СПРАВЕДЛИВІСТЮ, СТАБІЛЬНІСТЮ І ТОЧНІСТЮ ДЛЯ ВІДПОВІДАЛЬНОГО ВИБОРУ МОДЕЛІ МАШИННОГО НАВЧАННЯ

**Предметом дослідження** в статті є процес вибору моделі машинного навчання, що виконується дата-саєнтистами для побудови моделей у критично важливих сферах. **Мета роботи:** 1) створити програмну бібліотеку для вимірювання точності, стабільності та справедливості моделей; 2) провести експерименти для виявлення компромісів між справедливістю, стабільністю і точністю; 3) запропонувати відповідальний процес вибору моделей для підвищення безпеки використання моделей машинного навчання. У статті передбачено розв'язати такі **завдання:** виміряти справедливість і стабільність моделей машинного навчання та дослідити їх взаємозв'язок з точністю моделей. Упроваджено такі **методи:** емпіричне оцінювання, теорія розкладання помилки моделі на упередження та дисперсію, теорія алгоритмічної справедливості та методи кількісного оцінювання невизначеності. **Досягнуті результати:** 1) запропоновано низьку передбачувальну мінливість як бажану властивість для забезпечення безпеки та рівність варіативності між різними соціальними групами як нову метрику справедливості моделей машинного навчання; 2) продемонстровано, як аналіз стабільності допомагає фахівцям долати виклики множинності моделей і обирати надійні, стійкі та справедливі моделі; 3) створено програмний фреймворк з відкритим кодом для використання спільнотою, який інтегрує вимірювання стабільності у процеси розроблення моделей. **Висновки.** У цій роботі запропоновано нову парадигму групової справедливості, що об'єднує питання правильності / якості та випадковості / стабільності з порядку денного досліджень відповідального штучного інтелекту. Застосування запропонованих підходів допомагає у відповідальному виборі моделей машинного навчання за умов множинності моделей, демонструє, що, хоча може існувати чимало моделей із зівставною точністю, є лише одна (або декілька) "найкраща" модель, що є надійною, справедливою і стабільною, як це й потрібно.

**Ключові слова:** відповідальний штучний інтелект; алгоритмічна справедливість; стабільність моделей; експериментальний аналіз.

### Вступ

Упродовж останнього десятиліття моделі машинного навчання (МН) ширше застосовуються в реальних умовах. Ці передові моделі тепер використовуються для розв'язання різноманітних складних завдань у багатьох секторах, таких як перевірка заявок на кредит, ухвалення рішень щодо застави й умовно-дострокового звільнення, а також генерування тексту, подібного до людського, на основі зображень і текстової інформації. Зі збільшенням застосування МН у соціальних сферах стало очевидним, що, попри те, що ці моделі навчаються робити точні прогнози на основі вхідних характеристик, вони також мимоволі засвоюють дискримінаційні шаблони, що призводить до "несправедливості" в їх результатах. Чимало досліджень показали, що підходи, основані на даних, можуть ненавмисно підсилювати наявні людські упередження [1–4]. Зрештою справедливість стала ключовим питанням у розвитку відповідального штучного інтелекту в останні роки.

Занепокоєння щодо групової справедливості в дослідженнях МН зосереджуються на питанні: "Чи є прогнози моделі однаково якісними в середньому для різних соціальних груп?" Один із способів визначити "однаково якісні" полягає у вимозі, щоб модель допускала порівняні помилки на вибірках з різних груп. Це природно сприяло розробленню різноманітних метрик справедливості в науковій літературі, зазвичай визначених як різниця або співвідношення міри помилки моделі (таких як рівень правильних позитивних результатів або рівень правильних негативних результатів), агрегованих за привілейованими та непривілейованими соціальними групами відповідно [5–11].

Натомість занепокоєння щодо безпеки в дослідженнях МН зосереджуються на технічних вимогах, таких як стабільність і надійність. Стабільність тут означає мінливість і випадковість у прогнозах моделі, і проводяться цікаві дослідження на перетині цих напрямів, що вивчають взаємозв'язок між справедливістю та випадковістю в ухваленні

рішень у критичних соціальних сферах крізь призму множинності моделей [12–14].

### Нормативне обґрунтування

Для прикладу розглянемо ухвалення рішень щодо прийому до юридичних шкіл. Наявні визначення справедливості, такі як демографічний паритет і баланс показників помилок, засуджували б рішення комітету, яке або систематично обирає кандидатів з однієї соціальної групи (диспропорція позитивної ставки), або систематично відхиляє перспективних кандидатів із соціально неблагополучної групи (диспропорція негативної ставки).

Однак розглянемо, як ці визначення ігнорують несправедливість через випадковість. Припустимо, що в нас є правило прийняття рішень, яке задовольняє баланс помилок, але є дуже нестабільним. Це означає, що це правило іноді приймає значно різні рішення щодо прийому для схожих кандидатів. Навряд чи правило, чії рішення нестабільні, буде дуже точним, тому звітність про точність може відтворювати загальну стабільність. Далі розглянемо правило з високою точністю, яке є також досить стабільним у середньому. Однак це правило дуже випадкове для деяких вибірок, можливо, відповідних певній меншості соціальної групи. У такій ситуації правило задовольняє критерії стабільності, але не критерії стабільності-паритету. З погляду процедурної справедливості це стає моральною проблемою, оскільки правило, очевидно, застосовує дві різні процедури – більш систематичну для представників більшості та більш випадкову для представників меншості.

Диспропорція в стабільності може також призвести до несправедливості результатів. В умовах прийому до юридичних шкіл розглянемо здатність абітурієнтів звертатися за переглядом рішення. Якщо абітурієнт звертається до комітету з проханням пояснити причину певного рішення, то (1) надійність пояснення залежить від стабільності правила – як надійно пояснити правило, чії прогнози непослідовні? (2) ефективність перегляду залежить від диспропорції стабільності правила: перегляд буде менш ефективним для представників меншості, оскільки навіть якщо вони покращують свої характеристики (значення ознак), диспропорція випадковості правила робить невизначеним, чи отримають вони бажаний результат.

У цій роботі ґрунтуємося на позиції Кріла та Геллмана [15]. На їхню думку, "проблема з випадковими алгоритмами полягає не в їх випадковості як таких, а в систематичності цієї випадковості". Ми стверджуємо, що дисперсія або випадковість сама по собі не є моральною проблемою, але диспропорція у випадковості є моральним питанням.

### Стислий опис результатів

1. Запропоновано нову парадигму групової справедливості в машинному навчанні, таку, що досліджує не лише паритет у рівнях помилок, а також паритет в упередженні, дисперсії та шуму, на які ці помилки розкладаються. Першим кроком у цьому напрямі обрано паритет-дисперсії для різних соціальних груп як новий критерій справедливості.

2. За допомогою цього нового підходу визначено компроміси між справедливістю, точністю та стабільністю, спираючись на широкомасштабне емпіричне дослідження на реальних і синтетичних даних (<https://github.com/denysgerasymuk799/fairness-variance>).

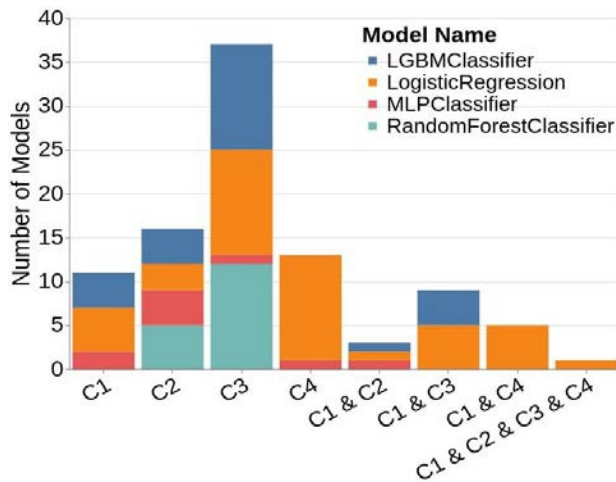
3. Продемонстровано, як цей аналіз допомагає практикам долати труднощі множинності моделей, інтегруючи додаткові критерії стабільності під час вибору моделі.

4. У межах цієї роботи створено відкритий програмний фреймворк, що передбачає вимірювання справедливості та стабільності у процесі розроблення моделей для використання спільнотою (<https://github.com/denysgerasymuk799/model-profiler>).

### Аналіз проблеми й наявних методів

Множинність моделей – це явище, в умовах якого існує кілька моделей з функціонально еквівалентною точністю для певного завдання, але ці моделі розрізняються внутрішньою структурою (що називається процедурною множинністю) або прогнозами на конкретних вибірках (що називається предикативною множинністю). У роботі демонструємо, як розуміння компромісів між справедливістю, стабільністю і точністю допомагає впоратися з множинністю моделей: включення нових критеріїв стабільності та паритету стабільності в процедури вибору моделі допомагає розрізнити моделі, які мають однакову точність (див. рис. 1).

Це дослідження конкурує з нещодавніми студіями Купера, Лонга та ін. [16, 17].



**Рис. 1.** Набір даних *Law school*: вибір моделей з найвищими показниками на основі декількох критеріїв. C1 – правильність (точність); C2 – паритет помилок (вирівняні шанси FPR); C3 – стабільність (*Label Stability*); C4 – паритет стабільності (співвідношення стабільності міток). З-поміж 84 натренованих моделей 11 мають бажану точність (C1), але лише одна модель відповідає всім чотирьом критеріям (C1&C2&C3&C4)

Так, Купер та ін. [16] досліджують справедливість за умов множинності моделей, розглядаючи розподіли можливих моделей замість окремих моделей, і пропонують нову міру випадковості, яка називається *самостійністю* (*self-consistency*). Їх експериментальна установка подібна до нашої: вони використовують простий підхід бутстрепу (*bootstrapping approach*) для вимірювання предикативної дисперсії. Важливо, що автори зосереджуються на методах зменшення випадковості (наприклад, за допомогою бегінгу (*bagging*)) та звітують про вплив на точність і справедливість. Це дослідження зосереджене на протилежній поведінці: як справедливість компрометується з точністю та стабільністю.

Лонг та ін. [17] розглядають групову справедливість у контексті стабільності. Крім того, як і наша робота, їхнє дослідження зосереджується на компромісах між справедливістю та стабільністю за умов множинності, пояснюючи наслідки як "вартість випадковості втручання для досягнення справедливості". Автори розглядають різноманітні метрики справедливості, тоді як ми обмежуємо

наше обрамлення метриками паритету помилок, щоб дослідити загальні та специфічні для груп компроміси крізь призму розкладання помилки моделі на упередження та дисперсію. Отже, як фокус, так і висновки наших досліджень різняться.

Найважливіше, що обидві згадані роботи розглядають випадковість лише загалом, тоді як ми пропонуємо паритет стабільності як новий критерій справедливості. Крім того, і Купер, і Лонг та ін. [16, 17] пропонують процедури для зменшення випадковості під час розроблення моделей. Натомість ми зосереджуємося на включенні цілей стабільності в процесі вибору моделі для контекстів ухвалення рішень, де випадковість і диспропорція у випадковості мають моральне значення.

## Технічне рішення

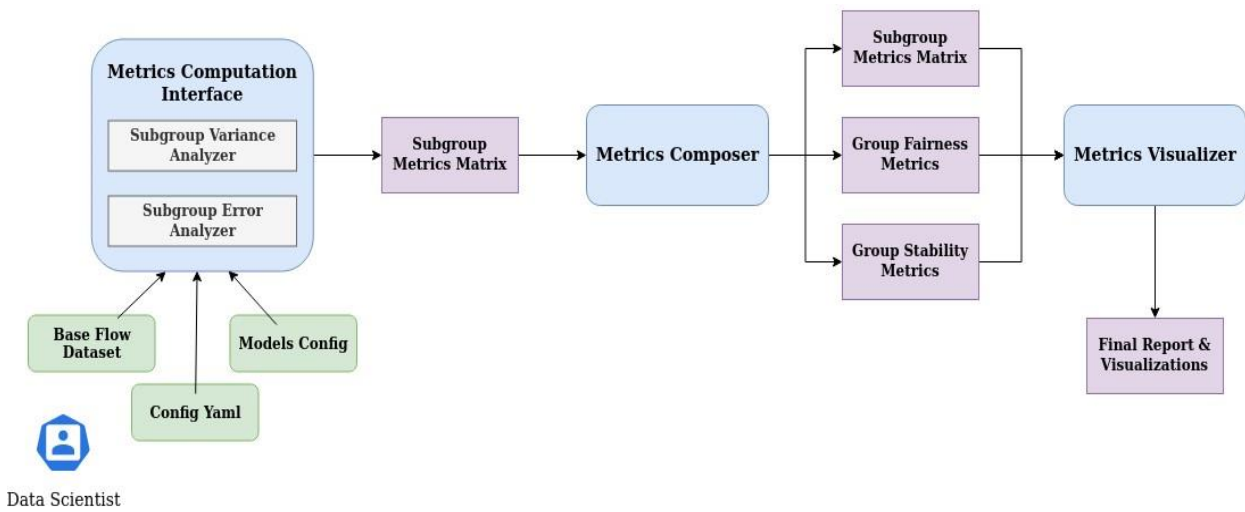
Для узгодження звітності про показники продуктивності, пов'язані зі справедливістю та стабільністю, ми створили бібліотеку *Python* спеціально для аудиту справедливості та стабільності моделей. Дизайн цієї бібліотеки керується трьома основними принципами:

- 1) спрощення розширення можливостей аналізу моделей;
- 2) забезпечення сумісності із широким спектром наборів даних і типів моделей;
- 3) надання можливості легкого створення метрик паритету відповідно до контексту використання.

Програмний каркас організовує аудит моделей у чіткі фази, зокрема *обчислення метрик підгруп*, *складання метрик для груп* та *візуалізацію метрик*. Такий структурований підхід забезпечує фахівцям з оброблення даних та практикам МН більший контроль і гнучкість, роблячи бібліотеку корисною як на етапі розроблення моделей, так і для моніторингу після їх впровадження.

## Огляд архітектури

Рис. 2 ілюструє підхід бібліотеки до побудови конвеєра аналізу моделі. Вхідні змінні для інтерфейсу користувача позначені зеленим кольором, етапи конвеєра – синім, а вихід кожного етапу відтворюється фіолетовим. Далі надамо детальний опис кожного етапу.



**Рис. 2.** Архітектура програмної бібліотеки. Вхідні змінні інтерфейсу користувача зображені зеленим кольором, етапи конвеєра – синім, а вихід кожного етапу – фіолетовим. Конвеєр аналізу передбачає три етапи оброблення: обчислення метрик підгруп, складання метрик груп і візуалізація та звітування метрик

**Вхідні змінні.** Для застосування бібліотеки користувачам необхідно надати три основні входи.

- **Основний набір даних (Base flow dataset).**

Це спеціальний об'єкт, що є набором даних користувача, зокрема такі описові характеристики, як цільовий стовпець, числові та категоріальні стовпці, а також навчальні й тестові набори. Цей об'єкт походить від класу *BaseFlowDataset*, розробленого для зручності користувача. Застосування спільного базового класу дає змогу здійснити початкову валідацію введених даних користувача, спрощуючи логіку подальших обчислень метрик.

- **Файл конфігурації YAML (Config YAML).**

Цей файл використовується з метою визначення параметрів конфігурації для інтерфейсів користувача фреймворку, які обробляють обчислення метрик. Даючи змогу користувачам визначати конфігурацію, цей підхід забезпечує більшу гнучкість, спрощуючи проведення експериментів. За допомогою одного файлу конфігурації YAML на експеримент користувачі можуть легко перемикатися між експериментами без додаткових змін в інтерфейсі користувача бібліотеки. Крім того, файл конфігурації є ефективним методом для вказівки складних налаштувань підгруп і об'єднання всіх параметрів, необхідних для аудиту моделей, в одному місці.

- Конфігураційний файл YAML містить різні деталі, такі як кількість оцінювачів в ансамблі для аналізу дисперсії, частка вибірки для випадкового відбору з навчального набору, режим обчислення метрик та інші параметри. Важливим є те, що

користувачі визначають підгрупи інтересу, просто передаючи словник із парами ключ-значення, де ключі є назвами стовпців, а значення відповідають невідповідним значенням (або списку значень) для чутливого атрибута, уможливаючи поділ підгруп. Такий підхід також дає змогу користувачам за потреби вказувати інтерсекційні групи.

- **Конфігурація моделей (Models config).**

Цей словник *Python* пов'язує назви моделей з їх ініціалізованими екземплярами для аналізу. Такий підхід дає змогу проводити аудит кількох моделей і підтримує оцінювання різних типів моделей, надаючи гнучкість у їх комплексному оцінюванні.

## Інтерфейси користувача

**Обчислення метрик підгруп.** Бібліотека надає кілька інтерфейсів користувача для обчислення метрик, зокрема інтерфейс для роботи з кількома моделями, інтерфейс для роботи з різними тестовими наборами та інтерфейс для збереження результатів у базі даних, визначеній користувачем. Після введення змінних в інтерфейс користувача основний набір даних обробляють аналізатори підгруп для отримання різноманітного набору метрик. Бібліотека використовує об'єктно орієнтовані шаблони проектування, такі як *Factory Method*, *Abstract Factory*, *Facade* і *Template Method* [18]. Її склад містить *Subgroup Variance Analyzer* і *Subgroup Error Analyzer*, що узгоджуються з підходом розкладання помилки моделі, запропонованим



у праці [19], і розроблені таким чином, щоб їх було легко розширювати додатковими аналізаторами. Після завершення обчислення метрик виходить об'єднуються в *pandas dataframe*. Користувачі також мають змогу встановити параметр збереження, що сприяє збереженню *dataframe* метрик на диску або в базі даних за допомогою функції *df\_writer*.

*Subgroup Variance Analyzer* відповідає за обчислення метрик стабільності як для всього тестового набору, так і для специфічних підгруп, визначених користувачем. Для визначення дисперсії оцінювача застосовується метод бутстрепінгу [20]. Окрім стандартного відхилення предикативних розподілів, також обчислюються додаткові метрики стабільності, такі як стабільність міток (*Label Stability*) [21], "тремтіння" (*Jitter*) [22] та IQR (міжквартильний розмах предикативної дисперсії). Аналогічно *Subgroup Error Analyzer* оцінює метрики помилок, зокрема точність, TPR (рівень правильних позитивних результатів), FPR (рівень хибних позитивних результатів), TNR (рівень правильних негативних результатів) і FNR (рівень хибних негативних результатів) – як для всього тестового набору, так і для зазначених підгруп інтересу.

**Складання метрик груп.** *Metrics Composer* керує другим етапом аудиту моделі, обчислюючи

групові метрики справедливості та стабільності. Користувачі також можуть налаштувати додаткові метрики за потреби. Наприклад, диспропорційний вплив, показник справедливості, обчислюється способом визначення співвідношення позитивних результатів для привілейованих (*priv*) і непривілейованих (*dis*) підгруп.

**Візуалізація метрик.** *Metrics Visualizer* об'єднує кілька етапів оброблення для складених метрик, створюючи формати даних, оптимізовані для візуалізації. Упроваджуючи методи цього класу, користувачі можуть створювати індивідуальні графіки, адаптовані до їхнього аналізу. Ці візуалізації також можна зібрати в інтерактивний звіт, що сприяє відповідальному вибору моделей.

#### Емпіричне оцінювання

#### Деталі експериментів

#### Набори даних

Досліджуємо компроміси між точністю, стабільністю та справедливістю (визначеними різними способами) на чотирьох наборах даних реального світу й завданнях, підсумованих у табл. 1. Ми свідомо обрали набори даних та завдання з контекстів політики, де паритет стабільності є моральною необхідністю.

Таблиця 1. Опис наборів даних і завдань

Набір даних	Галузь	Опис завдання	Групи
ACS Income	фінанси	передбачити, чи дохід людини перевищує національний медіанний дохід	стать, раса
ACS Public Coverage	охорона здоров'я	передбачити, чи має особа державне медичне страхування	стать, раса
Law school	освіта	передбачити, чи складе кандидат іспит на адвокатську практику	раса
Ricci v. De Stefano	юриспруденція	передбачити, чи отримає особа підвищення на основі результатів іспиту	раса

Для дослідження використали чотири популярні набори даних з метою аналізу справедливості, детально описані в огляді [26]. Нижче стисло подано кожний з них.

- **Folktables** (<https://github.com/zykls/folktables>).

Цей еталонний набір є збіркою сучасних даних, отриманих з опитувань Бюро перепису населення США з 50 штатів за 2014–2018 рр. Він охоплює кілька завдань прогнозування, пов'язаних із доходом, охороною здоров'я, транспортом, зайнятістю та житлом. Ми обрали два з них (перелічені нижче). Для аналізу групової справедливості формуємо групи на основі двох чутливих атрибутів: статі (бінарizzatoї на "жінок" (незахищена група)

і "чоловіків" (привілейована група)) та раси (бінарizzatoї на "небілих" (незахищена група) і "білих" (привілейована група)). Для нашого дослідження ми звітуємо про метрики диспропорцій щодо інтерсекційних груп, а саме "небілих жінок" (інтерсекційно незахищена група) порівняно з усіма іншими зразками.

- **ACS Income.** Це завдання бінарної класифікації для прогнозування: чи є дохід особи меншим за \$50,000 (мітка 0), або перевищує, або дорівнює \$50,000 (мітка 1). Цей набір даних містить вісім категоріальних і дві числові ознаки, зокрема освіту, професію та сімейний стан. Для нашого дослідження використано дані штату Джорджія

за 2018 р. і зменшено вибірку з 50,915 до 15,000 рядків для обчислювальної зручності.

- **ACS Public Coverage.** Це завдання бінарної класифікації для прогнозування: чи має особа державне медичне страхування (мітка 1), чи ні (мітка 0). Набір даних містить 17 категоріальних і дві числові ознаки, зокрема освіту, інвалідність та сімейний стан. Для нашого дослідження застосовано показники штату Каліфорнія за 2018 р. і зменшено вибірку з 138,554 до 15,000 рядків для скорочення обчислювальних вимог.

- **Law School**

([https://github.com/tailequy/fairness\\_dataset/blob/main/experiments/data/law\\_school\\_clean.csv](https://github.com/tailequy/fairness_dataset/blob/main/experiments/data/law_school_clean.csv)). Цей набір даних був зібраний за допомогою опитування, проведеного Радою з прийому до юридичних шкіл (LSAC) у 163 юридичних школах США 1991 р. Він містить записи про прийом до юридичних шкіл. Набір даних містить інформацію про 20,798 студентів, схарактеризованих 12 ознаками (три категоріальні, три бінарні та шість числових ознак). Завдання прогнозування полягає у визначенні: чи складе кандидат іспит на право (мітка 1), чи ні (мітка 0). Чутливі атрибути в цьому наборі даних – стать студента та його раса. Для нашого дослідження використовуємо повний набір даних і звітуємо про метрики диспропорції для груп, сформованих за расовою ознакою; "білі" (привілейовані) проти "небілих" (незахищені).

- **Ricci**

([https://github.com/tailequy/fairness\\_dataset/blob/main/experiments/data/ricci\\_race.csv](https://github.com/tailequy/fairness_dataset/blob/main/experiments/data/ricci_race.csv)). Цей набір даних походить з історичної справи *Ricci v. DeStefano*, у якій досліджували результати іспиту на підвищення в пожежній службі в листопаді 2003 р. Зазначений набір містить 118 результатів іспитів, де кожен зразок визначається шістьма ознаками (три числові та три бінарні ознаки). Хоча набір даних є відносно невеликим, він широко використовується у дослідженнях, спрямованих на забезпечення справедливості в класифікації. Завдання бінарної класифікації полягає в прогнозуванні: чи отримає особа підвищення на основі результатів іспиту. Єдиний чутливий атрибут – раса, що має три унікальні значення: чорний, білий і латиноамериканець. Відповідно до попередніх досліджень ми об'єднуємо "чорних" і "латиноамериканців" у "небілу" захищену групу та звітуємо про результати диспропорції для бінарних груп, сформованих за расовою ознакою.

Оскільки набір даних дуже незначний, змінюємо наше співвідношення поділу на навчальну і тестову вибірки з 80:20 на 67:33.

### Навчання та оцінювання моделі

Приймаючи орієнтований на дані підхід до стабільності, прагнемо виявити емпіричні компроміси між справедливістю, стабільністю та точністю, тому поєднуємо нашу систему оцінювання стабільності з інтервенцією передоброблення для справедливості, орієнтованої на дані. Зокрема застосовуємо *DisparateImpactRemover* – передову інтервенцію передоброблення, спрямовану на усунення дискримінаційних шаблонів у даних, реалізовану в інструментарії IBM AIF 360 [23].

Один експериментальний запуск відбувається таким чином: спочатку у випадковий спосіб ділимо набір даних на навчальний і тестовий набори (співвідношення 80:20). Потім ініціалізуємо процесор справедливості, тренуємо його на навчальному наборі й трансформуємо як навчальний, так і тестовий набори. Далі ініціалізуємо базову модель  $H$  і налаштуємо гіперпараметри один раз для кожної пари рівень виправлення / тип моделі. Після цього запускаємо процедуру бутстрепа для створення наближеного ансамблю з  $m=200$  учасниками, до того ж кожна модель навчається з оптимізованими налаштуваннями гіперпараметрів базової моделі  $H$ . Повторюємо цю процедуру шість разів, щоразу з іншим випадковим поділом навчальний: тестовий набір, для кожної пари рівень виправлення / тип моделі.

### Опис експериментів

Проведено два експерименти для кожного набору даних і завдання.

*Експеримент 1. Одна модель, багато рівнів виправлення.* Фіксуємо архітектуру моделі та змінюємо рівень виправлення  $\alpha$  методу передоброблення для справедливості. Використано *Random Forest* як тип моделі для цього експерименту та тестували для  $\alpha \in [0,1]$  з кроком 0,1. У цьому експерименті виявляємо компроміси між точністю та справедливістю (рис. 4), компроміси між стабільністю та справедливістю (рис. 5) і паритет у компромісах між стабільністю та справедливістю (рис. 3).

Експеримент 2. Один рівень виправлення, багато моделей. Цей експеримент доповнює орієнтований на дані підхід експерименту 1 моделєцентричним поглядом на стабільність. З огляду на експеримент 1 обираємо одне або два відповідні значення рівня виправлення

справедливості  $\alpha$  та навчаємо різні моделі для того самого рівня виправлення. Ми порівнюємо продуктивність лінійних моделей, моделей на основі дерев, ансамблевих моделей і нейронних мереж з бібліотеки *scikit-learn*.

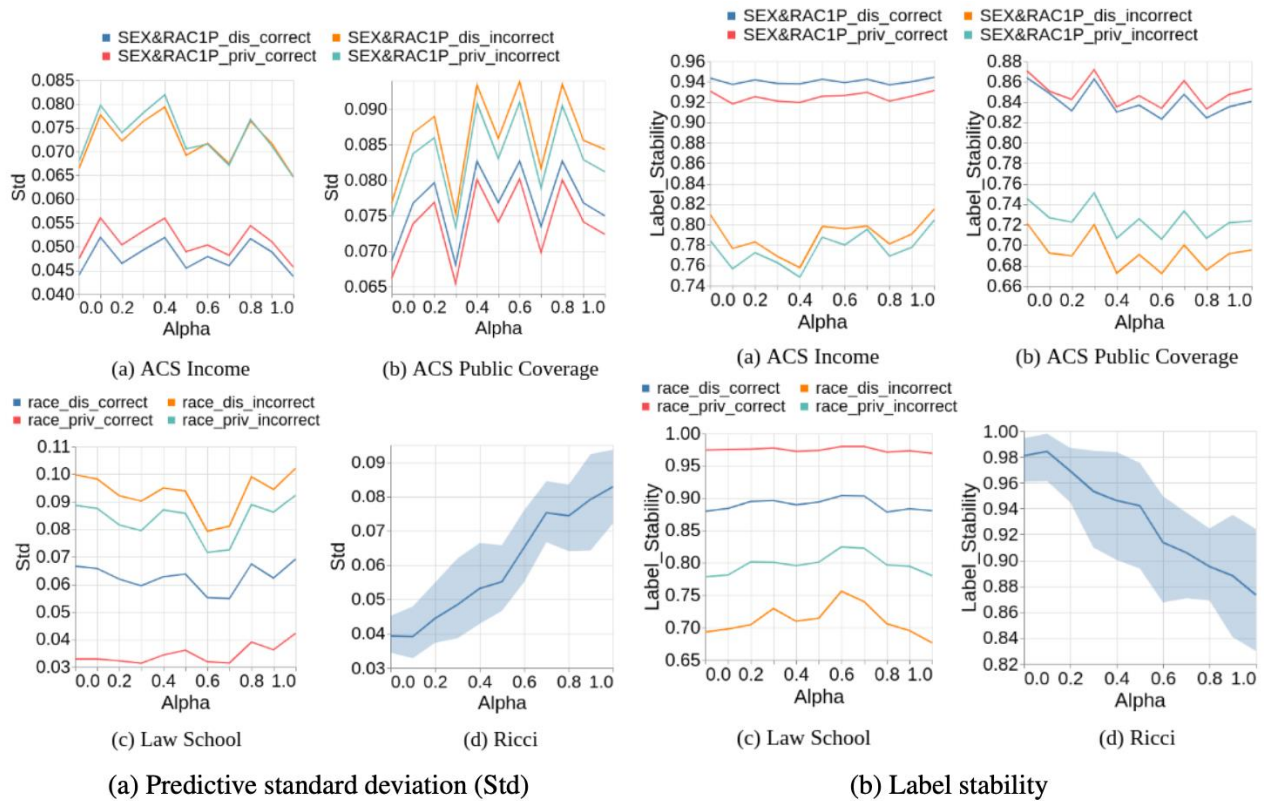


Рис. 3. Компроміси між справедливістю та стабільністю: метрика стабільності на осі  $y$  проти рівня справедливості ( $\alpha$ ) на осі  $x$ . Вищі значення *Std* і нижчі значення стабільності міток вказують на більшу нестабільність. Вище значення  $\alpha$  означає сильнішу інтервенцію для забезпечення справедливості

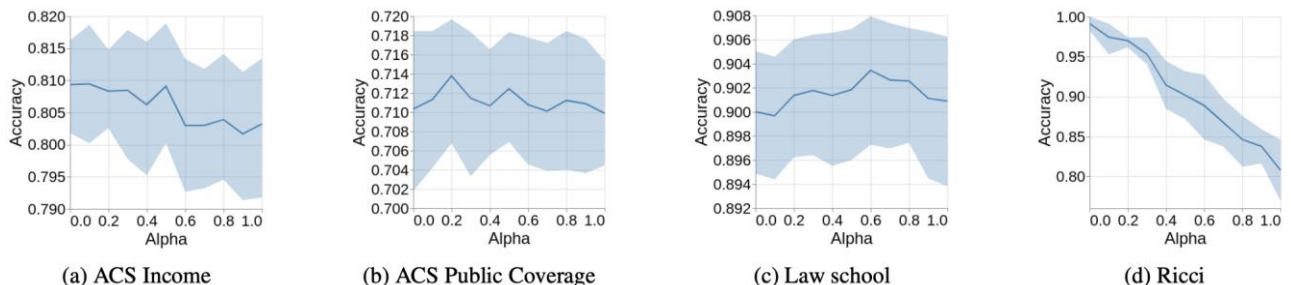
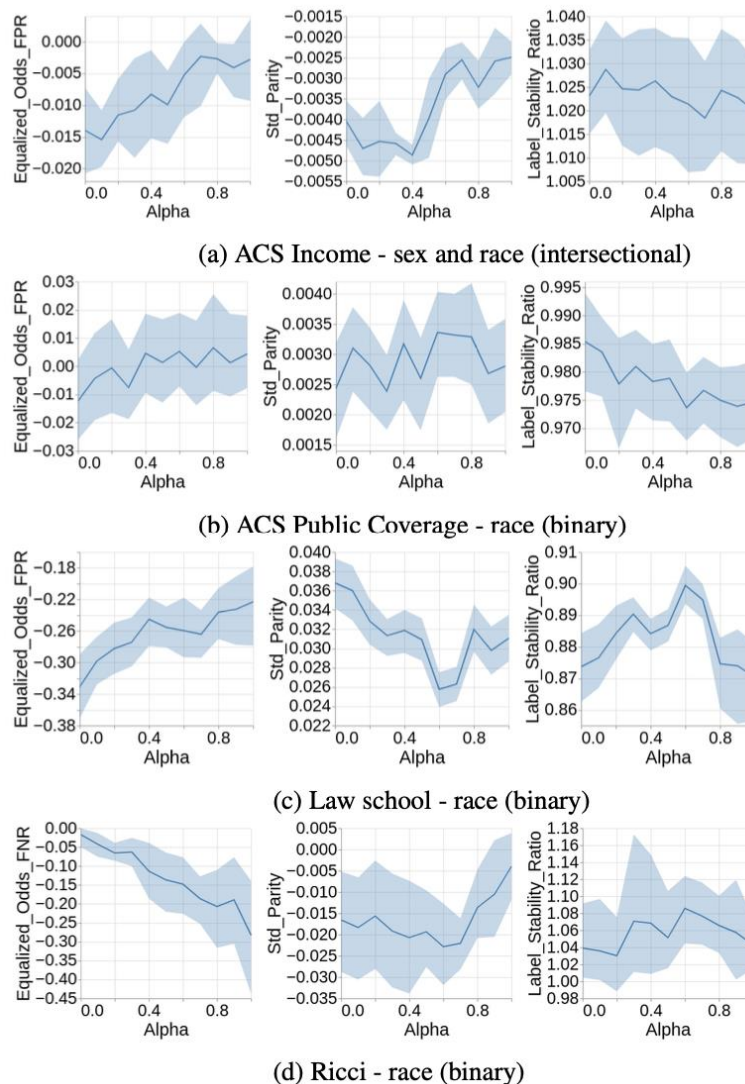


Рис. 4. Компроміси між точністю та справедливістю, де рівень справедливості  $\alpha$  зображено на осі  $x$ , а точність – на осі  $y$ . У трьох із чотирьох наборів даних спостерігається незначний вплив на точність за умови зростання справедливості, що спричиняє множинність моделей



**Рис. 5.** Тренди для метрик паритету. Вісь  $y$ : (ліворуч) паритет у рівнях помилок, значення, близьке до 0, є бажаним; (центр) паритет у стандартному відхиленні прогнозів, значення, близьке до 0, є бажаним; (праворуч) коефіцієнт стабільності міток, значення, близьке до 1, є бажаним. Вісь  $x$ : рівень справедливості ( $\alpha$ ), де більше значення вказує на сильнішу інтервенцію для забезпечення справедливості

### Метрики продуктивності моделі

Кількісно оцінюємо чотири аспекти продуктивності моделі, використовуючи широкий набір метрик.

- **Правильність.** Звітуємо про точність моделі як міру правильності її прогнозів.
- **Стабільність.** Звітуємо про стандартне відхилення прогнозів (квадратний корінь з дисперсії) та стабільність міток, усереднених по всіх вибірках, як міру нестабільності прогнозів моделі. Середнє значення  $Std$  0,1, як зображено на рис. 3, означає, що основний прогноз 0,4, наприклад, може варіюватися між 0,3 і 0,5 через невеликі відмінності в навчальних

даних. Аналогічно середня стабільність міток 0,8 означає, що очікується зміна прогнозованої мітки моделі у 20 % випадків за незначних змін у навчальних даних.

- **Паритет помилок** (класичний аспект справедливості). Звітуємо про диспропорцію в рівнях хибнопозитивних і хибнонегативних результатів для непривілейованих і привілейованих груп відповідно, як міру несправедливості моделі (класично визначену).

- **Паритет стабільності** (новий аспект справедливості). Також звітуємо про дві міри диспропорції, створені на основі наших показників стабільності, а саме паритет  $Std$  – різницю між

середнім значенням стандартного відхилення прогнозів для вибірок з непривілейованої та привілейованої груп відповідно, і коефіцієнт стабільності міток – співвідношення середньої стабільності міток для вибірок з непривілейованої та привілейованої груп відповідно. Ці метрики кількісно оцінюють диспропорцію у випадковості, яку пропонуємо як новий критерій справедливості. Диспропорція *Std*, що дорівнює 0, і коефіцієнт стабільності міток, що дорівнює 1, означають, що модель є рівномірно випадковою для різних соціальних груп у даних.

### Експеримент 1.

#### Справедливість – стабільність – точність

**Точність.** На рис. 4 продемонстровано графік залежності точності від рівня справедливості. Для трьох із чотирьох оцінених нами наборів даних вплив попереднього оброблення для справедливості на точність є незначним. Це означає, що ми отримуємо моделі, які порівняні за точністю, але розрізняються іншими характеристиками, такими як справедливість – саме це і є умовою множинності моделей. Винятком є набір даних *Ricci v. De Stefano*, де спостерігаємо класичний компроміс між справедливістю та точністю: підвищення рівня виправлення справедливості  $\alpha$  погіршує точність. На цьому наборі даних ми не спостерігаємо множинності моделей, оскільки моделі, які є порівняно справедливими, мають нижчу точність.

**Стабільність.** Далі розглядаємо, як загальна стабільність залежить від попереднього оброблення для справедливості. Звітуємо про стандартне відхилення прогнозів і стабільність міток на рис. 3 для різних рівнів справедливості ( $\alpha$ ), а також розбиваємо за демографічними групами (привілейовані або непривілейовані) і типами помилок (правильні або неправильні). Набір даних *Ricci v. De Stefano* є занадто малим для такого поділу, тому для цього набору звітуємо лише про загальні тенденції.

Експериментальні результати демонструють, що стабільність моделі залежить від попереднього оброблення для справедливості, але тренд (погіршується або покращується) є непостійним у різних наборах даних. Цікаво, що модель завжди більш стабільна (нижча, ніж *Std*, і вища, ніж *Label Stability*) на правильно класифікованих вибірках. Далі, і в межах типів помилок, модель є більш стабільною для привілейованих, ніж для непривілейованих груп

у наборах даних *ACS Public Coverage* та *Law school*. Ця тенденція для демографічних груп змінюється для *ACS Income*, де модель, як не дивно, є більш стабільною на непривілейованій групі, ніж на привілейованій.

Набір даних *Law school* показує найбільшу диспропорцію в стабільності для різних пар груп і типів помилок, тоді як *ACS Public Coverage* показує найбільшу варіацію стабільності для різних значень  $\alpha$ .

**Метрики паритету.** У цій роботі приймаємо погляд на справедливість для груп і звітуємо про диспропорцію здебільшого для вибірок з непривілейованої групи порівняно з привілейованою групою. Класично диспропорція в рівнях помилок вважалася метрикою справедливості. Звітуємо про це на рис. 5 разом з нашими новими метриками паритету стабільності, такими як паритет *Std* і коефіцієнт стабільності міток (*Label Stability*). Як очікувалося, для всіх наборів даних підвищення рівня справедливості зменшує диспропорцію в рівнях помилок (класична справедливість). Для *Ricci v. De Stefano* неконтрольована модель досягає ідеальної точності, тому модель покращує справедливість унаслідок погіршення показників для привілейованої групи, а не завдяки покращенню показників для непривілейованої групи. Отже, застосування попереднього оброблення для забезпечення справедливості до цього набору даних призводить до негативної дискримінації, де диспропорція в помилках насправді зростає для вищих рівнів справедливості на користь непривілейованої групи.

Для *ACS Income* та *Law school* – наборів даних, на яких спостерігали множинність моделей, – підвищення рівнів справедливості покращує паритет стабільності (паритет *Std* наближається до 0, коефіцієнт стабільності міток наближається до 1). Для *ACS Public Coverage* паритет *Std* коливається навколо значення за умови  $\alpha = 0$  (без втручання для забезпечення справедливості), тоді як коефіцієнт стабільності міток незначно погіршується (віддаляється від 1 зі збільшенням  $\alpha$ ).

**У підсумку** в нашому емпіричному аналізі зауважуємо певні тенденції.

1. Точність і стабільність зазвичай змінюються разом. Ми спостерігаємо незначний вплив на точність і незначний вплив на стабільність у *ACS Income* та *Law school*. Коли втручання для забезпечення справедливості впливають на точність, вони також позначаються на стабільності, як видно з *Ricci v. De Stefano*.

2. За умов множинності, якщо вплив втручання для забезпечення справедливості на точність і стабільність не значний, то покращення справедливості (паритет у помилках) також покращує паритет стабільності, як видно з *ACS Income* та *Law School*.

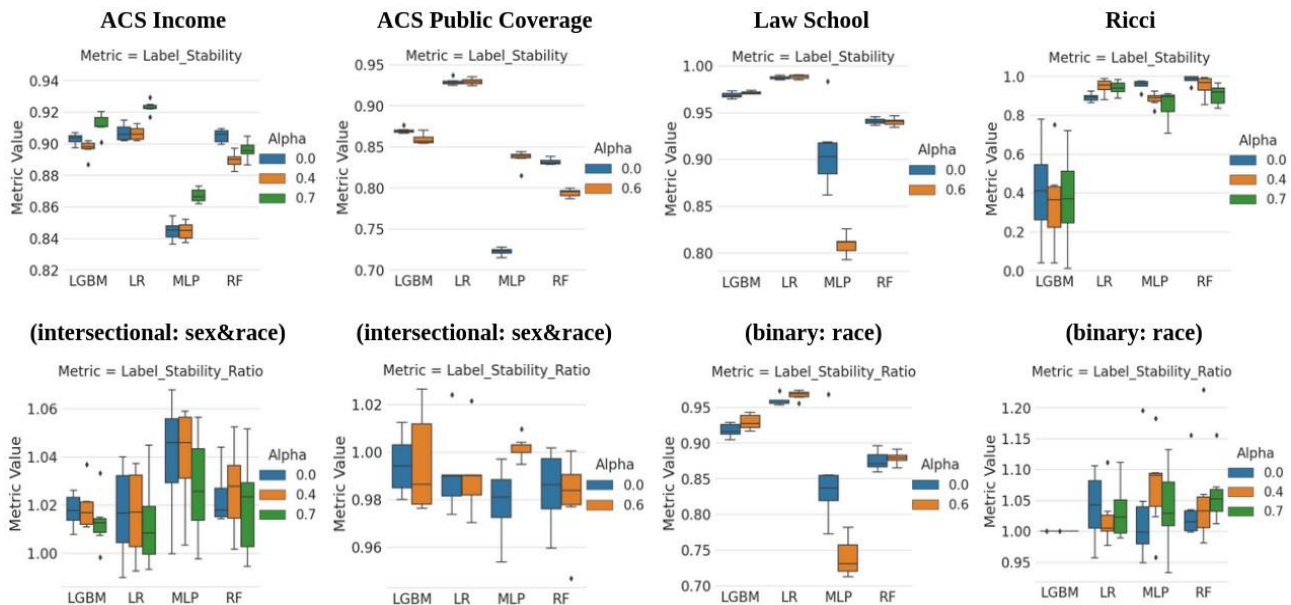
3. Якщо точність залишається незмінною (також за умов множинності), але стабільність змінюється, то підвищення справедливості (паритет у помилках) не покращує паритет стабільності, як видно з *ACS Public Coverage*, і в цьому разі це погіршує (збільшує) диспропорцію стабільності.

4. Нарешті, якщо вплив на точність і стабільність є значним (тобто підвищення рівня справедливості погіршує і точність, і стабільність), то досягнення справедливості (покращення паритету в помилках) не покращує паритет стабільності, як видно з *Ricci*.

## Експеримент 2.

### Модель – центричний підхід до стабільності

Далі досліджуємо, як втручання для забезпечення справедливості впливають на стабільність різних типів моделей. На рис. 6 наведені результати цього експерименту, де ми обираємо одне або два відповідні значення рівня справедливості ( $\alpha$ ), навчаємо різні моделі для одного й того самого рівня та порівнюємо їх продуктивність. Нейронні мережі демонструють найбільший вплив втручання для забезпечення справедливості на стабільність. Компроміс не є однозначним: для двох наборів даних стабільність покращується за умови вищих значень  $\alpha$ , для інших двох – погіршується, але обидва ефекти є більшими, ніж для інших типів моделей.



**Рис. 6.** Компроміси стабільності, орієнтовані на моделі. Вісь x: тип моделі, де LGBM – *LightGradientBoostingMachine*; LR – *LogisticRegression*; MLP – *MLPClassifier*; RF – *RandomForest*. Вісь y: стабільність міток (верхній ряд) і коефіцієнт стабільності міток (нижній ряд). Різні кольори відповідають рівням справедливості, де  $\alpha = 0$  означає відсутність втручання для забезпечення справедливості

Нейронні мережі також мають найнижчу стабільність міток серед усіх моделей на всіх наборах даних, за винятком LGBM на наборі *Ricci*, ймовірно, через те, що ми тренуємо ансамблевий бустинг-класифікатор на дуже малому наборі даних (118 зразків). Нейронні мережі також демонструють найгірший паритет стабільності на більшості завдань порівняно з усіма оціненими типами моделей. Лінійні моделі (LR) є найбільш стабільними на всіх завданнях.

Цікаво, що на наборі даних, який не призводить до множинності – *Ricci*, більшість моделей є досить

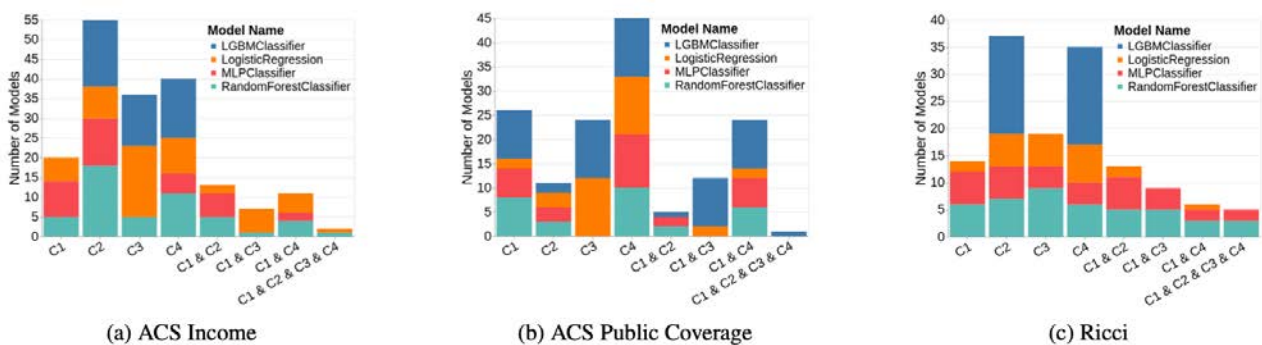
стабільними. Однак на наборах даних, де втручання для забезпечення справедливості призводять до множинності – *ACS Income*, *ACS Public Coverage* та *Law School*, спостерігаємо компроміси в стабільності, специфічні для моделей. З огляду на наш попередній результат про те, що втрати стабільності співвідносяться із втратами точності, це означає, що коли стабільність і точність погіршуються разом (як результат втручання для забезпечення справедливості), ефект не залежить від типу моделі. Однак, коли стабільність погіршується,

а точність залишається незмінною (як результат втручання для забезпечення справедливості), то ефект є високоспецифічним для кожної моделі.

### Відповідальний вибір моделі

Нарешті, розглянемо, як включення метрик стабільності (як загальних, так і з огляду на диспропорції між групами) допомагає покращити процедури вибору моделей. Для цього моделюємо процес вибору моделі, порівнюючи всі натреновані моделі (для різних рівнів  $\alpha$  в експерименті 1 та різних типів моделей в експерименті 2, із шістьма випадковими запусканнями для кожного налаштування). Ми порівнюємо приблизно 90 моделей для кожного набору даних (на основі різних виборів для експерименту 2). На рис. 7 продемонстровано кількість "найкращих" моделей для кожного критерію – точності, стабільності,

паритету в помилках (класична метрика справедливості) та паритету в стабільності (наша нова метрика справедливості). Спочатку застосовуємо ці обмеження окремо, а потім – у поєднанні. Ми демонструємо, що для трьох завдань, де спостерігалася множинність після застосування інтервенції з метою забезпечення справедливості, існує кілька моделей з порівняною точністю; однак лише одна (або дві) серед них є одночасно точною, стабільною та справедливою щодо наявності хорошого паритету як у помилках, так і в стабільності між групами. Цікаво, що вибір моделі для набору даних *Ricci* не сприяє вибору єдиної найкращої моделі. Нагадаємо з огляду на рис. 5, що *Ricci* був єдиним набором даних у нашому дослідженні, на якому попереднє оброблення для забезпечення справедливості не викликала множинності, а, навпаки, погіршувала точність. Це підтверджує ідею, що множинність є можливістю, а не викликом [12].



**Рис. 7.** Відповідальний вибір моделі: включення нормативно бажаних цілей щодо справедливості та стабільності в процедури вибору моделі розв'язує проблему множинності моделей. Визначення критеріїв: C1 – правильність (точність); C2 – паритет помилок (рівень хибнопозитивних результатів); C3 – стабільність (стабільність міток); C4 – паритет стабільності (коефіцієнт стабільності міток)

На рис. 7 також звітуємо про кількість відібраних моделей для кожного типу моделі. Моделі на основі дерев і лінійні моделі вважаються найсучаснішими за точністю для табличних даних, особливо у сферах, де справедливість є важливим фактором. Наше дослідження підтверджує сказане, додатково показуючи, що ці типи моделей також найкраще відповідають критеріям стабільності.

### Висновки

Створено програмний фреймворк, що інтегрує вимірювання справедливості та стабільності в конвеєр розроблення моделей. Запропоновано нову парадигму групової справедливості, яка об'єднує питання

правильності / якості та випадковості / стабільності з порядку денного досліджень відповідального штучного інтелекту. Звернено увагу на відомі теореми про розкладання похибки класифікатора на упередження та дисперсії, щоб обґрунтувати новий критерій групової справедливості, що розглядає паритет у стабільності, і досліджено, як це співвідноситься з точністю, стабільністю та паритетом помилок під час втручання для забезпечення справедливості. Застосовано ці висновки для розроблення методу відповідального вибору моделей за умов множинності моделей, продемонстровано, що, хоча може існувати чимало моделей із зівставною точністю, є лише одна (або декілька) "найкраща" модель, яка є надійною, справедливою і стабільною, як це й потрібно.

### Перспективи подальших досліджень

У роботі впроваджено простий підхід бутстрепа для вимірювання стабільності моделі. Це передбачає тренування 200 моделей на бутстреп-вибірках навчального набору та використання їх для наближення стабільності однієї моделі. Хоча обрано цю процедуру завдяки її простоті та надійності, вона є дуже ресурсомісткою. Альтернативні підходи для надійного та ефективного вимірювання

стабільності могли б посилити практичну значущість запропонованої процедури вибору моделей. Крім того, у дослідженні застосовано лише один метод попереднього оброблення для забезпечення справедливості. Було б цікаво розширити аналіз на інші втручання для забезпечення справедливості та дослідити, як інші властивості, зокрема невизначеність, співвідносяться зі стабільністю та справедливістю за умов множинності моделей.

### Список літератури

1. Man is to computer programmer as woman is to homemaker? debiasing word embeddings / T. Bolukbasi et al. *Advances in neural information processing systems*. 2016. No. 29. P. 4356–4364. DOI: <https://doi.org/10.48550/arXiv.1607.06520>
2. Buolamwini J., Gebru T. Gender shades: Intersectional accuracy disparities in commercial gender classification. *Conference on fairness, accountability and transparency*. 2018. P. 77–91. URL: <https://proceedings.mlr.press/v81/buolamwini18a.html>
3. Caliskan A., Bryson J. J., Narayanan A. Semantics derived automatically from language corpora contain human-like biases. *Science*. 2017. Vol. 356. P. 183–186. DOI: <https://doi.org/10.1126/science.aal4230>
4. Sweeney L. Discrimination in online ad delivery. *Communications of the ACM*. 2013. Vol. 56. No. 5. P. 44–54. DOI: <https://doi.org/10.1145/2447976.2447990>
5. Calders T., Verwer S. Three Naive Bayes Approaches for Discrimination-Free Classification. *Data Mining and Knowledge Discovery*. 2010. Vol. 21. No. 2. P. 277–292. DOI: <https://doi.org/10.1007/s10618-010-0190-x>
6. Chouldechova A. Fair Prediction with Disparate Impact: A Study of Bias in Recidivism Prediction Instruments. *Big Data*. 2017. Vol. 5. No. 2. P. 153–163. DOI: <https://doi.org/10.1089/big.2016.0047>
7. Preserving statistical validity in adaptive data analysis / C. Dwork et al. *Proceedings of the forty-seventh annual ACM symposium on Theory of computing*. 2015. P. 117–126. DOI: <https://doi.org/10.1145/2746539.2746580>
8. Fairness through awareness / C. Dwork et al. *Proceedings of the 3rd innovations in theoretical computer science conference*. 2012. P. 214–226. DOI: <https://doi.org/10.1145/2090236.2090255>
9. Certifying and Removing Disparate Impact / M. Feldman et al. *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2015. P. 259–268. DOI: <https://doi.org/10.1145/2783258.2783311>
10. Kamishima T., Akaho S., Sakuma J. Fairness-aware Learning through Regularization Approach. *IEEE 11th International Conference on Data Mining Workshops*. 2011. P. 643–650. DOI: <https://doi.org/10.1109/icdmw.2011.83>
11. Kleinberg J. M., Mullainathan S., Raghavan M. Inherent Trade-Offs in the Fair Determination of Risk Scores. *Innovations in Theoretical Computer Science Conference*. 2017. Vol. 67. P. 43:1–43:23. DOI: <https://doi.org/10.4230/LIPIcs.ITCS.2017.43>
12. Black E., Raghavan M., Barocas S. Model Multiplicity: Opportunities, Concerns, and Solutions. *Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency*. 2022. P. 850–863. DOI: <https://doi.org/10.1145/3531146.3533149>
13. Underspecification presents challenges for credibility in modern machine learning / A. D'Amour et al. *The Journal of Machine Learning Research*. 2022. Vol. 23. No. 1. P. 10237–10297. DOI: <https://doi.org/10.48550/arXiv.2011.03395>
14. Marx C., Calmon F., Ustun B. Predictive multiplicity in classification. *International Conference on Machine Learning*. 2020. P. 6765–6774. URL: <https://proceedings.mlr.press/v119/marx20a.html>
15. Creel K., Hellman D. The Algorithmic Leviathan: Arbitrariness, Fairness, and Opportunity in Algorithmic decision making systems. *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*. 2021. 816 p. DOI: <https://doi.org/10.1145/3442188.3445942>
16. Arbitrariness and social prediction: The confounding role of variance in fair classification / A. F. Cooper et al. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2024. Vol. 38. No. 20. P. 22004–22012. DOI: <https://doi.org/10.1609/aaai.v38i20.30203>
17. Arbitrariness Lies Beyond the Fairness-Accuracy Frontier / C. Long et al. *arXiv preprint arXiv:2306.09425*. 2023. DOI: <https://doi.org/10.48550/arXiv.2306.09425>
18. Shvets A. Dive into design patterns. *Refactoring Guru*. 2018. P. 22–29.



19. Domingos P. A unified bias-variance decomposition. *Proceedings of 17th international conference on machine learning*. 2000. P. 231–238. URL: <https://www.scirp.org/reference/referencespapers?referenceid=2848771>
20. Efron B., Tibshirani R. J. An introduction to the bootstrap. *CRC press*. 1994.
21. Darling M. C., Stracuzzi D. J. Toward Uncertainty Quantification for Supervised Classification. 2018. *OSTI.GOV*. DOI: <https://doi.org/10.2172/1527311>
22. Model Stability with Continuous Data Updates / H. Liu et al. *arXiv preprint arXiv:2201.05692*. 2022. DOI: <https://doi.org/10.48550/arXiv.2201.05692>
23. AI Fairness 360: An extensible toolkit for detecting and mitigating algorithmic bias / R. K. E. Bellamy et al. *IBM Journal of Research and Development*. 2019. Vol. 63. No. 4/5. P. 4:1–4:15. DOI: <https://doi.org/10.1147/jrd.2019.2942287>
24. Certifying and removing disparate impact / M. Feldman et al. *Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining*. 2015. P. 259–268. DOI: <https://doi.org/10.1145/2783258.2783311>
25. Preserving statistical validity in adaptive data analysis / C. Dwork et al. *Proceedings of the forty-seventh annual ACM symposium on Theory of computing*. 2015. P. 117–126. DOI: <https://doi.org/10.1145/2746539.2746580>
26. A survey on datasets for fairness-aware machine learning / T. Le Quy et al. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2022. Vol. 12. No. 3. DOI: <https://doi.org/10.1002/widm.1452>

## References

1. Bolukbasi, T., Chang, K.W., Zou, J.Y., Saligrama, V. and Kalai, A.T., (2016), "Man is to computer programmer as woman is to homemaker? debiasing word embeddings", *Advances in neural information processing systems*, 29, P. 4356-4364. DOI: <https://doi.org/10.48550/arXiv.1607.06520>
2. Buolamwini, J. and Gebru, T., (2018), "Gender shades: Intersectional accuracy disparities in commercial gender classification", *In Conference on fairness, accountability and transparency* P. 77-91, PMLR. available at: <https://proceedings.mlr.press/v81/buolamwini18a.html>
3. Caliskan, A., Bryson, J.J. and Narayanan, A., (2017), "Semantics derived automatically from language corpora contain human-like biases", *Science*, 356(6334), P.183-186. DOI: <https://doi.org/10.1126/science.aal4230>
4. Sweeney, L., (2013), "Discrimination in online ad delivery", *Communications of the ACM*, 56(5), P.44-54. DOI: <https://doi.org/10.1145/2447976.2447990>
5. Calders, T., and Verwer, S. (2010), "Three Naive Bayes Approaches for Discrimination-Free Classification", *Data Min. Knowl. Discov.*, 21(2). P. 277–292. DOI: <https://doi.org/10.1007/s10618-010-0190-x>
6. Chouldechova, A. (2017), "Fair Prediction with Disparate Impact: A Study of Bias in Recidivism Prediction Instruments", *Big Data*, 5(2). P. 153–163. DOI: <https://doi.org/10.1089/big.2016.0047>
7. Dwork, C., Feldman, V., Hardt, M., Pitassi, T., Reingold, O., and Roth, A. L. (2015), "Preserving statistical validity in adaptive data analysis", *In Proceedings of the forty-seventh annual ACM symposium on Theory of computing*, P. 117–126. DOI: <https://doi.org/10.1145/2746539.2746580>
8. Dwork, C., Hardt, M., Pitassi, T., Reingold, O., and Zemel, R. S. (2012), "Fairness through awareness", In Goldwasser, S., ed., *Innovations in Theoretical Computer Science 2012*, Cambridge, MA, USA, January 8-10, 2012, P. 214–226, ACM. DOI: <https://doi.org/10.1145/2090236.2090255>
9. Feldman, M., Friedler, S. A., Moeller, J., Scheidegger, C., and Venkatasubramanian, S. (2015), "Certifying and Removing Disparate Impact", *In Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '15, P. 259–268. New York, NY, USA: Association for Computing Machinery, ISBN 9781450336642. DOI: <https://doi.org/10.1145/2783258.2783311>
10. Kamishima, T., Akaho, S., and Sakuma, J. (2011), "Fairness-aware Learning through Regularization Approach", *In 2011 IEEE 11th International Conference on Data Mining Workshops*, P. 643–650. DOI: <https://doi.org/10.1109/icdmw.2011.83>
11. Kleinberg, J. M., Mullainathan, S., and Raghavan, M. (2017), "Inherent Trade-Offs in the Fair Determination of Risk Scores", *In Papadimitriou, C. H., ed., 8th Innovations in Theoretical Computer Science Conference, ITCS 2017*, January 9-11, 2017, Berkeley, CA, USA, Volume 67 of LIPIcs, P. 43:1–43:23, Schloss Dagstuhl Leibniz-Zentrum für Informatik. DOI: <https://doi.org/10.4230/LIPIcs.ITCS.2017.43>

12. Black, E., Raghavan, M., and Barocas, S. (2022), "Model Multiplicity: Opportunities, Concerns, and Solutions", In *Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency, FAccT '22*, P. 850–863. New York, NY, USA: Association for Computing Machinery, ISBN 9781450393522. DOI: <https://doi.org/10.1145/3531146.3533149>
13. D'Amour, A., Heller, K., Moldovan, D., Adlam, B., Alipanahi, B., Beutel, A., Chen, C., Deaton, J., Eisenstein, J., Hoffman, M. D., et al. 2022, "Underspecification presents challenges for credibility in modern machine learning", *The Journal of Machine Learning Research*, 23(1). P. 10237–10297. DOI: <https://doi.org/10.48550/arXiv.2011.03395>
14. Marx, C., Calmon, F., and Ustun, B. (2020), "Predictive multiplicity in classification", In *International Conference on Machine Learning*, P. 6765–6774, PMLR. available at: <https://proceedings.mlr.press/v119/marx20a.html>
15. Creel, K. and Hellman, D. (2021), "The Algorithmic Leviathan: Arbitrariness, Fairness, and Opportunity in Algorithmic decision making Systems", In *Elish, M. C.; Isaac, W.; and Zemel, R. S., eds., FAccT '21: 2021 ACM Conference on Fairness, Accountability, and Transparency*, Virtual Event / Toronto, Canada, March 3-10, 816 p. ACM. DOI: <https://doi.org/10.1145/3442188.3445942>
16. Cooper, A. F., Lee, K., Choksi, M. Z., Barocas, S., De Sa, C., Grimmelman, J., Kleinberg, J., Sen, S., and Zhang, B. (2024), "Arbitrariness and social prediction: The confounding role of variance in fair classification", In *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 38, No. 20, P. 22004-22012. DOI: <https://doi.org/10.1609/aaai.v38i20.30203>
17. Long, C. X., Hsu, H., Alghamdi, W., and Calmon, F. P. (2023), "Arbitrariness Lies Beyond the Fairness-Accuracy Frontier", *arXiv preprint arXiv:2306.09425*. DOI: <https://doi.org/10.48550/arXiv.2306.09425>
18. Shvets, A. (2018), *Dive into design patterns*, Refactoring, Guru, P.22-29.
19. Domingos, P. (2000), "A unified bias-variance decomposition", In *Proceedings of 17th international conference on machine learning*. P. 231–238, Morgan Kaufmann Stanford. available at: <https://www.scirp.org/reference/referencespapers?referenceid=2848771>
20. Efron, B. and Tibshirani, R. J. (1994), "An introduction to the bootstrap", *CRC press*.
21. Darling, M. C. and Stracuzzi, D. J. (2018), "Toward Uncertainty Quantification for Supervised Classification". *OSTI.GOV*. DOI: <https://doi.org/10.2172/1527311>
22. Liu, H., Patwardhan, S., Grasch, P., Agarwal, S., et al. (2022), "Model Stability with Continuous Data Updates", *arXiv preprint arXiv:2201.05692*. DOI: <https://doi.org/10.48550/arXiv.2201.05692>
23. Bellamy, R. K. E., Dey, K., Hind, M., Hoffman, S. C., Houde, S., Kannan, K., Lohia, P., Martino, J., Mehta, S., Mojsilovic, A., Nagar, S., Ramamurthy, K. N., Richards, J. T., Saha, D., Sattigeri, P., Singh, M., Varshney, K. R., and Zhang, Y. (2019), "AI Fairness 360: An extensible toolkit for detecting and mitigating algorithmic bias", *IBM J. Res. Dev.*, 63(4/5). P. 4:1–4:15. DOI: <https://doi.org/10.1147/jrd.2019.2942287>
24. Feldman, M., Friedler, S. A., Moeller, J., Scheidegger, C., and Venkatasubramanian, S. (2015), "Certifying and removing disparate impact", In *proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining*, P. 259–268. DOI: <https://doi.org/10.1145/2783258.2783311>
25. Dwork, C., Feldman, V., Hardt, M., Pitassi, T., Reingold, O., and Roth, A. L. (2015), "Preserving statistical validity in adaptive data analysis", In *Proceedings of the forty-seventh annual ACM symposium on Theory of computing*, P. 117–126. DOI: <https://doi.org/10.1145/2746539.2746580>
26. Le Quy, T., Roy, A., Iosifidis, V., Zhang, W., and Ntoutsi, E. (2022), "A survey on datasets for fairness-aware machine learning", *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 12(3): e1452. DOI: <https://doi.org/10.1002/widm.1452>

*Надійшла (Received) 03.01.2025*

#### *Відомості про авторів / About the Authors*

**Герасимук Денис Вікторович** – Харківський національний економічний університет імені Семена Кузнеця, магістр кафедри інформаційних систем, Харків, Україна; e-mail: [Herasyuk.Denys@m.hneu.edu.ua](mailto:Herasyuk.Denys@m.hneu.edu.ua); ORCID ID: <https://orcid.org/0009-0009-3997-5458>

**Поляков Андрій Олександрович** – кандидат технічних наук, доцент, Харківський національний економічний університет імені Семена Кузнеця, доцент кафедри інформаційних систем; Харківський національний університет радіоелектроніки, доцент кафедри прикладної математики, Харків, Україна; e-mail: [Andrii.Poliakov@m.hneu.edu.ua](mailto:Andrii.Poliakov@m.hneu.edu.ua); [Andrii.Poliakov@nure.ua](mailto:Andrii.Poliakov@nure.ua); ORCID ID: <https://orcid.org/0000-0003-1805-9011>

**Федорченко Володимир Миколайович** – кандидат технічних наук, доцент, Харківський національний університет радіоелектроніки, доцент кафедри електронних обчислювальних машин, Харків, Україна; e-mail: volodymyr.fedorchenko@nure.ua; ORCID ID: <http://orcid.org/0000-0001-7359-1460>

**Herasyuk Denys** – Simon Kuznets Kharkiv National University of Economics, Master's Student at the Department of Information Systems, Kharkiv, Ukraine.

**Poliakov Andrii** – PhD (Engineering Sciences), Associate Professor, Simon Kuznets Kharkiv National University of Economics, Associated Professor at the Department of Information Systems; Kharkiv National University of Radio Electronics, Associated Professor at the Department of Applied Mathematics, Kharkiv, Ukraine.

**Fedorchenko Volodymyr** – PhD (Engineering Sciences), Associate Professor, Kharkiv National University of Radio Electronics, Associate Professor at the Department of Electronic Computers, Kharkiv, Ukraine.

## DETECTING TRADE-OFFS BETWEEN FAIRNESS, STABILITY, AND ACCURACY FOR RESPONSIBLE MACHINE LEARNING MODEL SELECTION

The subject of the study in the article is the process of machine learning model selection performed by data scientists to build models in critical areas. The purpose of the work: 1) create a software library for measuring the accuracy, stability, and fairness of models; 2) conduct experiments to identify trade-offs between fairness, stability, and accuracy; 3) propose a responsible model selection process to improve the safety of using machine learning models. The article provides for the following tasks: to measure the fairness and stability of machine learning models and to investigate their relationship with the accuracy of models. The following methods are introduced: empirical evaluation, the theory of decomposition of model error into bias and variance, the theory of algorithmic fairness, and methods for quantitative assessment of uncertainty. Results achieved: 1) low predictive variability is proposed as a desirable property to ensure safety and equality of variability between different social groups as a new metric of fairness of machine learning models; 2) it is demonstrated how stability analysis helps specialists overcome the challenges of model multiplicity and choose reliable, stable and fair models; 3) an open-source software framework for community use is created that integrates stability measurements into model development processes. Conclusions. This work proposes a new paradigm of group fairness that combines the issues of correctness/quality and randomness/stability from the research agenda of responsible artificial intelligence. The application of the proposed approaches helps in the responsible selection of machine learning models under conditions of model multiplicity, demonstrating that, although there may be many models with comparable accuracy, there is only one (or a few) "best" model that is reliable, fair and stable, as it should be.

**Keywords:** responsible artificial intelligence; algorithmic fairness; model stability; experimental analysis.

### *Бібліографічні описи / Bibliographic descriptions*

Герасимук Д. В., Поляков А. О., Федорченко В. М. Виявлення компромісів між справедливістю, стабільністю і точністю для відповідального вибору моделі машинного навчання. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 5–19. DOI: <https://doi.org/10.30837/2522-9818.2025.1.005>

Herasyuk, D., Poliakov, A., Fedorchenko, V. (2025), "Detecting trade-offs between fairness, stability, and accuracy for responsible machine learning model selection", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 5–19. DOI: <https://doi.org/10.30837/2522-9818.2025.1.005>

Д. ДАШЕНКОВ, К. СМЕЛЯКОВ

## РОЗШИРЕННЯ НАБОРУ ДАНИХ *IMAGENET* ДЛЯ МУЛЬТИМОДАЛЬНОГО НАВЧАННЯ З ТЕКСТОМ ТА ЗОБРАЖЕННЯМИ

**Предмет дослідження:** методи оброблення зображень для класифікації та інших завдань комп'ютерного зору з використанням мультимодальної інформації, зокрема текстових описів класів і зображень. **Мета статті** – розроблення мультимодального набору даних для класифікації зображень за допомогою аналізу текстової метаданих. Отриманий набір має містити: дані зображень, класи зображень, а саме 1000 класів об'єктів, поданих на фото з набору *ImageNet*, текстові описи окремих зображень і текстові описи класів зображень загалом. **Завдання:** 1) на основі зображень набору *ImageNet* скомпіювати набір даних для навчання моделей-класифікаторів із текстовими описами класів зображень та окремих зображень; 2) на основі отриманого набору даних провести експеримент з навчання мовної нейронної мережі для підтвердження ефективності використання запропонованого підходу для виконання завдання класифікації. **Методи:** компіляція наборів даних вручну, навчання мовних нейронних мереж на основі архітектури *RoBERTa*. Навчання нейронної мережі проводилось за методом донавчання (*fine-tuning*), а саме надбудови шару нейронної мережі на наявну модель для отримання нової моделі машинного навчання, здатної виконувати обране завдання. **Результати дослідження.** Створено набір даних, що комбінує дані зображень з текстовою інформацією. Отриманий набір даних є корисним для встановлення зв'язку між інформацією, яку модель машинного навчання здатна виокремити з фото, та інформацією, яку модель може виокремити з текстових даних. Мультимодальний підхід може застосовуватись у розв'язанні широкого спектра завдань, що продемонстровано на прикладі навчання мовної нейронної мережі. Навчена мовна модель обробляє опис зображень, що містяться в наборі даних, та прогнозує клас зображення, з яким пов'язаний цей опис. Модель покликана відфільтрувати нерелевантну текстову метаданих, покращуючи якість набору. **Висновки:** набори даних, які комбінують в собі декілька видів інформації, здатні надавати ширший контекст для розв'язання завдань, що, як правило, асоціюються лише з одним типом даних. Це дає змогу більш ефективно застосовувати методи машинного навчання.

**Ключові слова:** мультимодальне машинне навчання; класифікація зображень; оброблення природної мови; набори даних; текстова метаданих.

### Вступ

З-поміж завдань комп'ютерного зору класифікація зображень є однією з найбільш поширених та вирішуваних. Саме завдання визначається як вибір із двох (бінарна класифікація) або більше (мультикласова класифікація) класів, до яких належить певне зображення. У цій роботі розглядається завдання мультикласової класифікації незалежно від того, чи стоїть завдання вибору одного чи багатьох класів.

Класифікація зображень може виконувати декілька різних завдань предметної галузі. Найбільш поширене з них, що розглядається в цій роботі, – це розпізнавання певної кінцевої множини типів об'єктів на зображенні [1]. У цьому завданні типи об'єктів, які необхідно розпізнати, і є цільовими класами.

Особливість завдання класифікації полягає в існуванні більш релевантних і менш релевантних класів. Більш релевантні класи – це ті, для яких знаходження даних для тренування моделей

нейронних мереж є простішим. Менш релевантні класи через брак даних для тренування становлять виклик для створення моделей з достатньо високою ефективністю. Для розв'язання цієї проблеми існує низка підходів:

– трансферне навчання дає змогу отримувати вищі показники ефективності роботи моделі на менш релевантних класах за допомогою навчання на більш релевантних класах [2];

– аргументація даних дає змогу створювати штучну, але близьку до реальної інформацію, що розширює вибірку для менш релевантних класів (наприклад, операції над зображеннями, зокрема кольорові зсуви, розмиття, перегортання, випадкова зміна розміру тощо) [3];

– мультимодальні підходи до навчання дають змогу отримувати інформацію про клас із сторонніх джерел унаслідок залучення даних з іншим типом (модальністю) [4].

У цьому дослідженні розглядається використання мультимодальних підходів для розв'язання завдання класифікації зображень. У цьому разі як другий тип

даних про зображення застосовується текст, що описує і самі зображення (так звані текстові анотації), і класи об'єктів, що необхідно розпізнати на поданих зображеннях. Інші підходи, зазначені вище, можуть використовуватись як разом із мультимодальним навчанням, так і окремо, проте це не є завданням цієї роботи.

Сучасні методи комп'ютерного зору значно розширюють свої можливості завдяки використанню мультимодальних підходів, що дають змогу інтегрувати різні типи даних, зокрема зображення та текстову інформацію [5]. Це відкриває нові перспективи для виконання таких завдань, як класифікація зображень завдяки поєднанню візуального контексту з текстовими описами, що підвищує точність і надійність моделей машинного навчання. Водночас розвиток цього напрямку стикається з низкою викликів, серед яких: обмеження наявних наборів даних, недостатність текстових метаописів, що відповідають зображенням, та складність у навчанні моделей, здатних обробляти такі комплексні дані.

Для розв'язання окреслених завдань мультимодальне навчання пропонує інтеграцію методів оброблення природної мови (NLP) та комп'ютерного зору з метою створення моделей, здатних працювати із зображеннями й текстом як єдиним джерелом інформації. Текстові описи можуть доповнювати зображення, надаючи їм семантичну глибину, що полегшує інтерпретацію та класифікацію об'єктів. Особливу актуальність має розроблення якісних мультимодальних наборів даних, що об'єднують ці два типи інформації. Вони є ключовими для навчання моделей, які можуть ефективно використовувати зв'язки між текстом і візуальними даними [5, 6].

У статті зосереджено увагу на створенні мультимодального набору даних для класифікації зображень із застосуванням текстових описів класів та окремих зображень. Запропонований підхід спрямований на оптимізацію використання даних *ImageNet* [7] унаслідок їх інтеграції з текстовою метаінформацією, що забезпечує ширші можливості для аналізу та підвищує якість класифікації. Розроблений набір даних може стати основою для навчання мовних нейронних мереж, зокрема архітектур, подібних до *RoBERTa* [8], за допомогою донавчання, що забезпечить високу точність і гнучкість моделей.

Мультимодальні підходи демонструють значний потенціал у розв'язанні завдань, де традиційно використовуються лише окремі типи даних. Вони не лише розширюють сферу застосування методів машинного навчання, але й беруть до уваги додаткові контексти, необхідні для точного аналізу складної інформації.

### Аналіз останніх досліджень і публікацій

Моделі машинного навчання є універсальним інструментом для розв'язання низки проблем комп'ютерного зору, зокрема сегментації зображень, оброблення та видозмінення зображень з метою досягнення бажаного естетичного ефекту, бінарної та багатокласової класифікації зображень, трекінгу об'єктів на відео, генерації зображень на відео або їх фрагментів тощо. Кілька останніх років методи, що впроваджують машинне навчання, набули значного розвитку. Архітектури моделей, що дають змогу працювати із зображеннями та відео, розвинулись від відносно простих згорткових нейронних мереж до резидуальних моделей, до рекурентних архітектур [9] та останнім часом до архітектур, що використовують механізми уваги, тобто трансформери та похідні від них моделі [10]. Оскільки методи трансформерів були запозичені зі сфери оброблення природної мови (NLP), застосування цих двох, на перший погляд, різних типів даних для досягнення кращих результатів обіцяє хороші результати за умови, що інформація з обох джерел може бути поєднана [10, 11].

Мультимодальний підхід до навчання й застосування нейронних мереж нині набув значного поширення. Зокрема передовою розробкою в цьому напрямі можна вважати модель CLIP. Зазначена модель є класифікатором об'єктів на зображеннях. Різниця CLIP від аналогів полягає в тому, що на основі текстової метаінформації модель здатна розширювати множину класів, які вона може ідентифікувати. Принцип роботи CLIP полягає у створенні спільного гіперпростору ембедингів із зображень та їх текстових анотацій. Під час навчання модель як вхід отримує і той, і інший тип даних. Завдання навчання – створити бінарний класифікатор, що відповідає на запитання "чи підходять одне одному зображення на текстовий опис?". Під час виконання модель, використовуючи заздалегідь підготовлені множини описів зображень

і класів, намагається поставити відповідність між відомими класами та зображеннями. Для цього модель виконується багато разів – у парі з усіма підготовленими анотаціями до можливих класів зображень. Самі анотації є гіперпараметрами моделі. Результатом виконання алгоритму є множина результатів бінарних класифікацій. Далі, залежно від завдання, з цієї множини обирається один або декілька класів із найвищими показниками впевненості моделі. Модель успішно переноситься на більшість завдань і часто є конкурентоспроможною з повністю контрольованою базовою лінією без необхідності будь-якого спеціального навчання набору даних [12].

Мультимодальний підхід до навчання нейронних мереж використовується в низці особливих завдань, наприклад у виявленні чуток за допомогою інформації з текстових і візуальних даних. Найкритичніша складність у виявленні мультимодальних чуток полягає в захопленні як внутрішньомодальних, так і міжмодальних зв'язків із мультимодальних даних. Тоді як конвенційні методи зазвичай зосереджені на мультимодальному процесі синтезу, приділяючи мало уваги внутрішньомодальним відношенням. Новий метод, запропонований Л. Пенг, упроваджує глибоке метричне навчання, щоб ефективно отримувати мультимодальні зв'язки новин для виявлення чуток. Зокрема розроблено триплетний метод навчання на основі метрики, щоб виокремити внутрішньомодальні зв'язки між чутками та нечутками в кожному типі даних, а також порівняльне попарне навчання, щоб охопити міжмодальні зв'язки в мультимодальному режимі. Масштабні експерименти на двох реальних мультимодальних наборах даних доводять чудову ефективність цього методу виявлення чуток [13].

Навчання мультимодальних моделей зазнає негативних наслідків від таких проблем, як семантичні конфлікти, дублювання та шум. Хоча механізм уваги може бути використаний для часткового розв'язання окреслених проблем, він працює неявно й не може бути активно контрольованим. Більш перспективним методом розв'язання цього питання є інтеграція здатності міркувати до мультимодальних репрезентативних навчальних мереж [14].

Навчання зі слабким контролем продемонструвало потенціал у застосуванні корисних знань, прихованих за мультимодальними даними. Наприклад, маючи

зображення та його опис, дуже ймовірно, що сегмент можна описати деякими словами в реченні. Хоча однозначна відповідність між ними повністю не відома, робота, запропонована А. Карпати на іншими [15], показує, що ці приховані зв'язки можна виявити за допомогою слабкоконтрольованого навчання. Потенційно більш перспективним застосуванням такого типу слабких методів наглядно є аналіз відео, де різні модальності, зокрема дії, аудіо, мови, приблизно вирівнюються на часовій шкалі.

Питання збору наборів даних актуальне не лише для зображень і тексту. Так, робота С. Шін та інших описує створення набору даних на основі відеокліпів корейської телереклами. Мітки та описи в цьому наборі даних містять різноманітну інформацію про контекст, наміри та емоції, що описується за допомогою зору та мови в кожному відеокліпі. Створений набір даних може розв'язати проблему відсутності публічної інформації для дослідження мультимодальної взаємодії з корейським. Очікується, що цей набір даних можна застосувати в конструкціях різних служб штучного інтелекту, таких як корейське оброблення діалогів, вилучення візуальної інформації та різні мультимодальні завдання аналізу інформації [16].

Важливим інструментом у підготовленні інформації для мультимодального навчання є визначення необхідних і достатніх характеристик в усіх типах даних. Метод, описаний в роботі Б. Чен та інших, демонструє можливість визначення таких характеристик за допомогою навчання моделей. Зазначений підхід демонструє ефективність використання так званого розплутування для вивчення подання високої вірогідності необхідності та достатності характеристик на основі мультимодального навчання. Зосереджуючись на необхідних і достатніх характеристиках та ігноруючи інші, модель вивчає більш інформативні та дискримінаційні подання, що призводить до кращої якості роботи моделі [17].

Отже, роль мультимодального навчання в розвитку методів машинного навчання полягає в інтеграції різних типів даних, таких як зображення, текст, відео, аудіо тощо, для отримання більшої кількості інформації про певний об'єкт чи явище без пошуку додаткових джерел однотипних даних.

Передові дослідження демонструють потенціал мультимодального підходу до навчання, даючи змогу створювати моделі, що, споживаючи більш різноманітну

інформацію з предметної галузі, показують кращі результати в деяких завданнях, ніж конвенційні моделі, що працюють з одним типом даних.

Дослідження, зосереджені на створенні мультимодальних наборів даних, розширюють для інших фахівців доступ до інформації з метою навчання. Водночас недоліком мультимодальних нейронних мереж є більший розмір мережі та більший обсяг даних. Методи визначення релевантної інформації та фільтрація нерелевантної допомагають зменшити вплив цього недоліку, зберігаючи якість роботи мережі.

### **Визначення не розв'язаних раніше частин загальної проблеми. Мета роботи, завдання**

Нині завдання класифікації зображень (за критерієм наявності певного класу об'єктів на фото) є поширеним. Завдання класифікації зображень за фіксованого заданого набору класів із достатньою кількістю даних загалом є виконаним, адже існує безліч наявних якісних моделей машинного навчання, здатних опрацьовувати зображення з передбачуваними класами. Кінцевою метою нашого дослідження є створення методів класифікації зображень для випадків, коли не всі класи об'єктів відомі на момент навчання моделі машинного навчання або не всі відомі класи мають достатню кількість інформації для навчання моделі. Такі методи можуть спиратись на додаткові дані про об'єкти, які не доступні моделям машинного навчання, що обробляють тільки зображення, а саме текстову інформацію.

Для розроблення таких методів необхідно створити набір даних, що містять інформацію про зображення, про класи об'єктів на зображеннях і текстову метаінформацію для цих зображень. У цьому разі для отримання більш якісної та повної інформації про об'єкти на зображеннях необхідно додати в набір даних як текстові описи окремих зображень, так і описи самих класів об'єктів, їх зовнішнього вигляду, фізичних характеристик, зв'язків з іншими об'єктами тощо. Метою роботи є створення такого набору даних. Для цього сформульовано завдання:

- 1) скопіювати набір даних з різних джерел;
- 2) розробити протокол перевірки релевантності інформації; ця перевірка покликана оцінити якість отриманого набору даних;

3) виконати перевірку відповідно до розробленого протоколу.

Отже, подальший розвиток класифікації зображень завдяки мультимодальному аналізу потребує створення мультимодального набору даних, що використовуватиме як самі зображення, так і текстову інформацію про зображення, що дасть змогу застосовувати останні віхи розвитку аналізу природної мови за допомогою мовних нейронних мереж для виконання завдання класифікації.

Серед публічно доступних наборів даних для навчання нейронних мереж уже існують деякі схожі набори, але жоден з них не оптимізований під описане вище завдання. Кожен з наведених наборів має переваги й недоліки для завдання класифікації зображень.

Набір *WIT (Wikipedia-based Image Text)* [18] є великою множиною даних і містить таку інформацію:

- зображення;
- мова статті Вікіпедії;
- заголовок статті;
- назва секції, де розміщене зображення;
- підпис зображення, зокрема й альтернативний текст, що відтворюється на Web-сторінці внаслідок наведення курсором на зображення й може відрізнитись від основного підпису;
- розміри зображення та його тип даних (*MIME-type*);
- контекстний опис зі сторінки;
- контекстний опис із секції;
- інша метаінформація.

У цьому наборі даних контекстні описи зображень наводяться таким чином, щоб текст максимально точно описував саме зображення. Це зроблено завдяки ручному вибору необхідних елементів сторінки Вікіпедії та секції сторінки в такий спосіб, щоб обраний текст описував зображення.

Важливою особливістю набору даних *WIT* є його розмір, а саме близько 3,5 млн елементів. Це дає змогу, відповідно до заяви авторів, використовувати цей набір даних для тренування мультимодальних моделей з нуля, тобто кількість елементів дає змогу навчати моделі загальних мультимодальних ознак, на основі яких можна добудовувати моделі під конкретні дані та завдання методом донавчання.

Недоліком набору даних *WIT* у розв'язанні завдання класифікації зображень є відсутність групування елементів за якісно виокремленими класами. На відміну від наборів даних, створених

спеціально для завдання класифікації зображень, *WIT* має безліч окремих зображень, а отже, не допомагає будувати моделі класифікації. Виокремлення класів із галузей, яким присвячені сторінки Вікіпедії, не є можливим з двох причин.

1. Галузі, описані на сторінках Вікіпедії, доволі загальні й не є конкретними класами об'єктів зображень, а скоріше є загальними галузями знань людства.

2. Для кожного конкретного класу зображень у наборі даних міститься незначна кількість елементів, недостатня для того, щоб навчити модель ні за умови підходу навчання з нуля, ні в разі донавчання моделі для конкретного завдання.

Загалом набір даних *WIT* не ефективний у розв'язанні завдання класифікації зображень, проте застосовує підходи до збирання інформації, що може бути корисною для цієї проблеми.

Набір даних *Flickr30K* [19] має меншу кількість інформації, але їй властиві певні переваги. Цей набір даних містить таку інформацію:

- зображення;
- декілька (в середньому близько п'яти) стислих описів цього зображення.

Описи зображень зазначеного набору даних створені операторами-людьми, тому точно описують зображення, без помилок, пов'язаних з ідентифікацією об'єктів чи дій на зображенні. Набір даних *Flickr30K* містить 31 783 зображення та 158 915 описів.

*Flickr30K* так само, як набір *WIT*, не має конкретних класів зображень, однак через особливість інформації, унаслідок використання наданих текстових описів із цього набору можна виокремити певну кількість класів зображень, оскільки зображення цього набору є менш різноманітними, ніж у *WIT*.

Отже, серед наявних наборів даних є такі, що можуть бути застосовані в навчанні моделі нейронної мережі для завдання класифікації зображень. Проте ці набори не є готовими до такого навчання й або потребують складного попереднього оброблення, або можуть надавати загальні ідеї щодо збору більш підхожих наборів даних.

### Матеріали й методи

Методи й матеріали дослідження варто розмежувати відповідно до його етапів, а саме: збирання набору даних і його оброблення та оцінювання релевантності набору даних щодо класів зображень цього набору.

Для отримання набору даних необхідно взяти джерело зображень, джерело текстових описів зображень та джерело загальних текстових описів класів зображень окремо від конкретних прикладів.

Джерелом зображень був обраний набір даних *ImageNet*. Завдяки великому розміру, значній кількості класів зображень (1000 класів) та широкому застосуванню в розв'язанні завдання класифікації зображень цей набір даних допомагає легко добувати необхідну додаткову інформацію, має широку підтримку реалізацій у бібліотеках для навчання нейронних мереж та дає змогу порівнювати виконане завдання із наявними результатами завдяки активній спільноті дослідників, які застосовують *ImageNet* як міру якості роботи моделей класифікації [20].

*ImageNet* має доволі просту структуру, у якій для кожного елемента набору є така інформація:

- зображення;
- клас зображення;
- інші метадані.

Загалом *ImageNet* покликаний розв'язувати не лише завдання класифікації. Але оскільки це дослідження зосереджене саме на цьому завданні, тому опис всіх можливостей набору даних *ImageNet* не наводиться.

За основу інформації текстових описів зображень обрано набір даних *ImageNet-Captions* [21]. Він створений на основі *ImageNet* і є набором текстових анотацій до зображень, взятих із сайту розміщення фотографій *Flickr*. Набір містить окремо назви зображень та їх описи. Для простоти роботи з ним вся інформація, назви і описи сприймаються як одне текстове поле, тобто стрічки конкатенуються. Сайт *Flickr* є джерелом зображень для набору даних *Flickr30K*, згаданого вище, а також для набору даних *ImageNet*. Тестові анотації є описами зображень на сайті, які створили автори зображень під час завантаження на сайт. Цей підхід дав змогу авторам *ImageNet-Captions* розробити мультимодальний набір даних без застосування додаткових ресурсів з анотування зображень людьми-операторами, що є складним і недешевим процесом.

Недоліком анотацій *ImageNet-Captions* є нижча якість текстової інформації. Оскільки дані не були згенеровані спеціально для опису зображень, а скоріше є текстовими частинами дописів авторів на сайті, що супроводжують відповідні зображення, ці анотації не завжди є релевантними для навчання



нейронних мереж, адже можуть не додавати інформацію, яка стосується самих зображень, а лише створювати шум. Розв'язання проблеми релевантності текстових даних для зображень описано далі.

Джерелом текстової інформації для опису окремих класів взяті фрагменти сторінок Вікіпедії англійською мовою, що описують клас об'єкта на зображенні. Наприклад, для опису класу *lesser\_panda* взяті фрагменти зі сторінки Вікіпедії під назвою *Red panda*. Пошук сторінок для цитування виконувався автоматично, де це можливо. Більшість класів *ImageNet* мають таку назву, яка напряму відповідає одній конкретній сторінці Вікіпедії. Якщо ж назва вимагала вибору з декількох сторінок чи пошук потрапляв на переадресацію сторінки або ж не знаходив потрібної сторінки взагалі, вона обиралася в ручному режимі.

З кожної сторінки для набору даних використано секцію підсумкового опису (*summary*). Також на сторінках, що мали спеціальну секцію з описом об'єкта, а саме з назвою *Description*, що властиво сторінкам, де описано види чи породи тварин, вміст цієї секції також був доданий до текстового опису класу. У такий спосіб для всієї тисячі класів було зібрано якісні описи об'єктів, що корелюють із інформацією, яку може вивчити нейронна мережа, що обробляє зображення, а також із загальною інформацією про об'єкти, їх властивості та взаємозв'язки.

Комбінація гарантовано релевантних описів класів та дещо релевантних описів зображень дає змогу проаналізувати релевантність текстових описів для підвищення ефективності навчання моделей на зібраному наборі даних.

Для оцінювання релевантності текстових описів зображень розроблений метод, що застосовує гарантовано релевантні описи класів зображень. Зазначений метод, оснований на окремій моделі машинного навчання, має на меті відфільтрувати менш релевантні текстові приклади набору даних. Алгоритм оцінювання релевантності передбачає певні кроки.

1. Створити набір, що містить класи зображень, текстові описи зображень та випадковим чином обрані речення з описів класів за принципом одне речення на один елемент набору даних.

2. На основі навченої мовної моделі донавити модель, яка буде отримувати на вхід сконкатенований опис зображення та речення з опису класу. Модель на вході віддає номер класу зображення.

3. За допомогою навченої моделі для кожного опису зображення, що є в наборі даних *ImageNet-Captions*, оцінити релевантність опису до класу зображення. Вилучити описи, що показують низьку релевантність з кінцевого набору даних. Для тих описів, що залишились, зберегти коефіцієнт впевненості моделі в релевантності опису до класу.

Отже, послідовно розглянемо кроки алгоритму, їх особливості та визначимо, які методи й матеріали необхідні для виконання кожного з них.

Створення тренувальної та тестової вибірки для навчання моделі-предиктора релевантності полягає у виділенні певної кількості інформації на кожну вибірку з набору даних *ImageNet-Captions*. Весь набір містить 445 984 зображення, для яких є або назва, або опис, або і те, та інше. Крім цього, зі всіх елементів 389 598 мають назву або опис, що містить більш ніж одне слово. Саме ці елементи взяті за основу набору даних для тренування моделі-предиктора релевантності. Ці елементи розділені на 999 класів набору *ImageNet*. Розподіл даних за класами приблизно відповідає нормальному розподілу з незначними відхиленнями (див. рис. 1). На рисунку зображена відповідність кількості прикладів для одного класу (вісь  $X$ ) до кількості класів із такою кількістю прикладів (вісь  $Y$ ).

Для тренувальної вибірки було випадковим чином обрано рівно 300 тис. елементів. Решта 89 598 елементів, тобто приблизно 23 %, становили тестову збірку. У цьому разі для покращення роботи моделі на менш релевантних класах, що містять 100 прикладів чи менше, гарантовано мінімум половина прикладів опинилась у тренувальній збірці, і мінімум 20 % прикладів опинились у тестовій.

Наступним кроком у створенні набору даних для тренування моделі-предиктора релевантності є виокремлення речень з описів класів зображень, зібраних із сторінок Вікіпедії. Для кожного класу зображень було виокремлено від двох до десяти речень. За наявності обирались найдовші речення із зібраних текстів. Далі ці речення були додані до текстових описів зображень. Речення з описів класів додані в кінець опису зображень. У цьому разі кожне речення, поєднане з кожним описом зображення, тобто множина отриманих текстових елементів набору даних, – це декартів добуток множини речень і множини описів зображень. Приклади елементів набору даних наведені в табл. 1. Опис класів у тексті скорочений заради простоти читання в цій статті.




Рис. 1. Розподіл кількостей елементів набору даних *ImageNet-Captions* за класами

Таблиця 1. Приклади елементів набору даних для тренування моделі-предиктора релевантності

Клас <i>ImageNet</i> (wnid / назва)	Текст
n07693725 / bagel	Homemade bagels-pre boiling I made the dough yesterday and let them rise in the 'fridge overnight, as per the recipe. i just pulled these out of the fridge and realize that i made them WAY too big. A bagel (Yiddish: ביגל, romanized: beygl; Polish: bajgiel ['bajgjel] ; also spelled beigel) is a bread roll originating in the Jewish communities of Poland. Bagels are traditionally made from yeasted wheat dough that is shaped by hand into a torus or ring, briefly boiled in water, and then baked.
n04462240 / toyshop	In the toy-shop Barbie, born 1959, still going strong A toy store or toy shop is a type of retail business specializing in selling toys.
n02277742 / ringlet	Ringlet ( <i>Aphantopus hyperantus</i> ) Ringlets are quite abundant at the moment - and seem to be a lot more approachable than most butterflies I've been attempting to photograph. Handheld, natural light The ringlet ( <i>Aphantopus hyperantus</i> ) is a butterfly in the family Nymphalidae. It is only one of the numerous 'ringlet' butterflies in the tribe Satyrini.

Зрештою було отримано набір даних, що містить близько 1,7 млн елементів, 1,3 млн в тренувальній вибірці і 400 тис. у тестовій вибірці.

Для створення моделі-предиктора релевантності обрано модель *RoBERTa*, попередньо натреновану на великих корпусах даних. Модель приймає на вхід текст та видає на виході векторне подання цього тексту. Векторне подання має форму послідовності ембедингів (тобто векторів) за принципом: один вектор на одне вхідне слово (токен). Класичним методом отримання ембедингу тексту з ембедингів окремих слів тексту є пулінг методом середнього, тобто з усіх векторів тексту береться поелементне середнє значення. Існують і більш складні стратегії пулінгу. Проте дослідження в галузі мультимодального оброблення текстової та графічної інформації показують, що коректно підібрана проста стратегія, така як пулінг методом середнього,

може давати вищу якість кінцевої моделі, на відміну від більш складних стратегій [22].

Формула (1) демонструє принцип роботи пулінгу методом середнього.

$$x_i = \sum_{n=1}^N a_{in} / N, \quad (1)$$

де  $x_i$  –  $i$ -й елемент ембедингу тексту;  $a_{in}$  –  $i$ -й елемент ембедингу  $n$ -го слова;  $N$  – кількість токенів.

Для того щоб перетворити ембединг тексту в клас зображення, використовується щільний шар нейронів, який генерує вірогідності того, що цей ембединг є конкретним класом. Тобто щільний шар генерує вектор розмірністю 999, де кожне значення – це вірогідність того, що вхідний текст описує саме клас із цим порядковим номером. Для отримання нормалізованих вірогідностей значення кожного елемента отриманого вектора обробляється функцією сигмоїди, перетворюючи їх на значення в діапазоні

від 0 до 1. Для контролю перенавчання на певну характеристику ембедінгу між операцією пулінгу та щільним шаром використана операція викидання (*dropout*) з вірогідністю викидання кожного конкретного значення  $P_{dropout} = 0,25$ . На рис. 2 зображена високорівнева архітектура моделі.

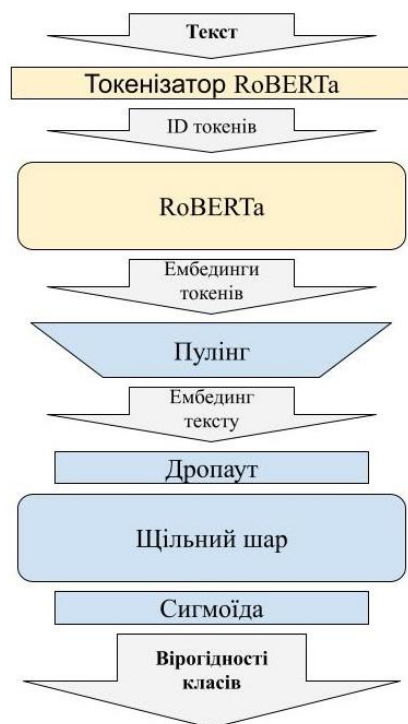


Рис. 2. Високорівнева архітектура моделі-предиктора релевантності

На рисунку напівжирним виділені вхідні та вихідні дані. Жовтим кольором позначені попередньо навчені елементи, а блакитним – додані елементи.

Запропонована модель була навчена на тренувальній вибірці. Тестова вибірка використовувалась для контролю перенавчання на всіх епохах навчання. Кожна епоха охоплювала 75 % тренувального набору, обраного та відсортованого випадковим чином. Безперервне тренування зайняло 120 епох і близько 80 год.

Унаслідок тренування отримано модель, що приймає на вхід текстову інформацію, а на вихід видає вірогідності того, що цей текст описує конкретний клас з набору даних *ImageNet*. Завдяки цій моделі можна оцінити релевантність кожного окремого опису зображення для кожного класу. Для цього необхідне виконання певних дій.

1. Обробити кожен текстовий опис зображення за допомогою отриманої моделі без додавання текстової інформації про сам клас зображення.

2. Для кожного обробленого прикладу взяти значення вірогідності того, що текст належить до того класу, до якого він насправді належить  $P_{correct}$ .

3. Якщо вірогідність  $P_{correct}$  нижча за середнє значення вірогідностей класів для цього прикладу, текстова інформація відкидається.

4. Якщо вірогідність  $P_{correct}$  нижча за 0,5, текстова інформація відкидається.

5. Якщо вірогідність  $P_{correct}$  перевищує чи дорівнює 0,5, текстова інформація зберігається в елементі набору даних як коефіцієнт релевантності тексту. Коефіцієнти релевантності тексту можуть використовуватись надалі в навчанні нейронних мереж чи в інших методах, де застосовується отриманий набір даних.

6. Для покращення результатів подальшого використання коефіцієнтів релевантності впроваджується нормалізація. Обране порогове значення  $P_{correct} = 0,9$ . Якщо значення релевантності тексту вище, ніж це порогове значення, то йому присвоюється значення 1. До інших значень додається 0,1. Потім усі значення нормалізуються таким чином, щоб вони були рівномірно розподілені на відрізку  $(0; 1]$ .

Отже, у дослідженні розроблено метод оцінювання релевантності текстових описів зображень для завдань класифікації на основі мультимодального набору даних. Джерелом зображень обрано *ImageNet*, текстових описів – *ImageNet-Captions* та Вікіпедія. Для підвищення якості інформації застосовано спеціалізовані методи оцінювання текстів, основані на навчанні мовної моделі *RoBERTa* та на різниці релевантностей різних джерел текстової інформації.

## Результати досліджень та їх обговорення

Дослідження передбачало два аспекти розвитку окресленого питання, а саме: розроблення методу покращення якості текстової інформації способом відсіювання шуму, тобто менш релевантних даних, які сповільнюють навчання нейронних мереж і пригнічують якість статистичних та інших конвенційних моделей; створення набору даних, що комбінує текстову метаінформацію про об'єкти на зображеннях із самими зображеннями.

Можливість навчання такої моделі основана на наявності більш релевантних описів класів, що допомагають тимчасово підвищити релевантність

описів зображень, надаючи цим нейронній мережі необхідний сигнал. Завдяки наявності гарантовано релевантних даних модель може вловлювати деталі описів зображень. Крім цього, якщо додане до опису зображення речення є ключовим у визначенні класу зображення, а внаслідок вилучення цього речення опис зображення перестає бути корисним для визначення класу, то опис зображення можна вважати нерелевантним і відкинути.

Після навчання моделі-предиктора релевантності й застосування її на даних набору *ImageNet-Captions* отримано набір даних, що містить 28 610 елементів. Завдяки цьому підходу вдалось вилучити з набору найбільш шумні, тобто найменш релевантні елементи, такі як технічні описи фотоапаратів, що використовувались для створення зображень, гештеги та інша метаінформація, не пов'язана із зображеними об'єктами.

Коефіцієнти релевантності текстових анотацій до зображень є цінним артефактом розробленого алгоритму створення набору даних. Ці значення, що рівномірно розподілені між 0 і 1, позначають рівень того, наскільки текст пов'язаний із зображенням. У процесі тренування класифікатора ця інформація буде корисною для модифікації функції помилки навчання. Отже, функція помилки зможе брати до уваги не лише різницю між правдивим значенням цільової змінної та передбаченим значенням, а також і те, наскільки можна очікувати, що вхідна інформація якісна. Це має сприяти швидшому навчанню моделі, адже приклади з вищим рівнем шуму менше впливатимуть на перебіг навчання, ніж більш релевантні приклади. Такий підхід також дає змогу підвищити ефективність запропонованої моделі.

### Висновки й перспективи подальшого розвитку

Набори даних, що комбінують у собі два чи більше видів інформації, здатні надавати ширший

контекст для розв'язання завдань, що, як правило, асоціюються лише з одним типом даних. Це сприяє більш ефективному впровадженню методів машинного навчання. У межах цієї роботи створено новий набір даних, на основі якого можуть проводитись подальші дослідження мультимодальних моделей.

Розроблений метод фільтрування текстових даних дає змогу завдяки публічно доступній інформації, без додаткового ручного анотування зібрати текстові метадані для зображень. Завдяки цьому методу відкриваються нові можливості для створення більшого за розміром та обсягом покриття, кращих за якістю різноманітних характеристик зображених об'єктів наборів текстових і графічних даних.

Потенціал подальшого покращення отриманого набору даних полягає в більш оптимальному підборі гіперпараметрів алгоритму, а саме порогових значень вірогідності релевантності, як нижнього (нижче якого анотації вважаються нерелевантними), так і верхнього (вище якого анотації вважаються абсолютно релевантними).

Також зміна розподілу коефіцієнтів релевантності з лінійної на більш складну криву може привести до ефективнішого корегування релевантності.

Подальшого розвитку також потребують методи автоматизованого збору даних без участі людей-операторів для анотації, більш оптимізовані методи вибору релевантної текстової інформації для окремих класів зображень та аналогічний метод фільтрування нерелевантних анотацій зображень без прив'язки до конкретного класу.

Отже, запропонований метод дасть змогу розширити обсяги публічно доступних наборів даних, що містять зображення та тексти. Кінцевою метою цього напряму дослідження було б повністю проанотоване створення набору даних із зображеннями, наближеним за своїм розміром до *ImageNet*, а за якістю анотацій – до *Flickr30K*. Мета роботи – створення мультимодального набору даних для класифікації зображень – досягнута.

### Список літератури

1. Mensink T., Verbeek J., Perronnin F., Csurka G. Distance-Based image classification: generalizing to new classes at near-zero cost. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2013. № 35 (11). P. 2624–2637. DOI: <https://doi.org/10.1109/tpami.2013.83>
2. Xu Z., Sun K., Mao J. Research on ResNet101 network chemical reagent label image classification based on transfer learning. *IEEE Xplore*. 2020. DOI: <https://doi.org/10.1109/ICCSIT50869.2020.9368658>

3. Tang X., Zhou C., Chen L., Wen Y. Enhancing medical image classification via augmentation-based pre-training. *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. 2021. DOI: <https://doi.org/10.1109/bibm52615.2021.9669817>
4. Dao H.N., Nguyen T., Cherubin Mugisha, Paik I. A multimodal transfer learning approach using pubmedclip for medical image classification. *IEEE Access*. 2024. №12. P. 75496–75507. DOI: <https://doi.org/10.1109/access.2024.3401777>
5. Ma M., Ma W., Jiao L., Liu X., Liu F., Li L., Yang S. MBSI-Net: multimodal balanced self-learning interaction network for image classification. *IEEE Transactions on Circuits and Systems for Video Technology*. 2024. №34(5). P. 3819–3833. DOI: <https://doi.org/10.1109/tcsvt.2023.3322470>
6. Chen Q., Shi Z., Zuo Z., Fu J., Sun Y. Two-Stream hybrid attention network for multimodal classification. *IEEE International Conference on Image Processing (ICIP)*. 2021. DOI: <https://doi.org/10.1109/icip42928.2021.9506177>
7. "ImageNet". URL: [www.image-net.org](http://www.image-net.org) (дата звернення: 10.10.2024).
8. Liu Y., Ott M., Goyal N., Du J., Joshi M.S., Chen D., Levy O., Lewis M., Zettlemoyer L., Stoyanov V. RoBERTa: A robustly optimized bert pretraining approach. *arXiv (Cornell University)*. 2019. DOI: <https://doi.org/10.48550/arxiv.1907.11692>
9. Satheesh Kumar NJ, CH A. DRCNN-WS: a novel approach for high-resolution video using recurrent neural networks and walrus search. *2022 10th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*. 2024. P. 1–6. DOI: <https://doi.org/10.1109/icrito61523.2024.10522118>
10. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. An image is worth 16x16 words: transformers for image recognition at scale. *arXiv.org*. 2021. DOI: <https://doi.org/10.48550/arXiv.2010.11929>
11. Arpit Bansal Mathematics, Kumar K., Singla S. Multimodal deep learning: integrating text and image embeddings with attention mechanism. *IEEE Xplore*. 2024. DOI: <https://doi.org/10.1109/aiiot58432.2024.10574665>
12. Radford A., Kim J.W., Hallacy C., Ramesh A., Goh G., Agarwal S., Sastry G., Askell A., Mishkin P., Clark J., Krueger G., Sutskever I. Learning transferable visual models from natural language supervision. *arXiv.org*. 2021. DOI: <https://doi.org/10.48550/arXiv.2103.00020>
13. Peng L., Jian S., Li D., Shen S. MRML: Multimodal rumor detection by deep metric learning. *IEEE Xplore*. 2023. DOI: <https://doi.org/10.1109/ICASSP49357.2023.10096188>
14. Guo W., Wang J., Wang S. Deep multimodal representation learning: a survey. *IEEE Access*. 2019. №7. P. 63373–63394. DOI: <https://doi.org/10.1109/access.2019.2916887>
15. Karpathy A., Fei-Fei L. Deep visual-semantic alignments for generating image descriptions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. №39(4). P. 664–676. DOI: <https://doi.org/10.1109/tpami.2016.2598339>
16. Shin S., Jang J., Jung M., Kim J., Jung Y., Jung H. Construction of a machine learning dataset for multiple AI tasks using korean commercial multimodal video clips. *ICTC*. 2020. P.1264–1266. DOI: <https://doi.org/10.1109/ictc49870.2020.9289319>
17. Chen B., Liu J., Li Z., Yang M. Seeking the sufficiency and necessity causal features in multimodal representation learning. *arXiv (Cornell University)*. 2024. DOI: <https://doi.org/10.48550/arxiv.2408.16577>
18. Srinivasan K., Raman K., Chen J., Bendersky M., Najork M. WIT: wikipedia-based image text dataset for multimodal multilingual machine learning. *SIGIR '21: Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2021. P. 2443–2449. DOI: <https://doi.org/10.1145/3404835.3463257>
19. Young P., Lai A., Hodosh M., Hockenmaier, J. From image descriptions to visual denotations: new similarity metrics for semantic inference over event descriptions. *Transactions of the Association for Computational Linguistics*. 2014. №2. P. 67–78. DOI: [https://doi.org/10.1162/tacl\\_a\\_00166](https://doi.org/10.1162/tacl_a_00166)
20. "Papers with Code – ImageNet Benchmark (Image Classification)". URL: <https://paperswithcode.com/sota/image-classification-on-imagenet> (дата звернення: 01.11.2024).
21. Fang A., Ilharco G., Wortsman M., Wan Y., Shankar V., Dave A., Schmidt L. Data determines distributional robustness in contrastive language image pre-training (CLIP). *arXiv (Cornell University)*. 2022. DOI: <https://doi.org/10.48550/arxiv.2205.01397>
22. Chen J., Hu H., Wu H., Jiang Y., Wang C. Learning the best pooling strategy for visual semantic embedding. *arXiv (Cornell University)*. 2020. DOI: <https://doi.org/10.48550/arxiv.2011.04305>

## References

1. Mensink, T., Verbeek, J., Perronnin, F., Csurka, G. (2013), "Distance-Based image classification: generalizing to new classes at near-zero cost". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, № 35(11), P. 2624–2637. DOI: <https://doi.org/10.1109/tpami.2013.83>

2. Xu, Z., Sun, K., Mao, J. (2020), "Research on ResNet101 Network chemical reagent label image classification based on transfer learning". *IEEE Xplore*. DOI: <https://doi.org/10.1109/ICCASIT50869.2020.9368658>
3. Tang, X., Zhou, C., Chen, L., Wen, Y. (2021), "Enhancing medical image classification via augmentation-based pre-training". *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. DOI: <https://doi.org/10.1109/bibm52615.2021.9669817>
4. Dao, H.N., Nguyen, T., Cherubin Mugisha, Paik, I. (2024), "A multimodal transfer learning approach using pubmedclip for medical image classification". *IEEE Access*, 12, P. 75496–75507. DOI: <https://doi.org/10.1109/access.2024.3401777>
5. Ma, M., Ma, W., Jiao, L., Liu, X., Liu, F., Li, L., Yang, S. (2024), "MBSI-Net: multimodal balanced self-learning interaction network for image classification". *IEEE Transactions on Circuits and Systems for Video Technology*, № 34(5), P. 3819–3833. DOI: <https://doi.org/10.1109/tcsvt.2023.3322470>
6. Chen, Q., Shi, Z., Zuo, Z., Fu, J., Sun, Y. (2021), "Two-stream hybrid attention network for multimodal classification". *2022 IEEE International Conference on Image Processing (ICIP)*. DOI: <https://doi.org/10.1109/icip42928.2021.9506177>
7. "ImageNet". available at: <https://www.image-net.org/>
8. Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M.S., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., Stoyanov, V. (2019), "RoBERTa: a robustly optimized bert pretraining approach". *arXiv (Cornell University)*, № 1. DOI: <https://doi.org/10.48550/arxiv.1907.11692>
9. Sathesh Kumar NJ, CH, A. (2024), "DRCNN-WS: A novel approach for high-resolution video using recurrent neural networks and walrus search". *2022 10th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, P. 1–6. DOI: <https://doi.org/10.1109/icrito61523.2024.10522118>
10. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., Houlsby, N. (2021), "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale". *arXiv.org*. DOI: <https://doi.org/10.48550/arXiv.2010.11929>
11. Arpit Bansal Mathematics, Kumar, K., Singla, S. (2024), "Multimodal deep learning: integrating text and image embeddings with attention mechanism". *IEEE Xplore*. DOI: <https://doi.org/10.1109/aiiot58432.2024.10574665>
12. Radford, A., Kim, J.W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger, G., Sutskever, I. (2021), "Learning transferable visual models from natural language supervision". *arXiv.org*. DOI: <https://doi.org/10.48550/arXiv.2103.00020>
13. Peng, L., Jian, S., Li, D. and Shen, S. (2023), "MRML: multimodal rumor detection by deep metric learning". *IEEE Xplore*. DOI: <https://doi.org/10.1109/ICASSP49357.2023.10096188>
14. Guo, W., Wang, J., Wang, S. (2019), "Deep multimodal representation learning: a survey". *IEEE Access*, № 7, P. 63373–63394. DOI: <https://doi.org/10.1109/access.2019.2916887>
15. Karpathy, A., Fei-Fei, L. (2017), "Deep visual-semantic alignments for generating image descriptions". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, № 39 (4), P. 664–676. DOI: <https://doi.org/10.1109/tpami.2016.2598339>
16. Shin, S., Jang, J., Jung, M., Kim, J., Jung, Y., Jung, H. (2020), "Construction of a machine learning dataset for multiple AI tasks using korean commercial multimodal video clips". *ICTC*. P. 1264–1266. DOI: <https://doi.org/10.1109/ictc49870.2020.9289319>
17. Chen, B., Liu, J., Li, Z., Yang, M. (2024), "Seeking the Sufficiency and Necessity Causal Features in Multimodal Representation Learning". *arXiv (Cornell University)*. DOI: <https://doi.org/10.48550/arxiv.2408.16577>
18. Srinivasan, K., Raman, K., Chen, J., Bendersky, M., Najork, M. (2021), "WIT: wikipedia-based image text dataset for multimodal multilingual machine learning". *SIGIR '21: Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2021. P. 2443–2449. DOI: <https://doi.org/10.1145/3404835.3463257>
19. Young, P., Lai, A., Hodosh, M., Hockenmaier, J. (2014), "From image descriptions to visual denotations: new similarity metrics for semantic inference over event descriptions". *Transactions of the association for computational linguistics*, № 2, P. 67–78. DOI: [https://doi.org/10.1162/tacl\\_a\\_00166](https://doi.org/10.1162/tacl_a_00166)
20. "Papers with Code - ImageNet Benchmark (Image Classification)". available at: <https://paperswithcode.com/sota/image-classification-on-imagenet>
21. Fang, A., Ilharco, G., Wortsman, M., Wan, Y., Shankar, V., Dave, A., Schmidt, L. (2022), "Data Determines Distributional Robustness in Contrastive Language Image Pre-training (CLIP)". *arXiv (Cornell University)*. DOI: <https://doi.org/10.48550/arxiv.2205.01397>
22. Chen, J., Hu, H., Wu, H., Jiang, Y., Wang, C. (2020), "Learning the Best Pooling Strategy for Visual Semantic Embedding". *arXiv (Cornell University)*. DOI: <https://doi.org/10.48550/arxiv.2011.04305>

*Відомості про авторів / About the Authors*

**Дашенков Дмитро Сергійович** – Харківський національний університет радіоелектроніки, аспірант кафедри програмної інженерії, Харків, Україна; e-mail: dmytro.dashenkov@nure.ua; ORCID ID: <https://orcid.org/0000-0001-9797-1863>

**Смеляков Кирило Сергійович** – доктор технічних наук, Харківський національний університет радіоелектроніки, професор кафедри програмної інженерії, Харків, Україна; e-mail: kyrylo.smelyakov@nure.ua; ORCID ID: <https://orcid.org/0000-0001-9938-5489>

**Dashenkov Dmytro** – Kharkiv National University of Radio Electronics, PhD Student at the Software Engineering department, Kharkiv, Ukraine.

**Smelyakov Kirill** – Doctor of Sciences (Engineering), Kharkiv National University of Radio Electronics, Professor at the Software Engineering department, Kharkiv, Ukraine.

## EXTENDING THE IMAGENET DATASET FOR MULTIMODAL TEXT AND IMAGE LEARNING

**Subject matter:** image processing methods for classification and other computer vision tasks using multimodal data, including text descriptions of classes and images. **Goal:** development of a multimodal dataset for image classification using textual meta-information analysis. The resulting dataset should consist of image data, image classes, namely 1000 classes of objects depicted in photos from the ImageNet set, textual descriptions of individual images, and textual descriptions of image classes as a whole. **Tasks:** 1) based on the images of the ImageNet dataset, compile a dataset for training classifier models with text descriptions of image classes and individual images; 2) based on the obtained dataset, conduct an experiment on training a language neural network to confirm the effectiveness of using this approach to solve the classification problem. **Methods:** compilation of datasets manually, training of speech neural networks based on the RoBERTa architecture. The neural network training was carried out using the fine-tuning method, namely, adding a neural network layer to an existing model to obtain a new machine learning model capable of performing the selected task. **Results:** the result of the work is the creation of a dataset that combines image data with text data. The resulting dataset is useful for establishing a connection between the information that a machine learning model is able to extract from photos and the information that the model can extract from text data. The multimodal approach can be used to solve a wide range of problems, as demonstrated by the example of training a language neural network. The trained language model processes the descriptions of images contained in the dataset and predicts the class of the image to which this description is associated. The model is designed to filter out irrelevant text metadata, improving the quality of the dataset. **Conclusions:** data sets that combine multiple types of data can provide a broader context for solving problems that are typically associated with only one type of data, allowing for more effective application of machine learning methods.

**Keywords:** multimodal machine learning; image classification; natural language processing; datasets; text metadata.

*Бібліографічні описи / Bibliographic descriptions*

Дашенков Д. С., Смеляков К. С. Розширення набору даних *ImageNET* для мультимодального навчання з текстом та зображеннями. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 20–31. DOI: <https://doi.org/10.30837/2522-9818.2025.1.020>

Dashenkov, D., Smelyakov, K. (2025), "Extending the *ImageNET* dataset for multimodal text and image learning", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 20–31. DOI: <https://doi.org/10.30837/2522-9818.2025.1.020>

А. Долгий, І. Шубін

## ДОСЛІДЖЕННЯ СУЧАСНИХ МЕТОДІВ ТА ІНСТРУМЕНТІВ ОНТОЛОГІЧНОГО ІНЖИНІРИНГУ В КОНТЕКСТІ СТВОРЕННЯ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ

**Предметом статті** є сучасні методи та інструменти онтологічного інжинірингу в контексті розроблення інтелектуальних систем, зокрема онтологічний інжиніринг як процес створення формалізованих баз знань для інтелектуальних систем. У статті аналізуються мови онтологічного моделювання (*RDF, OWL, SWRL* тощо), мова запитів *SPARQL* та інструментарій, такі як *Protégé, Hozo* та інші, що дають змогу реалізовувати зазначений підхід. **Мета дослідження** полягає у визначенні та аналізі сучасних інструментів і методів онтологічного інжинірингу для розроблення баз знань, що забезпечують високу точність прогнозування й адаптивність у складних інтелектуальних системах із використанням штучного інтелекту чи іншого алгоритму передбачення. **Завданням цього дослідження** є комплексний аналіз сучасних методів та інструментів онтологічного інжинірингу, зокрема порівняльна характеристика їх можливостей та обмежень у застосуванні в інтелектуальних системах. Дослідження передбачає вивчення методів автоматизації процесів створення та поповнення онтологій, зокрема з використанням глибокого навчання та оброблення природної мови, а також оцінювання перспективних мов та інструментів моделювання онтологій. Особлива увага приділяється аналізу застосування онтологій у різних предметних галузях, де потрібна висока точність прогнозування, з подальшим дослідженням методів оптимізації запитів до онтологічних баз даних. Практична частина роботи передбачає створення демонстраційної онтологічної бази знань для інтелектуальної системи управління віртуальними розподіленими електростанціями, що дасть змогу оцінити практичну цінність дослідження. **Методи дослідження:** ґрунтовний аналіз літератури та доступної документації з теми; порівняльний аналіз досягнутих результатів; подальша демонстрація на практиці застосування обраних інструментів та методів на основі їх показників. **Результати.** Розглянуто питання доцільності онтологічного інжинірингу в сучасних інтелектуальних системах. Наведено та проаналізовано інструменти та методи створення баз знань на основі онтологій. У роботі виконано порівняльну статистику сучасних інструментаріїв зі створення онтологій. Висунуто обґрунтоване бачення ситуації довкола інструментарію та методів онтологічного інжинірингу. Визначено обмеження та унікальні аспекти кожного з розглянутих інструментів. Виокремлено оптимальні підходи до створення баз знань для інтелектуальних систем. На практиці продемонстровано використання та особливості інструментарію онтологічного інжинірингу в контексті інтелектуальних систем із керування віртуальними розподіленими електростанціями. **Висновок.** Новизна дослідження полягає в сучасному погляді на питання вибору інструментів для створення баз знань за допомогою онтологічного інжинірингу, зокрема щодо їх використання в інтелектуальних системах, у поєднанні зі штучним інтелектом. Результати цієї роботи можуть бути впроваджені під час розроблення відповідних інтелектуальних систем, що застосовують бази знань. Дослідження надає широкий спектр інформації та порівнянь підходів та інструментаріїв онтологічного інжинірингу.

**Ключові слова:** онтологічний інжиніринг; семантичне моделювання; бази знань; онтологічні мови; інструментарій онтологій.

### Вступ

Розвиток ІТ-технологій, штучного інтелекту (ШІ) та інтелектуальних систем, побудованих на його основі, є регулярним явищем. Сервіси, що пропонують хмарні потужності ШІ, охоплюють безліч сфер, починаючи від створення зображень або анімованих кліпів (*Dall-E, Flux, Stable diffusion* тощо), текстових моделей, що пропонують подібно до людини оброблення запитів і навіть написання програмного коду за бажанням користувача, завершуючи інструментарієм зі створення музики. Варто зазначити, що розвиток технологій також досяг того рівня

в питанні продуктивності користувацьких систем, що персональні комп'ютери останніх років так само спроможні відтворювати всі ці можливості локально, без застосування великих серверних потужностей.

Необхідно наголосити на проблематиці нових систем штучного інтелекту. Сучасні моделі ШІ не є подібними до можливостей справжнього мозку людини. Усі згадані вище сервіси та системи є лише результатом опрацювання математично базованим алгоритмом, що має уяву лише про певну предметну галузь. Крім того, що більша система, то вірогідніші помилки та неточності через обмеженість та синтетичність розумової діяльності штучного інтелекту.



Отже, для предметних галузей, що не допускають значних відхилень у результатах роботи штучного інтелекту, необхідне зменшене подання даних для аналізу разом із дуже точно описаними зв'язками та залежностями між елементами. Це зумовлено високою ціною помилкового результату інтелектуальної системи, як, наприклад, у медицині чи в сервісі з віртуально розподіленими електростанціями.

Для подібного уточнення даних для штучного інтелекту можна використовувати підхід онтологічного інжинірингу. Онтологія – це сукупність елементів предметної галузі, їх взаємозв'язків та функцій інтерпретації елементів або зв'язків. Бази знань, побудовані за цим підходом, є чітко визначеними, що знижує ймовірність помилкових результатів роботи ШІ.

Існує чимало мов та інструментів для онтологічного інжинірингу, що мають переваги й недоліки. Нагальним є питання пошуку та підбору інструментарію за його доцільністю.

Основна мета дослідження – визначення сучасних інструментів, встановлення їх параметрів за єдиною системою оцінювання, аналіз можливостей кожного інструменту та демонстрація структурованого результату.

Новизна роботи полягає в аналізі та пошуку найкращого інструментарію та методів онтологічного інжинірингу в контексті інтелектуальних систем на основі порівняння, опрацювання наукових робіт і відкритої інформації щодо кожного ресурсу.

### Аналіз предметної галузі

Онтологічний інжиніринг, що впливає з назви, – це сфера знань, яка вивчає сукупність методів і методологій створення баз знань – онтологій [1]. Крім цього, варто надати визначення онтології. У контексті інформаційних технологій та, зокрема, інтелектуальних систем – це база знань, що описує предметну галузь через множину термінів, зв'язків між ними та інтерпретаціями всього зазначеного [2]. Онтології – це формальні семантичні моделі – понятійні бази, що можуть бути прочитані та опрацьовані машинами.

У межах сучасних потреб та запитів ІТ-індустрії наперед виходять інтелектуальні системи із використанням штучного інтелекту. За останні роки такі сервіси були розроблені для багатьох сфер – від творчих галузей, таких як створення зображень, відео, музики, людиноподібних асистентів до більш

серйозних систем, що можуть відповідати за безпеку людини тощо, як, наприклад, автопілот автівки, що платить високу ціну за помилку. Зі свого боку ШІ на поточний момент свого розвитку є лише алгоритмом певного розміру, що лише зчитує запит людини, обробляє його шарами штучних нейронів, після чого формує математично обчислений результат. Отримана відповідь від ШІ може містити похибки чи взагалі помилкові результати тощо. Це обґрунтовано обмеженням навчальних даних, простотою шарів нейронів моделі та найважливіше – ШІ, що сформував власні асоціації між елементами неосязної інформації та видає лише математично прораховану відповідь на основі ймовірностей тощо. Такий підхід є досить доречним у генерації тексту чи медіаконтенту, однак неприпустимий у контексті інтелектуальних систем, що потребують максимально точного результату, як, наприклад, медицина.

Для розв'язання окресленої проблеми можуть бути застосовані онтології як бази знань понятійного апарату штучного інтелекту. У разі використання онтологічного інжинірингу алгоритм буде мати готові, заздалегідь прописані та продумані зв'язки, терміни та їх інтерпретації в предметній галузі. Після застосування баз знань, замість сирової інформації навчальних даних, ШІ має вираховувати свої відповіді на основі ґрунтовної бази асоціацій та зв'язків.

Питання, зокрема мета цього дослідження, полягає у вивченні, класифікації та аналізі сучасних методів і методологій онтологічного інжинірингу для створення баз знань та подальшого їх використання в інтелектуальних системах, що ґрунтовані на моделях штучного інтелекту та мають високу ціну помилки, як, наприклад, сфера віртуальних розподілених електростанцій.

Для створення формального систематизованого подання галузей знань використовуються мови онтологій, зокрема *RDF (Resource Description Framework)*, *RDFS (Resource Description Framework Schema)*, *OWL (Ontology Web Language)* або їх похідні. Для створення бази знань упроваджується логіка опису. Як уже згадувалось вище, онтологія містить терміни, зв'язки та інтерпретації. У логіці опису інакше це можна назвати класами, ролями та об'єктами відповідно. У галузі комп'ютерних наук існують терміни для цих складників баз знань, а саме *TBox*, *RBox*, *ABox* [3], відповідно до порядку, згаданому вище. Для збереження даних після процесу формалізації аксіом за допомогою логіки опису

можна використовувати *RDF/XML* або *Turtle* тощо. Додатково може бути застосовано *SWRL (Semantic Web Rule Language)* для більшого спектра можливостей логіки опису та правил тощо. Зокрема необхідно зазначити, що, крім звичайних термінів, за допомогою мови *RDF* можна створювати зв'язки з іншою інформацією, такою як зображення, відео тощо. Зі свого боку це розширює межі онтології та дає змогу створювати великі та ґрунтовні семантичні мережі на основі неоднозначних даних [4, 5].

Як вже було зазначено, існує понад одна мова для опису баз знань – онтологій, тож перед їх подальшим і більш детальним розглядом необхідно звернути увагу на *Common Logic*. За своєю сутністю *Common Logic* – це фреймворк для сімейства логічних мов, що оснований на логіці першого порядку та слугує спрощенням обміну даними в комп'ютерних системах. Зокрема це відповідний стандарт ISO/IEC 24707:2018 [6]. *Common Logic* – основа для мов онтологічного інжинірингу, що є його діалектами та отримують від нього абстрактну семантику, яка ґрунтується на теоретичній інтерпретаційній моделі, та синтаксис. Зазначений стандарт виокремлює три напрями діалектів, а саме *Common Logic Interchange Format (CLIF) (Annex A)*, *Conceptual Graph Interchange Format (CGIF) (Annex B)* та оснований на нотації *XML Common Logic (XCL) (Annex C)*. Можна згадати відкритий репозиторій онтологій, створених із використанням *Common Logic* [7], *Hets (The heterogeneous tool set)* [8], і бібліотеку для *PROLOG* мови – *cltools*, що реалізує часткову підтримку *Common Logic* [9] тощо.

Повертаючись до мов онтологічного інжинірингу, хочемо виокремити такі з них: *CycL* – мова проекту *Cyc* [10]; *Gellish* – онтологічна мова, спрямована на збереження та обмін інформацією [11]; *IDEF5 (Integrated Definition for Ontology Description Capture Method)* – представник сімейства мов моделювання *IDEF* [12]; *KIF* – фреймворк, що більш сконцентрований не на обробленні інформації, а на її передачі між базами знань [13]; *OWL* – нащадок *RDF* та *RDFS*, є мовою онтологічного інжинірингу, спроектованою для використання у WWW [14]; *OntoUML* – мова онтологічного інжинірингу, основана на *UML*, що впливає з назви [15]; *SHACL (RDF SHapes Constraints Language)* – стандартна мова *W3C*, яка підтримує також

взаємодію із *OWL* та *RDFS* [16]; *XBRL (Extensible Business Reporting Language)* – фреймворк для створення онтологій, але більш зосереджений на бізнес-складнику [17]; *SPARQL (SPARQL Protocol and RDF Query Language)* – мова запитів до даних за моделлю *RDF* [18].

Розглядаючи мови та фреймворки онтологічного інжинірингу, необхідно обрати інструментарії та програми, що використовують відповідні мови для створення баз знань. Найбільш уживаними можна назвати такі: *Hozo* [19], *Lettria's Ontology Toolkit* [20], *Protégé* [21], *Onto4ALL* [22], *FluentEditor* [23]. Перелічені застосунки є інструментами для створення редакції та подальшого впровадження онтологій, однак вони розрізняються за функціоналом та можливостями. Порівняння їх властивостей подано в табл. 1.

У контексті розгляду питання про вибір кращого інструментарію для онтологічного інжинірингу для інтелектуальних систем є доречним також порівняти мови, що використовуються в застосунках, які розглядаються. Порівняння подано в табл. 2.

З наведених порівнянь застосунків-інструментаріїв та мов онтологічного інжинірингу (табл. 1 та 2 відповідно), можна прийти до обґрунтованих висновків. Кожен із застосунків підходить найбільше під власні спеціалізовані завдання. Так, для складних онтологій без текстової інформації найбільш підходить *Protégé*. Зі свого боку *Lettria's Ontology Toolkit* пропонує дуже потужний функціонал для оброблення текстових даних та створення баз знань на їх основі, що зосереджує його на текстових моделях штучного інтелекту, зокрема *ChatGPT*, *Gemini* тощо. *FluentEditor* має менш сфокусовану сферу застосування, однак завдяки підтримці *CNL* створення за його допомогою онтологій є більш інтуїтивним. *Onto4ALL* та *Hozo* є більш простими застосунками із загальним спектром можливостей, особливо впроваджуються в незначних завданнях і проєктах.

Однак з огляду на фактори доступності, зручності та можливостей найбільш бажаними інструментаріями є *Protégé* – для більш класичних онтологій, побудованих на термінах, відношеннях та інтерпретаціях, а для великих складних проєктів, що будуються навколо текстових баз знань, підійде *Lettria's Ontology Toolkit*, особливо зважаючи на її *enterprise*-формат поширення.

Таблиця 1. Порівняльна характеристика інструментів онтологічного інжинірингу

Критерій	<i>Hozo</i>	<i>Lettria's Ontology Toolkit</i>	<i>Protégé</i>	<i>Onto4ALL</i>	<i>FluentEditor</i>
Графічний інтерфейс	Певною мірою застарілий, проте зрозумілий; достатній для роботи, але вимагає покращень.	Інтуїтивний, сучасний, зосередженість на штучному інтелекті; гарна візуалізація.	Відносно сучасний, зрозумілий, багатофункціональний.	Інтуїтивний, сучасний, зручний, достатньо інформативний.	Певною мірою застарілий, менш функціональний та інформативний.
Підтримка мов, форматів та фреймворків	<i>Text/HTML, CSV, Hozo Text, XML-DTD, DAML+OIL, RDF, OWL (A, B, C, Old), Markdown, RDF (Relation), Sub-Language Data.</i>	<i>OWL, JSON-LD, RDF.</i>	<i>RDF/XML, Turtle, OWL/XML, OWL Functional, Manchester OWL, OBO, LaTeX, JSON-LD, SWRL, SPARQL, SQWRL.</i> <i>With plugins: Excel workbook, OAF, ROWL, SHACL.</i>	<i>OWL, OWL/XML, OWX, XML, TURTLE, SINTAXEMNCHESTER, RDF/XML, SVG.</i>	<i>CNL, RDF/XML, OWL/XML, HTML/HTML, SKOS, SPARQL.</i>
Особливість інструментарію	Простий функціональний застосунок із достатніми можливостями; управління залежностями, колаборативна робота, <i>API</i> для інтеграції.	Генерація онтологій з текстів, аналіз на основі <i>NLP</i> ; висока сумісність вихідного формату, зручність та простота.	Багатофункціональний застосунок із можливістю встановлювати плагіни, що розширюють можливості ще більше.	Простий вебзастосунок з інтуїтивним інтерфейсом та функціоналом.	Підтримка <i>CNL</i> , зручна робота із семантичними конструкціями, багатоінформативний інтерфейс.
Можливості співпраці	Підтримує спільне розроблення з менеджером версій.	Обмежена, зосередженість на автономне редагування.	Розширювана через плагіни та інструменти для командної роботи.	Не підтримує.	Підтримує інтеграцію з різними редакторами та онлайн-співпрацю.
Простота використання	Середня, вимагає базового навчання.	Висока, завдяки <i>AI</i> -функціям та інтуїтивному інтерфейсу.	Складна для новачків, але потужна для експертів.	Простий у використанні, зосередженість на початківцях або на маленьких проєктах.	Середня завдяки природній мові та змістовному інтерфейсу, однак вимагає навчання.
Доступність	<i>Desktop</i> -застосунок із вбудованим сервером, у відкритому доступі.	Вебзастосунок, однак поширюється за <i>enterprise</i> -форматом.	<i>Desktop</i> - застосунок у відкритому доступі.	Вебзастосунок у відкритому доступі.	<i>Desktop</i> - застосунок у відкритому доступі, зокрема в <i>Microsoft Store</i> .

Таблиця 2. Порівняльна характеристика мов онтологічного інжинірингу

Мова	Характеристики	Переваги	Недоліки	Основне застосування
1	2	3	4	5
<i>Text/HTML</i>	Простий текст або гіпертекстовий формат.	Легкий для створення та читання, підходить для невеликих онтологій.	Відсутність структурованості та семантичних зв'язків.	Документація, опис простих моделей.
<i>CSV</i>	Табличний формат, поділений комами.	Зручний для табличних даних, легко обробляється програмно.	Складний для моделювання ієрархій і складних зв'язків.	Таблиці даних, прості експорт / імпорт.
<i>XML-DTD</i>	Визначення структури <i>XML</i> -документів, що задає допустимі елементи та атрибути.	Чіткість та структурованість, стандарт у <i>XML</i> .	Старий формат, складний для оброблення сучасними інструментами.	Валідація <i>XML</i> -документів.

Продовження таблиці 2

1	2	3	4	5
<i>DAML+OIL</i>	Попередник <i>OWL</i> , розроблений для моделювання онтологій в <i>Semantic Web</i> .	Семантична потужність, гнучкість у створенні складних моделей.	Обмежена підтримка сучасними системами.	Моделювання семантичних систем (здебільшого застарілий).
<i>RDF</i>	Модель даних, що зберігає інформацію у вигляді триплетів (суб'єкт – предикат – об'єкт).	Простота, широко використовується в <i>Semantic Web</i> .	Відсутність підтримки складних аксіом або обмежень.	Семантичні вебресурси, базові моделі онтологій.
<i>OWL</i>	Високорівнева мова для створення складних онтологій, містить варіанти <i>OWL (A, B, C)</i> .	Підтримка складних зв'язків, сумісність із <i>RDF</i> .	Вимагає вивчення, складність реалізації.	Комплексні онтології, опис знань.
<i>OWL/XML, RDF/XML</i>	<i>XML</i> -варіанти <i>OWL</i> і <i>RDF</i> , що додають чіткість та зручність оброблення.	Уніфікація із <i>XML</i> -системами, підтримка багатьма інструментами.	Перевантаженість синтаксису, складність читання вручну.	Інтеграція з <i>XML</i> -системами.
<i>Turtle</i>	Спрощений синтаксис для <i>RDF</i> .	Зручність для розробників, компактний і легко читається.	Лімітований для складних структур.	Розроблення семантичних вебресурсів.
<i>JSON-LD</i>	Легковагова структура для опису даних у <i>JSON</i> з додаванням семантики.	Простота інтеграції з вебтехнологіями, легкість у розробленні.	Обмежена семантична потужність порівняно з <i>OWL</i> .	Вебзастосунки, інтеграція з <i>API</i> .
<i>SWRL</i>	Мова правил для <i>OWL</i> .	Розширення можливостей <i>OWL</i> , дає змогу створювати логічні правила.	Складність у реалізації та виконанні.	Додавання правил у складні онтології.
<i>SPARQL</i>	Мова запитів для <i>RDF</i> -даних.	Потужна для запитів семантичних даних.	Використовується лише для читання, не модифікації.	Пошук і оброблення семантичних даних.
<i>SKOS</i>	Простий об'єктний стандарт для моделювання класифікацій і словників.	Простота використання, підтримка семантики.	Обмежені можливості для складних онтологій.	Тезауруси, словники, класифікації.
<i>CNL</i>	Контрольована природна мова для створення й редагування онтологій.	Зрозумілість для людей, простота редагування.	Обмежений набір інструментів для використання.	Гуманізовані онтології, інтеграція з текстовими інтерфейсами.

Також варто розглянути, які саме мови та фреймворки є найбільш актуальними для онтологічного інжинірингу в контексті створення інтелектуальних систем. Мови *RDF* і *OWL* все ще залишаються стандартами для великих онтологій з підтримкою складних зв'язків і можливістю інтеграції з іншими форматами. *Turtle* і *JSON-LD* ефективні для швидкого розроблення та інтеграції з вебтехнологіями завдяки простому синтаксису. Мова запитів *SPARQL* надає потужні засоби для запитів семантичних даних, що робить її необхідним інструментом для аналізу онтологій.

#### Аналіз наукових досліджень у галузі

Як зазначалося вище, сучасний етап розвитку інформаційних технологій, зокрема в сферах штучного інтелекту та семантичного вебу, диктує необхідність постійного вдосконалення методів та інструментів онтологічного інжинірингу. Навіть за наявності добре усталених підходів, таких як *RDF*, *OWL* та *SPARQL*,

науковці не припиняють пошук інноваційних рішень для підвищення ефективності процесів створення, управління та практичного застосування онтологій. За останні п'ять років спостерігаємо значне дослідницьке зацікавлення до інтеграції онтологій з методами машинного навчання та ШІ. Цей тренд спрямований на створення більш адаптивних, інтелектуальних і автономних систем.

Одним із ключових напрямів сучасних досліджень є розроблення методів автоматизованого створення та динамічного поповнення онтологій. Традиційний процес онтологічного інжинірингу, як правило, є досить ресурсоемним і вимагає значної участі експертів. Утім сучасні підходи дають змогу спростити та оптимізувати цей процес. У дослідженні [24] пропонується нова методологія, що використовує глибокі нейронні мережі для вилучення онтологічних концепцій та семантичних відношень безпосередньо із текстових даних. Цей підхід оснований на архітектурі трансформерів, що дає змогу ефективно

аналізувати контекст і виявляти ключові елементи онтологій. Застосування методів глибокого навчання сприяє автоматизації рутинних етапів, що значно прискорює створення нових онтологій та підвищує їх якість. Крім того, нейронні мережі здатні розпізнавати неявні семантичні зв'язки між різними термінами, що не завжди є очевидним для експерта. У статті [25] запропоновано інтегрований метод, що поєднує лінгвістичний аналіз, зокрема оброблення природної мови (*NLP*), та семантичні мережі для автоматичного виявлення та структурування онтологічних знань із великих масивів неструктурованих даних. Цей метод використовує комбінацію алгоритмів розпізнавання іменованих сутностей, семантичного розпізнавання ролей та інших *NLP*-методів для ідентифікації онтологічних класів, відношень та атрибутів. Особлива увага приділяється обробленню неоднозначних термінів за допомогою *WordNet* та їх інтеграції в структуру онтології, що сприяє створенню більш точних і надійних онтологій. Важливими є належне оброблення неоднозначних термінів і контекстуалізація виявлених фактів, що сприяє створенню більш точних та надійних онтологій із збереженням часової ефективності.

Крім того, дослідників цікавить створення інструментів для візуалізації онтологій, які б відповідали викликам сучасних інтелектуальних систем. У роботі [26] описано інтерактивний інструмент *PRONTOVISE*, що ґрунтується на концепціях когнітивних карт для візуалізації знань і семантичних зв'язків. Цей інструмент надає розширені можливості для подання складних онтологічних просторів, спрощує процес вивчення онтологій та полегшує їх розуміння, що є вкрай важливим для моделювання інтелектуальних систем реального часу. Когнітивні карти дають змогу подавати знання в більш інтуїтивно зрозумілому вигляді, що спрощує процес моделювання та полегшує міждисциплінарну співпрацю між експертами з різних предметних галузей. У статті [27] запропоновано новий інструмент для інтерактивної 3D-візуалізації онтологій, що допомагає користувачам досліджувати ієрархії класів та імпортовані терміни в тривимірному просторі. Інструмент сприяє кращому розумінню складних онтологічних структур завдяки зручній навігації та інтерактивним графічним елементам.

Варто також зазначити, що в дослідженнях спостерігається тенденція до розширення

функціональності наявних мов, наприклад *OWL*, способом додавання нових конструкцій та правил [28–31]. Це дає змогу більш точно та детально описувати знання, зважаючи на особливості конкретних предметних галузей. Зокрема пропонуються нові методи для опису часових залежностей між різними поняттями або для уважного ставлення до контекстуальної інформації в процесі виведення нових фактів.

Іншим важливим аспектом є дослідження методів ефективного використання онтологій у різних предметних галузях. У роботах [32–34] детально проаналізовано застосування онтологічного інжинірингу для створення інтелектуальних систем у сфері охорони здоров'я, зокрема для розроблення систем підтримки прийняття клінічних рішень та інтеграції медичних знань із різних джерел. Автори наголошують, що онтології забезпечують формальне та структуроване подання медичних даних, що сприяє більш ефективному ухваленню клінічних рішень і підвищенню якості медичного обслуговування. У праці [35] розглядається застосування онтологій у сфері енергетики, зокрема для моделювання розумних енергетичних мереж, аналізу електроенергетичних ринків та інтеграції різних систем управління енергоресурсами. Автори статті [36] досліджують застосування онтологій у системах управління ланцюгами постачання, де онтології впроваджуються для моделювання та відстеження логістичних процесів, забезпечуючи прозорість і покращену взаємодію між учасниками ланцюга постачання.

Щодо підвищення продуктивності онтологічного інжинірингу існують дослідження, присвячені оптимізації запитів до онтологій та підвищенню швидкості оброблення семантичних даних. У роботі [37] запропоновано інноваційну структуру індексації для *RDF*-даних, що дає змогу значно прискорити виконання *SPARQL*-запитів, зменшуючи час пошуку необхідної інформації та підвищуючи масштабованість онтологічних систем. Також спостерігається тенденція щодо використання паралельних обчислень та розподілених систем для оброблення великих масивів онтологічних даних [38–40]. У статті [41] описано ключові напрями використання онтологій у хмарних обчисленнях, зокрема для забезпечення інтероперабельності, управління ресурсами та вибору сервісів. Обговорюються методи масштабування для

ефективного керування значними обсягами даних, що дає змогу використовувати онтології в обробленні великих даних та багатомарних середовищах.

Аналіз сучасних досліджень у сфері онтологічного інжинірингу свідчить про активний розвиток методів, інструментів та мов для створення, управління та застосування онтологій. Зокрема спостерігається тенденція до автоматизації процесів онтологічного інжинірингу, розширення можливостей наявних мов та інструментів, а також пошуку нових підходів до застосування онтологій у різних предметних галузях. Результати цих досліджень доводять важливість онтологій для створення інтелектуальних систем, що є особливо актуальним у контексті зростання складності сучасних інформаційних технологій.

### Результати практичного дослідження

На основі проаналізованої інформації та зроблених проміжних висновків розглянемо результати їх застосування в онтологічному інжинірингу бази знань для інтелектуальної системи. Для зразкової предметної галузі було обрано тематику застосування віртуальних розподілених електростанцій. У цій інтелектуальній системі передбачено на основі якісних онтологій та їх використання разом із штучним інтелектом запровадити застосунок, що розв'язує проблему розподілу ресурсів за наявними вимогами та потужностями [42–45].

Як зазначалося вище, галузь віртуальних розподілених систем має високу ціну помилкового прогнозування штучним інтелектом, саме тому для розв'язання окресленої проблеми доречно застосовувати онтологічний інжиніринг для надання більш точного контексту інтелектуальній системі, зокрема III.

Отже, метою практичної частини цього дослідження є демонстрація ефективності інструментарію, який розглянуто вище, та навести порівняння із спорідненими підходами до виконання обраного завдання (створення інтелектуальної системи – застосунок для керування віртуальними розподіленими електростанціями), що має досить високу потребу в правильних прогнозах штучного інтелекту.

Як інструментарій було обрано оптимальне поєднання – застосунок *Protégé* та мову запитів *SPARQL* для взаємодії із наповненням бази знань.

Також додатково буде застосовано *SWRL* з метою створення логічних правил у онтології [46–48].

Необхідно зазначити, що в межах демонстративної практичної частини буде створено онтологію лише за незначною частиною предметної галузі інтелектуальної системи контролю за віртуальними розподіленими електростанціями. Цього обсягу даних має бути достатньо для аналізу та ґрунтового висновку щодо використання онтологічного інжинірингу для подібних завдань.

Отже, розглянемо структуру та будову спрощеної онтології у формалізованому вигляді [49].

#### 1. Класи та підкласи:

а) Generator – джерело енергії:

- SolarPanel – сонячна панель;
- WindTurbine – вітряна турбіна;
- HydroGenerator – гідроелектростанція;

б) Consumer – споживач енергії:

- ResidentialConsumer – житловий споживач;
- IndustrialConsumer – промисловий споживач;

в) EnergyNode: вузли розподілу енергії:

- MainNode – основний вузол;
- SubNode – підпорядкований вузол;

г) Contract: угода між генератором і споживачем

із параметрами:

- EnergyAmount – кількість енергії;
- StartDate, EndDate – дати дії контракту.

#### 2. Полі (зв'язки):

а) providesEnergy: зв'язок між Generator і EnergyNode;

б) consumesEnergy: зв'язок між Consumer і EnergyNode;

в) hasContract: зв'язок між Generator, Consumer і Contract.

Зокрема необхідно виокремити "суперкласи", або загальні концепти, такі як *Entity*, *DistributionPoint* і *Agreement*.

Для більшої ґрунтовності та наочності зв'язків і будови створюваної бази знань – онтології – варто розглянути її з погляду логіки опису – математичної моделі. Вона формалізує відношення між класами, підкласами, індивідами та їх зв'язками.

Відповідно до термінологічної бази або *TBox* нижче подамо згадану онтологію.

#### 1) Класи та підкласи:

а) Generator  $\sqsubseteq$  Entity: джерело енергії є сутністю;

• SolarPanel  $\sqsubseteq$  Generator: сонячні панелі є генераторами;

• WindTurbine  $\sqsubseteq$  Generator: вітряні турбіни є генераторами;

• HydroGenerator  $\sqsubseteq$  Generator: гідроелектростанції є генераторами;

б) Consumer  $\sqsubseteq$  Entity: споживач енергії є сутністю;

• ResidentialConsumer  $\sqsubseteq$  Consumer: житлові споживачі є споживачами;

• IndustrialConsumer  $\sqsubseteq$  Consumer: промислові споживачі є споживачами;

в) EnergyNode  $\sqsubseteq$  DistributionPoint: вузли енергорозподілу є точками розподілу;

• MainNode  $\sqsubseteq$  EnergyNode: основний вузол є вузлом розподілу енергії;

• SubNode  $\sqsubseteq$  EnergyNode: підпорядкований вузол є вузлом розподілу енергії;

г) Contract  $\sqsubseteq$  Agreement: контракти є угодами;

• Contract  $\sqsubseteq \exists$ hasAttributes.(EnergyAmount  $\sqcap$  StartDate  $\sqcap$  EndDate): контракт містить параметри кількості енергії та дат початку й завершення.

2) Відношення (ролі):

а) ProvidesEnergy  $\sqsubseteq$  Relation: генератори постачають енергію до вузлів;

• Generator  $\sqsubseteq \exists$ providesEnergy.EnergyNode: кожен генератор постачає енергію до вузла;

б) ConsumesEnergy  $\sqsubseteq$  Relation: споживачі отримують енергію з вузлів;

• Consumer  $\sqsubseteq \exists$ consumesEnergy.EnergyNode: кожен споживач отримує енергію з вузла;

в) hasContract  $\sqsubseteq$  Relation: зв'язок між генератором, споживачем і контрактом;

• Generator  $\sqsubseteq \exists$ hasContract.Contract: генератори укладають контракти;

• Consumer  $\sqsubseteq \exists$ hasContract.Contract: споживачі мають контракти.

Розглядаючи базу знань під кутом *RBox* або властивостей та обмежень ролей, подамо такий опис:

• функціональність –  $\forall$ providesEnergy.  $\neg$ providesEnergy<sup>^</sup>:- генератор може постачати енергію лише одному вузлу одночасно;

• унікальність контрактів –  $\forall$ hasContract.( $\exists$ linkedByContract.Generator): споживач може мати контракт лише з одним генератором;

• обмеження вузлів –  $\forall$ providesEnergy.( $\leq$ MaxCapacity.EnergyNode): загальна кількість енергії, що постачається генераторами, не має перевищувати потужності вузла.

Зі свого боку асерційна база *ABox* представляє індивіди та відповідні зв'язки між ними для онтології, що створюється. Необхідно зазначити, що ця онтологія є лише демонстративним прикладом – наочним результатом дослідження, тож дані є лише схематичним нарисом та здебільшого заглушками й макетами, що не відтворюють повною мірою потенційно справжній вміст такої онтології на практиці.

Індивіди:

- SolarPanel\_1  $\sqsubseteq$  SolarPanel;
- WindTurbine\_2  $\sqsubseteq$  WindTurbine;
- Factory\_1  $\sqsubseteq$  IndustrialConsumer;
- Home\_1  $\sqsubseteq$  ResidentialConsumer;
- MainNode\_1  $\sqsubseteq$  MainNode;
- Contract\_101  $\sqsubseteq$  Contract.

Зв'язки між індивідами:

• providesEnergy(SolarPanel\_1, MainNode\_1): сонячна панель 1 постачає енергію до основного вузла 1;

• consumesEnergy(Factory\_1, MainNode\_1): завод 1 отримує енергію з основного вузла 1;

• hasContract(SolarPanel\_1, Contract\_101): контракт 101 пов'язаний із сонячною панеллю 1;

• hasContract(Factory\_1, Contract\_101): контракт 101 пов'язаний із заводом 1.

Також варто окремо подати математичні аксіоми онтології, що розглядається.

1) Генератор, споживач та вузли:

- Generator  $\sqsubseteq$  Entity;
- Consumer  $\sqsubseteq$  Entity;
- EnergyNode  $\sqsubseteq$  DistributionPoint.

2) Взаємозв'язки:

• providesEnergy(SolarPanel\_1, MainNode\_1)  
 $\Rightarrow$  SolarPanel\_1  $\sqsubseteq \exists$ providesEnergy.MainNode;  
 • consumesEnergy(Factory\_1, MainNode\_1)  $\Rightarrow$   
 Factory\_1  $\sqsubseteq \exists$ consumesEnergy.MainNode.

3) Контракти:

• Contract\_101  $\sqsubseteq \exists$ hasAttributes.(EnergyAmount  $\sqcap$  StartDate  $\sqcap$  EndDate);  
 • hasContract(SolarPanel\_1, Contract\_101)  $\sqcap$   
 hasContract(Factory\_1, Contract\_101)  $\Rightarrow$   
 $\exists$ linkedByContract.Generator.

Завдяки такому змістовному опису забезпечується формальна структура онтології в предметній галузі, що дає змогу виконувати логічне виведення для оптимізації роботи інтелектуальної системи з контролю віртуальних розподілених електростанцій. Логіка опису гарантує точність та стійкість

моделювання, гнучкість і можливість легкого масштабування застосунку.

Як вже зазначалося раніше, для онтологічного інжинірингу бази знань у контексті розподілених віртуальних електростанцій доречно використати *SPARQL*. Інтеграція мови запитів до бази знань дає змогу ефективно отримувати, аналізувати й модифікувати дані, зберігаючи їх формалізовану структуру й семантику, аналогічно до мови *SQL* тощо.

Необхідно відразу виокремити декілька важливих запитів, що мають бути додані до онтологічної моделі, що розробляється.

По-перше, код запиту на отримання всіх споживачів від конкретного вузла; це може бути корисним у багатьох ситуаціях використання інтелектуальної системи:

```
1. SELECT ?consumer
2. WHERE {
3.     ?consumer :consumesEnergy
      :MainNode_1.
4. }
```

Іншим, проте не менш корисним, є запит, що шукає перенавантажені вузли та допомагає в підтримці всієї системи бути стабільною, незважаючи на коливання потреб користувачів та наявних потужностей:

```
1. SELECT ?generator ?node
   (SUM(?energyAmount) AS ?totalEnergy)
2. WHERE {
3.     ?generator :providesEnergy ?node.
4.     ?generator :energyAmount
      ?energyAmount.
5. }
6. GROUP BY ?node
```

```
7. HAVING (?totalEnergy > ?nodeCapacity)
```

Запит, що відповідає за пошук активних користувачів, із актуальними контрактами на отримання потужностей системи розподілених станцій:

```
1. SELECT ?generator ?consumer
   ?energyAmount ?startDate ?endDate
2. WHERE {
3.     ?contract :linkedByContract
      ?generator.
4.     ?contract :linkedByContract
      ?consumer.
5.     ?contract :energyAmount
      ?energyAmount.
6.     ?contract :startDate ?startDate.
7.     ?contract :endDate ?endDate.
8.     FILTER (NOW() >= ?startDate &&
      NOW() <= ?endDate)
9. }
```

Завдяки мові запитів *SPARQL* та, зокрема, запитам на ній є можливість машинної швидкої взаємодії із відповідними даними. Зважаючи на це, онтологія, поєднуючись із цією мовою, підтримує оброблення штучним інтелектом або будь-яким іншим алгоритмом для аналізу даних та подальшого прогнозування й автоматизації процесів, що необхідно в обраному контексті – предметній галузі програмного застосунку – інтелектуальній системі з керування віртуальними розподіленими електростанціями.

Також варто порівняти підходи зі звичайним збереженням даних, наприклад, у реляційних базах даних із використанням мови запитів *SQL* та онтологіях у форматі триплетів "суб'єкт – предикат – об'єкт" із застосуванням *SPARQL*. Порівняльна характеристика наведена в табл. 3.

Таблиця 3. Порівняльна характеристика *SPARQL* (онтології) та *SQL* (реляційні бази даних)

Критерій 1	<i>SPARQL</i> (онтології) 2	<i>SQL</i> (реляційні бази даних) 3
Модель даних	Ґрунтується на <i>RDF</i> -триплетях (суб'єкт – предикат – об'єкт), що дає змогу моделювати семантичні зв'язки між сутностями.	Використовує реляційну модель, основу на таблицях, де дані зберігаються у вигляді рядків і стовпців.
Типи запитів	Орієнтований на графові дані; уможливує здійснення запитів до даних, пов'язаних семантичними зв'язками.	Орієнтований на табличні дані; добре підходить для агрегованих, транзакційних запитів.
Підтримка семантики	Підтримує семантичні відношення між даними; дає змогу здійснювати запити з огляду на логічні правила й аксіоми онтології.	Не має вбудованої семантики; зв'язки між таблицями задаються вручну за допомогою ключів ( <i>primary/foreign keys</i> ).
Масштабованість	Висока для структур із складними зв'язками (онтології, графи). Ефективний для динамічних, розподілених структур.	Краще працює для великих транзакційних даних із простою структурою (таблиці, індекси).
Адаптація до змін	Гнучка структура <i>RDF</i> дає змогу легко додавати нові сутності, відношення чи властивості без порушення наявних даних.	Зміна структури (додавання стовпців чи таблиць) може вимагати міграції даних та складного налаштування.



## Продовження таблиці 3.

1	2	3
Підтримка інтеграції	Призначений для роботи з онтологіями та <i>Semantic Web</i> ; дає змогу інтегрувати різні джерела даних за допомогою стандартів <i>RDF/OWL</i> .	Вимагає складнішої інтеграції між різними системами; немає вбудованої підтримки <i>Semantic Web</i> .
Логічні виведення	Дає змогу здійснювати запити з огляду на логічні виведення ( <i>Reasoning</i> ), наприклад, за допомогою <i>SWRL</i> або інших інструментів онтологій.	Логічні виведення не підтримуються; потрібно реалізовувати бізнес-логіку окремо на стороні застосунку.
Продуктивність	Ефективний для роботи з графами та пов'язаними даними, але може бути повільнішим для великих транзакційних даних.	Висока швидкість для оброблення значних обсягів структурованих даних у табличному вигляді.
Інструменти та підтримка	Підтримується інструментами, такими як <i>Protégé</i> , <i>GraphDB</i> , <i>Blazegraph</i> ; інтеграція із <i>Semantic Web</i> .	Широка підтримка СУБД ( <i>MySQL</i> , <i>PostgreSQL</i> , <i>Oracle</i> , <i>SQL Server</i> ); підходить для традиційних застосунків.
Використання в інтелектуальних системах з керування віртуальними розподіленими електростанціями	Ідеально підходить для моделювання складних взаємозв'язків у системах управління, таких як зв'язки між генераторами, вузлами й контрактами.	Ефективно для зберігання транзакційних даних, таких як журнали споживання чи фінансові операції.

Також зазначимо важливість використання *SWRL* – мови правил для *OWL*. Вона дає змогу описувати логічні правила за умови взаємодії абстракцій – концептів – та є розширенням до базових можливостей онтологічного інжинірингу, зокрема мови *OWL* тощо. У контексті інтелектуальних систем із важливістю правильних прогнозів алгоритмів штучного інтелекту, як тої, що розглядається, – застосунок із керуванням

віртуальними розподіленими електростанціями – *Semantic Web Rule Language* є інструментом для постанови та оптимізації логічних процесів тощо. Узагальнюючи, *SWRL* додає предикатну логіку до відношень та правил за допомогою форми "якщо, то".

Для більшого занурення в питання впровадження *SWRL* варто порівняти можливості звичайної *OWL* та онтологій із використанням мови правил (табл. 4).

Таблиця 4. Порівняльна характеристика базової *OWL* та онтологій із *SWRL*

Критерій	Логіка опису ( <i>OWL</i> )	<i>SWRL</i>
Формалізм	Формальні аксіоми	Розширення логіки за допомогою правила "якщо, то". Правила <i>SWRL</i> можуть бути використані для виведення нових фактів, наприклад ідентифікації споживачів, які можуть отримати додаткову енергію за наявності надлишкової потужності.
Можливості	Обмежений набір виразів	Динамічні правила для складних умов. Правила легко адаптуються до змін у системі, наприклад додавання нових типів генераторів або споживачів.
Динамічність	Фіксована структура онтології	Гнучкість для створення адаптивних рішень. Зокрема <i>SWRL</i> дає змогу автоматизувати складні процеси, наприклад перенаправлення енергії від перевантажених вузлів до менш завантажених.
Застосування в штучному інтелекті	Пасивна база знань	Активне виведення нових знань і оптимізація рішень. <i>SWRL</i> може бути використана разом із <i>Reasoner</i> (наприклад, <i>Hermit</i> або <i>Pellet</i> ) для розширення можливостей штучного інтелекту, зокрема автоматизації управління та прогнозування.

Зокрема можна виокремити низку правил, що є ефективними для впровадження інтелектуальної системи з контролю віртуальними розподіленими електростанціями:

- правило з управління перенавантаженням вузлів – якщо вузол перевантажений, то перенаправити енергію на інший вузол:  $\text{EnergyNode}(?n1) \wedge \text{EnergyNode}(?n2) \wedge$

$\text{Overloaded}(?n1) \wedge \text{Connected}(?n1, ?n2) \rightarrow \text{RedirectEnergy}(?n1, ?n2);$

- правило з оптимізації контрактів – якщо контракт між генератором і споживачем має вичерпаний термін дії, то позначити контракт як неактивний:  $\text{Contract}(?c) \wedge \text{hasEndDate}(?c, ?end) \wedge \text{CurrentDate}(?now) \wedge ?end < ?now \rightarrow \text{DeactivateContract}(?c);$

- правило про балансування енергоспоживання – якщо споживач перевищує допустиме споживання, зменшити потужність, яку надає генератор:  
 $\text{Consumer}(?c) \wedge \text{consumesEnergy}(?c, ?n) \wedge \text{Overconsuming}(?c) \rightarrow \text{AdjustOutput}(?n, ?c);$
- правило про прогнозування перевантажень – якщо загальне споживання на вузлі перевищує 90 % потужності, позначити вузол як потенційно перевантажений:  
 $\text{EnergyNode}(?n) \wedge \text{TotalConsumption}(?n, ?t) \wedge \text{MaxCapacity}(?n, ?m) \wedge (?t > 0.9 * ?m) \rightarrow \text{PotentialOverload}(?n).$

Також варто зазначити, що інструмент *Protégé* має підтримку *Reasoner* та, зокрема, мови *SWRL*.

Також перелічимо, що саме робить *Reasoner*. Він визначає, чи є правила узгодженими з онтологією, чи ні. Зі свого боку правила *SWRL* генерують нові факти, що зберігаються в базі знань для подальшого використання. Також *Reasoner* виконує правила в реальному часі, забезпечуючи автоматичний контроль системи.

Результатом відтворення описаних вище елементів та складників онтології розподілених віртуальних електростанцій стала демонстративна база знань, що зображена на рис. 1.

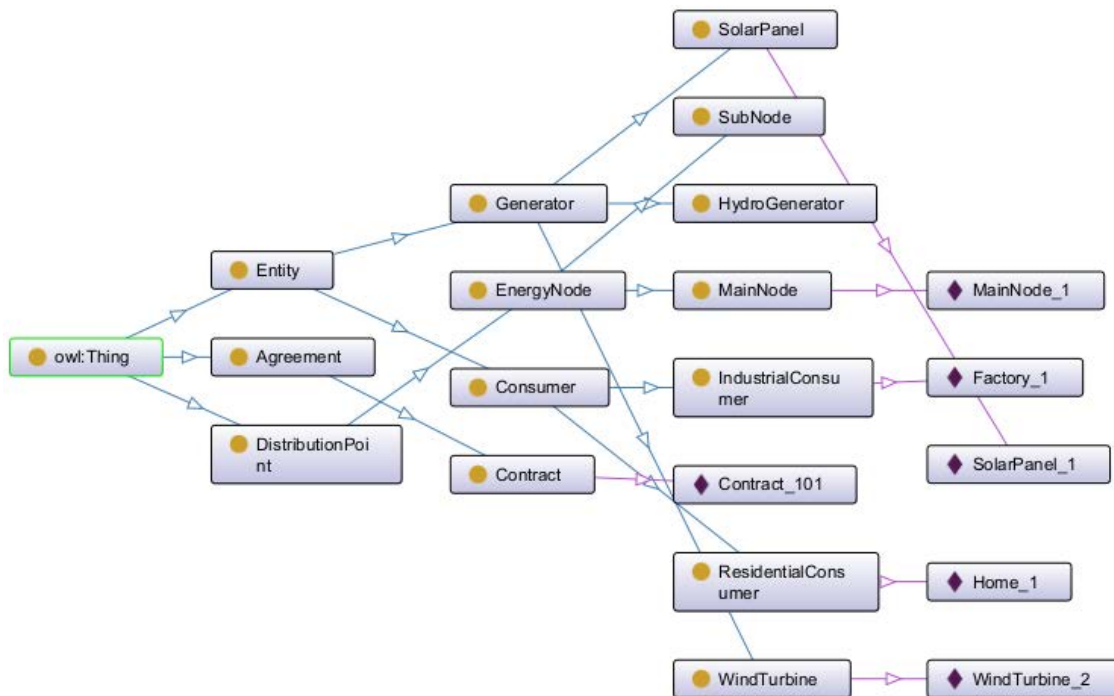


Рис. 1. Демонстративна онтологія за предметною галуззю віртуальних розподілених електростанцій

Отже, як практична демонстрація була розглянута скорочена реалізація онтологічного інжинірингу для інтелектуальної системи управління віртуальними розподіленими електростанціям. Вона підтвердила ефективність запропонованих методів і інструментів у розв'язанні проблеми уточнення відповідей ШІ. Було розглянуто та оприлюднено процес побудови бази знань із використанням застосунку *Protégé* та мов *OWL*, *SPARQL* і *SWRL*. Показано важливість і доцільність інтеграції онтологій у сучасні інтелектуальні системи, що використовують ШІ або інші алгоритми прогнозування відповіді за умови високої ціни помилкового результату.

Підсумовуючи результати практичної частини дослідження, можна наголосити, що онтологічний інжиніринг забезпечує формальну структуру даних, що мінімізує ризики помилок у прогнозах і розрахунках. Використання *RDF*-структур дає змогу легко розширювати базу знань, додаючи нові класи, властивості та правила без порушення наявної моделі. *SPARQL* і *SWRL* забезпечують глибокий аналіз даних, автоматизацію логічних операцій та можливість прогнозування на основі поточного стану системи. Інтелектуальна система на основі онтологій є сумісною з алгоритмами штучного інтелекту, що сприяє розробленню самонавчальних і прогнозуючих моделей.

### Висновки

У статті проаналізовано галузь знань онтологічного інжинірингу. Розглянуто важливість застосування онтологій з метою уточнення даних для ШІ та інших інтелектуальних систем, що математично прогнозують відповіді на основі базової інформації за галуззю знань. Підставою для дослідження стала нагальна потреба в уточненні системи прогнозування відповідей штучним інтелектом, зокрема для галузей, де ціна помилки надто висока, як, наприклад, медицина чи інтелектуальні системи із віртуальними розподіленими електростанціями тощо.

Досліджено наявні мови та фреймворки онтологічного інжинірингу та розглянуто інструментарій, що використовує логіку цих мов для створення баз знань. У статті подано актуальні застосунки, спроектовані для створення та редагування онтологій.

Наведено порівняльні характеристики для обох аспектів онтологічного інжинірингу: як інструментів – застосунків, так і формальних мов опису баз знань. Під час порівняння всебічно розглянуто предмети аналізу, завдяки чому створено обґрунтовану базу знань про інструментарій із можливістю подальшого формулювання висновків на цій основі.

Ця робота відповідає на питання пошуку актуальних методів та інструментів створення баз

знань із використанням онтологічного інжинірингу в контексті інтелектуальних систем. Результатом дослідження стає висунення найбільш оптимальних сценаріїв для використання кожного із застосунків та онтологічних мов, апелюючи до їх параметрів і характеристик, порівнюючи їх з іншими, що розглядалися в роботі.

Дослідження містить практичну демонстрацію та закріплення висновків, які були зроблені під час аналізу наявного інструментарію та мов онтологічного інжинірингу. Зокрема була створена обмежена версія онтології для інтелектуальної системи з керування віртуальними розподіленими системами.

Уся практична частина була основана на закріпленні відомостей про оптимальний інструментарій – *Protégé*, та відповідні мови – *OWL*, *SPARQL*, *SWRL*. Проаналізовано використання онтологічного інжинірингу для створення нарисів предметної галузі машинною мовою порівняно з неонтологічним підходом та, зокрема, переваги мови правил *SWRL* над базовою логікою *OWL* тощо.

Досягнуті результати свідчать про високу практичну цінність онтологічного інжинірингу в умовах, де точність прогнозів і адаптивність системи є критично важливими. Подальший розвиток цього підходу може передбачати розширення онтології, оптимізацію правил та інтеграцію з розподіленими обчислювальними системами для забезпечення масштабованості.

### Список літератури

1. Pouchard L., Ivezić N., Schlenoff C. Ontology engineering for distributed collaboration in manufacturing. AIS2000 Conf. 2000. 1012 p. URL: [https://www.researchgate.net/publication/228596365\\_Ontology\\_engineering\\_for\\_distributed\\_collaboration\\_in\\_manufacturing](https://www.researchgate.net/publication/228596365_Ontology_engineering_for_distributed_collaboration_in_manufacturing) (дата звернення: 02.12.2024).
2. Guarino N. Ontologies and knowledge bases: towards a terminological clarification, Towards Very Large Knowl. Bases. Amsterdam:IOS Press. 1995. P. 25–32. URL: [https://www.researchgate.net/publication/220041941\\_Ontologies\\_and\\_knowledge\\_bases\\_towards\\_a\\_terminological\\_clarification](https://www.researchgate.net/publication/220041941_Ontologies_and_knowledge_bases_towards_a_terminological_clarification) (дата звернення: 02.12.2024).
3. Motz R., Rohrer E., Severi P. The description logicSHIQwith a flexible meta-modelling hierarchy. *Journal of Web Semantics*. 2015. №. 35. P. 214–234. DOI: 10.1016/j.websem.2015.05.002
4. jsld.org. jsld.org. URL: <https://jsld.org/> (дата звернення: 02.12.2024).
5. Kellogg G., Champin P.-A., Longley D. JSON-LD 1.1 – A JSON-based Serialization for Linked Data. 2020. URL: <https://hal.science/hal-02141614v2> (дата звернення: 02.12.2024).
6. ISO/IEC 24707:2018. ISO. URL: <https://www.iso.org/standard/66249.html> (дата звернення: 02.12.2024).
7. GitHub – gruninger/colore: Automatically exported from code.google.com/p/colore. GitHub. URL: <https://github.com/gruninger/colore> (дата звернення: 22.11.2024).
8. Hets (The heterogeneous tool set). Hets (The heterogeneous tool set). URL: <http://hets.eu/> (дата звернення: 22.11.2024).
9. GitHub – cmungall/cltools: tools for common-logic. GitHub. URL: <https://github.com/cmungall/cltools> (дата звернення: 22.11.2024).

10. Home - сус. Сус - The Next Generation of Enterprise AI. URL: <https://cyc.com/> (дата звернення: 22.11.2024).
11. Renssen V., Ashp. Gellish – A generic extensible ontological language – design and application of a universal data structure. Delft: Delft University Press. 2005. 238 p. URL: [https://www.researchgate.net/publication/339529625\\_Gellish\\_A\\_Generic\\_Extensible\\_Ontological\\_Language\\_-\\_Design\\_and\\_Application\\_of\\_a\\_Universal\\_Data\\_Structure](https://www.researchgate.net/publication/339529625_Gellish_A_Generic_Extensible_Ontological_Language_-_Design_and_Application_of_a_Universal_Data_Structure)
12. Maniraj V., Sivakumar D. Ontology Languages – A Review. International Journal of Computer Theory and Engineering. 2010. №. 6, № 2. 887 p. URL: [https://www.researchgate.net/publication/269801838\\_Ontology\\_Languages\\_-\\_A\\_Review](https://www.researchgate.net/publication/269801838_Ontology_Languages_-_A_Review) (дата звернення: 22.11.2024).
13. Shen W. Multi-Agent systems for concurrent intelligent design and manufacturing. Taylor & Francis Group, 2019. 416 p.
14. OWL: A Large Language Model for IT Operations / H. Guo та ін. Computation and Language. 2023. URL: <https://doi.org/10.48550/arXiv.2309.09298> (дата звернення: 22.11.2024).
15. Koen de J. Transformation from OntoUML models to the OpenAPI Specification. 2024. URL: <https://purl.utwente.nl/essays/98294> (дата звернення: 22.11.2024).
16. Pareti P. A Review of SHACL: From Data Validation to Schema Reasoning for RDF Graphs. *Reasoning Web. Declarative Artificial Intelligence*. 2021. P. 115–144. DOI: 10.1007/978-3-030-95481-9\_6
17. Hoitash R., Hoitash U., Morris L. eXtensible Business Reporting Language (XBRL): A Review and Implications for Future Research. *AUDITING: A Journal of Practice & Theory*. 2021. Vol. 40, № 2. P. 107–132. DOI: 10.2308/ajpt-2019-517
18. A survey of RDF stores & SPARQL engines for querying knowledge graphs / W. Ali та ін. The VLDB Journal. 2021. № 31. P. 1–26. URL: <https://link.springer.com/article/10.1007/s00778-021-00711-3> (дата звернення: 22.11.2024).
19. Hozo – Ontology Editor. Hozo – Ontology Editor. URL: <https://www.hozo.jp/> (дата звернення: 22.11.2024).
20. GraphRAG for enterprise GenAI - Lettria. GraphRAG for enterprise GenAI – Lettria. URL: <https://www.lettria.com/> (дата звернення: 22.11.2024).
21. Protégé. protégé. URL: <https://protege.stanford.edu/> (дата звернення: 22.11.2024).
22. Onto4ALL – Ontology Graphical Editor. Onto4ALL – Ontology Graphical Editor. URL: <https://onto4all.com> (дата звернення: 22.11.2024).
23. FluentEditor – Ontology Editor Semantic Web. Cognitum Software House. URL: <https://www.cognitum.eu/semantics/fluenteditor/> (дата звернення: 22.11.2024).
24. Pertsas V., Constantopoulos P. Ontology-Driven Extraction of Contextualized Information from Research Publications. *15th International Conference on Knowledge Engineering and Ontology Development*, Rome, Italy, 13–15 листоп. 2023 p. DOI: 10.5220/0012254100003598
25. Salim M. N., Mustafa B. S. UTtoKB: a Model for Semantic Relation Extraction from Unstructured Text. *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Turkey, 21–23 жовт. 2021 p. DOI: 10.1109/ismsit52890.2021.9604538
26. Demelo J., Sedig K. Forming Cognitive Maps of Ontologies Using Interactive Visualizations. *Multimodal Technologies and Interaction*. 2021. Vol. 5, № 1. 2 p. DOI: 10.3390/mti5010002 (дата звернення: 05.02.2025).
27. Dooley D., Nguyen M. H., Hsiao W. W. L. OntoTrek: 3D visualization of application ontology class hierarchies. *PLOS ONE*. 2023. Vol. 18, № 6. DOI: 10.1371/journal.pone.0286728
28. Brahmia Z., Grandi F., Bouaziz R. τSQWRL: A TSQL2-Like Query Language for Temporal Ontologies Generated from JSON Big Data. *Big Data Mining and Analytics*. 2023. Vol. 6, № 3. P. 288–300. DOI: 10.26599/bdma.2022.9020044
29. Bolatito Y. A. An Enhanced OWL-Time Ontology for Complex Recurring Temporal Patterns / Y. A. Bolatito та ін. *Kasu Journal of Computer Science*. 2024. Vol. 1, № 2. P. 340–365. DOI: 10.47514/kjcs/2024.1.2.0013
30. Achich N. Approach to Reasoning about Uncertain Temporal Data in OWL 2, *Procedia Computer Science*. 2020. №. 176. P. 1141–1150. DOI:10.1016/j.procs.2020.09.110
31. Shanmurthy P. Augmentation of contextual knowledge based on domain dominant words for IoT applications interoperability. *Indonesian Journal of Electrical Engineering and Computer Science*. 2022. Vol. 27, № 1. 504 p. DOI: 10.11591/ijeecs.v27.i1.pp504-512
32. Ertuğrul D. Ç. A knowledge-based decision support system for inferring supportive treatment recommendations for diabetes mellitus. *Technology and Health Care*. 2023. P. 1–24. DOI: 10.3233/thc-230237
33. Saha R. Ontology-based intelligent decision support systems: A systematic approach/ *Web Semantics*. 2021. P. 177–193. DOI: 10.1016/b978-0-12-822468-7.00005-5
34. Spoladore D., Pessot E. Collaborative Ontology Engineering Methodologies for the Development of Decision Support Systems: Case Studies in the Healthcare Domain. *Electronics*. 2021. Vol. 10, № 9. 1060 p. DOI:10.3390/electronics10091060

35. Teixeira B. Application Ontology for Multi-Agent and Web-Services' Co-Simulation in Power and Energy Systems. *IEEE Access*. 2020. Vol. 8. P. 81129–81141. DOI: 10.1109/access.2020.2991010
36. Nacet B., Frendi M., Adla A. Physical Internet Enabled Traceability Systems for Sustainable Supply Chain Management. *Journal of information and organizational sciences*. 2024. Vol. 48, № 1. P. 99–116. DOI: 10.31341/jios.48.1.5
37. Aslam S., Vassilev V. T., Ouazzane K. Parallel Querying of Distributed Ontologies with Shared Vocabulary. *World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering*. 2019. Vol. 13, № 5. P. 287–294. DOI: [10.5281/zenodo.3298789](https://doi.org/10.5281/zenodo.3298789)
38. Query Optimization for Large Scale Clustered RDF Data / I. Zouaghi та ін. International Workshop on Data Warehousing and OLAP. 2020. P. 56–65. URL: <https://api.semanticscholar.org/CorpusID:212727545> (дата звернення: 05.02.2025).
39. Lin X., Jiang D. A Two-Phase Method for Optimization of the SPARQL Query. *Journal of Sensors*. 2022. Vol. 2022. P. 1–12. DOI: 10.1155/2022/4624856
40. Kang X. Grace: An Efficient Parallel SPARQL Query System over Large-Scale RDF Data. *2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, м. Dalian, China, 5–7 трав. 2021 р. 2021. DOI: 10.1109/cscwd49262.2021.9437674
41. Agbaegbu J. Ontologies in Cloud Computing – Review and Future Directions. *Future Internet*. 2021. Vol. 13, № 12. 302 p. DOI: 10.3390/fi13120302
42. Karataiev O., Shubin I. Formal model of multi-agent architecture of a software system based on knowledge interpretation. *Radioelectronic and Computer Systems*. 2023. № 4. P. 53–64. DOI: 10.32620/reks.2023.4.05
43. Xie Y. Virtual Power Plants for Grid Resilience: A Concise Overview of Research and Applications. *IEEE/CAA Journal of Automatica Sinica*. 2024. Vol. 11, № 2. P. 329–343. DOI: 10.1109/jas.2024.124218
44. Ullah Z., Arshad A., Nekahi A. Virtual Power Plants: Challenges, Opportunities, and Profitability Assessment in Current Energy Markets. *Electricity*. 2024. Vol. 5, № 2. P. 370–384. DOI: 10.3390/electricity5020019
45. Zhang W. Virtual power plant integration with smart grids: a Review. *2022 IEEE 5th International Electrical and Energy Conference (CIEEC)*, Nanjing, China, 27–29 трав. 2022 р. DOI: 10.1109/cieec54735.2022.9846220
46. Bassiliades N. A Tool for Transforming Semantic Web Rule Language to SPARQL Inferencing Notation. *International Journal on Semantic Web and Information Systems*. 2020. Vol. 16, № 1. P. 87–115. DOI: 10.4018/ijswis.2020010105
47. Calvanese D. Ontop: Answering SPARQL queries over relational databases. *Semantic Web*. 2016. Vol. 8, № 3. P. 471–487. DOI.org/10.3233/sw-160217
48. Jajaga E., Ahmedi L. C-SWRL: SWRL for Reasoning over Stream Data. *2017 IEEE 11th International Conference on Semantic Computing (ICSC)*, San Diego, CA, USA, 30 січ. – 1 лют. 2017 р. DOI: 10.1109/icsc.2017.64
49. Dudar Z., Litvin S. Ontological description method for building service-oriented distributed learning systems. *Innovative technologies and scientific solutions for industries*. 2024. № 1 (27). P. 39–53. DOI: 10.30837/itssi.2024.27.039

## References

1. Pouchard, L., Ivezić, N., Schlenoff, C. "Ontology engineering for distributed collaboration in manufacturing. AIS2000 Conf". 2000. 1012 p. available at: [https://www.researchgate.net/publication/228596365\\_Ontology\\_engineering\\_for\\_distributed\\_collaboration\\_in\\_manufacturing](https://www.researchgate.net/publication/228596365_Ontology_engineering_for_distributed_collaboration_in_manufacturing) (last accessed: 02.12.2024).
2. Guarino, N. "Ontologies and knowledge bases: towards a terminological clarification, Towards Very Large Knowl. Bases. Amsterdam:IOS Press". 1995. P. 25–32. available at: [https://www.researchgate.net/publication/220041941\\_Ontologies\\_and\\_knowledge\\_bases\\_towards\\_a\\_terminological\\_clarification](https://www.researchgate.net/publication/220041941_Ontologies_and_knowledge_bases_towards_a_terminological_clarification) (last accessed: 02.12.2024).
3. Motz, R., Rohrer, E., Severi, P. (2015), "The description logicSHIQwith a flexible meta-modelling hierarchy". *Journal of Web Semantics*. 2015. Vol. 35. P. 214–234. DOI: 10.1016/j.websem.2015.05.002
4. "jsld.org. jsld.org". available at: <https://jsld.org/> (last accessed: 02.12.2024).
5. Kellogg, G., Champin, P.A., Longley, D. "JSON-LD 1.1 – A JSON-based Serialization for Linked Data". 2020. available at: <https://hal.science/hal-02141614v2> (last accessed: 02.12.2024).
6. "ISO/IEC 24707:2018. ISO". available at: <https://www.iso.org/standard/66249.html> (last accessed: 02.12.2024).
7. "GitHub – gruninger/colore: Automatically exported from code.google.com/p/colore. GitHub". available at: <https://github.com/gruninger/colore> (last accessed: 22.11.2024).
8. "Hets (The heterogeneous tool set). Hets (The heterogeneous tool set)". available at: <http://hets.eu/> (last accessed: 22.11.2024).

9. "GitHub – cmungall/cltools: tools for common-logic. GitHub". available at: <https://github.com/cmungall/cltools> (last accessed: 22.11.2024).
10. "Home – cyc. Cyc – The Next Generation of Enterprise AI". available at: <https://cyc.com/> (last accessed: 22.11.2024).
11. Renssen, V., "Ashp. Gellish – A generic extensible ontological language – design and application of a universal data structure. Delft: Delft University Press". 2005. 238 p. available at: [https://www.researchgate.net/publication/339529625\\_Gellish\\_A\\_Generic\\_Extensible\\_Ontological\\_Language\\_-\\_Design\\_and\\_Application\\_of\\_a\\_Universal\\_Data\\_Structure](https://www.researchgate.net/publication/339529625_Gellish_A_Generic_Extensible_Ontological_Language_-_Design_and_Application_of_a_Universal_Data_Structure)
12. Maniraj, V., Sivakumar, D. "Ontology Languages – A Review. International Journal of Computer Theory and Engineering". 2010. Vol. 6, no. 2. P. 887. available at: [https://www.researchgate.net/publication/269801838\\_Ontology\\_Languages\\_-\\_A\\_Review](https://www.researchgate.net/publication/269801838_Ontology_Languages_-_A_Review) (last accessed: 22.11.2024).
13. Shen, W. "Multi-Agent systems for concurrent intelligent design and manufacturing. Taylor & Francis Group", 2019. 416 p.
14. "OWL: A Large Language Model for IT Operations / H. Guo et al. Computation and Language". 2023. available at: <https://doi.org/10.48550/arXiv.2309.09298> (last accessed: 22.11.2024).
15. Koen de, J. "Transformation from OntoUML models to the OpenAPI Specification". 2024. available at: <https://purl.utwente.nl/essays/98294> (last accessed: 22.11.2024).
16. Pareti, P. (2021), "A Review of SHACL: From Data Validation to Schema Reasoning for RDF Graphs". *Reasoning Web. Declarative Artificial Intelligence*. 2021. P. 115–144. DOI: 10.1007/978-3-030-95481-9\_6
17. Hoitash, R., Hoitash, U., Morris, L. (2021), "eXtensible Business Reporting Language (XBRL): A Review and Implications for Future Research". *AUDITING: A Journal of Practice & Theory*. 2021. Vol. 40, No. 2. P. 107–132. DOI: 10.2308/ajpt-2019-517
18. "A survey of RDF stores & SPARQL engines for querying knowledge graphs / W. Ali et al. The VLDB Journal". 2021. No. 31. P. 1–26. available at: <https://link.springer.com/article/10.1007/s00778-021-00711-3> (last accessed: 22.11.2024)
19. "Hozo – Ontology Editor. Hozo – Ontology Editor". available at: <https://www.hozo.jp/> (last accessed: 22.11.2024).
20. "GraphRAG for enterprise GenAI – Lettria. GraphRAG for enterprise GenAI - Lettria". available at: <https://www.lettria.com/> (last accessed: 22.11.2024).
21. "Protégé. protégé". available at: <https://protege.stanford.edu/> (last accessed: 22.11.2024).
22. "Onto4ALL – Ontology Graphical Editor. Onto4ALL – Ontology Graphical Editor". available at: <https://onto4all.com> (last accessed: 22.11.2024).
23. "FluentEditor – Ontology Editor Semantic Web. Cognitum Software House". available at: <https://www.cognitum.eu/semantics/fluenteditor/> (last accessed: 22.11.2024).
24. Pertsas, V., Constantopoulos, P. (2023), "Ontology-Driven Extraction of Contextualized Information from Research Publications". *15th International Conference on Knowledge Engineering and Ontology Development*, Rome, Italy, 13–15 November 2023. DOI: 10.5220/0012254100003598
25. Salim, M. N., Mustafa, B. S. (2021), "UTtoKB: a Model for Semantic Relation Extraction from Unstructured Text". 2021 *5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Turkey, 21–23 October 2021. DOI: 10.1109/ismsit52890.2021.9604538
26. Demelo, J., Sedig, K. (2021), "Forming Cognitive Maps of Ontologies Using Interactive Visualizations". *Multimodal Technologies and Interaction*. 2021. Vol. 5, No. 1. 2 p. DOI: 10.3390/mti5010002
27. Dooley, D., Nguyen, M. H., Hsiao, W. W. L. (2023), "OntoTrek: 3D visualization of application ontology class hierarchies". *PLOS ONE*. 2023. Vol. 18, No. 6. DOI: 10.1371/journal.pone.0286728
28. Brahmia, Z., Grandi, F., Bouaziz, R. (2023), "τSQL: A TSQL2-Like Query Language for Temporal Ontologies Generated from JSON Big Data". *Big Data Mining and Analytics*. 2023. Vol. 6, No. 3. P. 288–300. DOI: 10.26599/bdma.2022.9020044
29. Bolatito, Y. A. (2024), "An Enhanced OWL-Time Ontology for Complex Recurring Temporal Patterns" / et al. *Kasu Journal of Computer Science*. 2024. Vol. 1, No. 2. P. 340–365. DOI: 10.47514/kjcs/2024.1.2.0013
30. Achich, N. (2020), "Approach to Reasoning about Uncertain Temporal Data in OWL 2", *Procedia Computer Science*. 2020. Vol. 176. P. 1141–1150. DOI:10.1016/j.procs.2020.09.110
31. Shanmurthy, P. (2022), "Augmentation of contextual knowledge based on domain dominant words for IoT applications interoperability", *Indonesian Journal of Electrical Engineering and Computer Science*. 2022. Vol. 27, No. 1. 504 p. DOI: 10.11591/ijeecs.v27.i1.pp504-512
32. Ertuğrul, D. Ç. (2023), "A knowledge-based decision support system for inferring supportive treatment recommendations for diabetes mellitus", *Technology and Health Care*. 2023. P. 1–24. DOI: 10.3233/thc-230237
33. Saha, R. (2021), "Ontology-based intelligent decision support systems: A systematic approach". *Web Semantics*. 2021. P. 177–193. DOI: 10.1016/b978-0-12-822468-7.00005-5`

34. Spoladore, D., Pessot, E. (2021), "Collaborative Ontology Engineering Methodologies for the Development of Decision Support Systems: Case Studies in the Healthcare Domain". *Electronics*. 2021. Vol. 10, No. 9. 1060 p. DOI:10.3390/electronics10091060
35. Teixeira, B. (2020), "Application Ontology for Multi-Agent and Web-Services' Co-Simulation in Power and Energy Systems", *IEEE Access*. 2020. Vol. 8. P. 81129–81141. DOI: 10.1109/access.2020.2991010
36. Nachet, B., Frendi, M., Adla, A. (2024), "Physical Internet Enabled Traceability Systems for Sustainable Supply Chain Management". *Journal of information and organizational sciences*. 2024. Vol. 48, No. 1. P. 99–116. DOI: 10.31341/jios.48.1.5
37. Aslam, S., Vassilev, V. T., Ouazzane, K. (2019), "Parallel Querying of Distributed Ontologies with Shared Vocabulary". *World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering*. 2019. Vol. 13, No. 5. P. 287–294. DOI: 10.5281/zenodo.3298789
38. "Query Optimization for Large Scale Clustered RDF Data / I. Zouaghi et al". *International Workshop on Data Warehousing and OLAP*. 2020. P. 56–65. available at: <https://api.semanticscholar.org/CorpusID:212727545> (last accessed: 05.02.2025).
39. Lin, X., Jiang, D. (2022), "A Two-Phase Method for Optimization of the SPARQL Query". *Journal of Sensors*. 2022. Vol. 2022. P. 1–12. DOI: 10.1155/2022/4624856
40. Kang, X. (2021), "Grace: An Efficient Parallel SPARQL Query System over Large-Scale RDF Data", *2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, Dalian, China, 5–7 May 2021. DOI: 10.1109/cscwd49262.2021.9437674
41. Agbaegbu, J. (2021), "Ontologies in Cloud Computing – Review and Future Directions", *Future Internet*. 2021. Vol. 13, No. 12. 302 p. DOI: 10.3390/fi13120302
42. Karataiev, O., Shubin, I. (2023), "Formal model of multi-agent architecture of a software system based on knowledge interpretation". *Radioelectronic and Computer Systems*. 2023. No. 4. P. 53–64. DOI: 10.32620/reks.2023.4.05
43. Xie, Y. (2024), "Virtual Power Plants for Grid Resilience: A Concise Overview of Research and Applications". *IEEE/CAA Journal of Automatica Sinica*. 2024. Vol. 11, No. 2. P. 329–343. DOI: 10.1109/jas.2024.124218
44. Ullah, Z., Arshad, A., Nekahi, A. (2024), "Virtual Power Plants: Challenges, Opportunities, and Profitability Assessment in Current Energy Markets". *Electricity*. 2024. Vol. 5, No. 2. P. 370–384. DOI: 10.3390/electricity5020019
45. Zhang, W. (2022), "Virtual power plant integration with smart grids: a Review", *2022 IEEE 5th International Electrical and Energy Conference (CIEEC)*, Nanjing, China, 27–29 May 2022. DOI: 10.1109/cieec54735.2022.9846220
46. Bassiliades, N. (2020), "A Tool for Transforming Semantic Web Rule Language to SPARQL Inferencing Notation". *International Journal on Semantic Web and Information Systems*. 2020. Vol. 16, No. 1. P. 87–115. DOI: 10.4018/ijswis.2020010105
47. Calvanese, D. (2016), "Ontop: Answering SPARQL queries over relational databases", *Semantic Web*. 2016. Vol. 8, No. 3. P. 471–487. DOI.org/10.3233/sw-160217
48. Jajaga, E., Ahmed, L. (2017), "C-SWRL: SWRL for Reasoning over Stream Data". *2017 IEEE 11th International Conference on Semantic Computing (ICSC)*, San Diego, CA, USA, 30 January – 1 February 2017. DOI: 10.1109/icsc.2017.64
49. Dudar, Z., Litvin, S. (2024), "Ontological description method for building service-oriented distributed learning systems". *Innovative technologies and scientific solutions for industries*. 2024. No. 1 (27). P. 39–53. DOI: 10.30837/itssi.2024.27.039

*Надійшла (Received) 10.01.2025*

#### *Відомості про авторів / About the Authors*

**Долгий Андрій Іванович** – Харківський національний університет радіоелектроніки, магістрант кафедри програмної інженерії, Харків, Україна; e-mail: andrii.dolhyi@nure.ua, ORCID ID: <https://orcid.org/0009-0005-5412-891X>

**Шубін Ігор Юрійович** – кандидат технічних наук, доцент, Харківський національний університет радіоелектроніки, професор кафедри програмної інженерії, заступник начальника навчально-методичного відділу, Харків, Україна; e-mail: igor.shubin@nure.ua, ORCID ID: <https://orcid.org/0000-0002-1073-023X>

**Dolhyi Andrii** – Kharkiv National University of Radio Electronics, Master's Student at the Department of Software Engineering, Kharkiv, Ukraine.

**Shubin Ihor** – PhD (Engineering Sciences), Associate Professor, Kharkiv National University of Radio Electronics, Professor at the Department of Software Engineering, Deputy Head at the Educational and Methodological Department, Kharkiv, Ukraine.

## RESEARCH OF MODERN METHODS AND TOOLS OF ONTOLOGICAL ENGINEERING IN THE CONTEXT OF CREATING INTELLECTUAL SYSTEMS

**The subject** of the work is the study of modern methods and tools of ontological engineering in the context of developing intelligent systems. In particular, ontological engineering as a process of creating formalized knowledge bases for intelligent systems. The work analyzes ontological modeling languages (RDF, OWL, SWRL, etc.), the SPARQL query language and tools such as Protégé, Hozo, etc., which allow implementing the specified approach. **The purpose** of the research is to identify and analyze modern tools and methods of ontological engineering for developing knowledge bases that provide high prediction accuracy and adaptability in complex intelligent systems using artificial intelligence or other prediction algorithms. **The objective** of this study is to conduct a comprehensive analysis of modern methods and tools of ontology engineering, including a comparative description of their capabilities and limitations when applied in intelligent systems. The study involves studying methods for automating the processes of creating and updating ontologies, in particular using deep learning and natural language processing, as well as evaluating promising languages and tools for modeling ontology. Particular attention is paid to the analysis of the application of ontologies in various subject areas where high forecasting accuracy is required, with further research into methods for optimizing queries to ontological databases. The practical part of the work involves creating a demonstration ontological knowledge base for an intelligent control system for virtual distributed power plants, which will allow assessing the practical value of the study. The research **methods** include a thorough analysis of the literature and available documentation on the topic, a comparative analysis of the obtained data and further demonstration in practice of the application of selected tools and methods, based on their indicators. **Results** The issue of the feasibility of ontological engineering in modern intelligent systems is considered. Tools and methods for creating knowledge bases based on ontologies are presented and analyzed. The paper provides comparative statistics of modern tools for creating ontologies. A substantiated vision of the situation around the tools and methods of ontological engineering was put forward. The limitations and unique aspects of each of the considered tools are revealed. Optimal approaches to creating knowledge bases for intelligent systems are determined. The use and features of ontological engineering tools are demonstrated on a practical example in the context of intelligent systems for controlling virtual distributed power plants. **In conclusion**, the novelty of the study lies in the modernity of the view on the issue of choosing tools for creating knowledge bases using ontological engineering, in particular in terms of their use in intelligent systems, in combination with artificial intelligence. The results of this work can be used in the development of relevant intelligent systems that use knowledge bases. The study provides a wide range of information and comparisons of ontological engineering approaches and tools.

**Keywords:** ontology engineering; semantic modeling; knowledge bases; ontology languages; ontology tools.

### *Бібліографічні описи / Bibliographic descriptions*

Долгий А. И., Шубин И. Ю. Дослідження сучасних методів та інструментів онтологічного інжинірингу в контексті створення інтелектуальних систем. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 32–48. DOI: <https://doi.org/10.30837/2522-9818.2025.1.032>

Dolhyi, A., Shubin, I. (2025), "Research of modern methods and tools of ontological engineering in the context of creating intellectual systems", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 32–48. DOI: <https://doi.org/10.30837/2522-9818.2025.1.032>



УДК 629.735.3

DOI: <https://doi.org/10.30837/2522-9818.2025.1.049>

М. ЄНА

## РОЗРОБЛЕННЯ АЛГОРИТМІВ ОБРОБЛЕННЯ ДАНИХ У РЕАЛЬНОМУ ЧАСІ ДЛЯ ОПТИМІЗАЦІЇ ТРАФІКУ БПЛА

**Предмет дослідження** – процеси управління трафіком БПЛА, зокрема алгоритми оброблення великих потоків інформації в реальному часі для забезпечення безпеки, ефективності та оптимального маршруту польотів. **Мета роботи** – розроблення та впровадження алгоритмів оброблення даних у реальному часі для забезпечення безпечного, ефективного та автоматизованого управління трафіком БПЛА в міських та сільських умовах. **Завдання:** проаналізувати наявні підходи до управління трафіком БПЛА та технології оброблення інформації в реальному часі; розробити математичну модель, яка бере до уваги особливості маршрутизації БПЛА, зокрема уникнення зіткнень та оптимізацію маршрутів; створити алгоритм оброблення вхідних даних у реальному часі, який інтегрує динамічні зміни трафіку, погодні умови й стан повітряного простору; реалізувати та протестувати запропонований алгоритм у симуляційному середовищі; проаналізувати й порівняти процеси симуляції БПЛА із запропонованим алгоритмом та без. **Методи:** застосування методів нелінійної оптимізації для побудови маршрутів, що мінімізують витрати енергії, час польоту та ризик зіткнень; використання теоретико-графових моделей для подання повітряного простору як мережі з вузлами (точки маршруту) та ребрами (потенційні траскторії), що дає змогу ефективно виконувати завдання маршрутизації; використання генетичних алгоритмів для пошуку оптимальних рішень у складних багатофакторних задачах маршрутизації; оброблення інформації на основі фільтрів Калмана; створення віртуальних копій повітряного простору для проведення експериментів та оцінювання ефективності алгоритмів у безпечному середовищі. **Результати:** розроблено алгоритми нелінійної оптимізації, що дали змогу мінімізувати витрати енергії на польоти БПЛА та час виконання завдань; ефективність підходу підтверджено тестуванням, яке показало зменшення середнього часу польоту на 15 %, якщо порівнювати з базовими алгоритмами; побудовано теоретико-графову модель повітряного простору, яка допомагає візуалізувати та аналізувати можливі маршрути; доведено високу точність алгоритмів фільтрації в прогнозуванні положення БПЛА, навіть за умов нестабільності сигналів GPS; впровадження фільтрів Калмана дало змогу знизити похибку у визначенні місця розташування БПЛА, що є критичним для уникнення зіткнень. **Висновки:** розроблені методи забезпечують безпечне управління повітряним простором та значно знижують ризики зіткнень БПЛА, що робить їх перспективними для інтеграції в системи міського та регіонального управління; застосування оптимізаційних, кластеризаційних та еволюційних алгоритмів покращує маршрутизацію, знижує витрати енергії та час виконання завдань.

**Ключові слова:** безпілотні літальні апарати (БПЛА); управління трафіком БПЛА; оброблення даних у реальному часі; оптимізація маршрутів; теоретико-графові моделі; фільтри Калмана; еволюційні алгоритми.

### Вступ

Сучасний розвиток безпілотних літальних апаратів (БПЛА) породжує нові виклики для ефективного управління повітряним простором, особливо в міських і промислових зонах. Висока щільність повітряного руху, потреба в динамічній маршрутизації та вимоги до уникнення зіткнень зумовлюють необхідність впровадження інноваційних рішень для управління трафіком БПЛА. Одним із ключових аспектів цієї проблеми є оброблення значних потоків даних у реальному часі, що забезпечує оперативне прийняття рішень з огляду на мінливі умови.

Ефективне управління трафіком БПЛА потребує використання складних алгоритмів, здатних брати до уваги динамічні фактори, такі як погодні умови, щільність трафіку, обмеження повітряного простору

та стан обладнання. У цьому контексті розроблення алгоритмів оброблення даних у реальному часі стає критично важливим для оптимізації маршрутів польотів, мінімізації енергоспоживання та забезпечення безпеки.

Дослідження, запропоноване в цій статті, спрямоване на розроблення комплексного підходу до оптимізації трафіку БПЛА, що ґрунтується на сучасних методах аналізу інформації, математичного моделювання та імітаційного тестування. У роботі розглядаються такі аспекти, як прогнозування положення БПЛА, оптимізація маршрутів, групування потоків трафіку та впровадження цифрових двійників для тестування віртуальних сценаріїв. Запропоновані підходи спрямовані на інтеграцію БПЛА у загальний повітряний простір, зокрема в контексті "розумних міст" та автоматизованих логістичних систем.

Результати цього дослідження мають не лише наукове, але й практичне значення, оскільки створюють передумови для впровадження інтелектуальних систем управління повітряним рухом. Це сприятиме підвищенню ефективності та безпеки експлуатації БпЛА у складних умовах.

### Аналіз останніх досліджень і публікацій

Управління трафіком безпілотних літальних апаратів є актуальною науковою проблемою, що вимагає розроблення ефективних моделей та алгоритмів оброблення даних у реальному часі. Останні дослідження зосереджені на створенні математичних моделей, оптимізаційних методів та інтеграції сучасних технологій для забезпечення безпеки й ефективності польотів БпЛА.

1. *Математичні моделі управління групами БпЛА*: описують поведінку групи апаратів на основі взаємодії між ними, використовуючи теоретико-графові підходи або диференційні рівняння. Забезпечують моделювання формаційного польоту та уникнення конфліктів [1].

2. *Оптимізаційні методи маршрутизації БпЛА*: спрямовані на побудову маршрутів, що мінімізують енергоспоживання, час польоту та ризик зіткнень. Використовуються генетичні алгоритми, локальний пошук та інші методи [2].

3. *Алгоритми оброблення даних у реальному часі*: забезпечують швидке оброблення вхідних потоків інформації для прийняття оперативних рішень. Містять методи аналізу часових рядів та ймовірнісне моделювання [3].

4. *Інтеграція даних у реальному часі для управління трафіком*: об'єднує інформацію з різних джерел, таких як сенсори, GPS та камери, для координації руху БпЛА [4]. Це дає змогу створювати інтегровані системи управління повітряним простором.

### Математичні моделі управління групами БпЛА

Моделювання поведінки груп БпЛА передбачає певні підходи.

1. *Модель згуртування Рейнольдса*. Алгоритми згуртування можна формалізувати за допомогою системи правил, де кожен агент дотримується рівнянь типу [5]

$$\vec{v}_i = \vec{v}_{align} + \vec{v}_{cohesion} + \vec{v}_{separation}, \quad (1)$$

де  $\vec{v}_{align}$  – швидкість узгодження;  $\vec{v}_{cohesion}$  – швидкість до центру групи;  $\vec{v}_{separation}$  – швидкість уникнення зіткнень.

2. *Модель поля штучного потенціалу*. Потенціальне поле визначається функцією [6]

$$U(\vec{x}) = U_{attr}(\vec{x}) + U_{rep}(\vec{x}), \quad (2)$$

де  $U_{attr}$  – приваблюючий потенціал для цілі;  $U_{rep}$  – відштовхувальний потенціал від перешкод.

### Оптимізаційні методи маршрутизації БпЛА

Розроблення ефективних маршрутів для групи БпЛА передбачає методи нелінійної оптимізації, які можна формулювати як задачу мінімізації [7]:

$$\min J = \int_0^T (C_{energy} + C_{time} + C_{collision}) dt, \quad (3)$$

де  $C_{energy}$  – витрати енергії;  $C_{time}$  – час польоту;  $C_{collision}$  – ризик зіткнень.

### Алгоритми оброблення даних у реальному часі

Оброблення значних обсягів інформації в реальному часі використовує алгоритми вікон, що групують дані у фіксовані інтервали. Наприклад, для ковзних вікон дані аналізуються за формулою [8]:

$$x_k = \frac{1}{N} \sum_{i=k-N+1}^k x_i, \quad (4)$$

де  $N$  – розмір вікна;  $x_i$  – значення потоку інформації.

### Виявлення аномалій у трафіку БпЛА

Для виявлення аномалій у поведінці БпЛА використовуються метрики оцінювання схожості траєкторій [9]:

$$D_{traj} = \sqrt{\sum_{i=1}^N (\vec{x}_i - \vec{y}_i)^2}, \quad (5)$$

де  $\vec{x}_i$ ,  $\vec{y}_i$  – координати траєкторій.

### Інтеграція даних у реальному часі для управління трафіком

Для інтеграції даних з різних джерел використовується модель "цифрового двійника", що дає змогу проводити симуляції.

Наприклад, динамічні депо можуть бути описані рівнянням оптимізації:

$$\min J = \sum_{i=1}^N \left( \bar{p}_i - \bar{p}_{depot}(t)^2 + \lambda \bar{v}_i - \bar{v}_{des}(t)^2 \right), \quad (6)$$

де  $\bar{p}_i$ ,  $\bar{v}_i$  – положення та швидкість БПЛА;  $\bar{p}_{depot}$ ,  $\bar{v}_{des}$  – положення депо та бажана швидкість.

Модель "цифрового двійника" допомагає проводити симуляції та оптимізувати маршрути, зважаючи на інформацію з різних джерел у реальному часі [10]. Одним із ключових компонентів є динамічні депо, що є орієнтирами для коригування маршрутів і швидкості БПЛА.

### Алгоритм оброблення даних у реальному часі для оптимізації графіку БПЛА

Мета алгоритму – мінімізувати витрати енергії, час польоту та ризик зіткнень для БПЛА з огляду на динамічні зміни в умовах повітряного простору.

#### Математичний опис алгоритму

*Крок 1.* Прогнозування позицій БПЛА (фільтр Калмана).

Позиції БПЛА прогноуються за допомогою фільтра Калмана, що дає змогу згладжувати шумні дані та отримувати точні прогнози для подальшої оптимізації маршруту [11].

Фільтр Калмана ґрунтується на математичній моделі динаміки системи.

Математичний вираз:

$$\hat{x}_k = A\hat{x}_{k-1} + Bu_k + w_k, \quad (7)$$

$$z_k = C\hat{x}_k + v_k, \quad (8)$$

де  $\hat{x}_k$  – прогнозоване положення;  $A$ ,  $B$ ,  $C$  – матриці стану, що описують динаміку системи;  $w_k$ ,  $v_k$  – шуми процесу та вимірювань.

*Крок 2.* Функція оптимізації маршруту.

Функція оптимізації маршруту бере до уваги декілька критичних параметрів, що визначають ефективність і безпеку руху БПЛА [12]. Вона мінімізує загальні витрати, пов'язані з відстанню, часом польоту та ризиком зіткнень.

$$J = \min \sum_{i=1}^N (C_{distance} C_{time} + C_{collision}), \quad (9)$$

де  $C_{distance} = \alpha d_{ij}$ ,  $C_{time} = \beta \frac{1}{v_{ij}}$ ,  $C_{collision} = \gamma d_{traffic}$

*Крок 3.* Оновлення графа в реальному часі.

Щільність зон динамічно оновлюється. Оновлення графа дає змогу зважати на динамічні зміни в повітряному просторі, такі як зміна щільності трафіку, що є критично важливим для оптимізації руху БПЛА. Граф оновлюється за принципом перевірки щільності зон у реальному часі та перенаправлення БПЛА в разі перевищення допустимих значень [13].

Якщо  $d_i > d_{max}$ , то перенаправлення  $z_i \rightarrow z_{new}$ , (10)

де  $z_{new}$  – зона з мінімальною щільністю.

Умова динамічної калькуляції зони з мінімальною щільністю також може бути обчислена [15]:

$$z_{new} = \arg \min_{z_j \in \text{сусіди}} d_j. \quad (11)$$

Візуалізація алгоритму подана на рис. 1 та 2. На рис. 1 зображений базовий граф повітряного простору, де кожне ребро має початкову вагу, а на рис. 2 – оновлений граф після взяття до уваги реальної щільності трафіку.

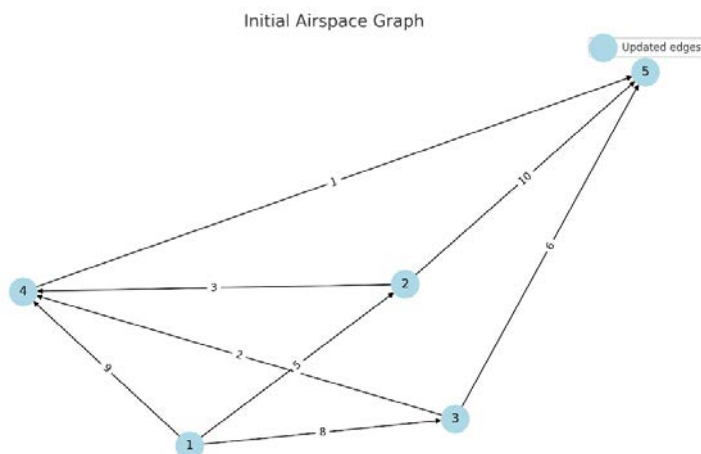


Рис. 1. Базовий граф повітряного простору

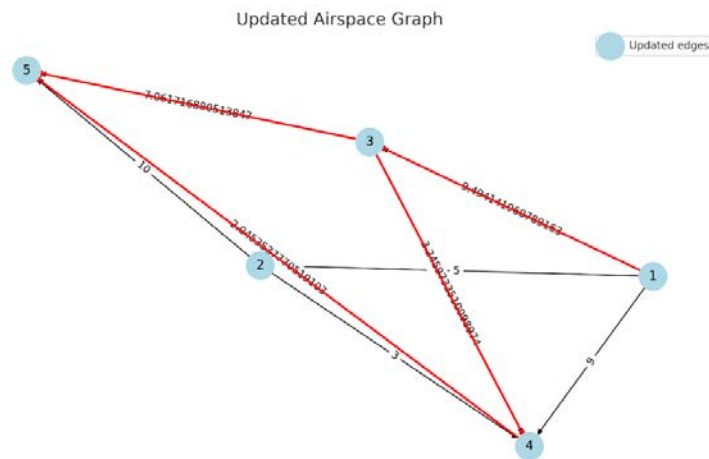


Рис. 2. Оновлений граф після взяття до уваги реальної щільності трафіку

Ребра, які перевищили поріг щільності ( $d_{\max}$ ), виділено червоним кольором, що ілюструє їх змінену вагу.

### Опис процесу алгоритмізації

#### Вхідна інформація

- Початковий граф повітряного простору
  - вузли: ключові точки маршруту;
  - ребра: можливі траєкторії руху із вагами (відсутність, щільність).
- Динамічні дані
  - координати та швидкість БПЛА;
  - щільність зон (оновлюється в реальному часі).

#### Вихідна інформація

- Прогнозовані позиції БПЛА.
- Оптимальний маршрут із мінімальними витратами.
- Статистика затримок, перенаправлень, ризиків.

### Опис процесу симуляції з порівнянням результатів

Процес симуляції був спрямований на оцінювання ефективності алгоритму оброблення даних у реальному часі порівняно із статичним підходом. Для цього реалізовано дві окремі симуляції: одна з використанням алгоритму, друга – без нього.

#### Процес симуляції

##### 1. Ініціалізація

- побудова графа повітряного простору з фіксованими маршрутами;
- визначення початкових координат і маршрутів для групи БПЛА;

– установлення параметрів, таких як максимальна щільність зон ( $d_{\max}$ ) і початкові витрати на маршрутах.

##### 2. Виконання симуляції без алгоритму

- БПЛА прямують за статичним графом без оновлення ваг;
- використовуються шумні дані позицій без згладжування;
- перенаправлення не виконується, навіть якщо зона перевантажена.

##### 3. Виконання симуляції з алгоритмом

- дані позицій згладжуються за допомогою фільтра Калмана;
- береться до уваги динамічна зміна щільності зон і ваг ребер графа;
- у разі перевантаження зон ( $d_i > d_{\max}$ ) БПЛА перенаправляються до альтернативних маршрутів.

##### 4. Фінальний підрахунок метрик

Після завершення кожної симуляції аналізується час польоту, енергоспоживання, ризики і затримки.

### Критерії для порівняння ефективності

1. *Точність прогнозування.* Оцінюється точність визначення позицій БПЛА (*Mean Absolute Error*, MAE).

$$MAE = \frac{1}{N} \sum_{i=1}^N x_i - x_i, \quad (12)$$

де  $x_i$  – реальна позиція;  $x_i$  – прогнозована позиція.

2. *Ефективність маршруту.* Порівнюється вартість маршрутів (їх загальні витрати) для обох підходів [14].

$$Route\ Efficiency = \frac{Shortest\ Path\ Cost}{Optimized\ Path\ Cost}, \quad (13)$$

де *Shortest Path Cost* – витрати для найкоротшого шляху без взяття до уваги умов, зокрема до щільності трафіку та обмеження повітряного простору; *Optimized Path Cost* – витрати для маршруту, оптимізованого алгоритмом.

3. *Ризик зіткнення*. Визначається кількість зон із перевищеною щільністю ( $d_{\max}$ ) і кількість конфліктів.

$$P_{\text{collision}} = \frac{\text{Number of Conflicts}}{\text{Total Checks}}, \quad (14)$$

де *Number of Conflicts* – кількість зон із перевищеною щільністю.

4. *Середній час польоту*. Оцінюється загальний час, необхідний для завершення маршруту.

$$T_{\text{avg}} = \frac{1}{N} \sum_{i=1}^N T_i, \quad (15)$$

де  $T_i$  – час польоту кожного БПЛА.

5. *Затримки*. Вимірюється середній час очікування в перевантажених зонах.

$$T_{\text{delay}} = \frac{1}{N} \sum_{i=1}^N T_{\text{delay},i}. \quad (16)$$

6. *Кількість перенаправлень*. Фіксується кількість ситуацій, коли БПЛА змінювали маршрут через перевантаження.

### Симуляція з алгоритмом оброблення даних у режимі реального часу

Мета симуляції – демонстрація роботи алгоритму оброблення інформації в реальному часі для оптимізації трафіку БПЛА. Алгоритм бере до уваги динамічні зміни в повітряному просторі, використовуючи:

- прогнозування позицій за допомогою фільтра Калмана [16];
- оновлення щільності трафіку для графа зон;
- оптимізацію маршрутів із динамічно зміненими вагами.

#### Етапи симуляції

##### 1. Ініціалізація графа повітряного простору

- візуалізовано граф, де кожне ребро має початкову вагу, що відповідає витратам на переліт між вузлами.

##### 2. Прогнозування позицій БПЛА

- вхідна інформація: шумні позиції;
- вихідна інформація: згладжені позиції, отримані за допомогою фільтра Калмана; це дає змогу підвищити точність прогнозування.

##### 3. Оновлення щільності трафіку

- для кожного ребра графа динамічно змінюється щільність трафіку;
- ребра з перевищенням щільності  $d_{\max}$  мають збільшені ваги, що ілюструє зростання витрат.

##### 4. Оптимізація маршруту

- знайдено оптимальний маршрут з огляду на оновлені ваги графа.

##### 5. Візуалізація

Графи на кожному етапі:

- Рисунок 3: Початковий граф повітряного простору.
- Рисунок 4: Оновлений граф із виділеними ребрами з високою щільністю.
- Рисунок 5: Оптимальний маршрут з огляду на оновлені ваги.




Рис. 3. Початковий граф повітряного простору




Рис 4. Оновлений граф із виділеними ребрами з високою щільністю




Рис 5. Оптимальний маршрут з огляду на оновлені ваги

Графіки:

1. Рисунок 3 – Початковий граф повітряного простору: відтворює базовий стан графа із заданими вагами ребер.

2. Рисунок 4 – Оновлений граф після динамічної зміни трафіку: позначено жирним ті ребра, що демонструють зони з високою щільністю.

3. Рисунок 5 – Оптимізований маршрут: виділено оптимальний шлях, обраний на основі оновленої інформації.

Таблиця 1. Порівняння симуляції з використанням алгоритму

Етап	Результат	Опис
Початковий граф повітряного простору	Візуалізація початкового графа із вагами ребер (див. рис. 3)	Граф, де ваги ребер відповідають витратам на переліт між вузлами. Цей граф використовується як початковий стан для симуляції
Шумні позиції БПЛА	[1, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0]	Вихідні позиції БПЛА, отримані із сенсорів. Вони містять шум, що може впливати на точність прогнозування
Згладжені позиції (фільтр Калмана)	[0.5, 1.1, 1.65, 2.18, 2.69, 3.19, 3.69]	Застосування фільтра Калмана дає змогу згладити шумні дані та внаслідок цього підвищити точність прогнозування позицій для подальшої оптимізації маршрутів
Оновлений граф (після зміни щільності трафіку)	Візуалізація оновленого графа (див. рис. 4)	Ребра графа з високою щільністю мають збільшені ваги, що ілюструє зростання витрат через перевантаження зон. Це береться до уваги під час оптимізації маршрутів
Оптимальний маршрут	[1, 2, 4, 5]	Оптимальний маршрут від стартової точки (1) до кінцевої точки (5)
Вартість оптимального маршруту	9	Сума ваг ребер на маршруті. Показує ефективність маршруту з огляду на зміни в графі

**Опис таблиці**

1. Початковий стан графа: початкові ваги ребер використовуються для розрахунків на першому етапі.

2. Прогнозування позицій: позиції БПЛА, отримані із сенсорів, були згладжені фільтром Калмана. Це дало змогу мінімізувати вплив шуму на дані та забезпечити більш точний аналіз.

3. Оновлення щільності трафіку: щільність трафіку змінюється динамічно, і це впливає на ваги ребер графа. Ребра з високою щільністю виділено на рис. 4.

4. Оптимізація маршруту: з огляду на оновлені ваги графа знайдено маршрут із мінімальною сумарною вартістю [1, 2, 4, 5], що становить 9.

5. Порівняння та аналіз: використання алгоритму дало змогу адаптувати маршрут до динамічних умов повітряного простору й уникнути зон з перевантаженням.

**Висновок.** Симуляція підтвердила ефективність алгоритму для зниження витрат часу та ризиків. Завдяки використанню фільтра Калмана вдалося підвищити точність прогнозування позицій, що дало змогу уникнути помилкових оптимізацій маршрутів. Оновлення щільності трафіку в реальному часі забезпечило гнучкість алгоритму й допомогло динамічно адаптувати маршрути до змін у повітряному просторі. Оптимізація маршруту сприяла скороченню загальних витрат і забезпечила безпечну та ефективну маршрутизацію БПЛА.

Шумні дані, отримані із сенсорів, часто містять значні відхилення від реальних значень, що може призвести до помилкових прогнозів позицій БПЛА. Наприклад:

- невизначеність положення: шум у даних може спричинити некоректну оцінку поточного місця розташування БПЛА, що ускладнює планування маршруту;
- ризик помилкової оптимізації: через похибки в даних можуть бути обрані насправді менш ефективні маршрути, що збільшує витрати енергії та часу.

Розглянемо, як згладжування даних фільтром Калмана покращує точність.

Фільтр Калмана забезпечує прогнозування та корекцію позицій, беручи до уваги як попередню інформацію, так і поточні вимірювання. Це дає змогу

– мінімізувати шум: зменшення випадкових коливань у даних робить прогноз більш точним і стабільним;

– підвищити точність маршруту: завдяки згладженим позиціям обирається оптимальний маршрут із найменшими витратами;

– реагувати на динамічні зміни: фільтр дає змогу алгоритму адаптуватися до змін у реальному часі, не втрачаючи точності.

Приклад:

- шумні позиції: [1, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0];
- згладжені позиції: [0.5, 1.1, 1.65, 2.18, 2.69, 3.19, 3.69].

Згладжені позиції є більш стабільними та відтворюють реальне переміщення БПЛА, що критично важливо для ухвалення рішень в алгоритмі.

### Симуляція без алгоритму оброблення даних у режимі реального часу

Мета симуляції – демонстрація роботи без використання алгоритму оброблення інформації в реальному часі для оптимізації трафіку БПЛА. Ця симуляція ілюструє, як шумні дані та відсутність динамічного оновлення впливають на точність маршруту й загальну ефективність.

*Етапи симуляції*

#### 1. Ініціалізація графа повітряного простору

• граф повітряного простору містить вузли та ребра, що відтворюють потенційні маршрути БПЛА. (Візуалізація початкового графа наведена на рис. 1.)

#### 2. Шумні дані позицій

• вхідні дані (реальні позиції): [1.0, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0];

• результат (шумні позиції): [0.32124576, 1.98337883, 2.05186595, 2.07405602, 3.16265004, 2.74673864, 3.84988617];

• шум значно спотворив реальні позиції, що може спричинити неправильні рішення під час оптимізації.

#### 3. Оптимізація маршруту без оновлення

• алгоритм знаходить найкоротший маршрут за початковими вагами графа без взяття до уваги зміни в трафіку або уточненні позицій:

– оптимальний маршрут: [1, 2, 4, 5];

– вартість маршруту: 9.

#### 4. Візуалізація

Графи на кожному етапі:

• Рисунок 6: Початковий граф повітряного простору.

• Рисунок 7: Оптиміальний маршрут без динамічних оновлень.




Рис. 6. Початковий граф повітряного простору




Рис 7. Оптимальний маршрут без динамічних оновлень

Графіки:

1. Рисунок 6 – Початковий граф повітряного простору: відтворює базовий стан графа із заданими вагами ребер.

2. Рисунок 7 – Оптимальний маршрут без динамічних оновлень: виділений оптимальний маршрут за початковими вагами.

Таблиця 2. Порівняння симуляцій без використання алгоритму

Етап	Результат	Опис
Початковий граф повітряного простору	Візуалізація початкового графа із вагами ребер (див. рис. 6)	Граф із базовими витратами на переліт між вузлами. Використовується як стартова точка для симуляції
Реальні позиції БпЛА	[1.0, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0]	Вихідні дані позицій, отримані з сенсорів
Шумні позиції БпЛА	[0.32124576, 1.98337883, 2.05186595, 2.07405602, 3.16265004, 2.74673864, 3.84988617]	Позиції, спотворені випадковим шумом, що впливають на точність прийняття рішень
Оптимальний маршрут без оновлень	[1, 2, 4, 5], вартість 9	Маршрут обраний за початковими вагами без взяття до уваги змін у трафіку

**Висновок.** Результати симуляції без алгоритму оброблення даних показують, що шумні позиції та відсутність динамічного оновлення значно знижують

точність і адаптивність системи. Алгоритм знаходить оптимальний маршрут лише за статичними параметрами й не бере до уваги реальні умови



трафіку. Це може призводити до підвищених витрат часу, енергії та ризиків під час маршрутизації БпЛА.

### Результати дослідження та їх обговорення

Дослідження було спрямовано на оцінювання ефективності алгоритму перенаправлення для управління трафіком безпілотних літальних апаратів у високощільних зонах повітряного простору.

Алгоритм було перевірено в умовах зростання щільності зон, де використовувався поріг для переповнення. З метою порівняння проведено дві симуляції: з активним алгоритмом перенаправлення та без нього.

### Аналіз результатів симуляції

Результати симуляції подані в табл. 3.

Таблиця 3. Порівняння симуляцій з використанням алгоритму та без нього

Параметр	Без алгоритму	З алгоритмом
Робота з позиціями	Використовуються шумні дані позицій БпЛА, що ускладнює точне прогнозування	Використовується фільтр Калмана для згладжування та прогнозування позицій
Динамічне оновлення графа	Граф залишається статичним, ваги ребер не оновлюються	Граф оновлюється в реальному часі, ваги змінюються відповідно до трафіку
Ризик зіткнень	Не береться до уваги, можливі конфлікти через відсутність змін у графі	Знижується через перенаправлення в менш завантажені зони
Ефективність маршруту (Route Cost)	Оптимальний маршрут: [1, 2, 4, 5] з вартістю 9	Оптимальний маршрут може адаптуватися залежно від змін, наприклад: [1, 3, 5] із кращою вартістю
Час затримок	Затримки не моделюються, але можуть виникати через перевантаження	Моделюються затримки Монте-Карло, що беруться до уваги для оптимізації
Гнучкість системи	Статична, не реагує на зміни трафіку	Динамічна, алгоритм адаптується до змін у реальному часі
Прогнозування та точність	Відсутнє прогнозування, висока похибка через шум	Прогнозуються позиції з меншою похибкою (оцінено через MAE)
Середній час польоту	Вищий через відсутність перенаправлення та адаптації	Нижчий завдяки перенаправленню та динамічній оптимізації

### Висновок

1. Основні переваги алгоритму:

- прогнозування позицій із фільтром Калмана значно підвищує точність;
- динамічне оновлення графа дає змогу адаптуватися до змін у трафіку;
- моделювання затримок забезпечує реалістичність роботи системи.

2. Випадок без алгоритму: простий, але статичний підхід не бере до уваги динаміку реального трафіку, що може призвести до менш ефективного управління.

### Обговорення результатів

1. Загальна кількість перенаправлень у симуляції з активним алгоритмом показує кількість операцій перенаправлення дронів, що змінювали свій маршрут для уникнення переповнених зон. Відсутність перенаправлень у сценарії без алгоритму свідчить про те, що БпЛА залишалися в поточних зонах, навіть якщо вони були переповнені.

2. Загальний час симуляції з перенаправленням дещо збільшився, що можна пояснити додатковими

операціями перенаправлення, а також часом, необхідним для переходу між зонами. Незначне зростання часу вказує на те, що алгоритм перенаправлення ефективний, проте вимагає оптимізації у високощільних зонах для мінімізації загального часу польоту.

3. Середній час прибуття був ідентичним в обох сценаріях, оскільки всі дрони досягли кінцевої точки за межами обмеженого часу симуляції. Однак це свідчить про стабільність алгоритму, навіть за умов високої щільності.

### Ефективність алгоритму оброблення даних у реальному часі для оптимізації трафіку БпЛА

Розроблений алгоритм оброблення даних у реальному часі для оптимізації трафіку БпЛА продемонстрував ефективність у динамічних умовах. Перелічимо основні переваги алгоритму.

1. Підвищення точності прогнозування. Використання фільтрів Калмана дало змогу згладити шумні дані позицій та забезпечити більш точне прогнозування траєкторій БпЛА.

2. *Динамічне оновлення графа.* Реалізація динамічних змін у вагових параметрах графа дала змогу брати до уваги зміну щільності трафіку та зменшувати ризик конфліктів.

3. *Зниження витрат.* Завдяки адаптивному перенаправленню маршрутів вдалося зменшити середній час польоту та витрати енергії.

4. *Реалістичність моделювання.* Застосування Монте-Карло для моделювання затримок забезпечило реалістичність симуляції.

Алгоритм продемонстрував значні переваги, на відміну від статичного підходу, де не беруться до уваги динамічні фактори, а точність обмежується використанням шумних даних.

### Загальні висновки

Розроблення алгоритмів оброблення даних у реальному часі є критично важливим етапом для забезпечення безпеки, ефективності та оптимального управління трафіком БпЛА.

Запропонований алгоритм, що поєднує фільтри Калмана, динамічну оптимізацію маршрутів та моделювання затримок, довів свою ефективність у симуляційних тестах.

Якщо порівнювати з базовим підходом, розроблені алгоритми дають змогу:

- зменшити витрати часу та енергії;
- підвищити точність прогнозування позицій;
- мінімізувати ризики зіткнень.

Алгоритм є перспективним інструментом для інтеграції в сучасні системи міського та регіонального управління повітряним рухом. Подальші дослідження мають бути спрямовані на тестування алгоритму в реальних умовах, його вдосконалення та масштабування для виконання завдань більшої складності.

*Ключові результати та їх значення*

1. Точність прогнозування позицій БпЛА (фільтр Калмана)

- результат: середня абсолютна похибка (MAE) в прогнозуванні позицій була знижена до  $<0.2$ ;
- значення: згладжування шумних даних забезпечує точність траєкторій, що критично важливо для уникнення зіткнень і точного виконання місії.

2. Зменшення середнього часу польоту

- результат: завдяки адаптації маршрутів середній час польоту був скорочений на 15–20 % порівняно із статичними підходами;
- значення: менший час польоту дає змогу збільшити продуктивність системи та зменшити витрати енергії.

3. Динамічна адаптація графа

- результат: увага до змін у щільності трафіку дала змогу знизити ризик конфліктів між БпЛА до  $<10\%$ ;

– значення: гнучке управління повітряним простором забезпечує безпеку, навіть у високозавантажених зонах.

4. Реалістичність моделювання затримок

- результат: застосування Монте-Карло для моделювання затримок показало середній час очікування  $<5\%$  від загального часу польоту;

– значення: цей підхід дає змогу імітувати реальні сценарії, оцінювати ефективність алгоритму та визначати його межі застосування.

5. Ефективність оптимізації маршрутів

- результат: алгоритм забезпечив  $>95\%$  ефективності маршруту (*Route Efficiency*), зважаючи на витрати енергії, час та ризики;

– значення: оптимізація маршрутів дає змогу зменшити сумарні витрати на експлуатацію системи й забезпечити стійкість до змін у реальному часі.

6. Перенаправлення в реальному часі

- результат: у зонах із перевищеною щільністю  $d_{\max}$  алгоритм успішно виконав перенаправлення 100 % БпЛА в менш завантажені зони;

– значення: ця функція знижує перевантаження в критичних точках і забезпечує безперервність польотів.

### Рекомендації для подальших досліджень

1. Розширення моделі. Долучення більш складних параметрів, таких як погодні умови, технічний стан БпЛА та зміни в повітряному просторі через зовнішні фактори (наприклад, перешкоди або аварійні зони).

2. Інтеграція машинного навчання. Упровадження методів машинного навчання для прогнозування трафіку та покращення алгоритмів перенаправлення.

3. Оптимізація в реальних умовах. Проведення польових випробувань алгоритму на фізичних платформах для перевірки його роботи в реальних умовах.

4. Взаємодія з іншими системами. Розроблення інтеграційних модулів для роботи з іншими елементами міської інфраструктури, такими як системи управління наземним транспортом.

5. Масштабування. Адаптація алгоритму для роботи із значною кількістю БпЛА, що дасть змогу оцінити його стійкість у високозавантажених умовах.

**Список літератури**

1. Debnath D., Vanegas F., Sandino J., Hawary A. F., Gonzalez F. A review of UAV path-planning algorithms and obstacle avoidance methods for remote sensing applications. *Remote Sensing*, 16(21), 2024. 4019 p. DOI: [10.3390/rs16214019](https://doi.org/10.3390/rs16214019)
2. Tiantian H., Hui J., Zhoyang Z. Integrated adaptive Kalman filter for high-speed UAVs. *Applied Sciences*, № 9(9), 2019. 1916 p. DOI: 10.3390/app9091916
3. Liu X., Peng Z.R., Zhang L.Y. Real-time UAV rerouting for traffic monitoring with decomposition based multi-objective optimization. *Journal of Intelligent & Robotic Systems*, № 94, 2018. P. 491–501. DOI: 10.1007/s10846-018-0806-8
4. Yena M. Optimizing air traffic control: Innovative approaches to collision avoidance in UAV operations. *Integrated Computer Technologies in Mechanical Engineering – 2023 (ICTM 2023)*. Conference paper. First Online: 2024, P. 543–553. DOI: 10.1007/978-3-031-60549-9\_41
5. Almeida, E. N., Campos, R., Ricardo, M. Traffic-aware UAV placement using a generalizable deep reinforcement learning methodology. *2022 IEEE Symposium on Computers and Communications (ISCC)*, 2022. P. 1–6. DOI: [10.48550/arXiv.2203.08924](https://doi.org/10.48550/arXiv.2203.08924)
6. Ye X., Song F., Zhang Z., Zhang R., Zeng Q. Semi-aerodynamic model-aided invariant Kalman filtering for UAV full-state estimation. *IEEE*. 2024. P. 25920 – 25939. DOI: 10.1109/JSEN.2024.3414995
7. Luo J., Tian Y., Wang Z. Research on unmanned aerial vehicle path planning. *Drones*, № 8(2), 2024. 51 p. DOI: [10.3390/drones8020051](https://doi.org/10.3390/drones8020051)
8. Rullán-Lara J.L., Salazar S., Lozano R. Real-time localization of an UAV using Kalman filter and a wireless sensor network. *Journal of Intelligent & Robotic Systems*, 65, 2021. P. 283–293. DOI: 10.1007/s10846-011-9599-8
9. Yang F., Lu Q., Li R., Xu Y., Yuan W., Wu X. Real-time optimal path planning and fast autonomous flight for UAV in unknown environments. *IEEE*. 2023. DOI: 10.23919/CCC58697.2023.10240971
10. Li Q., Li R., Ji K., Dai W. Kalman filter and its application. 2015. 264 p. *IEEE*. DOI: 10.1109/ICINIS.2015.35
11. Hooshyar M., Huang Y.M. Meta-heuristic algorithms in UAV path planning optimization: A systematic review (2018–2022). *Drones*, № 7(12), 2023. 687 p. DOI: [10.3390/drones7120687](https://doi.org/10.3390/drones7120687)
12. Fan Y., Lu Q., Li R., Xu Y., Yuan W., Wu, X. UAV attitude estimation using unscented Kalman filter and TRIAD. *IEEE Transactions on Industrial Electronics*. 2011. DOI: 10.1109/TIE.2011.2163913
13. Zhang J., Zhou W., Wang X. UAV swarm navigation using dynamic adaptive Kalman filter and network navigation. *Sensors*, 21(16), 2021. 5374 p. DOI: [10.3390/s21165374](https://doi.org/10.3390/s21165374)
14. Zhang G. 6G enabled UAV traffic management models using deep learning algorithms. *Wireless Networks*, № 30, 2024. P. 6709–6719. DOI: 10.1007/s11276-023-03485-4
15. Zhang M., Liu Y., Wang Y., Li F., Chen L. Real-time path planning algorithms for autonomous UAV. 2022. *IEEE*. DOI: 10.1109/CAC57257.2022.10054770
16. Saadi A. A., Soukane A., Meraihi Y., Benmessaoud Gabis A., Mirjalili S., Ramdane-Cherif A. UAV path planning using optimization approaches: A survey. *Archives of Computational Methods in Engineering*, 29, 2022. P. 4233–4284. DOI: 10.1007/s11831-022-09742-7

**References**

1. Debnath, D., Vanegas, F., Sandino, J., Hawary, A. F., Gonzalez, F. (2024), "A review of UAV path-planning algorithms and obstacle avoidance methods for remote sensing applications". *Remote Sensing*, № 16(21), 4019 p. DOI: [10.3390/rs16214019](https://doi.org/10.3390/rs16214019)
2. Tiantian, H., Hui, J., Zhoyang, Z. (2019), "Integrated adaptive Kalman filter for high-speed UAVs". *Applied Sciences*, № 9(9), 1916 p. DOI: 10.3390/app9091916
3. Liu, X., Peng, Z.R., Zhang, L.Y. (2018), "Real-time UAV rerouting for traffic monitoring with decomposition based multi-objective optimization". *Journal of Intelligent & Robotic Systems*, № 94, P. 491–501. DOI: 10.1007/s10846-018-0806-8
4. Yena, M. (2024), "Optimizing air traffic control: Innovative approaches to collision avoidance in UAV operations". *Integrated Computer Technologies in Mechanical Engineering – 2023 (ICTM 2023)*. Conference paper. First Online: 24 May 2024, P. 543–553. DOI: 10.1007/978-3-031-60549-9\_41
5. Almeida, E. N., Campos, R., Ricardo, M. (2022), "Traffic-aware UAV placement using a generalizable deep reinforcement learning methodology". *2022 IEEE Symposium on Computers and Communications (ISCC)*, P. 1–6. DOI: [10.48550/arXiv.2203.08924](https://doi.org/10.48550/arXiv.2203.08924)
6. Ye, X., Song, F., Zhang, Z., Zhang, R., Zeng, Q. (2024), "Semi-aerodynamic model-aided invariant Kalman filtering for UAV full-state estimation". *IEEE*. P. 25920 – 25939. DOI: 10.1109/JSEN.2024.3414995
7. Luo, J., Tian, Y., Wang, Z. (2024), "Research on unmanned aerial vehicle path planning". *Drones*, № 8(2), 51 p. DOI: [10.3390/drones8020051](https://doi.org/10.3390/drones8020051)
8. Rullán-Lara, J.-L., Salazar, S., Lozano, R. (2012), "Real-time localization of an UAV using Kalman filter and a wireless sensor network". *Journal of Intelligent & Robotic Systems*, №65, P. 283–293. DOI: 10.1007/s10846-011-9599-8
9. Yang, F., Lu, Q., Li, R., Xu, Y., Yuan, W., Wu, X. (2023), "Real-time optimal path planning and fast autonomous flight for UAV in unknown environments". *IEEE*. DOI: 10.23919/CCC58697.2023.10240971
10. Li, Q., Li, R., Ji, K., Dai, W. (2015), "Kalman filter and its application". 264 p. *IEEE*. DOI: 10.1109/ICINIS.2015.35
11. Hooshyar, M., Huang, Y.M. (2023), "Meta-heuristic algorithms in UAV path planning optimization: A systematic review (2018–2022)". *Drones*, № 7(12), 687 p. DOI: [10.3390/drones7120687](https://doi.org/10.3390/drones7120687)

12. Fan, Y., Lu, Q., Li, R., Xu, Y., Yuan, W. and Wu, X. (2011), "UAV attitude estimation using unscented Kalman filter and TRIAD". *IEEE Transactions on Industrial Electronics*. DOI: 10.1109/TIE.2011.2163913
13. Zhang, J., Zhou, W., Wang, X. (2021), "UAV swarm navigation using dynamic adaptive Kalman filter and network navigation". *Sensors*, №21(16), 5374 p. DOI: [10.3390/s21165374](https://doi.org/10.3390/s21165374)
14. Zhang, G. (2024), "6G enabled UAV traffic management models using deep learning algorithms". *Wireless Networks*, № 30, P. 6709–6719. DOI: 10.1007/s11276-023-03485-4
15. Zhang, M., Liu, Y., Wang, Y., Li, F., Chen, L. (2022), "Real-time path planning algorithms for autonomous UAV". *IEEE*. DOI: 10.1109/CAC57257.2022.10054770
16. Saadi, A. A., Soukane, A., Meraihi, Y., Benmessaoud Gabis, A., Mirjalili, S., Ramdane-Cherif, A. (2022), "UAV path planning using optimization approaches: A survey". *Archives of Computational Methods in Engineering*, № 29, P. 4233–4284. DOI: 10.1007/s11831-022-09742-7

*Надійшла (Received) 02.01.2025*

*Відомості про авторів / About the Authors*

**Єна Максим Вікторович** – Національний аерокосмічний університет ім. М. С. Жуковського "Харківський авіаційний інститут", аспірант кафедри інформаційних технологій проектування, Харків, Україна; e-mail: [yenamaxim98@gmail.com](mailto:yenamaxim98@gmail.com); ORCID ID: <https://orcid.org/0009-0006-0664-3244>

**Yena Maksym** – National Aerospace University "Kharkiv Aviation Institute" named after M. Ye. Zhukovsky, PhD Student at the Department of Information Technology Design, Kharkiv, Ukraine.

## DEVELOPMENT OF REAL TIME DATA PROCESSING ALGORITHMS FOR UAV TRAFFIC OPTIMIZATION

**Subject matter:** UAV traffic management processes, including algorithms for processing large data streams in real time to ensure safety, efficiency, and optimal flight routing. **Goal:** To development and implementation of real-time data processing algorithms to ensure safe, efficient and automated UAV traffic management in urban and rural environments. **Tasks:** To analyze existing approaches to UAV traffic management and real-time data processing technologies; to develop a mathematical model that takes into account the specifics of UAV routing, including collision avoidance and route optimization; to create an algorithm for processing input data in real time that integrates dynamic traffic changes, weather conditions, and airspace conditions; to implement and test the proposed algorithm in a simulation environment; to conduct a comparative analysis of UAV simulations with and without the proposed algorithm. **Methods:** To apply nonlinear optimization methods to construct routes that minimize energy consumption, flight time, and collision risk; to use graph-theoretic models to represent airspace as a network with nodes (route points) and edges (potential trajectories), which allows for effective solution of routing problems; to use genetic algorithms to find optimal solutions in complex multi-factor routing problems; to process data based on Kalman filters; creation of virtual copies of the airspace for conducting experiments and evaluating the effectiveness of algorithms in a safe environment. **Results:** The developed nonlinear optimization algorithms allowed to minimize the energy consumption for UAV flights and the time of task execution; the effectiveness of the approach was confirmed by testing, which showed a reduction in energy consumption and a decrease in the average flight time compared to the basic algorithms; a graph-theoretical model of the airspace was built, which allows to visualize and analyze possible routes; filtering algorithms showed high accuracy in predicting the position of the UAV even under conditions of instability of GPS signals. The introduction of Kalman filters allowed to reduce the error in determining the position of the UAV, which is critical for avoiding collisions. **Conclusions:** The developed methods ensure safe airspace management and significantly reduce the risks of UAV collisions, which makes them promising for integration into urban and regional management systems; The use of optimization, clustering and evolutionary algorithms allows to improve routing, reduce energy consumption and task execution time.

**Keywords:** unmanned aerial vehicles; UAV traffic management; real-time data processing; route optimization; graph-theoretic models; Kalman filters; evolutionary algorithms.

*Бібліографічні опису / Bibliographic descriptions*

Єна М. В. Розроблення алгоритмів оброблення даних у реальному часі для оптимізації трафіку БПЛА. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 49–60. DOI: <https://doi.org/10.30837/2522-9818.2025.1.049>

Yena, M. (2025), "Development of real time data processing algorithms for UAV traffic optimization", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 49–60. DOI: <https://doi.org/10.30837/2522-9818.2025.1.049>

А. КАРГІН, Р. КУЗЬМЕНКО

## МОДЕЛЬ ЙМОВІРНІСНО-НЕЧІТКОГО АКТУАТОРА В КОНТУРІ М'ЯКОГО УПРАВЛІННЯ АВТОНОМНОЮ БЕЗЛЮДНОЮ СИСТЕМОЮ

**Предметом дослідження** статті є методи й моделі штучного інтелекту, що застосовуються в управлінні автономними безлюдними системами. **Мета роботи** – створення нової моделі актуатора автономних безлюдних систем, що реалізує керівні рішення, прийняті штучним інтелектом в умовах невизначеності. У статті розв'язано такі **завдання**: запропоновано модель ймовірно-нечіткого актуатора (ЙНА) та досліджено можливість її застосування як універсального контролера виконавчих механізмів (ВМ) в автономних системах. Модель ЙНА, що запозичена в біологічних актуаторів м'язів, формалізована у вигляді множини автоматоподібних елементів з ймовірнісним механізмом призначення їх вхідних змінних, розрахованих на підставі нечітких характеристик керівних рішень, отриманих від системи ШІ, що підтримує технологію м'якого управління. Упроваджено такі **методи**: нечітке управління, прийняття рішень в умовах невизначеності на основі фактора впевненості, теорія автоматів, теорія ймовірностей. **Досягнуті результати**: запропоновано й обґрунтовано модель ЙНА, запозичену у живих істот; розроблено алгоритм ЙНА, що реалізує керівні рішення, отримані методом м'якого управління. **Висновки**. Ймовірно-нечіткий актуатор, на відміну від наявних методів реалізації керівних рішень у моделях м'якого управління, відкриває можливості реалізації команди, що в прийнятті рішень не мали абсолютної переваги з-поміж усіх потенційно можливих. Така здатність актуаторів, що застосовуються в автономних системах, корисна в умовах, коли система стикається з незнайомою ситуацією, оскільки всі наявні в її пам'яті прототипи реакції визначаються незначною впевненістю. У цих випадках для підтримання автономності важливо спробувати різні поведінки, а не тільки ту, що в рейтингу стоїть першою. Крім цього, метод "спроб і помилок" властивий для моделі самонавчання в автономних системах, яка спирається на нього. Комп'ютерні експерименти підтвердили можливість реалізації цього механізму за допомогою запропонованої моделі ЙНА.

**Ключові слова**: штучний інтелект; м'яке управління; автономна безлюдна система; нечіткі системи; ймовірнісні моделі.

### Вступ

Сучасний етап визначається широким застосуванням різних автономних систем [1], зокрема роботів, автономних систем військового, промислового, побутового, аграрного [2] та освітнього призначення [3]. Автономні системи дають змогу звільнити людину від виконання складних завдань [2], замінити людину у виконанні завдань, пов'язаних зі шкідливим довкіллям [2]. Якщо ж завдання належать до військової галузі [4], то це допомагає зберегти здоров'я та життя. У сфері обслуговування автономні системи сприяють підвищенню ефективності, безпеки та якості обслуговування [4], зокрема у сфері освіти можуть покращувати навчальний процес [3, 5]. Автономні системи ефективні також у галузі залізничного транспорту [6]. Наведений перелік напрямів, де автономні системи застосовуються постійно, збільшується.

У створенні автономних безлюдних систем найбільш важливим компонентом є система прийняття рішень та управління. Нині застосовуються такі моделі систем управління: жорстке програмне

управління, гнучке програмне управління та гнучке ситуаційне управління, нечітке та нейронечітке управління. Жорстке програмне управління ефективно для типових стандартних завдань, які мають чітко визначені маршрути та сталі умови середовища [2]. Гнучке програмне управління розширює можливості автономного прийняття рішень, наприклад, робот здатний реалізувати свій маршрут з огляду на мінливі умови й перешкоди в довкіллі [7]. Гнучке ситуаційне управління розв'язує проблеми, що виникають унаслідок динамічних змін в оточенні завдяки зберіганню в пам'яті множини прототипів поведінки для різних класів ситуацій. Нечіткі та нейронечіткі моделі управління є ефективними в ситуаціях, коли автономна безлюдна система долає невизначеність і неповноту знань за допомогою узагальнення ситуацій [8]. Для перелічених моделей м'якого управління (ситуаційне, нечітке та нейронечітке) забезпечення високого рівня автономності потребує наявності попередніх прототипів усіх можливих ситуацій. Це обмежує застосування цих методів в автономних системах, що працюють в умовах високого рівня невизначеності, зумовленої динамікою навколишніх процесів [9].

### Аналіз останніх досліджень і публікацій

Особливістю завдань автономних роботизованих систем є формування керівних рішень в умовах невизначеності та неповноти знань. Рішення у вигляді множини команд на ВМ можуть бути реалізованими чи асинхронно й паралельно, чи послідовно-паралельно. Для підтримки такого типу завдань застосовується декілька підходів. Розглянемо їх.

Управління на основі поведінки (*Behavior-Based Control*). У цьому підході система керування роботом підтримує декілька прототипів його поведінки, що виконуються одночасно. Особливістю цієї архітектури є те, що кожна поведінка може діяти незалежно та активуватися або ж деактивуватися залежно від поточної ситуації та контексту [9, 10].

Підхід до керування роботами на основі архітектури підпорядкування (*Subsumption Architecture*) передбачає різні рівні контролю. Вищі рівні контролю можуть підпорядковувати нижчі, і це дає змогу виконувати декілька команд одночасно. Наприклад, є поведінка нижчого рівня з функцією уникнення перешкод, і вона працює постійно. Водночас на поведінку вищого рівня покладене завдання пошуку певної мети, і за потреби цей рівень може переривати або коригувати дії нижчого рівня. Коли робот виконує конкретні завдання, цей підхід забезпечує надійність та гнучкість [11].

Архітектура управління завданнями (*Task Control Architecture*). Зазначений підхід надає засоби для опису, координації та виконання завдань на високому рівні абстракції. Основні компоненти архітектури: менеджер завдань, роботи, які виконують завдання, і механізми

для їх комунікації та синхронізації. Роботи здатні виконувати завдання асинхронно, тобто без очікування завершення попередніх подій чи команд [12].

Концепція *Behavior-Based Control* найбільше бере до уваги згадану вище особливість прийняття керівних рішень в автономних системах. Ця концепція управління в автономних системах розвивається різними напрямками штучного інтелекту (ШІ) для роботів [13]. Щоб подолати проблему налаштування роботів на певні послуги, що зазвичай досягаються за допомогою навчання, і консолідувати зусилля роботизованих лабораторій по всьому світу, було запущено проєкт RT-X [14]. Мета проєкту – створення узагальненого робота мозку (*General Robots Brain, GRB*) унаслідок збору інформації, ресурсів і коду, що стосуються навичок, яким роботи вже навчені [15]. ШІ відіграє провідну роль, оскільки збір і створення знань про семантичні зв'язки між об'єктами в оточенні роботів покладають на штучний інтелект. Одним з нових підходів для роботів є штучний інтелект, що відчуває (*Feeling AI, FAI*). Його дослідженню присвячені праці [9, 16, 17]. У статті розглядається можливість застосування моделі ЙНА для реалізації керівних рішень м'якого управління у FAI.

### Мета роботи й завдання

Для пояснення проблеми розглянемо завдання з керування автономною безлюдною системою на прикладі колісного робота. Нехай місія робота полягає в перевезенні вантажу з вихідної позиції до позиції 2 за заданим маршрутом (рис. 1).




Рис. 1. Маршрут переміщення колісного робота

Колісний робот реалізує керівні рішення за допомогою типових команд, наприклад, рух

у якомусь напрямку з певною швидкістю, поворот коліс на певний кут, прискорення, гальмування тощо.

У разі жорсткого програмного управління параметри цих команд є попередньо розрахованими й не змінюються. Наприклад, для переміщення це може бути рух уперед з певною швидкістю протягом 30 с, потім виконання повороту на місці на 90°. Керівна програма такого типу має чітку послідовність команд, реалізацію яких підтримує контролер програмного управління. У разі гнучкого програмного управління команди цієї програми подібні до тих, що використовуються в жорсткому програмному управлінні, але вони містять умови завершення команди у вигляді прототипів даних від сенсорів. Наприклад, для руху прямо на 120 см контролер зчитує показники сенсора одометра, і після отримання

даних, що відповідають умовам, здійснює перехід до наступної команди, визначеної в керівній програмі.

Описані підходи мають деякі обмеження. Наприклад, робот, наближаючись до повороту, має спочатку знизити швидкість і плавно повернути колеса для виконання маневру повороту. У певні моменти часу необхідно, щоб не завершувалася поточна команда й починала виконуватися інша, потім обидві команди реалізовувалися одночасно.

Приклад розподілу в часі виконання команд за умови наближення до повороту, під час повороту та продовження руху наведені на рис. 2. На рисунку видно, що кожна наступна команда виконується без завершення попередньої.




Рис. 2. Виконання команд робота з часом

На рис. 2 проілюстровано виконання таких команд: команда 1 (К1) – рух уперед, команда 2 (К2) – гальмування, команда 3 (К3) – поворот направо, команда 4 (К4) – прискорення та команда 5 (К5) – поворот наліво. Наведений комплекс команд з м'якою синхронізацією в часі є типовим для методів ситуаційного управління з нечіткими моделями прототипів ситуацій [17, 18]. Але всі переваги від використання нечітких моделей прийняття керівних рішень нівелюються останньою фазою нечіткого оброблення даних, а саме фазою дефазифікації. Усі відомі моделі нечіткого виведення виконують попереднє усереднення рішень, отриманих різними незалежними вирішувачами, а потім обчислення чисельного значення сигналу управління. Такий підхід звужує можливості автономних систем, оскільки завжди має пріоритет чи основний внесок рішення-переможця. Рішення, які мають незначну впевненість, ніколи не можуть бути реалізованими.

Водночас такі "слабкі" рішення виникають через неповноту знань, і без їх пробної реалізації неможливе самонавчання, що є необхідною функцією автономної системи.

Отже, для автономних систем, що приймають керівні рішення в умовах невизначеності, недостатньо одного використання м'якого управління, необхідна нова модель ВМ, яка давала б змогу поряд з "потужними" щодо впевненості реалізувати й "слабкі" керівні рішення. Модель такого ВМ пропонується запозичити у живих істот.

У праці [18] запропоновано модель актуатора, запозичену в біологічного актуатора, а саме м'язи живих істот, і розглянуто можливості її застосування в робототехніці. Модель повною мірою бере до уваги нечіткі характеристики керівного рішення у вигляді впевненості, динаміку реалізації рішення у вигляді постійного запізнення. Однак у моделі відсутня можливість реалізувати "слабке" рішення, отримане

нечіткою системою управління, оскільки воно не може конкурувати з "потужним" нечітким рішенням з більшим фактором упевненості.

**Мета статті** – запропонувати модель ЙНА та дослідити можливості її застосування для реалізації прийнятих FAI рішень в автономних системах.

### Ймовірнісно-нечітка модель актуатора, запозичена у живих істот

На практиці, залежно від інтерфейсу системи управління та ВМ, розрізняють кілька типів ВМ [18].

ВМ першого типу приймає на вхід цифровий код із певного діапазону  $[K_{min}, K_{max}]$ , а на виході створює фізичну властивість, кількісна характеристика якої лежить у діапазоні  $[0, N]$  і відповідає значенню вхідного коду.

Другий тип ВМ реалізує багатоопозиційне управління загалом. Наприклад, двопозиційне управління реалізує "увімкнене" / "вимкнене", трипозиційне управління швидкістю "стоп" / "мала" / "середня". Багатоопозиційний ВМ можна також розглядати як представника першого типу: на вході цифровий код із певного діапазону, а на виході – фізичний параметр, що відповідає обраній позиції.

Для третього типу ВМ на вхід надходить сигнал "зменшити" або "збільшити" на величину вхідного коду управління, або "зберегти" попереднє (поточне) значення фізичного параметра. Наприклад, команди "трохи чи сильно загальмувати або прискоритися". ВМ декрементує або інкрементує поточне значення вихідного фізичного параметра на величину з певного діапазону  $[N_{min}, N_{max}]$  відповідно до значення вхідного коду або не змінює нічого.

Отже, незалежно від типу ВМ, відповідно до інтерфейсу системи управління з ВМ, усі три типи однакові: за значенням вхідного коду  $q \in [Q_{min}, Q_{max}]$  формується вихідний фізичний параметр із значенням  $n \in [N_{min}, N_{max}]$ .

Нехай поведінка робота, сформована FAI, визначається на множині з  $L$  можливих команд управління та реалізується  $L$  універсальними ВМ. Кожному ВМ відповідає актуатор, що виконує роль нечітко-ймовірнісного інтерфейсу між вихідними змінними системи прийняття рішень FAI та ВМ.

Вихідні змінні FAI – це нечіткі характеристики команд, наприклад "трохи прискоритися" або "встановити середню швидкість".

Система прийняття керівних рішень FAI формує як нечітку характеристику команди "нечіткий фактор впевненості" (НФВ)  $-1 \leq cf \leq +1$ , який є чисельною оцінкою впевненості, що актуатор має бути активованим. Значення  $cf = +1$  відповідає повній впевненості, а  $cf = -1$  означає повну впевненість навпаки, що актуатор не має бути активований [16].

Отже, на вхід актуатора надходить НФВ  $cf$ , а на вихід – код  $m \in [0, M]$ . Актуатори є універсальними як за реалізованою функцією, так і за входом/виходом. Значення вихідного коду актуатора масштабується під значення вхідного коду ВМ і слугує вхідним значенням для реальних ВМ. Актуатор реалізує ймовірнісно-нечітке перетворення значення НФВ  $cf$  у чітке число  $m$ . Тому будемо використовувати запропоновану аббревіатуру ЙНА, посилаючись на модель актуатора, викладену нижче.

Модель ЙНА запозичена у живих істот, а точніше симулює поведінку м'яза, який містить  $M$  незалежних м'язових волокон [19]. Нижче розглянуто модель елементарного актуатора (ЕА) – біологічного виконавчого механізму, тобто клітини м'яза, або м'язового волокна.

Динаміка реакції на команду як вплив рівня активації та ступеня актуальності на скоротливу реакцію волокна наведена в графічному вигляді на рис. 3. Показано реакцію м'язового волокна на одиночний подразник ( $a$ ), два ( $b$ ) і три ( $c$ ) подразники, що відстають один від одного на певний часовий інтервал. З графіків випливають два важливі висновки. Перший полягає в тому, що реакція починається із запізненням на час  $n\tau$  після активації волокна. Другий висновок: одиночний подразник незалежно від його амплітуди недостатній для того, щоб волокно скоротилося на максимально можливе значення.

У третьому випадку скорочення м'язового волокна досягає максимальних значень. І, нарешті, з рис. 3,  $c$  видно, що за умови 20 і більше стимулів волокно скорочується до максимального значення та зберігає цей стан деякий час, після чого розслабляється через втомлюваність. На основі цих даних додано модель ЕА, яка, власне, є чіткою.






Рис. 3. Залежність реакції м'язового волокна від кількості подразників

Стан ЕА залежить від кількості дискретних інтервалів часу, коли вхід був активований. У моменти часу  $k\tau$  на вхід ЕА надходить інформація про активацію, і ЕА може перейти в інший стан та змінити значення вихідної змінної з 0 на 1 або навпаки. Приймається автоматоподібна модель.

Динамічну характеристику задано двома числами –  $n_1$  та  $n_2$ . Коли значення вихідної змінної  $x=0$ , і в момент часу  $t$  на вхід ЕА надходить інформація про активацію, то за деякий час у момент  $t+n_1\tau$  зміниться значення виходу ЕА, тобто  $x=1$ . Якщо до моменту часу  $t+n_2\tau$  активації не було, то значення виходу зміниться на  $x=0$ . Додано три стани: спокою (П), розігріву (Р) та активності (А). У кожен такт часу  $k\tau$  ЕА може перебувати в одному з перелічених станів і залежно від значення вхідної змінної здатний переходити з одного стану в інший відповідно до графа на рис. 4. На дугах графа зображені умови переходу, а після скісної риски вказані додаткові обчислювальні операції.

$$\begin{aligned} \alpha(0) &= -1, \alpha(\tau) = -1, \alpha(2\tau) = +1, \alpha(3\tau) = +1, \alpha(4\tau) = +1, \alpha(5\tau) = -1, \alpha(6\tau) = +1, \\ \alpha(7\tau) &= -1, \alpha(8\tau) = -1, \alpha(9\tau) = -1, \alpha(10\tau) = -1. \end{aligned} \quad (1)$$

Послідовності (1), згідно з графом (рис. 4), відповідають послідовності станів і значень вихідної змінної:

$$\begin{aligned} S(0) &= \text{П}, S(\tau) = \text{П}, S(2\tau) = \text{Р}, S(3\tau) = \text{Р}, S(4\tau) = \text{Р}, S(5\tau) = \text{Р}, \\ S(6\tau) &= \text{А}, S(7\tau) = \text{А}, S(8\tau) = \text{А}, S(9\tau) = \text{А}, S(10\tau) = \text{А}, S(11\tau) = \text{А}, S(12\tau) = \text{П}. \end{aligned}$$

$$\begin{aligned} x(0) &= 0, x(\tau) = 0, x(2\tau) = 0, x(3\tau) = 0, x(4\tau) = 0, x(5\tau) = 0, \\ x(6\tau) &= +1, x(7\tau) = +1, x(8\tau) = +1, x(9\tau) = +1, x(10\tau) = +1, x(11\tau) = +1, x(12\tau) = 0. \end{aligned}$$

Наприклад,  $I_p := n_1$  змінній  $I_p$ , що відповідає стану "розігрів", надається значення параметра  $n_1$  динамічної характеристики. Аналіз рисунка показує, що в стані "спокій" у моменти часу  $k\tau$  у разі значень вхідної змінної  $\alpha \leq 0$  ЕА залишається в цьому самому стані до наступного моменту часу  $(k+1)\tau$ , а за умови  $\alpha > 0$  переходить у стан "розігрів" з виконанням операції  $I_p := n_1$ .

Аналогічно, в стані "розігрів", якщо обидва значення вхідного сигналу  $\alpha \leq 0$  і  $\alpha > 0$ , ЕА може як залишитися в цьому стані (на рисунку дуги не позначені умовами  $\alpha \leq 0$  і  $\alpha > 0$ ), так і перейти в стан "активність", якщо змінна  $I_p = 0$ . Перехід з останнього в стан "спокій" можливий за умови  $I_A = 0$ , у цьому разі не виконується жодна додаткова обчислювальна операція (за вертикальною рисою вказаний знак порожньої множини).

Проаналізуємо поведінку ЕА на прикладі вхідної послідовності для значень параметрів динамічної характеристики  $n_1 = 3$  і  $n_2 = 4$ .




Рис. 4. Граф переходів станів ЕА

Після того, як було додано модель ЕА, опишемо модель ЙНА як систему, створену з  $M$  незалежних ЕА. Розглядаємо динамічну модель, що функціонує в дискретні моменти часу  $k\tau$ ,  $k=1,2,\dots$ , де  $\tau$  – інтервал дискретизації. На момент  $k\tau$  на вході ЙНА є поточне значення НФВ  $cf(k\tau)$ . Стан ЙНА подає множину станів усіх  $M$  ЕА  $\{(l_{\Pi}^i(k-1)\tau), (l_{\Pi}^i(k-1)\tau), (l_{\Pi}^i(k-1)\tau), i=1,2,\dots,M\}$ . Ймовірно-нечіткий механізм ЙНА на підставі значення НФВ, по-перше, формує значення ймовірності на вході кожного ЕА, по-друге, методом рулетки знаходить для кожного ЕА значення функції активації його входу  $\alpha_i(k\tau) = \{0 \text{ чи } 1\}$ ,  $i=1,2,\dots,M$ . Значення  $\alpha_i(k\tau) = 0$  говорить про те, що ЕА на цей час не буде активованим, а  $\alpha_i(k\tau) = 1$ , навпаки, означає, що на вході ЕА буде 1. На наступному етапі оброблення вхідної інформації ЙНА розраховують значення виходів для всіх ЕА  $x_i(k\tau)$   $i=1,2,\dots,M$ . Алгоритм обчислення  $x_i(k\tau)$  спочатку знаходить стан  $\{(l_{\Pi}^i(k\tau), l_{\Pi}^i(k\tau), l_{\Pi}^i(k\tau))\}$   $i$ -го ЕА згідно з можливими переходами (рис. 4) для заданого значення входу  $\alpha_i(k\tau)$ , а потім для нового вектора стану знаходиться  $x_i(k\tau) = \{0 \text{ чи } 1\}$ . І на останньому етапі обчислюється значення вихідної змінної моделі ЙНА

$$m(k\tau) = \sum_{i=1}^M x_i(k\tau). \quad (2)$$

У роботі розглядаємо два варіанти переходу від НФВ до ймовірностей подій.

Перший варіант ґрунтується на дослідженнях з біології [19]. Щоб активізувати біологічний

актуатор, в ділянку, де він розташований, випускаються ліганди – спеціальні молекули, які запускають хімічні реакції, що активують актуатор. Кількість (концентрація) лігандів залежить від характеристики збурення нейронів. Нейробіологи оцінюють параметри перелічених процесів ймовірностями. Отже, якщо прийняти, що значення НФВ визначає ступінь збурення нейрона, то концентрація лігандів в оточенні ЕА може бути подана кількістю лігандів, кожен з яких має вірогідність зіткнутися з ЕА й активізувати його. Для цього варіанта застосована наступна спрощена ймовірнісна модель. Множина можливих подій  $\{A_j, j=0,1,2,\dots,J(k\tau)+1\}$ , де  $J(k\tau) = f(cf(k\tau))$ ,  $cf \in [-1, +1]$  – це кількість елементів-лігандів, запущених для активізації  $i$ -го ЕА;  $A_0$  – подія, що жоден з лігандів не зіткнеться з ЕА;  $A_j$  – подія що  $j$ -й ліганд зіткнеться з ЕА. Кількість лігандів  $J(k\tau)$  залежить від значення НФВ. Завдання – знайти розподіл ймовірностей для повної групи незалежних подій і обрати тільки одну з них методом рулетки.

У другому варіанті значення НФВ  $\{cf_i, i=1,2,\dots,n\}$ ,  $cf \in [-1, +1]$  розглядають як безпосереднє значення ймовірності, що  $i$ -й ЕА буде активізованим на цьому такті часу, тобто на вході  $i$ -го ЕА буде  $\alpha_i(k\tau) = 1$ . Завдання ймовірнісного механізму – знайти множину ЕА, які будуть активовані в цьому такті часу. Для кожного ЕА незалежно методом рулетки вирішується, чи буде він активованим, чи ні.

Для першого варіанта спочатку знаходять ймовірності  $P_0 = P(A_0)$ ,  $P_1 = P(A_1)$ ,  $\dots$ ,  $P_J = P(A_J)$  повної групи подій  $P_0 + P_1 + \dots + P_J = 1$ .

Ймовірності розраховують таким чином:

$$P_0 = \frac{1.75 - cf}{2}, \quad P_j = \frac{(0.25 + cf)/J}{2}, \quad j = 1, 2, \dots, J, \quad \text{якщо } cf \geq 0;$$

$$P_0 = 1, \quad P_1 = \dots = P_J = 0, \quad \text{якщо } cf_i \leq 0.75;$$

$$P_0 = \frac{1.25 + |cf|}{2}, \quad P_j = \frac{(0.75 - |cf|)/J}{2}, \quad j = 1, 2, \dots, J, \quad \text{якщо } 0.75 < cf_i < 0.$$
(3)

Алгоритм визначення значення вхідної змінної  $\alpha_i(k\tau)$  ЕА подано нижче:

```

start Main_Program
Step 1. Initialization
initialize array = { -0.5, 0.5, 0.6 }
normalizedArray = NormalizeArray(array)
Step 2. Perform roulette selection
selectedIndex = RouletteSelection(normalizedArray)
print "Selected index: " + selectedIndex + " Selected
value: " + normalizedArray[selectedIndex]
end Main_Program

```

**RouletteSelection(normalizedArray)**

**Step 1. Initialization**

initialize *rnd* as Random

initialize *randomValue* as rnd.NextDouble()

**Step 2. Iterating through normalizedArray**

initialize *cumulative* as 0.0

**for each** element in normalizedArray **do**

*cumulative* += element

**if** randomValue <= *cumulative* **then**

**return** current index

**end if**

**end for**

**return** 0

**end RouletteSelection**

**NormalizeArray(arr)**

**Step 1. Initialization**

initialize *normalizedArr* as array of doubles with length equal to arr length

**Step 2. Conversion from confidence to probability**

**for each** *element* in arr **do**

*normalizedArr*[*i*] = (element + 1) / 2

**end for**

**Step 3. Calculation of sum of normalized values**

initialize *sum* as 0

**for each** item in *normalizedArr* **do**

*sum* += item

**end for**

**Step 4. Normalization to sum of 1**

**for each** *element* in *normalizedArr* **do**

*normalizedArr*[*i*] /= *sum*

**end for**

**return** *normalizedArr*

**end NormalizeArray**

У другому варіанті також спочатку для заданого значення НФВ знаходять ймовірності активації кожного ЕА за тими самими формулами (3), що й для першого варіанта за умови  $J = 1$ . Потім визначають, чи буде активованим ЕА для кожного окремо ЕА, чи ні. З цією метою також використано метод рулетки для кожного з ЕА. Алгоритм цього завдання виглядає так:

**start Main\_Program**

**Step 1. Initialization**

initialize array = { -0.5, 0.25, 0.5 }

*probabilityArray* = ConvertToProbabilityArray(array)

*selectedList* = RouletteSelection(array,

*probabilityArray*)

**end Main\_Program**

**RouletteSelection(array, probabilityArray)**

**Step 1. Initialization**

initialize *selectionList* as empty list of integers

initialize *rnd* as Random

**Step 2. Iterating through array elements**

**for each** *element* in array **do**

*randomValue* = rnd.NextDouble()

    print "Array item: " + element + " Probability

value: " + *probabilityArray*[*i*]

**if** *randomValue* <= *probabilityArray*[*i*] **then**

        print "Random Value: " + *randomValue* + "

Result of selection: True"

        add 1 to *selectionList*

**else**

        print "Random Value: " + *randomValue* + "

Result of selection: False"

        add 0 to *selectionList*

**end if**

**end for**

**return** *selectionList*

**end RouletteSelection**

**ConvertToProbabilityArray(arr)**

**Step 1. Initialization**

initialize probabilityArray as array of doubles with length equal to arr length

**Step 2. Conversion from confidence to probability for each element in arr do**

probabilityArray[i] = (element + 1) / 2

end for

return probabilityArray

end ConvertToProbabilityArray

**Результати моделювання**

У процесі моделювання поведінки колісного робота з використанням ЙНА розглянуто рух робота по маршруту, що зображено червоною лінією на рис. 1.

$$q(k\tau) = Q_{min} + \frac{m(k\tau)}{Q_{max} - Q_{min}} \quad \text{однопозиційний ВМ;}$$

$$q_i(k\tau) = \begin{cases} 1, & \text{if } m_i(k\tau) = m^*, \\ 0, & \text{other wise,} \end{cases} \quad \text{де } m^* = \text{MAX}(m_1(k\tau), m_2(k\tau), \dots, m_n(k\tau)) \quad (4)$$

*n*-позиційний ВМ.

Нижче наведено фрагменти результатів моделювання п'яти кроків руху робота по маршруту (рис. 1). Розглянуто спрощену часову модель: система управління генерувала команди з періодичністю  $T=10$  одиниць часу, і протягом цього інтервалу НФВ команди на вході ЙНА не змінювалися. ЙНА використовував ці значення з періодичністю  $\tau=1$ , тобто 10 разів за інтервал  $T$  обчислювали вихідну

Було змодельовано п'ять кроків м'якого управління, що описують рух робота від початкової точки до кінцевої. Розглянуто наведену вище множину ВМ з такими характеристиками команд: трипозиційний перемикач передач швидкості руху вперед ( $K1_{\text{стоп}}, K1_{\text{мала}}, K1_{\text{велика}}$ ); двопозиційне гальмування ( $K2_{\text{вимкнуте}}, K2_{\text{увімкнуте}}$ ); трипозиційний поворот направо ( $K3_0, K3_{45}, K3_{90}$ ); однопозиційне прискорення ( $K4$ ); трипозиційний поворот наліво ( $K5_0, K5_{45}, K5_{90}$ ). Для кожної команди було створено ЙНА з множиною із  $M=100$  ЕА. Кількість лігандів на один ЕА була обрана  $J=5$ . Перетворення виходу ЙНА (1) у вхідний код ВМ наведено нижче.

змінну ЙНА. Розрахунки виконували за моделлю другого варіанта, коли НФВ на вході ЙНА розглядали як безпосереднє значення ймовірності.

*Крок 1.* Початок руху колісного робота.

Робот починає рух з початкової точки. Система м'якого управління (СМУ) FAI прийняла керівні рішення щодо руху прямо переважно з малою швидкістю. Вектор управління має такий вигляд:

$$\begin{aligned} &((cf_{K1_{\text{стоп}}}(T=0) = -0.95, cf_{K1_{\text{мала}}}(T=0) = +0.85, cf_{K1_{\text{велика}}}(T=0) = +0.3), \\ &(cf_{K2_{\text{вимкнуте}}}(T=0) = +0.65, cf_{K2_{\text{увімкнуте}}}(T=0) = -0.95), \\ &(cf_{K3_0}(T=0) = -0.95, cf_{K3_{45}}(T=0) = -0.95, cf_{K3_{90}}(T=0) = -0.95), \\ &(cf_{K4}(T=0) = +0.35), (cf_{K5_0}(T=0) = -0.95, cf_{K5_{45}}(T=0) = -0.95, cf_{K5_{90}}(T=0) = -0.95)). \end{aligned} \quad (5)$$

Вихідний вектор кодів ЙНА, що подаються на ВМ, має такі значення:

$$\begin{aligned} &((m_{K1_{\text{стоп}}}(T+k\tau) = 0/0, m_{K1_{\text{мала}}}(T+k\tau) = 78/1, m_{K1_{\text{велика}}}(T+k\tau) = 17/0), \\ &(m_{K2_{\text{вимкнуте}}}(T+k\tau) = 67/1, m_{K2_{\text{увімкнуте}}}(T+k\tau) = 0/0), \\ &(m_{K3_0}(T+k\tau) = 0/0, m_{K3_{45}}(T+k\tau) = 0/0, m_{K3_{90}}(T+k\tau) = 0/0), \\ &(m_{K4_{\text{вимкнуте}}}(T+k\tau) = 0/0, m_{K4}(T+k\tau) = 26/98), \\ &(m_{K5_0}(T+k\tau) = 0/0, m_{K5_{45}}(T+k\tau) = 0/0, m_{K5_{90}}(T+k\tau) = 0/0)), \quad k = 4, 5, \dots, 9. \end{aligned} \quad (6)$$

У (6) наведено по два значення кодів, наприклад, для  $m_{K1_{\text{мала}}}(T+k\tau) = 78/1$ . Перша цифра 78 показує

значення вихідної змінної (1) ЙНА (кількість ЕА із 100 мають значення виходу  $x=1$ ). Друга цифра –

це значення коду  $q_i(k\tau)$  в (4), що подається на вхід ВМ. Наприклад, код входу ВМ команди К1 є  $(0,1,0)$ . Ще один коментар до (6) стосується того, що вказано початкове значення часу  $k = 4$ . Це пов'язано з початком моделювання множини ЕА, оскільки обрано  $n_1 = 3$  в моделі (рис. 4).

Крок 2. Виконання повороту направо.

Моделюється повороту направо на перехресті (рис. 1), коли СМУ FAI прийняла неоднозначне рішення: рухатися прямо на тій самій передачі швидкості "мала", пригальмовуючи, або переключити передачу швидкості на "стоп" та виконати поворот направо на  $90^\circ$ . Вектор управління має такий вигляд:

$$\begin{aligned} & ((cf_{K1стоп}(T=10) = +0.49, cf_{K1мала}(T=10) = +0.55, cf_{K1велика}(T=10) = -0.95), \\ & (cf_{K2вимкнуте}(T=10) = -0.15, cf_{K2увімкнуте}(T=10) = +0.65), \\ & (cf_{K30}(T=10) = -0.85, cf_{K345}(T=10) = +0.45, cf_{K390}(T=10) = +0.85), \\ & (cf_{K4}(T=0) = -0.95), (cf_{K50}(T=10) = -0.95, cf_{K545}(T=10) = -0.95, cf_{K590}(T=10) = -0.95)). \end{aligned} \quad (7)$$

Отримано вихідний вектор кодів ЙНА на момент часу  $T+0$

$$\begin{aligned} & ((m_{K1стоп}(T+0) = 47/0, m_{K1мала}(T+0) = 53/1, m_{K1велика}(T+0) = 0/0), \\ & (m_{K2вимкнуте}(T+0) = 6/0, m_{K2увімкнуте}(T+0) = 48/1), \\ & (m_{K30}(T+0) = 0/0, m_{K345}(T+0) = 29/0, m_{K390}(T+0) = 77/1), \\ & (m_{K4}(T+0) = 0/0), (m_{K50}(T+0) = 0/0, m_{K545}(T+0) = 0/0, m_{K590}(T+0) = 0/0)), \end{aligned}$$

який принципово не змінювався протягом трьох наступних часових інтервалів  $T+\tau$ ,  $T+2\tau$ ,  $T+3\tau$ . А на момент часу  $T+4\tau$  ЙНА отримав

принципово інші значення для ВМ, що реалізує команду К1, а саме замість рух на передачі "мала" реалізував "стоп".

$$((m_{K1стоп}(T+4\tau) = 51/1, m_{K1мала}(T+0) = 46/0, m_{K1велика}(T+0) = 0/0), \dots).$$

### Висновки

ЙНА, на відміну від наявних методів реалізації керівних рішень у моделях м'якого управління, відкриває можливості реалізації команди, що не набула абсолютної переваги з-поміж усіх потенційно можливих команд і не була першою в пріоритетному переліку. Таку особливість потребують актуатори, що застосовуються в автономних системах. В умовах невизначеності, коли автономна система опиняється в незнайомій ситуації, для якої попередньо не було сформовано прототипу поведінки, всі наявні прототипи реакції визначаються незначною впевненістю в тому, що темплейт, який зберігається в пам'яті, відповідає фактичній ситуації. У цьому разі важливо спробувати

різні прототипи поведінки, а не тільки той, що в рейтингу відповідності стоїть першим з незначною різницею від інших. Цей висновок підтверджують дослідження з біології, що механізм самонавчання живої істоти оснований на методі "спроб і помилок". Щоб знайти й запам'ятати відповідну реакцію, потрібна диверсифікація реакцій на незнайому ситуацію. Комп'ютерні експерименти, наведені в роботі, підтвердили можливість реалізації цього механізму за допомогою запропонованої моделі ЙНА.

Надалі заплановано дослідити універсальну модель ЙНА й розробити рекомендації щодо її застосування в різних застосунках м'якого управління, зокрема управління колісним роботом на основі даних від різних сенсорів.

**Список літератури**

1. Litman T. A. Autonomous Vehicle Implementation Predictions: Implications for Transport Planning. Victoria Transport Policy Inst., Aug. 2022. URL: <https://www.vtpi.org/avip.pdf> (дата звернення: 27.11.2024).
2. Siciliano B., Khatib O. (Eds.). Modeling and Control of Underwater Robots. *Springer Handbook of Robotics* (2nd ed.). Berlin, Heidelberg: Springer-Verlag, 2016. 2225 p. DOI: <https://doi.org/10.1007/978-3-319-32552-1>
3. Belpaeme T., Kennedy J., Ramachandran A., Scassellati B., Tanaka F. Social robots for education: A review. *International Journal of Social Robotics*. 2018. Vol. 10. No. 3. P. 299–315. DOI: <https://doi.org/10.1126/scirobotics.aat5954>
4. Pagliarini L., Lund H. H. The future of Robotics Technology. *Journal of Robotics, Networking and Artificial Life*. Vol. 3. No. 4. March 2017. P. 270–273. DOI: 10.2991/jrnal.2017.3.4.12
5. Mubin O., Stevens C. J., Shahid S., Mahmud A. A., Dong J. J. A Review of the Applicability of Robots in Education. *Journal of Technology in Education and Learning*. 2013. Vol. 1. No. 1. P. 1–7. DOI: 10.2316/Journal.209.2013.1.209-0015
6. Singh P., Dulebenets M. A., Pasha J., Gonzalez E. D. R. S., Lau Y.-y., Kampmann R. Deployment of Autonomous Trains in Rail Transportation: Current Trends and Existing Challenges. *IEEE Access*. 2021. Vol. 9. P. 1550–1562. DOI: 10.1109/ACCESS.2021.3091550
7. Thrun S., Burgard W., Fox D. Probabilistic Robotics. MIT Press, 2005. Розділ 5: Robot Motion. P. 91–119. URL: <https://docs.ufpr.br/~danielsantos/ProbabilisticRobotics.pdf> (дата звернення: 27.11.2024).
8. Piegat A (2001) Fuzzy modelling and control. Physica-Verlag, 728 p.
9. Kargin A., Petrenko T. Feeling Artificial Intelligence for AI-Enabled Autonomous Systems. *In Proc. of 2022 IEEE Global Conf. on Artificial Intelligence and Internet of Things (GCAIoT)*. Alamein New City, Egypt, Dec. 18, 2022, P. 88–93. DOI: 10.1109/GCAIoT57150.2022.10019235
10. Beetz M., Jain D., Mösenlechner L., Tenorth M. Towards performing everyday manipulation activities. *Robotics and Autonomous Systems*. 2010. P. 1–10. DOI: 10.1016/j.robot.2010.05.007
11. Arkin R. Behavior-Based Robotics. *Automatica*. 1998. P. 69–79. DOI: 10.1016/S0005-1098(02)00169-3
12. Brooks R. A Robust Layered Control System for a Mobile Robot. *IEEE Journal on Robotics and Automation*. 1986. Vol. 2, № 1. P. 14–23. DOI: 10.1109/JRA.1986.1087032
13. Simmons R. Experience with a Task Control Architecture for Mobile Robots. 1989. P. 4–8. URL: [https://www.academia.edu/51291699/Experience\\_with\\_a\\_Task\\_Control\\_Architecture\\_for\\_Mobile\\_Robots](https://www.academia.edu/51291699/Experience_with_a_Task_Control_Architecture_for_Mobile_Robots) (дата звернення: 27.11.2024).
14. Guizzo E. Types of Robots. Categories frequently used to classify robots. [Robotsguide.com](https://robotsguide.com). URL: <https://robotsguide.com/learn/types-of-robots> (дата звернення: 15.06.2024).
15. Open X-Embodiment: Robotic Learning Datasets and RT-X Models. Open X-Embodiment Collaboration, 2024. URL: <https://robotics-transformer-x.github.io/> (дата звернення: 15.06.2024).
16. Levine S., Hausman K. The global project to make a general robotic brain. *IEEE Spectrum*. Jan 2024. URL: <https://spectrum.ieee.org/global-robotic-brain> (дата звернення: 15.06.2024).
17. Kargin A., Petrenko T. Knowledge Distillation for Autonomous Intelligent Unmanned System. In Pedrycz W., Chen S.-M. *Advancements in Knowledge Distillation: Towards New Horizons of Intelligent Systems*. Studies in Comput. Intell., vol. 1100. Springer International Publishing, 2023, P. 193–230. DOI: 10.1007/978-3-031-32095-8
18. Kargin A., Petrenko T. Spatio-Temporal Data Interpretation Based on Perceptual Model. In Mashtalir V, Ruban I, Levashenko V. *Advances in Spatio-Temporal Segmentation of Visual Data. Studies in Computational Intelligence*, Vol. 876. Springer, Cham, 2020, P. 101-159. DOI: 10.1007/978-3-030-35480-0\_3
19. Hengji Wang, Joshua Swore, Shashank Sharma, and Adrienne L. Fairhall. A complete biomechanical model of Hydra contractile behaviors, from neural drive to muscle to movement. *PNAS*, March 10, 2023, 120 (11). DOI: 10.1073/pnas.2210439120

**References**

1. Litman, T. A. (2022), "Autonomous Vehicle Implementation Predictions: Implications for Transport Planning, Victoria Transport Policy Institute", available at: <https://www.vtpi.org/avip.pdf> (last accessed 27.11.2024).

2. Siciliano, B., Khatib, O. (2016), "Modeling and Control of Underwater Robots". *Springer Handbook of Robotics* (2nd ed.), Springer-Verlag, Berlin, Heidelberg, 2225 p. DOI: <https://doi.org/10.1007/978-3-319-32552-1>
3. Belpaeme, T., Kennedy, J., Ramachandran, A., Scassellati, B., Tanaka, F. (2018), "Social robots for education: A review", *International Journal of Social Robotics*, Vol. 10, No. 3, P. 299–315. DOI: <https://doi.org/10.1126/scirobotics.aat5954>
4. Pagliarini, L., Lund, H. H. (2017), "The future of Robotics Technology", *Journal of Robotics, Networking and Artificial Life*, Vol. 3, No. 4, P. 270–273. DOI: 10.2991/jrml.2017.3.4.12
5. Mubin, O., Stevens, C. J., Shahid, S., Mahmud, A. A., Dong, J. J. (2013), "A Review of the Applicability of Robots in Education", *Journal of Technology in Education and Learning*, Vol. 1, No. 1, P. 1–7. DOI: 10.2316/Journal.209.2013.1.209-0015
6. Singh, P., Dulebenets, M. A., Pasha, J., Gonzalez, E. D. R. S., Lau, Y.-y., Kampmann, R. (2021), "Deployment of Autonomous Trains in Rail Transportation: Current Trends and Existing Challenges", *IEEE Access*, Vol. 9, P. 1550–1562. DOI: 10.1109/ACCESS.2021.3091550
7. Thrun, S., Burgard, W., Fox, D. (2005), "*Probabilistic Robotics*", MIT Press, Chapter 5: Robot Motion", P. 91–119, available at: <https://docs.ufpr.br/~danielsantos/ProbabilisticRobotics.pdf> (last accessed 27.11.2024).
8. Piegat A (2001), Fuzzy modelling and control. Physica-Verlag, 728 p.
9. Kargin, A., Petrenko, T. (2022), "Feeling Artificial Intelligence for AI-Enabled Autonomous Systems. In Proc". *IEEE Global Conf. on Artificial Intelligence and Internet of Things (GCAIoT)*. Alamein New City, Egypt, Dec. 18, 2022, P. 88–93. DOI: 10.1109/GCAIoT57150.2022.10019235
10. Beetz, M., Jain, D., Mösenlechner, L., Tenorth, M. (2010), "Towards performing everyday manipulation activities", *Robotics and Autonomous Systems*. P. 1–10. DOI: 10.1016/j.robot.2010.05.007
11. Arkin, R. (1998), "*Behavior-Based Robotics*", *Automatica*. P. 69–79. DOI: 10.1016/S0005-1098(02)00169-3
12. Brooks, R. (1986), "A Robust Layered Control System for a Mobile Robot", *IEEE Journal on Robotics and Automation*, Vol. 2, No. 1, P. 14–23. DOI: 10.1109/JRA.1986.1087032
13. Simmons, R. (1989), "Experience with a Task Control Architecture for Mobile Robots", P. 4–8, available at: [https://www.academia.edu/51291699/Experience\\_with\\_a\\_Task\\_Control\\_Architecture\\_for\\_Mobile\\_Robots](https://www.academia.edu/51291699/Experience_with_a_Task_Control_Architecture_for_Mobile_Robots) (last accessed 27.11.2024).
14. Guizzo, E. (2024), "Types of Robots. Categories frequently used to classify robots", *Robotsguide.com*, available at: <https://robotsguide.com/learn/types-of-robots> (last accessed 15.06.2024).
15. Open X-Embodiment Collaboration (2024), "Open X-Embodiment: Robotic Learning Datasets and RT-X Models", available at: <https://robotics-transformer-x.github.io/> (last accessed 15.06.2024).
16. Levine, S., Hausman, K. (2024), "The global project to make a general robotic brain", *IEEE Spectrum*, Jan. 2024, available at: <https://spectrum.ieee.org/global-robotic-brain> (last accessed 15.06.2024).
17. Kargin, A., Petrenko, T. (2023), "Knowledge Distillation for Autonomous Intelligent Unmanned System", in Pedrycz, W., Chen, S.-M. (Eds.), *Advancements in Knowledge Distillation: Towards New Horizons of Intelligent Systems*, Studies in Computational Intelligence, Vol. 1100, Springer International Publishing, P. 193–230. DOI: 10.1007/978-3-031-32095-8
18. Kargin, A., Petrenko, T. (2020), "Spatio-Temporal Data Interpretation Based on Perceptual Model". In Mashtalir V, Ruban I, Levashenko V (eds) *Advances in Spatio-Temporal Segmentation of Visual Data. Studies in Computational Intelligence*, Vol. 876. Springer, Cham, P. 101-159. DOI: 10.1007/978-3-030-35480-0\_3
19. Hengji, Wang, Joshua, Swore, Shashank, Sharma, and Adrienne, L. Fairhall (2023), "A complete biomechanical model of Hydra contractile behaviors, from neural drive to muscle to movement". *PNAS*, March 10, 2023, 120 (11). DOI: 10.1073/pnas.2210439120

Надійшла (Received) 01.02.2025

#### Відомості про авторів / About the Authors

**Каргін Анатолій Олексійович** – доктор технічних наук, професор, Український державний університет залізничного транспорту, завідувач кафедри інформаційних технологій, Харків, Україна; e-mail: [kargin@kart.edu.ua](mailto:kargin@kart.edu.ua); ORCID ID: <http://orcid.org/0000-0003-2885-9071>

**Кузьменко Роман Сергійович** – Український державний університет залізничного транспорту, аспірант кафедри інформаційних технологій, Харків, Україна; e-mail: [kuzmenko88@kart.edu.ua](mailto:kuzmenko88@kart.edu.ua); ORCID ID: <https://orcid.org/0009-0000-1675-8658>

**Kargin Anatolii** – Doctor of Sciences (Engineering), Professor, Ukrainian State University of Railway Transport, Department of Information Technology, Kharkiv, Ukraine.

**Kuzmenko Roman** – Ukrainian State University of Railway Transport, PhD Student at the Department of Information Technology, Kharkiv, Ukraine.

## **PROBABILISTIC-FUZZY ACTUATOR MODEL IN THE SOFT CONTROL CIRCUIT OF AN AUTONOMOUS UNMANNED SYSTEM**

The **subject matter** of the article is artificial intelligence methods and models used in autonomous unmanned system control. The **goal** of the work is to create a new actuator model for autonomous unmanned systems that implements control decisions made by Artificial Intelligence under conditions of uncertainty. The following **tasks** were solved in the article: a model of a Probabilistic Fuzzy Actuator (PFA) is proposed and the possibility of its application as a universal controller of the actuators in autonomous systems is investigated. The PFA model, borrowed from biological muscle actuators, is formalized as a set of automata-like elements with a probabilistic mechanism for assigning their input variables calculated on the basis of fuzzy characteristics of control decisions obtained from an AI system that supports soft control technology. The following **methods** are used – fuzzy control, decision-making under uncertainty based on the confidence factor, automata theory, probability theory. The following **results** were obtained – a model of PFA borrowed from living beings has been proposed and substantiated; a PFA algorithm has been developed that implements control decisions obtained by the soft control method. **Conclusions:** Probabilistic Fuzzy Actuator, unlike existing methods of implementing decisions in soft control models, opens up the possibility of implementing commands that do not have an absolute advantage among all potentially possible ones when making decisions. This capability of autonomous system actuators is useful in conditions when the system encounters an unfamiliar situation since all reaction prototypes existing in its memory are characterized by low confidence. In these cases, to maintain autonomy, it is important to try different behaviors, not just the one that ranks first. Besides this, the "trial and error" method is still required by the self-learning model in autonomous systems that rely on it. Computer experiments confirmed the possibility of implementing this mechanism using the proposed PFA model.

**Keywords:** artificial intelligence; soft-computing-based control; autonomous unmanned system; fuzzy systems; probabilistic models.

### *Бібліографічні описи / Bibliographic descriptions*

Каргін А. О., Кузьменко Р. С. Модель ймовірнісно-нечіткого актуатора в контурі м'якого управління автономною безлюдною системою. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 61–72. DOI: <https://doi.org/10.30837/2522-9818.2025.1.061>

Kargin, A., Kuzmenko, R. (2025), "Probabilistic-fuzzy actuator model in the soft control circuit of an autonomous unmanned system", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 61–72. DOI: <https://doi.org/10.30837/2522-9818.2025.1.061>

---



О. Ляшенко, І. Михайліченко

## МОДЕЛЬ АВТОНОМНОЇ СИСТЕМИ МОНІТОРИНГУ ТА ОПТИМІЗАЦІЇ ІТ-ІНФРАСТРУКТУРИ З ВИКОРИСТАННЯМ ТРАНСФОРМЕРІВ

**Предметом дослідження** є модель автономної системи моніторингу та оптимізації ІТ-інфраструктури, що використовує трансформери для аналізу багатовимірних часових рядів і виявлення аномалій у реальному часі. У статті розглянуто сучасні підходи до моніторингу ІТ-інфраструктури, зокрема використання машинного навчання та класичних методів статистичного аналізу. Огляд літератури показує, що наявні підходи мають обмеження, зокрема низьку ефективність в умовах динамічних змін параметрів системи. **Мета статті** – розроблення автономної системи, здатної здійснювати багатофакторний аналіз у реальному часі та автоматично реагувати на виявлені загрози. Запропоновано модель на основі трансформерів, що дає змогу виявляти складні аномалії та прогнозувати можливі збої. З огляду на окреслену мету необхідно розв'язати такі **завдання**: сформувати модель багатовимірного аналізу часових рядів; розробити алгоритм виявлення аномалій і прогнозування можливих проблем; реалізувати механізми автономного налаштування системи для стабілізації ІТ-інфраструктури. Упроваджено такі **методи**: математичне моделювання, машинне навчання (трансформери), статистичний аналіз (крос-валідація), алгоритми прогнозування на основі часових рядів. **Здобуті результати**. Модель досягла середньої абсолютної похибки (MAE) 4.3 % на синтетичних даних, що доводить її здатність точно виявляти аномалії. Крос-валідація підтвердила стабільність навчання без перенавчання, а гістограма залишків продемонструвала рівномірний розподіл похибок. Крім того, теплові карти кореляції показали взаємозв'язки між ключовими параметрами ІТ-інфраструктури. **Висновки**. Розроблена система дає змогу автоматично виявляти та прогнозувати проблеми в роботі ІТ-інфраструктури, забезпечуючи автономне налаштування параметрів для підтримки її стабільності. Запропонований підхід може бути інтегрований у сучасні системи управління ІТ-інфраструктурою для покращення їх ефективності.

**Ключові слова:** автономна система; трансформери; багатовимірні часові ряди; ІТ-інфраструктура; виявлення аномалій; прогнозування.

### Вступ

У сучасному світі інформаційних технологій стабільність та безпека ІТ-інфраструктури мають критичне значення для надійної роботи організацій будь-якого масштабу. Різноманіття серверів, мережевого обладнання, систем зберігання та інших компонентів генерують значні обсяги даних, що містять цінну інформацію для аналізу й ухвалення оперативних рішень. Проте збільшення складності систем, динаміка їх змін і стрімке зростання обсягів даних знижують ефективність класичних підходів до моніторингу та діагностики інфраструктури.

### Аналіз проблеми

Сучасні комерційні системи забезпечують певний рівень автоматизації та використовують методи машинного навчання. Проте вони часто мають обмеження, серед яких недостатня здатність до глибокого аналізу багатовимірних даних

і виявлення багатофакторних аномалій, залежність від ручного налаштування.

Традиційні методи моніторингу зазвичай ґрунтуються на використанні фіксованих порогів для кожного окремого показника, що дає змогу виявляти прості аномалії, але є недостатньо точним для визначення комплексних проблем, що виникають у взаємодії між різними параметрами [1].

Застосування трансформерів у аналізі часових рядів продемонструвало значні переваги, зокрема здатність опрацьовувати довгострокові залежності та висока продуктивність в аналізі даних у реальному часі.

Запропонована в цій роботі система розв'язує питання, пов'язані з обмеженнями, за допомогою застосування адаптованих трансформерів, таких як *Timesformer* та *Informer*, що забезпечують ефективний аналіз часових рядів, зважаючи як на довгострокові, так і короткострокові залежності. Основними перевагами запропонованого підходу є виявлення багатофакторних аномалій – використання трансформерів дає змогу ідентифікувати складні

аномалії в режимі реального часу навіть за умов багатовимірних відхилень у різних компонентах системи.

Також система здатна використовувати історичні дані для передбачення майбутніх загроз, що допомагає запобігати потенційним збоєм і порушенням у роботі інфраструктури, і застосовувати автономне налаштування: з огляду на виявлені аномалії та прогнозовані проблеми, система може автоматично запускати процеси оптимізації, щоб забезпечити стабільну та енергоефективну роботу інфраструктури.

**Метою статті** є розроблення та впровадження автономної системи моніторингу ІТ-інфраструктури, що здатна здійснювати багатofакторний аналіз у реальному часі та автономно реагувати на виявлені загрози. У роботі вперше запропоновано трансформерну модель для складного моніторингу часових рядів, модифіковано архітектуру трансформера для потреб багатовимірного аналізу ІТ-інфраструктури, розроблено механізм автономної оптимізації на основі прогнозування проблем. Досягнуті результати мають потенціал для подальшого розвитку сучасних підходів до управління ІТ-інфраструктурою в умовах динамічного середовища.




Рис. 1. Основні компоненти системи

Визначальний принцип роботи системи передбачає декілька ітерацій, перша з яких – генерація та попереднє оброблення інформації. Система генерує синтетичні дані, до яких додаються аномальні відхилення для моделювання потенційних проблем у ІТ-інфраструктурі. Дані масштабуються й перетворюються в послідовності для подачі на вхід трансформерної моделі. Наступний етап – навчання трансформера з використанням крос-валідації [1]. Дані проходять п'ятикратну крос-валідацію, де модель навчається і перевіряється на валідаційних наборах. Параметри моделі, зокрема кількість шарів, розмір вектора ознак і кількість голів уваги, оптимізовані для точного виявлення аномалій у послідовностях. Упровадження крос-валідації дає змогу визначити найкращі параметри для запобігання

## Розв'язання завдання

Розроблена система для моніторингу та аналізу ІТ-інфраструктури містить кілька ключових модулів, що забезпечують збір і попереднє оброблення інформації, навчання моделі на основі трансформерів для виявлення аномалій, оцінювання якості моделі за допомогою крос-валідації, а також візуалізацію результатів прогнозування та аналізу аномалій. Основні компоненти системи (рис. 1):

- модуль збору та генерації даних;
- модуль попереднього оброблення та підготовки інформації: для забезпечення стабільності моделі всі параметри нормалізуються з використанням *StandardScaler*;
- модуль моделі на основі трансформера: модель, яку застосовує система, є трансформером, налаштованим на оброблення багатовимірних часових рядів;
- модуль крос-валідації: для оцінювання стабільності та узагальненості моделі реалізовано п'ятикратну крос-валідацію;
- модуль візуалізації результатів: система генерує візуальні графіки для аналізу якості роботи моделі. Зокрема для кожного фолду крос-валідації будується графік динаміки втрат.

перенавчання. Після цього починається прогнозування та оцінювання якості моделі. Після навчання модель застосовується до тестових даних для отримання прогнозів використання CPU. Порівнюючи реальні значення з прогнозами, система ідентифікує відхилення, які вказують на можливі аномалії. Якість моделі визначається за допомогою метрик MAE та RMSE, що дає змогу оцінити похибку моделі [2]. Наприкінці візуалізуються результати й аналізуються аномалії. Результати подаються у вигляді графіків, що відбивають реальні значення та прогнозовані дані, а також гістограму розподілу залишків, що дає змогу оцінити точність роботи моделі та її здатність фіксувати аномалії (рис. 2).



Рис. 2. Узагальнена схема принципу роботи системи

## Матеріали й методи

Для створення навчального й тестового наборів використовуються синтетичні дані, що моделюють поведінку ключових параметрів ІТ-інфраструктури, таких як:

- використання CPU (*cpu\_usage*);
- використання пам'яті (*memory\_usage*);
- мережевий трафік (*network\_traffic*);
- температура сервера (*temperature*);
- енергоспоживання (*energy\_consumption*).

Кожен із цих параметрів генерується з використанням періодичних функцій (синусоїд і косинусоїд) з додаванням нормального шуму, що дає змогу створити реалістичний часовий ряд. Наприклад, застосування CPU моделюється так:

$$cpu\_usage = np.\sin(np.linspace(0, 50, num\_samples)) * 20 + 50 + np.random.randn(num\_samples) * 5.$$

Інші параметри моделюються аналогічним способом.

Аномальні значення додаються до деяких відліків у кожному параметрі для тестування здатності моделі виявляти аномалії. Зміна значень в окремих точках призводить до значних відхилень, що допомагає оцінити здатність моделі фіксувати аномалії. Щоб забезпечити стабільне навчання моделі, дані кожного параметра нормалізуються до стандартного розподілу із середнім значенням 0 та стандартним відхиленням 1 [3]. Цей процес описується такою формулою:

$$x_i = \frac{x_i - \mu_x}{\sigma_x}, \quad (1)$$

де  $x_i$  – значення показника;  $\mu_x$  – середнє значення;  $\sigma_x$  – стандартне відхилення.

Оскільки модель працює з часовими рядами, дані організуються у послідовності фіксованої довжини  $L$  (наприклад, 30 відліків) [4]. Цей процес створює фрагменти даних, де кожен фрагмент має  $L$  відліків, що дає змогу моделі аналізувати часову динаміку змін. Формалізовано це виглядає так:

$$X = \{(x_i, x_{i+1}, \dots, x_{i+L-1}), y_{i+L}\}, \quad (2)$$

де  $X$  – вхідна послідовність;  $y$  – цільова змінна для прогнозування;  $i$  – початкова точка фрагменту.

## Архітектура трансформера для аналізу аномалій

Модель для аналізу часових рядів побудована на основі трансформера, що містить кілька шарів з увагою, *feed-forward*-шари і позиційне кодування. Трансформери, зокрема *Timesformer* та *Informer*, демонструють високу ефективність у задачах аналізу багатовимірних часових рядів завдяки здатності моделювати довгострокові залежності [5].

Трансформер не використовує рекурентні зв'язки, тому потребує позиційного кодування для врахування порядку елементів у послідовності [6]. Позиційне кодування додається до вхідного вектора  $x_i$  у вигляді додаткових ознак і розраховується за формулами:

$$PE(pos, 2i) = \sin\left(\frac{pos}{10000^{2i/d}}\right) \quad (3)$$

$$PE(pos, 2i+1) = \cos\left(\frac{pos}{10000^{2i/d}}\right), \quad (4)$$

де  $pos$  – позиція в послідовності;  $i$  – індекс ознаки;  $d$  – розмірність вхідного вектора. Позиційне

кодування додається до вхідного вектора  $x_i$ , забезпечуючи необхідну інформацію про порядок елементів у послідовності. Механізм *multi-head attention* є ключовим компонентом трансформера, що дає змогу моделювати залежності між елементами вхідної послідовності [7]. Він обчислює кілька паралельних *head* уваги, кожна з яких розраховується за формулою:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (5)$$

де  $Q, K, V$  – матриці запитів, ключів та значень;  $d_k$  – розмірність простору ключів. Механізм *multi-head attention* сприяє одночасному зосередженню на різних аспектах взаємозв'язків між елементами. Вихід обчислюється як конкатенація всіх голів (*head*), після чого застосовується лінійна трансформація:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O, \quad (6)$$

де  $h$  – кількість голів;  $W^O$  – матриця ваг.

Кожен блок трансформера також містить два *feed-forward*-шари з нелінійністю ReLU [8]. Вхідні дані проходять крізь два лінійні шари, що дає змогу моделі навчати більш складні залежності:

$$\text{FFN}(x) = \max(0, xW_1 + b_1)W_2 + b_2, \quad (7)$$

де  $W_1$  і  $W_2$  – матриці ваг;  $b_1$  і  $b_2$  – зміщення [9]. Функція втрат, яка мінімізується під час навчання, –

це середньоквадратична похибка (*Mean Squared Error*, MSE), що обчислюється як

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (8)$$

де  $y_i$  – справжнє значення;  $\hat{y}_i$  – прогнозоване значення. MSE підходить для задачі прогнозування та забезпечує чутливість до значних помилок, що корисно у виявленні аномалій.

### Навчання моделі та гіперпараметри

Для оцінювання узагальненості моделі застосовується п'ятикратна крос-валідація, що дає змогу визначити стабільність і точність моделі на різних підмножинах даних. Крос-валідація розділяє дані на п'ять непересічних наборів, де кожен з них використовується один раз як валідаційний набір, а чотири інші слугують для навчання [10].

Крос-валідація забезпечує більш стійкі результати, оскільки дає змогу моделі зважати на різні аспекти даних під час навчання. Кожен фолд обчислює середні значення втрат для навчального й валідаційного наборів, що допомагає оцінити рівень узагальненості моделі. Процес крос-валідації зображено на рис. 3.

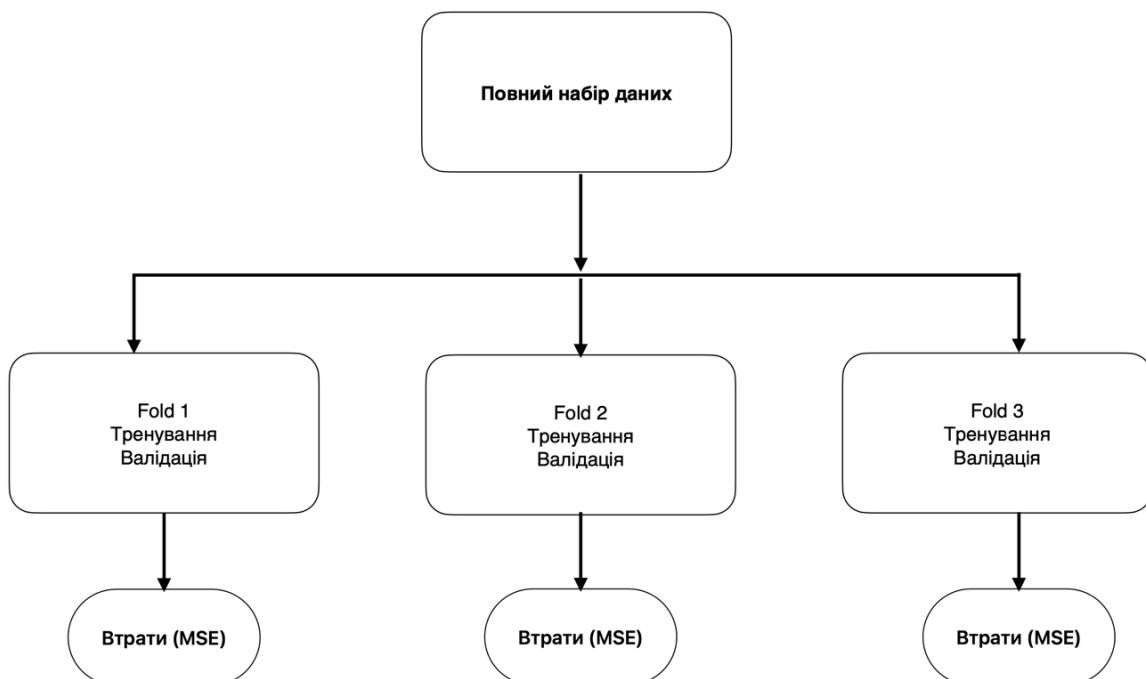


Рис. 3. Процес крос-валідації

Щоб уникнути перенавчання, застосовують метод ранньої зупинки, який завершує навчання, якщо функція втрат на валідаційних даних не покращується протягом визначеного числа епох. У реалізації це значення встановлено на 10. Це означає, що навчання припиняється, якщо впродовж десяти епох модель не демонструє покращення на валідаційному наборі.

Додатково для підвищення стабільності навчання використовують адаптивні регулятори швидкості навчання (*Learning Rate Scheduler*) [11], які зменшують коефіцієнт навчання на 50 % у разі, якщо втрати на валідаційних даних не покращуються протягом трьох епох. Це дає змогу моделі більш повільно оновлювати ваги на пізніх етапах навчання, забезпечуючи кращу збіжність.

Функція втрат, що використовується для оптимізації, – це середньоквадратична похибка (*Mean Squared Error*, MSE). MSE забезпечує чутливість до великих помилок, що є корисним для завдань, де критично важливо виявляти значні відхилення від нормального стану.

### Метрики оцінювання точності та якості

Для оцінювання ефективності моделі та її здатності виявляти аномалії використовують кілька метрик, що дають змогу провести кількісний аналіз якості прогнозів. Основними метриками є середня абсолютна похибка (*Mean Absolute Error*, MAE), корінь середньоквадратичної похибки (*Root Mean Squared Error*, RMSE). RMSE є чутливішою до великих похибок, ніж MAE, і забезпечує більше значення для завдань, де великі помилки є критичними.

Система реалізована на основі мови *Python* з використанням сучасних бібліотек для нейронних мереж, машинного навчання та оброблення даних, що допомагає ефективно працювати з часовими рядами, навчати модель, здійснювати крос-валідацію та оцінювати точність прогнозів. Основні бібліотеки та фреймворки:

– *PyTorch* – обраний як основний фреймворк для побудови трансформерної моделі. *PyTorch* надає інструменти для створення складних нейронних мереж і забезпечує високу ефективність у виконанні на GPU, що особливо важливо для навчання глибоких моделей;

– *scikit-learn* – використовується для попереднього оброблення даних і масштабування ознак, що дає змогу підготувати вхідні дані у відповідному форматі. Крім цього, *scikit-learn* забезпечує зручні методи для обчислення метрик точності (MAE, RMSE), необхідних для оцінювання продуктивності моделі;

– *NumPy* – застосовується для роботи з багатовимірними масивами даних і математичними операціями, такими як масштабування та підготовка векторів, що покращує швидкість виконання операцій;

– *Matplotlib* та *Seaborn* – інструменти для створення візуалізацій, що використовуються для аналізу втрат на навчальних і валідаційних даних, а також для візуалізації залишків та інших показників, що допомагають оцінити якість роботи моделі.

### Етапи навчання моделі

*Генерація синтетичних даних.* Для тренування моделі генеруються синтетичні дані про роботу IT-інфраструктури, що містять показники, зокрема використання CPU, пам'ять, мережевий трафік, температура й енергоспоживання [12]. Ці дані генеруються як часові ряди, до яких додається випадковий шум, що дає змогу моделі навчитися зважати на варіативність у реальних системах.

*Введення аномалій.* До обраних точок даних додаються аномальні відхилення, що моделюють потенційні проблеми в IT-інфраструктурі. Це дає змогу перевірити, як модель справляється з виявленням таких аномалій і чи може вона диференціювати їх від нормальних варіацій.

*Масштабування даних.* Щоб запобігти впливу різниці в масштабах між параметрами, кожен показник нормалізується до стандартного розподілу з середнім значенням 0 і стандартним відхиленням 1 [13]. Це сприяє більш стабільному навчальному процесу та запобігає домінуванню будь-якої ознаки у вхідних даних.

*Формування послідовностей.* Для забезпечення моделі контекстом послідовності дані розбиваються на фрагменти фіксованої довжини. Кожен фрагмент – це часовий проміжок, що дає змогу моделі брати до уваги часову динаміку параметрів. Цільова змінна для кожної послідовності є значенням CPU у наступний момент часу, що моделює завдання прогнозування.

**Позиційне кодування.** Оскільки трансформери не використовують рекурентних зв'язків, позиційне кодування дає змогу зважати на порядок елементів у послідовності [14]. Для цього застосовуються синусоїдальні функції, які додаються до кожного вектора вхідних даних, надаючи інформацію про позицію елементів у послідовності.

**Механізм багатоголової уваги.** Модель використовує кілька голів уваги, що аналізують різні аспекти взаємозв'язків між елементами вхідної послідовності. Багатоголова увага допомагає моделі більш ефективно захоплювати як короткострокові, так і довгострокові залежності, що є критичним для виявлення аномалій у багатофакторних часових рядах.

**Feed-forward-шари.** Кожен блок трансформера містить *feed-forward*-шари, які обробляють вбудовані подання після уваги, застосовуючи нелінійну функцію активації [15]. Це дає змогу моделі навчатися більш складних залежностей між ознаками та завдяки цьому підвищувати точність прогнозування.

Для мінімізації функції втрат використовують алгоритм оптимізації *AdamW*, який бере до уваги адаптивну швидкість навчання з ваговим спадом (*weight decay*), що запобігає перенавчанню. Функцією втрат обрано середньоквадратичну похибку (*Mean Squared Error*, MSE), яка підходить для завдань прогнозування, забезпечуючи чутливість до значних помилок.

Для забезпечення стабільної продуктивності моделі застосовується п'ятикратна крос-валідація. Кожен фолд розбиває дані на навчальний та валідаційний набори, де модель навчається на більшій частині даних, а перевіряється на валідаційному наборі. Це дає змогу уникнути перенавчання та оцінити, наскільки модель здатна узагальнювати залежності на різних підмножинах даних.

Щоб уникнути перенавчання, в процесі навчання використовується рання зупинка: якщо валідаційні втрати не знижуються протягом кількох епох поспіль, навчання припиняється. Крім того, застосовується динамічне зменшення швидкості навчання, яке активується, якщо втрати на валідаційних даних не покращуються впродовж визначеного числа епох, що сприяє більш точному налаштуванню ваги на пізніх етапах навчання.

## Результати досліджень та їх обговорення

Результати експериментів на синтетичних даних показують здатність моделі виявляти аномалії та

прогнозувати використання CPU в IT-інфраструктурі. Модель пройшла навчання за допомогою п'ятикратної крос-валідації, що дало змогу оцінити її стабільність і узагальненість. Нижче наведено детальний аналіз досягнутих результатів. Основними метриками оцінювання моделі є *Mean Absolute Error* (MAE) та *Root Mean Squared Error* (RMSE), що вказують на середню абсолютну похибку та середньоквадратичне відхилення відповідно.

MAE для моделі становить 4.3001, що означає середню похибку прогнозу в межах 4.3%.

RMSE становить 5.5387, що свідчить про те, що модель має більшу чутливість до великих помилок, хоча загальна точність залишається на прийнятному рівні.

Такі результати вказують на здатність моделі фіксувати тенденції у використанні CPU, але також на присутність незначних відхилень, що можуть бути спричинені як особливостями генерації синтетичних даних, так і потенційними обмеженнями архітектури моделі.

Графік крос-валідації, на якому показано динаміку втрат (*Train Loss* і *Validation Loss*) для кожного з п'яти фолдів, свідчить про стабільну роботу моделі на навчальних і валідаційних даних (рис. 4).

Різниця між *Train Loss* і *Val Loss* для кожного фолду вказує на відсутність суттєвого перенавчання, а також на стабільність збіжності для кожного набору даних. Зокрема після 40–60 епох модель досягає стабільних значень втрат як на навчальних, так і на валідаційних даних. Діаграма динаміки втрат для різних фолдів підтверджує, що модель досягає збіжності внаслідок регуляризації (*dropout*) та механізму ранньої зупинки, що забезпечує стабільність навчання та запобігає перенавчанню.

Теплова карта кореляцій між параметрами демонструє взаємозв'язки між основними показниками IT-інфраструктури. Найбільш значуща кореляція спостерігається між використанням CPU та енергоспоживанням (коефіцієнт кореляції – 0.75), що вказує на взаємозалежність між навантаженням на процесор та рівнем споживання енергії. Інші параметри мають нижчий рівень кореляції, що вказує на їх незалежність. Це є важливим для побудови багатофакторної моделі (рис. 5).

Теплова карта кореляцій дає змогу також оцінити, які параметри необхідно брати до уваги в аналізі аномалій, оскільки сильні кореляції можуть впливати на точність прогнозів.

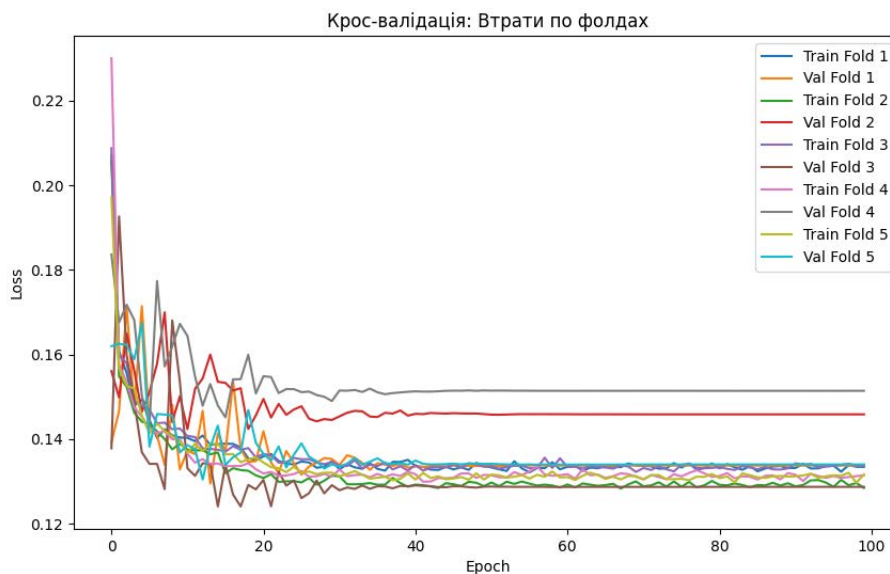


Рис. 4. Графік крос-валідації

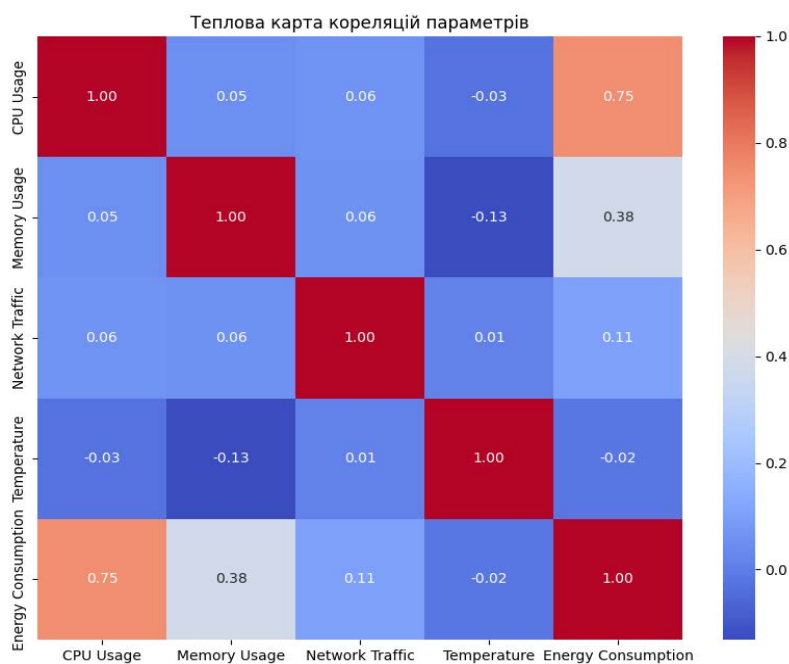


Рис. 5. Теплова карта кореляції між параметрами

Гістограма розподілу залишків показує симетричний розподіл із середнім, близьким до нуля, що є позитивною ознакою для моделі, оскільки свідчить про відсутність систематичних похибок у прогнозуванні (рис. 6). Більшість залишків зосереджені навколо нуля, що вказує на високу точність моделі в процесі прогнозування звичайних значень.

Присутність незначної кількості великих залишків вказує на відносно рідкісні великі відхилення, що можуть бути спричинені аномальними подіями або значними коливаннями в синтетичних даних.

Це наголошує на важливості налаштування моделі для виявлення таких великих залишків, як потенційних аномалій.

Графік прогнозування аномалій демонструє, що модель успішно слідкує за трендом реальних значень і точно відтворює нормальні коливання у використанні CPU (рис. 7). Червоні точки на графіку позначають контрольовані аномалії, що були додані до даних під час генерації. Ці точки збігаються з підвищеними значеннями в прогнозах моделі, що вказує на її здатність фіксувати різкі зміни та відхилення.

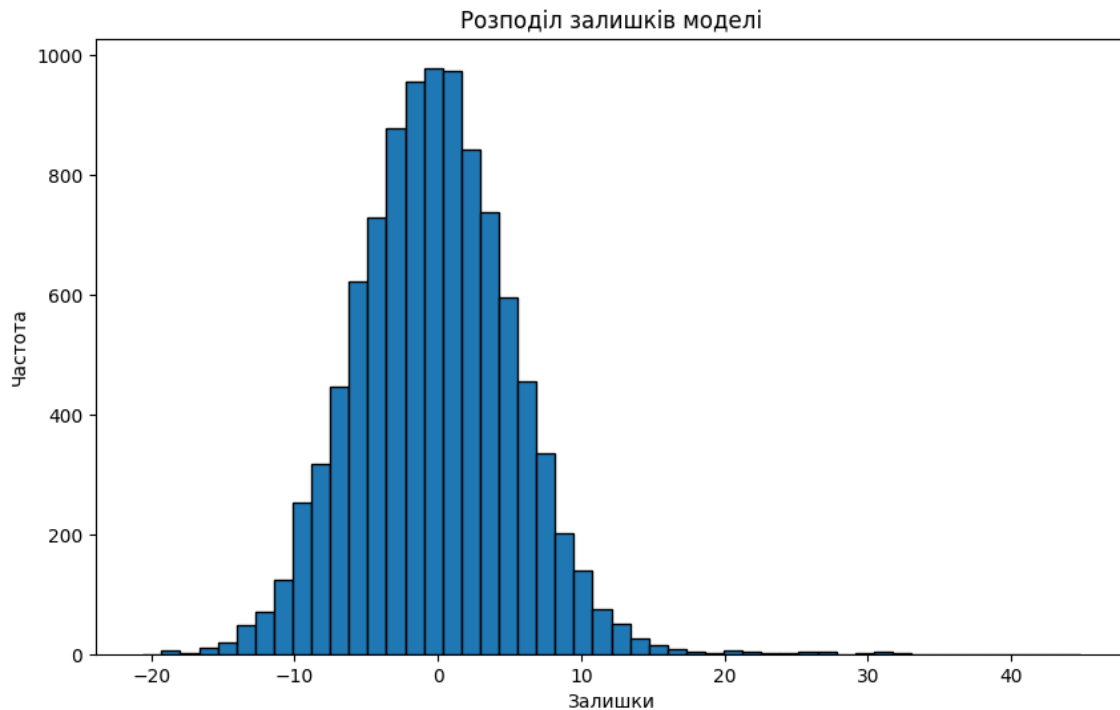


Рис. 6. Гістограма розподілу залишків




Рис. 7. Графік прогнозування аномалій

Аналіз графіка прогнозування вказує на високу чутливість моделі до різких змін у даних, що є критично важливим для вчасного виявлення аномалій в умовах реального часу. Це підтверджує можливість використання моделі для автоматичного виявлення відхилень у критичних параметрах ІТ-інфраструктури.

### Висновки

Досягнуті результати експериментів підтверджують високу здатність моделі до аналізу багатofакторних часових рядів і виявлення аномалій. Крос-валідація

демонструє стабільність навчання без значного перенавчання, тоді як розподіл залишків свідчить про відсутність систематичних похибок у прогнозах. Графіки кореляцій та прогнозів підтверджують, що модель успішно фіксує ключові взаємозв'язки між параметрами та вчасно реагує на значні відхилення.

Основні результати доводять, що розроблена система є ефективною для завдань моніторингу та прогнозування в ІТ-інфраструктурі та може бути використана як основа для подальшого розширення функціональності, наприклад, для виявлення більш комплексних типів аномалій та інтеграції із системами автономного налаштування.



**Список літератури**

1. Mykhailichenko I., Ivashchenko H., Barkovska O., Liashenko O., Application of Deep Neural Network for Real-Time Voice Command Recognition, *2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek)*, Kharkiv, Ukraine, 2022, P. 1–4, DOI: 10.1109/KhPIWeek57572.2022.9916473
2. Barkovska O., Pyvovarova D., Kholiiv V., Ivashchenko H., Rosinskyi D. Model zberezhenia informatsiinykh obektiv iz pryskorenymy metodamy obrobky tekstiv, *CEUR Workshop Proceedings*. 2021. № 2870. P. 286–299. DOI: 10.20944/preprints202412.2147.v1
3. Hunko M., Tkachov V., Liashenko O., Rabchan Y. Arkhitektura zastosunku dlia otrymannia danykh iz naukometrychnykh baz danykh // *Materialy konferentsii IEEE 3rd KhPI Week on Advanced Technology, KhPI Week 2022*. 2022. DOI: 10.1109/KhPIWeek57572.2022.9916473
4. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I. Attention is All You Need. *Advances in Neural Information Processing Systems*. Vol. 30. 2017. P. 5998–6008. DOI: 10.48550/arXiv.1706.03762
5. Wu H., Xu J., Wang L., Chen K. Long-Term Time-Series Forecasting with Triangular Matrix-Based Attention. *Proceedings of the 9th International Conference on Learning Representations (ICLR)*. 2021. 15 p. DOI: 10.48550/arXiv.2106.13008
6. Машинне навчання у виявленні аномалій / Л. Г. Кравченко та ін. *Системний аналіз і прикладна інформатика*. 2018. № 5. С. 90–102.
7. Informer: новий підхід до прогнозування / В. О. Мельник та ін. *Журнал штучного інтелекту*. 2019. № 4. С. 12–25.
8. Василенко В. О., Петров І. М. Методи виявлення аномалій у багатовимірних часових рядах. Київ, 2019. 256 с.
9. Lin T., Guo T., Wang K., Xu J. A Survey on Transformer Architectures in Time Series Applications. *arXiv*, 2021. 29 p. DOI: 10.48550/arXiv.2106.13008
10. Li S., Jin X., Xuan Y., Zhou X., Chen W., Wang Y.-X., Yan X. Enhancing the Locality and Breaking the Memory Bottleneck of Transformer on Time Series Forecasting. *Advances in Neural Information Processing Systems*. Vol. 32. 2019. P. 5243–5253. DOI: 10.48550/arXiv.1907.00235
11. Aggarwal C. C. *Outlier Analysis*. 2nd ed. Cham: Springer, 2017. 466 p. DOI: 10.1007/978-3-319-47578-3
12. Іванченко М. С., Гриценко О. В. Застосування трансформерів у аналізі часових рядів. Львів, 2021. 220 с.
13. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge, 2016. 775 p. DOI: 10.5555/3086952
14. Zhou T. et al. Fedformer: Frequency Enhanced Decomposed Transformer for Long-Term Series Forecasting. *International Conference on Machine Learning*. 2022. P. 27268–27286. URL: <https://proceedings.mlr.press/v162/zhou22g.html>
15. Zhou H. et al. Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*. Vol. 35. No. 12. 2021. P. 11106–11115. DOI: <https://doi.org/10.1609/aaai.v35i12.17325>

**References**

1. Mykhailichenko, I., Ivashchenko, H., Barkovska, O., Liashenko, O., (2022), "Application of Deep Neural Network for Real-Time Voice Command Recognition ", *2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek)*, Kharkiv, Ukraine, 2022, P. 1-4, DOI: 10.1109/KhPIWeek57572.2022.9916473
2. Barkovska, O., Pyvovarova, D., Kholiiv, V., Ivashchenko, H., Rosinskyi, D. (2021), "Model for Preserving Information Objects with Accelerated Text Processing Methods" ["Model zberezhenia informatsiinykh obektiv iz pryskorenymy metodamy obrobky tekstiv"], *CEUR Workshop Proceedings*, No. 2870, P. 286–299. DOI: 10.20944/preprints202412.2147.v1
3. Hunko, M., Tkachov, V., Liashenko, O., Rabchan, Y. (2022), "Application Architecture for Retrieving Data from Scientometric Databases" ["Arkhitektura zastosunku dlia otrymannia danykh iz naukometrychnykh baz danykh"], *IEEE 3rd KhPI Week on Advanced Technology, KhPI Week 2022*. DOI: 10.1109/KhPIWeek57572.2022.9916473
4. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., Polosukhin, I. (2017), "Attention is All You Need", *Advances in Neural Information Processing Systems*, Vol. 30, P. 5998–6008. DOI: 10.48550/arXiv.1706.03762
5. Wu, H., Xu, J., Wang, L., Chen, K. (2021), "Long-Term Time-Series Forecasting with Triangular Matrix-Based Attention", *Proceedings of the 9th International Conference on Learning Representations (ICLR)*, 15 p. DOI: 10.48550/arXiv.2106.13008
6. Kravchenko, L. H., et al. (2018), "Machine Learning in Anomaly Detection" ["Mashynne navchannia u vyvavlenni anomalii"], *System Analysis and Applied Informatics*, No. 5, P. 90–102.
7. Melnyk, V. O., et al. (2019), "Informer: A New Approach to Forecasting" ["Informer: novyi pidkhdid do prohnouzuvannia"], *Journal of Artificial Intelligence*, No. 4, P. 12–25.
8. Vasylenko, V. O., Petrov, I. M. (2019), "Methods for Anomaly Detection in Multidimensional Time Series" ["Metody vyvavlennia anomalii u bahatovymirnykh chasovykh riadakh"], Kyiv, 256 p.
9. Lin, T., Guo, T., Wang, K., Xu, J. (2021), "A Survey on Transformer Architectures in Time Series Applications", *arXiv*, 29 p. DOI: 10.48550/arXiv.2106.13008
10. Li, S., Jin, X., Xuan, Y., Zhou, X., Chen, W., Wang, Y.-X., Yan, X. (2019), "Enhancing the Locality and Breaking the Memory Bottleneck of Transformer on Time Series Forecasting", *Advances in Neural Information Processing Systems*, Vol. 32, P. 5243–5253. DOI: 10.48550/arXiv.1907.00235

11. Aggarwal, C. C. (2017), "Outlier Analysis", 2nd ed., *Springer*, Cham, 466 p. DOI: 10.1007/978-3-319-47578-3
12. Ivanchenko, M. S., Hrytsenko, O. V. (2021), "Application of Transformers in Time Series Analysis" ["Zastosuvannya transformeriv u analizi chasovykh riadiv"], Lviv, 220 p.
13. Goodfellow, I., Bengio, Y., Courville, A. (2016), "Deep Learning", Cambridge, 775 p. DOI: 10.5555/3086952
14. Zhou, T., et al. (2022), "Fedformer: Frequency Enhanced Decomposed Transformer for Long-Term Series Forecasting", *International Conference on Machine Learning*, P. 27268–27286. available at: <https://proceedings.mlr.press/v162/zhou22g.html>
15. Zhou, H., et al. (2021), "Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting", *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 35, No. 12, P. 11106–11115. DOI: <https://doi.org/10.1609/aaai.v35i12.17325>

*Надійшла (Received) 01.03.2025*

*Відомості про авторів / About the Authors*

**Ляшенко Олексій Сергійович** – кандидат технічних наук, доцент, Харківський національний університет радіоелектроніки, декан факультету комп'ютерної інженерії та управління, Харків; Україна; e-mail: [oleksii.liashenko@nure.ua](mailto:oleksii.liashenko@nure.ua); ORCID ID: <https://orcid.org/0000-0002-0146-3934>

**Михайліченко Ігор Володимирович** – Харківський національний університет радіоелектроніки, асистент кафедри електронних обчислювальних машин, Харків; Україна, e-mail: [igor.mykhailichenko@nure.ua](mailto:igor.mykhailichenko@nure.ua); ORCID ID: <https://orcid.org/0009-0005-5476-8992>

**Liashenko Oleksii** – PhD (Computer Engineering Science), Associate Professor, Kharkiv National University of Radio Electronics, Dean at the Faculty of Computer Engineering and Management, Kharkiv, Ukraine.

**Mykhailichenko Ihor** – Kharkiv National University of Radio Electronics, Assistant at the Department of Electronic Computing Machines, Kharkiv, Ukraine.

## AUTONOMOUS MONITORING AND OPTIMIZATION SYSTEM FOR IT INFRASTRUCTURE USING TRANSFORMERS

The **subject matter** of the article is an autonomous IT infrastructure monitoring and optimization system using transformers for analyzing multidimensional time series and detecting anomalies in real time. The study reviews current approaches to IT infrastructure monitoring, including machine learning and traditional statistical methods. A literature review reveals that existing methods often lack efficiency in dynamically changing system parameters. The **goal** of this research is to develop an autonomous system capable of performing real-time multifactor analysis and autonomously responding to detected threats. A transformer-based model is proposed, allowing for complex anomaly detection and failure prediction. The methodology includes mathematical modeling, machine learning (transformers), statistical analysis (cross-validation), and time series forecasting. The following **tasks** were solved in the article: formulation of a model for multidimensional time series analysis, development of an algorithm for anomaly detection and problem forecasting, implementation of autonomous adjustment mechanisms for stabilizing IT infrastructure. The following **methods** used are – mathematical modeling, machine learning methods (transformers), statistical analysis (cross-validation), and forecasting algorithms based on time series. The following **results** the model achieved a mean absolute error (MAE) of 4.3% on synthetic data, confirming its ability to accurately detect anomalies. Cross-validation validated the stability of training without overfitting, while a residual histogram showed a symmetrical error distribution. Additionally, correlation heatmaps highlighted interdependencies between key IT infrastructure parameters. **Conclusions:** the proposed system effectively detects and predicts IT infrastructure failures, ensuring autonomous parameter adjustment to maintain stability. The developed approach can be integrated into modern IT infrastructure management systems to enhance operational efficiency.

**Keywords:** autonomous system; transformers; multidimensional time series; IT infrastructure; anomaly detection; forecasting.

*Бібліографічні описи / Bibliographic descriptions*

Ляшенко О. С., Михайліченко І. В. Модель автономної системи моніторингу та оптимізації ІТ-інфраструктури з використанням трансформерів. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 73–82. DOI: <https://doi.org/10.30837/2522-9818.2025.1.073>

Liashenko, O., Mykhailichenko, I. (2025), "Autonomous monitoring and optimization system for IT infrastructure using transformers", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 73–82. DOI: <https://doi.org/10.30837/2522-9818.2025.1.073>

Ю. МАЦЕЛЮХ, В. ЛИТВИН

## МЕТОД К-СЕРЕДНІХ ДЛЯ АНАЛІЗУ ДАНИХ З ОРГАНІЗАЦІЇ ПАСАЖИРСЬКИХ ПЕРЕВЕЗЕНЬ У РОЗУМНОМУ МІСТІ

Щороку методи кластеризації великих даних набувають популярності в прийнятті рішень з організації пасажирських перевезень у розумному місті, забезпечуючи ефективність, адаптивність і екологічність транспортної системи. Актуальність зазначених методів зумовлена зростанням обсягів даних, зміною попиту та негативним впливом транспорту на довкілля. **Об'єктом дослідження** є процес кластеризації масивів даних з організації пасажирських перевезень. **Предмет дослідження** – засади вивчення метрик кластеризації в процесі обчислення кількості кластерів виконання графіків перевезень. **Мета роботи** полягає в застосуванні з огляду на метрики якості методу К-середніх для кластеризації даних з організації пасажирських перевезень у розумному місті. Для досягнення мети необхідно виконати такі завдання: дослідити особливості методів кластеризації та їх метрик; проаналізувати масштабний неоднорідний набір даних щодо тривалості перегонів електротранспортом у середньому за розмірами міста; розробити ефективний алгоритм вибору методу обчислення кількості кластерів на основі метрик оцінювання якості кластеризації даних. Упроваджено **методи** аналізу, синтезу, узагальнення, порівняння, групування, кластерного аналізу, системного аналізу, метод К-середніх. **Досягнуті результати.** Установлено, що вибір методу кластеризації залежить від особливостей завдання, характеристик даних і цілей аналізу транспортних потоків. Виявлено складну, неоднорідну й необроблену структуру даних щодо тривалості перегонів електротранспортом. Кластерний аналіз методом К-середніх зумовлено потребою в точному розподілі даних між кластерами. Запропоновано алгоритм вибору методу обчислення кількості кластерів на основі метрик оцінювання якості кластеризації даних, серед яких метод ліктя, метод силуету та індекс Калінського – Харабаша. Рекомендовано застосовувати кластеризацію для створення маршрутів із скороченим часом очікування, меншою кількістю пересадок та відповідністю до потреб пасажирів. **Висновки.** Метод К-середніх використано для аналізу тривалості виконання перегонів електротранспортом. Аналіз даних виявив ділянки маршрутів із різною інтенсивністю транспортних потоків, що залежить від сезонності, їх розташування в міських зонах тощо. Запропоновано алгоритм вибору методу обчислення кількості кластерів на основі внутрішніх метрик.

**Ключові слова:** пасажирські перевезення; розумне місто; кластерний аналіз; метод К-середніх; системний аналіз.

### Вступ

Питання організації пасажирських перевезень у розумному місті тісно пов'язано з пошуком ефективних методів і засобів, що забезпечують оптимальну динамічну взаємодію з транспортом під час організації пасажирських перевезень. В організації пасажирських перевезень важливо брати до уваги різноманітні показники, зокрема маршрути руху, час очікування, тривалість виконання графіків, зміни трафіку, завантаженість транспортних засобів, погодні умови, екологічну ефективність, індивідуальні потреби пасажирів тощо. Зібрані великі масиви даних потребують належного зберігання, відповідного аналізу, ефективного групування та якісної кластеризації.

**Актуальність проблеми** задекларована на світовому рівні в багатьох документах (угодах, комюніке, деклараціях тощо). Міжнародні організації, зокрема ООН і ЄС, активно підтримують ініціативи щодо зниження викидів парникових газів

у міських агломераціях. Нині проблема організації низьковуглецевих пасажирських перевезень є надзвичайно актуальною через глобальне потепління та зростання потреби в екологічно чистих транспортних засобах. Розумне місто, що використовує сучасні технології та системи управління, може стати ефективним інструментом для досягнення визначених цілей.

Розв'язання окресленої проблеми неможливе без використання методів і засобів теорії системного аналізу та інструментів інформаційних систем. З погляду системного аналізу та інформаційних систем проблема організації низьковуглецевих пасажирських перевезень є складником комплексних систем управління транспортними потоками. Системний підхід дає змогу розглядати всі компоненти системи (транспортні засоби, інфраструктуру, пасажирів) як взаємопов'язані елементи, що впливають один на одного. Інформаційні системи відіграють провідну роль у зборі, обробленні та аналізі даних для оптимізації

маршрутів і часу очікування на транспорт, а також для моніторингу екологічних показників.

Проблема має неабияке **практичне значення**, що збільшується щороку й щоразу із впровадженням інтелектуальних систем динамічної взаємодії пасажирів з транспортними засобами в розумному місті, серед яких виокремимо такі: зниження викидів вуглецю, покращення якості життя, економія ресурсів і формування розумної міської інфраструктури. Зібрані масиви даних потребують належного та якісного аналізу, що неможливий без застосування ефективних алгоритмів кластеризації під час оптимізації маршрутів, упровадження екологічно чистих транспортних засобів на маршрутах, а також ефективної організації перевезень, спрямованої на зменшення часу очікування та завантаженості транспортних засобів, на покращення комфорту пасажирів, зниження викидів парникових газів, зменшення витрат на перевезення, оптимізацію використання транспортної інфраструктури та енергоефективні технології тощо. Загалом розв'язання окресленої проблеми робить вагомий внесок у розвиток розумних міст, які використовують сучасні технології для покращення якості життя мешканців. Тому пошук шляхів упровадження методів кластеризації, серед яких метод *K*-середніх, в організації пасажирських перевезень у розумному місті є важливим складником загальної проблеми розроблення методів і засобів динамічної взаємодії пасажирів із транспортними засобами й має вагоме практичне значення для розвитку низьковуглецевих пасажирських перевезень у громадському транспорті великих, середніх та малих міст. **Об'єктом дослідження** є процес кластеризації масивів даних з організації пасажирських перевезень, а **предметом** – засади вивчення метрик кластеризації під час обчислення кількості кластерів виконання графіків перевезень.

#### Аналіз останніх досліджень і публікацій

Провівши детальний огляд методів і засобів кластерного аналізу [1, 2], що використовуються для моделювання [3], оптимізації маршрутів [4], аналізу великих даних [5] з метою розроблення адаптивних алгоритмів для організації транспортної мережі в розумному місті [6, 7], з'ясували, що особлива увага приділяється моделям прийняття рішень для оптимізації пасажирських потоків з огляду на сучасні підходи, що ґрунтуються як на висхідних

(агломератних) [8, 9], так і на низхідних (дивізивних) [10] методах кластеризації, а також методам роздільної [11], нечіткої кластеризації [12], DBSCAN [13] та самоорганізованих карт [14]. Сучасні дослідження у галузі системного аналізу [15–17] підтверджують, що інтеграція методів кластеризації до системи управління транспортом сприяє створенню адаптивних, ефективних і низьковуглецевих моделей перевезень [18, 19]. Розвитку фундаментальних основ методів кластеризації в організації пасажирських перевезень, розробленню сучасних інформаційно-комунікаційних систем пасажирських перевезень громадським транспортом присвячені дослідження відомих науковців як в Україні, так і за її межами. Серед учених, чий внесок сприяв розвитку теоретичних засад і практичного досвіду застосування кластерного аналізу даних з організації пасажирських перевезень на основі концепції розумного міста, доцільно згадати таких: Дж. Бездек [20], М. Бублик [21, 22], М. Естер [23], А. Джейн [24], Т. Кохонен [25], Д. Коштура [26], В. Литвин [27], А. Лов [28], Н. Нат [29], Л. Сан [30], Р. Тібішрані [31].

Основними методами кластеризації, що використовують для аналізу великих даних у сфері організації пасажирських перевезень розумного міста [32–36], є ієрархічна кластеризація, роздільна кластеризація, кластеризація на основі щільності, сітки, штучні нейронні мережі. Вони дають змогу не лише зрозуміти індивідуальні потреби пасажирів і патерни споживання послуг, а й сприяють оптимізації ресурсів для задоволення цих потреб. Щоб виокремити, які методи кластеризації використовують для організації пасажиропотоків, було проведено порівняння основних методів кластеризації у сфері організації пасажирських перевезень розумного міста. Результати порівняльного аналізу наведено в табл. 1.

У разі ієрархічної кластеризації агломератні, або, як їх інакше називають, висхідні методи виходять з того, що кожен елемент у наборі даних є окремим кластером. Сам процес об'єднання двох найближчих кластерів до одного відбувається за певними правилами (за вказаною метрикою), доки не утвориться лише один кластер. Застосовуються висхідні методи для організації пасажиропотоків, коли потрібно визначити структуру маршрутів, і об'єднання відбувається за схожими ділянками маршрутів або територіями. У дивізивних, або низхідних, методах, навпаки, починають з одного

кластера, що містить усі дані, і розділяють його на менші кластери. Їх застосовують для організації пасажиропотоків, коли потрібно виокремити конкретні

маршрути або їх ділянки (перегони, зони) з різною інтенсивністю пасажиропотоку, щоб оптимізувати послуги в конкретних зонах.

**Таблиця 1.** Результати порівняльного аналізу основних методів кластеризації у сфері організації пасажирських перевезень у розумному місті (складено авторами за джерелами [1–36])

Група кластеризації	Метод кластеризації	Сутність методу	Вимоги до даних	Особливості застосування в організації пасажирських перевезень
Ієрархічна	Агломератна ієрархія, або висхідний метод	створює на дендрограмі ієрархічну структуру, відстежує процес об'єднання або розділення кластерів знизу вгору на основі найближчих сусідів	потребує від невеликого до середнього набору даних	підходить для визначення структури транспортних маршрутів і аналогій у розподілі пасажиропотоків з огляду на динамічні зміни
	Дивізивна ієрархія, або низхідний метод	поєднує кластери зверху вниз на основі найближчих сусідів	потребує повної матриці відстаней між об'єктами	підходить для динамічного моделювання пасажиропотоків у різних часових інтервалах
Розділяюча	$K$ -середніх	поділяє дані на $k$ -кластери за найменшою відстанню до центрів, оптимізуючи внутрішню структуру	чисельні показники зі складним просторовим розподілом, попередньо нормалізовані, погано працює з якісними характеристиками	використовується для оптимізації маршрутизації транспорту за зонами попиту, а в статичних системах для розподілу пасажиропотоків за визначеними маршрутами
	$K$ -медоїд	групує об'єкти на $k$ -медоїдних точках, що є класичними представниками	потребує попередньої нормалізації даних	підходить для визначення центрів маси для оптимального розподілу транспортних засобів
	Нечітких $C$ -середніх	дає змогу елементам належати до кількох кластерів одночасно з різними ступенями належності	працює в складних системах із великою неоднозначністю та перекриттям між даними, працює з якісними характеристиками	використовується для створення більш гнучких та адаптивних зон міського транспорту, де пасажир одночасно належить до кількох зон
На основі щільності	DBSCAN	виявляє кластери будь-якої форми на основі щільності даних у просторі, знаходить шум	найкраще працює з даними з високою щільністю у певних ділянках, потребує значення мінімальної кількості точок у кластері	корисна для оброблення інформації про пасажиропотоки з різноманітними густинами на різних маршрутах, ідентифікує вузькі місця маршрутів і зони із значною концентрацією пасажирів
Сітка	STING або CLIQUE	поділяє простір на ґрид, кластеризує дані у вказаних окремих комірках за допомогою структурованих ієрархічних інтервалів	розмір і розділ ґрида впливає на ефективність, розбиття даних на менші групи дає кращі результати	аналізує пасажиропотоки у великому місті на основі зонування, корисна для класифікації маршрутів за часовими інтервалами та густиною пасажиропотоків
Штучні нейронні мережі	Самоорганізованих карт	використовує алгоритми навчання для самоорганізації вхідних даних у кластери, використовує самоорганізаційні карти	потребує значної кількості інформації для навчання нейронної мережі, попередньої нормалізації даних та розбиття на менші групи для аналізу	використовується для оптимізації ресурсів на основі здобутих даних з попередньої інформації у процесі прогнозування пасажиропотоків і створення динамічних моделей пасажиропотоків з огляду на часові інтервали

У разі роздільної кластеризації метод  $K$ -середніх розподіляє дані на кластери, знаходячи середню

точку в кожному кластері та повторюючи цей процес до досягнення стабільного розподілу. Зазначений

метод обов'язково точно розподіляє дані, де кожен об'єкт належить лише одному класу. Проте він погано адаптований для даних з непростим розподілом або з якісними характеристиками. Метод *K*-середніх ефективний для зонування транспортної мережі, наприклад, для оптимізації маршрутів за зонами попиту. Метод *K*-медоїд виявляє центри кластерів, що мають найбільш можливий відрив від загального пасажиропотоку. Особливістю цього методу є більша стійкість до шуму. Використовується він для оптимізації робочого графіку транспортних засобів, визначення оптимального розташування зупинок на маршрутах, наприклад станцій метро, здатних покривати значні потреби пасажирів. Метод нечіткої кластеризації *C*-середніх допомагає створити більш гнучкі та адаптивні стратегії управління пасажиропотоками, що важливо в сучасних міських середовищах із динамічною природою попиту на транспортні послуги. Цей метод відрізняється від традиційного методу *K*-середніх тим, що дає змогу елементам належати до кількох кластерів одночасно з різними ступенями належності. Це означає, що кожен елемент має певну ймовірність, за якою він належить до кожного з *k*-кластерів. У зазначеному методі використовується функція належності, що визначає ступінь належності елемента до кожного з можливих кластерів. Метою оптимального розподілу є мінімізація функції, яка бере до уваги як відстань до центрів кластерів, так і ступені належності. Дає найкращі результати в складних системах з великою неоднозначністю та перекриттям між даними. Використовується для створення більш гнучких та адаптивних зон міського транспорту, де пасажир одночасно належить до кількох зон, зважаючи на непередбачуваність попиту, наприклад, зміни пасажиропотоку протягом доби або за різних погодних умов. Виявляє патерни, невидимі для інших методів, що можуть бути важливими в розробленні стратегій оптимізації. Використання *C*-середніх дає точнішу картину сегментування користувачів транспорту, знижує ризик надлишкових або недостатніх обсягів послуг на певних ділянках транспортної мережі. Метод також ефективний для передбачення змішаних потреб та їх впливу на розподіл кластерів, покращуючи цим прийняття стратегічних рішень в організації транспорту.

У класифікації на основі щільності найбільш відомим є метод DBSCAN, що найчастіше використовується для аналізу пасажиропотоків

із різноманітною густиною на маршрутах та для визначення кластерів з огляду на часову динаміку. У класифікації на основі сітки метод STING розбиває для аналізу дані на більш малі групи, щоб створити моделі часових інтервалів та густину. З-поміж штучних нейронних мереж, що використовують для кластеризації, найпоширенішим є метод самоорганізованих карт, який дає змогу створити динамічні карти пасажиропотоків, зважаючи на часові інтервали та густину на різних маршрутах, проте він потребує значної кількості даних для навчання нейронної мережі, попередньої їх нормалізації та розбиття на менші групи для аналізу.

Отже, кожен метод кластеризації має переваги й може бути застосований у різних сценаріях для ефективної організації та оптимізації пасажирських перевезень у розумному місті. Вибір методу залежить від особливостей завдання, характеристик даних і цілей, що висуваються для аналізу транспортних і пасажирських потоків. Висхідні методи кластеризації застосовуються, коли потрібно визначити структуру маршрутів, об'єднати схожі ділянки маршрутів або прилеглих до маршруту територій. Низхідні методи – коли потрібно виокремити деякі маршрути або їх ділянки (перегони, зони) з різною інтенсивністю пасажиропотоків у конкретних зонах. Метод роздільної кластеризації *K*-середніх корисний для зонування транспортної мережі в процесі оптимізації маршрутів за тривалістю виконання перегонів, за зонами попиту тощо. Метод роздільної кластеризації *K*-медоїд завдяки більшій стійкості до шуму застосовують для оптимізації робочого графіка транспортних засобів, визначення оптимального розташування зупинок на маршрутах для задоволення потреб пасажирів. Метод нечіткої кластеризації *C*-середніх – у розробленні більш гнучких і адаптивних стратегій управління пасажиропотоками в сучасних міських середовищах з динамічною природою попиту на транспортні послуги. Метод DBSCAN найчастіше використовують для аналізу пасажиропотоків із різноманітною густиною на різних маршрутах та для кластеризації з огляду на часову динаміку. Метод самоорганізованих карт – для створення динамічних карт пасажиропотоків, зважаючи на часові інтервали та густину на різних маршрутах.

У розумному місті створюється величезна кількість даних із різних джерел, зокрема GPS-систем, мобільних застосунків, сенсорів, соціальних мереж та відеоспостережень. Оброблення таких значних

обсягів інформації є критично важливим для прийняття обґрунтованих рішень у сфері пасажирських перевезень. Потоки пасажирів постійно змінюються залежно від часу доби, дня тижня, погоди, соціальних подій тощо. Методи кластеризації дають змогу виокремити ключові групи або патерни в таких потоках для кращого розуміння їх природи. Методи кластеризації є основою багатьох сучасних алгоритмів штучного інтелекту. Використання інтелектуальних транспортних систем (ITS) [37–41] потребує складних алгоритмів аналізу та моделювання для виявлення оптимальних шляхів і управління транспортною мережею. Ефективна кластеризація даних сприяє оптимізації маршрутів, зменшенню часу простою та обсягів викидів, що є важливим у контексті боротьби зі змінами клімату. Таке групування є надзвичайно важливим для розроблення адаптивних алгоритмів оптимізації маршрутів, адже воно дає змогу ефективно розподіляти транспортні ресурси, знижувати час очікування та мінімізувати викиди вуглецевмісних сполук.

Як зазначає М. Бублик [42], концепція розумної спеціалізації для трансформації української економіки передбачає не лише оптимізацію господарської діяльності транспортних компаній, але й перехід до зеленої економіки, де значну роль відіграє зниження викидів CO<sub>2</sub> завдяки впровадженню інноваційних рішень у транспортну індустрію. В основі інноваційних моделей для зменшення обсягів викидів в атмосферу лежить концепція техносолітону, що розробив М. Бублик [43, 44]. У межах концепції оцінено шкоду та збитки в дуже забруднювальних секторах економіки, яким тривалі роки залишається транспорт. Концепція техносолітону набуває особливого значення для розроблення стратегій організації пасажирських перевезень, оскільки оптимізація маршрутів за допомогою методу *K*-середніх дає змогу не лише покращити якість обслуговування, але й зменшити викиди в атмосферу, що має вирішальне значення для досягнення цілей сталого розвитку [45–50].

#### **Визначення не розв'язаних раніше частин загальної проблеми. Мета роботи, завдання**

Проведений вище аналіз останніх досліджень проблеми застосування методів кластеризації, серед яких метод *K*-середніх, в організації пасажирських перевезень у розумному місті дає змогу підсумувати, що недостатньо розв'язаним

залишається питання впливу методів визначення закономірностей пасажиропотоків, оптимізації транспортних маршрутів і підвищення ефективності мережі в режимі реального часу на покращення комфорту пасажирів, зниження викидів парникових газів, зменшення витрат на перевезення, оптимізацію використання транспортної інфраструктури та енергоефективні технології тощо. Недостатньо також приділено увагу пошуку ефективних способів застосування алгоритмів кластеризації під час оптимізації маршрутів, у впровадженні екологічно чистих маршрутів, а також під час ефективної організації перевезень, спрямованої на зменшення часу очікування пасажирами загалом чи завантаженості транспортних засобів зокрема. Це вказує на необхідність наукових досліджень у зазначеному напрямі, а саме застосуванні з огляду на метрики якості методу *K*-середніх для кластеризації даних з організації пасажирських перевезень у розумному місті, що і є **метою цієї роботи**.

Відповідно до мети окреслено такі **завдання**: дослідження особливостей методів кластеризації та їх метрик; аналіз масштабного неоднорідного набору даних щодо тривалості перегонів електротранспортом у середньому за розмірами місті; розроблення ефективного алгоритму вибору методу обчислення кількості кластерів на основі метрик оцінювання якості кластеризації даних.

#### **Матеріали й методи**

Для аналізу даних після їх порівняння та групування було обрано метод кластерного аналізу *K*-середніх. Особливістю застосування методів кластеризації даних є вибір метрики відстані, яку серед багатьох інших різних показників необхідно обирати з огляду на її відповідність до конкретного прикладу. У нашому випадку це дослідження набору даних про рух низьковуглецевих транспортних засобів на одному маршруті в середньому за розмірами міста, тому для цього використано евклідову відстань, що описується формулою

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (1)$$

де  $x = (x_1, x_2, \dots, x_n)$  – вектор характеристики точки  $x$ , що містить  $n$  компонент;  $y = (y_1, y_2, \dots, y_n)$  – вектор характеристики точки  $y$ , який містить  $n$  компонент;  $i$  – індекс для кожного з атрибутів (номер атрибута).

Вибір кількості кластерів безпосередньо впливає на якість кластеризації, тому важливо обрати оптимальну кількість кластерів для набору даних. Ми обрали метод ліктя, що передбачає аналіз залежності суми квадратичних відстаней  $SSE(k)$  між точками й центрами їх кластерів від величини  $k$ . Сума квадратичних відстаней обчислюється за формулою

$$SSE(k) = \sum_{i=1}^k \sum_{x_j \in C_i} |x_j - \mu_i|^2, \quad (2)$$

де  $SSE(k)$  – сума квадратичних відстаней;  $k$  – кількість кластерів;  $x_j$  – точка в наборі даних, що належить кластеру  $C_j (x_j \in C_j)$ ;  $\mu_i$  – центр  $i$ -го кластера.

Алгоритм методу  $K$ -середніх є одним із найбільш поширених, що використовується для розбиття набору даних на  $k$  кластерів. Він працює ітеративно, мінімізуючи суму квадратів відстаней точок до центрів кластерів. Алгоритм методу  $K$ -середніх має чотири етапи: ініціалізацію, призначення точок до кластерів, оновлення центрів кластерів і перевірку критерію зупинки.

Ініціалізація передбачає вибір  $k$  початкових центрів кластерів  $\mu_1, \mu_2, \dots, \mu_k$  випадковим чином або за допомогою спеціальних стратегій, а також призначення точок до кластерів. Кожен елемент даних  $x_i$  призначається до найближчого центра  $\mu_k$  кластера за критерієм найменшої відстані, для обчислення якого використовується формула

$$c_i = \arg \min_k \|x_i - \mu_k\|^2, \quad (3)$$

де  $c_i$  – кластер, до якого призначається точка  $x_i$ ;  $\|x_i - \mu_k\|^2$  – квадрат евклідової відстані.

Оновлення центрів кластерів відбувається щоразу, коли додається нова точка до кластера. Розглядається послідовно кожна точка, виділена в кластер, до якого вона розташована ближче за критерієм найменшої відстані. Після призначення всіх точок до кластерів обчислюється новий центр  $\mu_k$  кожного кластера як середнє значення всіх точок, що до нього належать:

$$\mu_k = \frac{1}{|S_k|} \sum_{x_i \in S_k} x_i, \quad (4)$$

де  $S_k$  – множина точок, що належать до  $k$ -го кластера.

Центроїд послідовно перераховується щоразу, коли додається нова точка до кластера, тобто коли

змінюється розбиття точок на кластери, тоді змінюються координати центроїдів на нові. Щоб бути впевненим, що кожна точка була оптимально призначена в правильний кластер, порівнюється відстань кожної точки кластера до центра свого власного кластера та до центра найближчого протилежного кластера за формулою

$$C_{opt} = \sum_{k=1}^K \sum_{x_i \in S_k} \operatorname{argmin}_k |x_i - \mu_k|^2. \quad (5)$$

Ітераційне перенесення точок триває в процесі кожного нового поділу на кластери доти, доки останній поділ не буде визнано остаточним результатом кластеризації.

Перевірка критерію зупинки вказує на зупинку алгоритму. Алгоритм кластеризації завершується, якщо центри кластерів перестають змінюватися або зміни є незначними. Інакше повертаємось до кроку 2. Цілком можливо, що алгоритм  $K$ -середніх не знайде остаточного рішення. У цьому разі доцільно встановити зупинку алгоритму після того, як алгоритм досягне попередньо обраного максимального значення ітерацій. Отже, алгоритм  $K$ -середніх ітеративно покращує розподіл точок між кластерами, зменшуючи значення функції втрат.

### Результати досліджень та їх обговорення

У нашому випадку кластеризація здійснювалася з використанням набору даних про тривалість виконання перегонів низьковуглецевим громадським транспортом у межах середнього за розміром міста. Саме тут аналізується час виконання перегону упродовж однієї години всіма транспортними засобами, що перебувають на маршруті, у межах одного маршруту для кожного тижня протягом року. Структура даних має такий вигляд: Номер запису; Геозона; Планований час прибуття; Фактичний час прибуття; Місяць; День; Час; Дата; Тиждень; Година; День тижня; Робочий / вихідний; Перегін 1; Тривалість 1; Перегін 2; Тривалість 2; Перегін 3; Тривалість 3; ... Перегін 10; Тривалість 10.

Унаслідок аналізу зібраних даних про тривалість виконання кожного перегону транспортними засобами в межах кожної доби для кожного тижня протягом досліджуваного періоду було виявлено, що вони мають складну, неоднорідну й великомасштабну структуру, тому потребують відповідного оброблення перед початком аналізу. Після очищення й групування даних було отримано матрицю виконання



графіків перевезень пасажирів транспортними засобами на кожному з десятих перегонів із середніми значеннями тривалості перегону для кожного тижня впродовж десяти місяців. Як приклад,

у табл. 2 наведено тривалість виконання перегону в середньому за добу протягом кожного тижня досліджуваного періоду.

**Таблиця 2.** Середньодобова тривалість виконання кожного перегону транспортними засобами для кожного тижня (розрахунок авторів відповідно до зібраної інформації)

Перегін Тиж- день	Час виконання перегону 1	Час виконання перегону 2	Час виконання перегону 3	Час виконання перегону 4	Час виконання перегону 5	Час виконання перегону 6	Час виконання перегону 7	Час виконання перегону 8	Час виконання перегону 9	Час виконання перегону 10
9	00:03:04	00:02:14	00:02:35	00:03:16	00:03:42	00:02:25	00:02:22	00:01:56	00:01:44	00:02:03
10	00:03:10	00:02:17	00:02:48	00:03:21	00:03:24	00:02:22	00:02:25	00:01:59	00:01:46	00:01:57
11	00:03:09	00:02:02	00:02:25	00:03:26	00:03:24	00:02:24	00:02:23	00:02:00	00:01:41	00:01:55
12	00:03:08	00:02:04	00:02:22	00:03:21	00:03:15	00:02:26	00:02:24	00:01:59	00:01:46	00:01:58
13	00:03:28	00:02:08	00:02:09	00:03:18	00:03:58	00:02:22	00:02:25	00:02:01	00:01:43	00:01:58
14	00:03:16	00:02:01	00:02:25	00:03:19	00:03:18	00:02:19	00:02:19	00:01:56	00:01:40	00:01:53
15	00:03:21	00:02:02	00:02:07	00:03:14	00:03:06	00:02:20	00:02:22	00:01:57	00:01:45	00:01:53
16	00:04:00	00:02:56	00:02:42	00:03:24	00:03:09	00:02:16	00:02:25	00:01:56	00:01:39	00:01:52
17	00:04:05	00:02:23	00:02:15	00:03:10	00:03:08	00:02:20	00:02:20	00:01:54	00:01:40	00:01:48
18	00:04:02	00:02:04	00:01:50	00:02:47	00:02:50	00:02:22	00:02:14	00:01:55	00:01:39	00:01:53
19	00:04:05	00:02:05	00:02:12	00:03:08	00:03:05	00:02:23	00:02:20	00:01:58	00:01:42	00:01:55
20	00:03:23	00:02:27	00:02:07	00:03:12	00:03:13	00:02:23	00:02:22	00:01:58	00:01:41	00:01:52
21	00:04:27	00:04:19	00:03:31	00:03:54	00:03:24	00:02:36	00:02:22	00:02:06	00:01:45	00:01:54
22	00:03:26	00:03:51	00:03:17	00:03:19	00:03:52	00:02:32	00:02:26	00:01:58	00:01:41	00:01:52
27	00:04:21	00:03:49	00:02:13	00:03:15	00:03:00	00:02:24	00:02:17	00:01:59	00:01:42	00:01:55
28	00:04:51	00:04:23	00:02:16	00:03:06	00:02:55	00:02:22	00:02:14	00:01:58	00:01:42	00:01:57
29	00:04:44	00:03:44	00:02:06	00:02:57	00:02:55	00:02:22	00:02:16	00:01:59	00:01:42	00:01:57
30	00:04:08	00:04:01	00:02:07	00:03:18	00:02:56	00:02:23	00:02:17	00:01:58	00:01:45	00:01:55
31	00:04:30	00:03:24	00:02:18	00:03:31	00:02:52	00:02:23	00:02:20	00:01:53	00:01:47	00:01:56
32	00:05:13	00:04:00	00:02:03	00:03:12	00:02:59	00:02:25	00:02:17	00:01:53	00:01:43	00:02:00
33	00:05:30	00:03:54	00:01:57	00:03:03	00:02:57	00:02:20	00:02:14	00:01:55	00:01:44	00:01:53
34	00:05:17	00:03:02	00:01:53	00:02:50	00:02:41	00:02:26	00:02:32	00:02:00	00:01:44	00:01:54
35	00:05:23	00:03:47	00:02:09	00:02:55	00:02:54	00:02:25	00:02:19	00:01:58	00:01:48	00:01:54
36	00:05:36	00:03:19	00:02:28	00:03:24	00:03:02	00:02:31	00:02:23	00:01:56	00:01:42	00:01:57
37	00:05:12	00:03:15	00:02:24	00:03:12	00:03:05	00:02:29	00:02:22	00:01:57	00:01:43	00:01:55
38	00:05:16	00:03:14	00:02:57	00:03:27	00:03:11	00:02:26	00:02:22	00:01:57	00:01:49	00:01:54
39	00:04:39	00:03:43	00:02:18	00:03:11	00:03:01	00:02:24	00:02:22	00:01:55	00:01:48	00:01:54
40	00:05:03	00:03:29	00:02:25	00:03:16	00:03:15	00:02:31	00:02:26	00:02:00	00:01:46	00:01:57
41	00:04:20	00:03:07	00:02:27	00:03:10	00:03:15	00:02:28	00:02:21	00:02:02	00:01:45	00:01:57
42	00:04:58	00:02:48	00:02:26	00:03:16	00:03:10	00:02:30	00:02:25	00:01:57	00:01:46	00:01:58
43	00:04:47	00:02:31	00:02:53	00:03:23	00:03:23	00:02:22	00:02:22	00:01:58	00:01:44	00:01:57
44	00:04:36	00:03:25	00:04:47	00:04:16	00:03:03	00:02:21	00:02:18	00:01:56	00:01:42	00:01:55
45	00:04:58	00:04:06	00:06:04	00:04:13	00:03:25	00:02:23	00:02:21	00:01:55	00:01:44	00:01:54
46	00:04:47	00:03:00	00:05:46	00:04:11	00:03:09	00:02:23	00:02:26	00:02:01	00:01:46	00:01:56
47	00:04:03	00:03:05	00:04:19	00:04:05	00:03:04	00:02:22	00:02:20	00:01:57	00:01:48	00:01:56
48	00:04:27	00:03:04	00:04:31	00:04:23	00:03:04	00:02:29	00:02:22	00:02:10	00:01:46	00:01:55
49	00:04:19	00:03:24	00:05:08	00:04:08	00:03:16	00:02:21	00:02:20	00:01:57	00:01:42	00:01:55
50	00:04:35	00:04:08	00:04:44	00:04:06	00:03:15	00:02:17	00:02:25	00:01:55	00:01:44	00:01:56
51	00:04:09	00:04:22	00:05:00	00:04:45	00:03:20	00:02:18	00:02:30	00:01:56	00:01:45	00:02:01
52	00:05:03	00:04:12	00:04:54	00:05:20	00:03:44	00:02:18	00:02:26	00:01:52	00:01:43	00:01:57

Бачимо, що середньодобова тривалість виконання перегонів у середньому за рік найвища для перегону 1 (00:04:22), а найнижча – для перегону 9 (00:01:44), що вказує на залежність пасажирських перевезень у середньому за розмірами міста від трафіку та типу перегону, бо перегін 1 – це перегін у середмісті з високою ймовірністю

виникнення заторів, а перегін 9 – це перегін на відокремленій саме для цього громадського транспорту лінії ізольованого типу. Усереднена для всього маршруту тривалість перегону для кожного тижня вказує на наявність сезонних залежностей кількості транспорту на дорогах, а також на вплив змін погоди на тривалість перегонів.

За результатами аналізу пасажирських перевезень у середньому за розміром місті виявлено, що середньодобова тривалість виконання кожного перегону для кожного тижня зростає з початком осінньо-зимового періоду й досягає максимуму на 52 тиждень року (00:03:21), менші від середніх значень середньодобової тривалості виконання кожного перегону спостерігаються у весняний період, у цьому разі мінімальне значення (00:02:22) припадає на 18 тиждень року (кінець квітня – початок травня).

Кластерний аналіз такого масштабного неоднорідного набору даних щодо тривалості виконання перегонів електротранспортом у межах середнього за розміром міста з розвинуеною мережею громадського транспорту проводився методом кластеризації  $K$ -середніх з огляду на його особливості обов'язково точного розподілу даних між кластерами.


Зазначимо, що існує кілька варіантів підбору оптимального значення кількості кластерів  $k$ , серед яких найчастіше застосовують метод ліктя, метод силуету та індексу Калінського – Харабаша. Метод ліктя розглядає суб'єктивно зрозумілі графіки характеру зміни розкиду точок ( $W_{total} \rightarrow \max$ ) від найбільшого значення для всіх точок в одному кластері до найменшого значення ( $W_{total} \rightarrow 0$ ) зі збільшенням кількості груп  $k$  ( $k \rightarrow n$ ).

Метод силуету вимірює, наскільки схожі точки в одному кластері порівняно з іншими кластерами.

Значення індексу силуету перебуває в діапазоні  $[-1, 1]$ , де більші значення вказують на кращу якість кластеризації. Цей метод оцінює, як добре точки розташовані всередині своїх кластерів порівняно з іншими кластерами. Більше значення коефіцієнта силуету вказує на кращу якість кластеризації.

Індекс Калінського – Харабаша, відомий ще під назвою "критерій співвідношення дисперсії", передбачає визначення співвідношення міжкластерного поділу до внутрішньо кластерної дисперсії, нормалізованого на їх число ступенів свободи. Найвище значення індексу Калінського – Харабаша вказує на те, що кластери визначено найбільш чітко. Хоча ця метрика найкраще підходить для розрахунку значення кількості кластерів, але має той самий недолік, що й коефіцієнт силуету – завищує оцінку для опуклих форм кластерів і занижує для складних форм кластерів.

З метою пошуку оптимальної кількості кластерів для набору даних із середньодобовими тривалостями виконання транспортними засобами кожного з перегонів протягом тижня на маршруті в середньому за розміром місті (табл. 2) було використано методи ліктя, силуету та Калінського – Харабаша. Результати оцінювання коефіцієнта загальної варіації точок всередині кластера щодо центра кластера  $SSE$  за методом ліктя подано на рис. 1. Оптимальне значення кількості кластерів становить  $k = 5$  зі значенням (рис. 1).



**Рис. 1.** Залежність величини  $SSE$  (*Sum of Squared Errors*) від кількості кластерів  $k$ , розрахована за методом ліктя, де синім позначено графік оцінки  $SSE(k)$  – ліва вісь, зеленим позначено очікуваний час навчання – права вісь (розрахунок авторів)

Результати оцінювання коефіцієнта силуету  $S_i$  за методом силуету наведено на рис. 2. У нашому випадку максимальне значення коефіцієнта силуету  $S_i = 0,507$  настає за умови  $k = 2$ , яке й вважається оптимальним значенням числа кластерів у процесі кластеризації (рис. 2). На рис. 3 наведено результати оцінювання індексу Калінського – Харабаша та відповідних до них значень числа кластерів. У нашому випадку максимальне значення індексу Калінського – Харабаша  $S = 56.186$  настає за умови  $k = 3$  (рис. 3), що вказує на оптимальне значення кількості кластерів для кластеризації даних.

У процесі кластеризації середньодобової тривалості виконання перегонів для кожного тижня за методом  $K$ -середніх було взято до уваги отримані результати розрахунку кількості кластерів  $k$  за допомогою методів ліктя, силуету та Калінського – Харабаша, відповідно,  $k = 5$ ,  $k = 2$  і  $k = 3$  (рис. 1–3). На рис. 4 подано розподіл даних (середньодобових значень тривалості виконання кожного перегону для кожного тижня протягом року) на кластери, отриманий для  $k = 2$  (а);  $k = 3$  (б) і  $k = 5$  (в).




Рис. 2. Залежність коефіцієнта силуету від величини кількості кластерів  $k$ , де синім позначено графік оцінки  $S_i(k)$  – ліва вісь, зеленим позначено очікуваний час навчання – права вісь (розрахунок авторів)


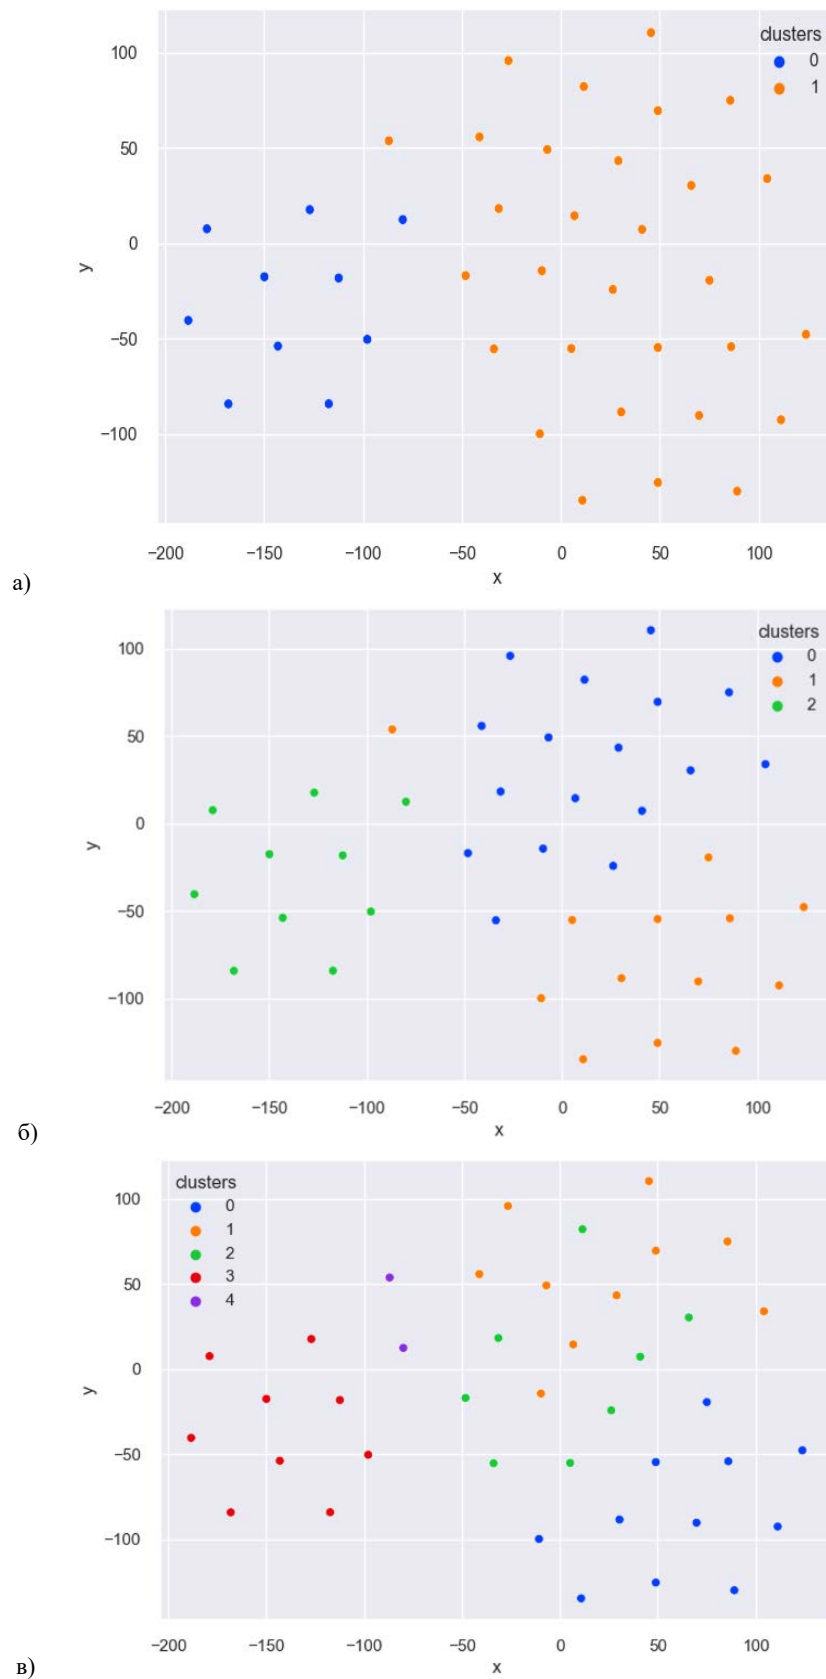


Рис. 3. Залежність індексу Калінського – Харабаша від величини кількості кластерів  $k$ , де синім позначено графік оцінки  $S(k)$  – ліва вісь, зеленим позначено очікуваний час навчання – права вісь (розрахунок авторів)



**Рис. 4.** Результати кластеризації середньодобових значень виконання графіків пасажирських перевезень для кожного тижня впродовж року на кожній ділянці (перегоні), а саме: а – кластеризація набору даних для  $k = 2$  ; б – кластеризація набору даних для  $k = 3$  ; в – кластеризація набору даних для  $k = 5$  (розрахунок авторів)

Виконаємо детальний аналіз розподілу даних на кластери. У процесі поділу на два кластери, де значення  $k = 2$  отримано за методом силуету, маємо кластери з номерами 0 і 1 (відповідно до рис. 4, а). Перший кластер під номером 0 утворюють дані виконання графіків пасажирських перевезень на кожному перегоні для тижнів 9–20 і 22–43 із середньодобовими значеннями, близькими до середнього чи меншими від нього (табл. 2 і 3). Другий кластер під номером 1 утворюють дані виконання графіків пасажирських перевезень на кожному перегоні для тижнів 21 і 44–52 із середньодобовими значеннями, значно вищими від середнього (табл. 2 і 3) як мінімум для двох перегонів. Цей кластер характеризується також наявністю тижнів (21, 45, 46, 50–52) із значним перевищенням (у 1,5–2 рази) середньодобових значень виконання графіків пасажирських перевезень на трьох і більше перегонах. Значна кількість таких перевищень припадає на осінньо-зимовий період, що зумовлено складними погодними умовами.

Унаслідок поділу на три кластери, де значення  $k = 3$  отримано за методом Калінського – Харабаша, маємо кластери з номерами 0, 1 і 2 (див. рис. 4, б). Перший кластер під номером 0 утворюють дані виконання графіків пасажирських перевезень для тижнів 21 і 44–52 із середньодобовими значеннями, значно вищими від середньорічного на кожному перегоні (табл. 2 і 3) переважно для трьох і більше перегонів. Цей кластер характеризується також наявністю тижнів (21, 44–46, 48, 50–52) із значним перевищенням середньодобових значень виконання графіків пасажирських перевезень на трьох і більше перегонах, що зумовлено складними погодними умовами в осінньо-зимовий період. Це вказує на залежність тривалості виконання перегонів від сезонності. Другий кластер під номером 1 утворюють дані виконання графіків пасажирських перевезень тільки для тижнів 9–20 і 22 із середньодобовими значеннями, меншими від середньорічного на кожному перегоні (табл. 2 і 3). Третій кластер під номером 2 утворюють дані виконання графіків пасажирських перевезень для тижнів 27–43 із середньодобовими значеннями, близькими до середньорічного на кожному перегоні, до того ж незначні перевищення середньорічної величини спостерігаються не більше як на двох перегонах протягом тижня (табл. 2 і 3).

**Таблиця 3.** Поділ на кластери за методом  $K$ -середніх середньодобової тривалості виконання кожного перегону транспортними засобами для кожного тижня (розрахунок авторів)

Тижень \ К-сть кластерів $k$	2	3	5
9	0	1	0
10	0	1	0
11	0	1	0
12	0	1	0
13	0	1	0
14	0	1	0
15	0	1	0
16	0	1	2
17	0	1	0
18	0	1	0
19	0	1	0
20	0	1	0
21	1	0	4
22	0	1	4
27	0	2	1
28	0	2	1
29	0	2	1
30	0	2	1
31	0	2	1
32	0	2	1
33	0	2	1
34	0	2	1
35	0	2	1
36	0	2	2
37	0	2	2
38	0	2	2
39	0	2	1
40	0	2	2
41	0	2	2
42	0	2	2
43	0	2	2
44	1	0	3
45	1	0	3
46	1	0	3
47	1	0	3
48	1	0	3
49	1	0	3
50	1	0	3
51	1	0	3
52	1	0	3

У процесі поділу на п'ять кластерів ( $k = 5$ ), значення якого отримано за методом ліктя (рис. 1), маємо кластери з номерами 0; 1; 2; 3 і 4, наведені на рис. 4, в. Перший кластер під номером 0 утворюють дані виконання графіків пасажирських перевезень на кожному перегоні для тижнів 9–15 і 17–20 із середньодобовими значеннями, меншими від середньорічного (табл. 2 і 3). Другий кластер під номером 1 утворюють дані виконання графіків пасажирських перевезень на кожному перегоні для

тижнів 27–35 і 39 із середньодобовими значеннями, вищими від середньорічного не більше як для двох перегонів (табл. 2 і 3). Третій кластер під номером 2 утворюють дані виконання графіків пасажирських перевезень для тижнів 16, 36–38 і 40–43 із середньодобовими значеннями, близькими до середньорічного майже на кожному перегоні (табл. 2 і 3), до того ж перевищення середньорічного значення спостерігається не більше як для одного перегону. Перевищення спостерігаються тільки для перегону в центрі міста, що вказує на залежність тривалості виконання перегонів від їх розташування в конкретних міських зонах. Четвертий кластер під номером 3 утворюють дані виконання графіків пасажирських перевезень для тижнів 44–52 із середньодобовими значеннями, значно вищими від середньорічного переважно на трьох і більше перегонах (табл. 2 і 3), що зумовлено наявністю сезонності досліджуваної залежності тривалості виконання перегонів. Цей кластер також характеризується наявністю тижнів 45 і 52 із значним перевищенням середньодобових значень виконання графіків пасажирських перевезень на п'ятьох перегонах, що може вказувати як на високий вплив трафіку разом із сезонністю. П'ятий кластер під номером 4 утворюють дані виконання графіків пасажирських перевезень тільки для тижнів 21 і 22 у літній період із середньодобовими значеннями, значно вищими від середньорічного на трьох і більше перегонах (табл. 2 і 3). Цей кластер вказує тільки на високий вплив трафіку на середньодобові значення виконання графіків пасажирських перевезень на перегонах у центрі міста. Необхідно звернути увагу, що жодних перевищень середньорічних значень виконання графіків не спостерігалось для перегонів 6–10, розташованих на ізольованій лінії, що виділена тільки для цього виду електротранспорту. Це вказує на оптимальний спосіб розв'язання проблем із пасажирськими перевезеннями громадським транспортом, однак він є складним, бо потребує значних інвестицій в інфраструктуру міста та є тривалим у реалізації.

Отже, кластерний аналіз великомасштабного неоднорідного набору даних щодо тривалості виконання перегонів електротранспортом у межах середнього за розмірами міста виявив окремі ділянки (перегони, зони) маршруту з різною інтенсивністю, на які значно впливають трафік, їх розташування в конкретних міських зонах (середмістя, спальний район тощо), а також сезонність.

Незважаючи на суб'єктивність визначення оптимального значення кількості кластерів за методом ліктя, бачимо, що поділ середньодобової тривалості виконання перегонів для кожного тижня на кластери дав найкращі результати для  $k = 5$ , де значення оцінки внутрішньокластерної загальної варіації точок всередині кластера щодо центра кластера  $SSE = 70896.042$  (рис. 1). Важливо звернути також увагу, що за умови  $k = 5$  значення коефіцієнта силуету  $S_i = 0,378$  і значення індексу Калінського – Харабаша  $S = 42.5086$  не є набагато меншими від максимальних значень відповідно до коефіцієнта силуету (рис. 2) та індексу Калінського – Харабаша (рис. 3).

Отже, можна стверджувати, що запропонований алгоритм вибору методу обчислення кількості кластерів на основі внутрішніх метрик оцінювання якості кластеризації даних, зібраних з інфраструктури пасажирських перевезень громадським транспортом у середньому за розміром міста, є достатньо простим та ефективним. До метрик кластеризації були додані метод ліктя, метод силуету та індекс Калінського – Харабаша, що дають змогу швидко й просто підібрати оптимальне значення кількості кластерів, а також зважати на особливості даних. Метод ліктя дає змогу брати до уваги внутрішньокластерну загальну варіацію точок усередині кластера щодо його центра, метод силуету вимірює, наскільки схожі точки в одному кластері порівняно з іншими кластерами, а найвище значенням індексу Калінського – Харабаша вказує на те, що кластери визначено найбільш чітко.

Алгоритм вибору оптимальної кількості кластерів можна узагальнити такими етапами:

- 1) вибір методу кластеризації, наприклад,  $K$ -середніх;
- 2) визначення діапазону кількості кластерів  $k$ , наприклад, від 2 до 10;
- 3) ітераційне застосування методу кластеризації для різних значень  $k$ ;
- 4) розрахунок результатів кластеризації та внутрішніх метрик оцінювання якості кластеризації;
- 5) аналіз метрик та вибір оптимальної кількості кластерів, що забезпечує баланс між якістю кластеризації (за метриками) та інтерпретованістю результатів з погляду предметної галузі (пасажирських перевезень);
- 6) візуальне оцінювання кластеризації для різних  $k$  з метою кращого розуміння структури даних.

Отже, виявлені методом кластеризації *K*-середніх перегони з високим перевищенням середньодобових значень тривалості виконання, порівняно із середньорічними, також вказують на зростання часу очікування пасажирів на зупинках, що позначається на кількості перевезених пасажирів та на якості наданих послуг. Це вказує на потребу прийняття обґрунтованих рішень у сфері пасажирських перевезень громадським транспортом у місті з метою його оптимізації.

Метод кластеризації *K*-середніх в аналізі середньодобової тривалості виконання кожного перегону транспортними засобами для кожного тижня протягом досліджуваного періоду рекомендуємо застосовувати для прийняття обґрунтованих рішень у сфері пасажирських перевезень громадським транспортом у розумному місті, а саме для оптимізації маршрутів, адаптації самої транспортної мережі, прогнозуванні та плануванні попиту на транспортні послуги, впровадженні персоналізованих послуг, а також в інтегруванні різних видів транспорту для створення єдиної ефективної багатомодальної транспортної системи.

Так, у процесі аналізу пасажиропотоків за допомогою методу кластеризації *K*-середніх виявлені зони високого попиту допоможуть створити оптимальні транспортні маршрути, які відповідають реальним потребам пасажирів у конкретний момент часу, скорочуючи час очікування та кількість пересадок до мінімально можливих. Цей метод кластеризації *K*-середніх також буде ефективний в аналізі змін потреб пасажирів і сприятиме адаптації маршрутів громадського транспорту до змін у попиті, наприклад, додавання нових зупинок, зміна розкладу руху транспортних засобів та їх графіків. Це також дасть змогу керівникам на рівні міської влади краще планувати інфраструктурні проекти та інвестиції в модернізацію транспортної системи з метою інтегрування різних видів транспорту (електротранспорт, звичайні автобуси, метро, якщо є) для створення єдиної ефективної транспортної системи. У розумному місті також є важливою персоналізація послуг, де основну роль відіграють мобільні застосунки для громадського транспорту, які для надання персоналізованих рекомендацій пасажирам про вибір оптимального маршруту чи часу поїздки використовуватимуть результати кластеризації тривалості виконання графіків перегонів у реальному часі. До основних проблем, які доцільно розв'язувати

із застосування кластеризації великих даних, є виокремлення кластерів пасажирів за типами (робітники, студенти, туристи тощо), визначення гарячих точок (районів із найвищим попитом на транспорт у певний час), виявлення неефективних маршрутів чи низького завантаження окремих ділянок транспортної мережі, аналіз залежності пасажиропотоків від зовнішніх чинників (погоди, подій у місті, соціальних тенденцій), а також побудова динамічних моделей прогнозування змін у потоках.

Отже, досягнуті результати кластерного аналізу середньодобової тривалості виконання кожного перегону транспортними засобами для кожного тижня протягом досліджуваного періоду мають практичну цінність в оптимізації маршрутів, адаптації самої транспортної мережі, прогнозуванні та плануванні попиту на транспортні послуги, впровадженні персоналізованих послуг, а також в інтегруванні різних видів транспорту для створення єдиної ефективної багатомодальної транспортної системи. Рекомендовано застосовувати кластеризацію для оптимізації маршрутів, а саме для створення оптимальних транспортних маршрутів, що мають скорочений час очікування та меншу кількість пересадок, а також відповідають реальним потребам пасажирів у визначений ними момент часу.

#### **Висновки й перспективи подальших досліджень**

З метою вивчення можливостей застосування методів кластеризації в організації пасажирських перевезень у розумному місті проаналізовано особливості їх застосування для покращення організації пасажирських перевезень громадським транспортом. Це дало змогу встановити, що вибір методу кластеризації залежить від специфіки поставленого завдання, характеристик даних і цілей, що висуваються для аналізу транспортних і пасажирських потоків. Так, висхідні методи кластеризації застосовують, коли потрібно визначити структуру маршрутів, об'єднати схожі ділянки маршрутів або прилеглих до маршруту територій. Низхідні методи впроваджують для виокремлення маршрутів або їх ділянок (перегонів, зон) із різною інтенсивністю пасажиропотоку з метою подальшої оптимізації послуги в конкретних зонах. Метод роздільної кластеризації *K*-середніх ефективний для зонування транспортної мережі, наприклад, під час оптимізації маршрутів за тривалістю виконання

перегонів, за зонами попиту тощо. Метод роздільної кластеризації *K*-медоїд є більш стійким до шуму, тому його використовують для оптимізації робочого графіку транспортних засобів, визначення оптимального розташування зупинок на маршрутах, щоб найкраще покрити потреби пасажирів. Метод нечіткої кластеризації *S*-середніх застосовують у розробленні більш гнучких та адаптивних стратегій управління пасажиропотоками, що важливо в сучасних міських середовищах з динамічною природою попиту на транспортні послуги. Метод DBSCAN, що класифікує елементи на основі щільності, найчастіше впроваджують для аналізу пасажиропотоків з різноманітною густиною на різних маршрутах та для кластеризації з огляду на часову динаміку. Метод самоорганізованих карт використовують у процесі кластеризації для створення динамічних карт пасажиропотоків, зважаючи на часові інтервали й густину на різних маршрутах.

Унаслідок проведення кластерного аналізу пасажирських перевезень у середньому за розміром місті з розвинутою мережею громадського транспорту виявлено, що зібрані дані про тривалість виконання кожного перегону транспортними засобами в межах кожної доби для кожного тижня протягом досліджуваного періоду мають складну, неоднорідну й масштабну структуру, тому потребують відповідного оброблення перед початком аналізу. Кластерний аналіз такого масштабного неоднорідного набору даних щодо тривалості виконання перегонів електротранспортом у межах середнього за розміром міста проводиться методом кластеризації *K*-середніх, оскільки цей метод, зменшуючи значення функції втрат, реалізує обов'язково точний розподіл даних, де кожен об'єкт належить лише одному класу.

Запропоновано простий та найбільш ефективний алгоритм вибору методу обчислення кількості кластерів на основі внутрішніх метрик оцінювання якості кластеризації даних, зібраних з інфраструктури пасажирських перевезень громадським транспортом у середньому за розміром місті. До метрик кластеризації додано метод ліктя, метод силуету та індекс Калінського – Харабаша, що дають змогу

швидко й просто підібрати оптимальне значення кількості кластерів. Метод ліктя допомагає встановити внутрішньокластерну загальну варіацію точок всередині кластера щодо його центра, метод силуету вимірює, наскільки схожі точки в одному кластері порівняно з іншими кластерами, а найвище значенням індексу Калінського – Харабаша вказує на те, що кластери визначено найбільш чітко.

Досягнуті результати кластерного аналізу середньодобової тривалості виконання кожного перегону транспортними засобами для кожного тижня протягом досліджуваного періоду мають практичну цінність в оптимізації маршрутів, адаптації самої транспортної мережі, прогнозуванні та плануванні попиту на транспортні послуги, впровадженні персоналізованих послуг, а також в інтегруванні різних видів транспорту для створення єдиної ефективної багатомодальної транспортної системи. Було рекомендовано застосовувати кластеризацію для оптимізації маршрутів, а саме для створення оптимальних транспортних маршрутів, що мають скорочений час очікування та меншу кількість пересадок, а також відповідають реальним потребам пасажирів у визначений ними момент часу.

Отже, метод кластеризації *K*-середніх в аналізі середньодобової тривалості виконання кожного перегону транспортними засобами для кожного тижня протягом досліджуваного періоду доцільно застосовувати для оптимізації організації пасажирських перевезень громадським транспортом у розумному місті.

Перспективою подальших досліджень є застосування кластеризації великих даних з метою виокремлення кластерів пасажирів за типами (робітники, студенти, туристи тощо), визначення гарячих точок (районів із найвищим попитом на транспорт у певний час), виявлення неефективних маршрутів чи низького завантаження окремих ділянок транспортної мережі, аналіз залежності пасажиропотоків від зовнішніх чинників (погоди, подій у місті, соціальних тенденцій), а також побудова динамічних моделей прогнозування змін у потоках.

## Список літератури

1. Saxena A., Prasad M., Gupta A., Bharill N., Patel O. P., Tiwari A., Er M. J., Ding W., Lin C. A review of clustering techniques and developments. *Neurocomputing*. 2017. No. 267. P. 664–681. DOI: 10.1016/j.neucom.2017.06.053
2. Isoli N., Chaczykowski M. Net energy analysis and net carbon benefits of CO<sub>2</sub> capture and transport infrastructure for energy applications and industrial clusters. *Applied Energy*. 2025. No. 382, 125227 p. DOI: 10.1016/j.apenergy.2024.125227



3. Kowalska-Styczeń A., Bublyk M., Lytvyn V. Green innovative economy remodeling based on economic complexity. *Journal of Open Innovation: Technology, Market, and Complexity*. 2023. V.9 (3), 100091 p. DOI: 10.1016/j.joitmc.2023.100091
4. Podlesna L., Bublyk M., Grybyk I., Matseliukh Y., Burov Y., Kravets P., Lozynska O., Karpov I., Peleshchak I., Peleshchak R. Optimization model of the buses number on the route based on queueing theory in a Smart City. *CEUR Workshop Proceedings*. 2020. Vol. 2631. P. 502–515. URL: <https://ceur-ws.org/Vol-2631/paper37.pdf> (дата звернення: 01.02.2025).
5. Bianchini D., De Antonellis V., Garda M. A big data exploration approach to exploit in-vehicle data for smart road maintenance. *Future Generation Computer Systems*. 2023. No. 149. P. 701–716. DOI: 10.1016/j.future.2023.08.004
6. Katrenko A., Krislata I. Veres O., Oborska O., Basyuk T., Vasyliuk A., Rishnyak I., Demyanovskyi N., Meh O. Development of traffic flows and smart parking system for smart city. *CEUR Workshop Proceedings*. 2020. Vol. 2604. P. 730–745. URL: <https://ceur-ws.org/Vol-2604/paper50.pdf> (дата звернення: 01.02.2025).
7. Matseliukh Y., Bublyk M., Vysotska V. Development of intelligent system for visual passenger flows simulation of public transport in Smart City based on neural network. *CEUR Workshop Proceedings*. 2021. Vol. 2870. P. 1087–1138. URL: <https://ceur-ws.org/Vol-2870/paper82.pdf> (дата звернення: 01.02.2025).
8. Visan M., Negrea S. L., Mone F. Towards intelligent public transport systems in Smart Cities; Collaborative decisions to be made. *Procedia Computer Science*. 2021. No. 199. P. 1221–1228. DOI: 10.1016/j.procs.2022.01.155
9. Ezugwu A. E., Ikotun A. M., Oyelade O. O., Abualigah L., Agushaka J. O., Eke C. I., Akinyelu A. A. A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. *Engineering Applications of Artificial Intelligence*. 2022. No. 110, 104743 p. DOI: 10.1016/j.engappai.2022.104743
10. Chavent M., Lechevallier Y., Briant O. DIVCLUS-T: A monothetic divisive hierarchical clustering method. *Computational Statistics & Data Analysis*. 2007. No. 52(2). P. 687–701. DOI: 10.1016/j.csda.2007.03.013
11. Celebi M. E., Kingravi H. A., Vela P. A. A comparative study of efficient initialization methods for the k-means clustering algorithm. *Expert Systems With Applications*. 2012. No. 40(1). P. 200–210. DOI: 10.1016/j.eswa.2012.07.021
12. Bublyk M., Kowalska-Styczeń A., Lytvyn V., Vysotska V. The Ukrainian economy transformation into the circular based on fuzzy-logic cluster analysis. *Energies*. 2021. No. 14(18). 5951 p. DOI: 10.3390/en14185951
13. Singh J., Singh D. A comprehensive review of clustering techniques in artificial intelligence for knowledge discovery: Taxonomy, challenges, applications and future prospects. *Advanced Engineering Informatics*. 2024. No. 62, 102799 p. DOI: 10.1016/j.aei.2024.102799
14. Yan J., Liu J., Tseng F. An evaluation system based on the self-organizing system framework of smart cities: A case study of smart transportation systems in China. *Technological Forecasting and Social Change*. 2020. No. 153, 119371 p. DOI: 10.1016/j.techfore.2018.07.009
15. Matseliukh Y., Vysotska V., Bublyk M. Intelligent system of visual simulation of passenger flows. *CEUR Workshop Proceedings*. 2020. Vol. 2604. P. 906–920. URL: <https://ceur-ws.org/Vol-2604/paper60.pdf> (дата звернення: 01.02.2025).
16. Prasetyo E. A., Novizayanti D., Putri A. N. A. Cluster analysis of potential autonomous vehicle (AV) adopters in Indonesia's new capital. *Transportation Research Interdisciplinary Perspectives*. 2024. No. 29, 101318 p. DOI: 10.1016/j.trip.2024.101318
17. Singh J., Singh D. A comprehensive review of clustering techniques in artificial intelligence for knowledge discovery: Taxonomy, challenges, applications and future prospects. *Advanced Engineering Informatics*. 2024. No. 62, 102799 p. DOI: 10.1016/j.aei.2024.102799
18. Liu J., Li J., Chen Y., Lian S., Zeng J., Geng M., Zheng S., Dong Y., He Y., Huang P., Zhao Z., Yan X., Hu Q., Wang L., Yang D., Zhu Z., Sun Y., Shang W., Wang D., Chen X. Multi-scale urban passenger transportation CO2 emission calculation platform for smart mobility management. *Applied Energy*. 2023. No. 331, 120407 p. DOI: 10.1016/j.apenergy.2022.120407
19. Matseliukh Y., Bublyk M., Bosak A., Naychuk-Khrushch M. The role of public transport network optimization in reducing carbon emissions. *CEUR Workshop Proceedings*. 2024. Vol. 3723. P. 340–364. URL: <https://ceur-ws.org/Vol-3723/paper19.pdf>
20. Bezdek J. C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Bon, Springer, 1981, 245 p.
21. Bublyk M., Vysotska V., Matseliukh Y., Mayik V., Nashkerska M. Assessing Losses of Human Capital Due to Man-Made Pollution Caused by Emergencies. *CEUR Workshop Proceedings*. 2020. Vol. 2805. P. 74–86. URL: <https://ceur-ws.org/Vol-2805/paper6.pdf> (дата звернення: 01.02.2025).
22. Бублик М.І., Бабій Т.І. Розвиток логістики в сучасних умовах функціонування ринку. *Науковий вісник НЛТУ України*. 2009. No. 19(6). С. 138–142.
23. Ester M., Kriegl H.-P., Sander J., Xu X. *A density-based algorithm for discovering clusters in large spatial databases with noise*. Proceedings of the Second International Conference on Knowledge Discovery and Data Mining. 1996. P. 226–231.
24. Jain A. K. Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*. 2010. No. 31(8). P. 651–666. DOI: 10.1016/j.patrec.2009.09.011
25. Kohonen T. *Self-Organizing Maps* (3rd ed.). Bon, Springer, 2001. 554 p.
26. Koshtura D., Bublyk M., Matseliukh Y., Dosyn D., Chyrun L., Lozynska O., Karpov I., Peleshchak I., Maslak M., Sachenko O. Analysis of the demand for bicycle use in a smart city based on machine learning. *CEUR workshop proceedings*. 2020. Vol. 2631, P. 172–183. URL: <https://ceur-ws.org/Vol-2631/paper13.pdf> (дата звернення: 01.02.2025).

27. Литвин В., Бублик М., Висоцька В., Мацелюх Ю. Технологія візуальної симуляції пасажиропотоків у сфері громадського транспорту Smart City. *Радіоелектроніка, інформатика, управління*. 2022. №4. С. 106–121. DOI: 10.15588/1607-3274-2021-4-10
28. Law A. M. *Simulation Modeling and Analysis* (5th ed.). Bon, McGraw-Hill, 2015. 495 p.
29. Nath N., Nitanai R., Manabe R., Murayama A. A global-scale review of smart city practice and research focusing on residential neighbourhoods. *Habitat International*. 2023. Vol. 142, P. 102963 p. DOI: 10.1016/j.habitatint.2023.102963
30. Sun L., Zhao J., Zhang J., Zhang F., Ye, K., Xu C. Activity-based individual travel regularity exploring with entropy-space K-means clustering using smart card data. *Physica A: Statistical Mechanics and its Applications*. 2024. No. 636, 129522 p. DOI: 10.1016/j.physa.2024.129522
31. Tibshirani R., Walther G., Hastie T. Estimating the number of clusters in a data set via the gap statistic. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*. 2001. No. 63(2). P. 411–423.
32. Subudhi S., Panigrahi S. Use of optimized Fuzzy C-Means clustering and supervised classifiers for automobile insurance fraud detection. *Journal of King Saud University – Computer and Information Sciences*. 2020. No. 32(5). P. 568–575. DOI: 10.1016/j.jksuci.2017.09.010
33. Duan Y., Liu C., Li S., Guo X., Yang C. An automatic affinity propagation clustering based on improved equilibrium optimizer and t-SNE for high-dimensional data. *Information Sciences*, 2023.No. 623. P. 434–454. DOI: 10.1016/j.ins.2022.12.057
34. Bide P., Shedje R. Improved document clustering using K-means algorithm. *2015 IEEE Int. Conf. on Electrical, Computer and Communication Technologies (ICECCT)*. New York: IEEE, 2015. 1048 p.
35. Zhong C., Miao D., Wang R., Zhou X. DIVFRP: An automatic divisive hierarchical clustering method based on the furthest reference points. *Pattern Recognition Letters*. 2008. No. 29(16). P. 2067–2077. DOI: 10.1016/j.patrec.2008.07.002
36. Elassy M., Al-Hattab M., Takruri M., Badawi S. Intelligent transportation systems for sustainable smart cities. *Transportation Engineering*. 2024. No. 16, 100252 p. DOI: 10.1016/j.treng.2024.100252
37. Zhu W. A spatial decision-making model of smart transportation and urban planning based on coupling principle and Internet of Things. *Computers and Electrical Engineering*. 2022. No. 102, 108222 p. DOI: 10.1016/j.compeleceng.2022.108222
38. Bushuev S., Inna L., Alla B., Alexander L., Khusainova M. Creating Urban Transportation Networks Grounded In the Principles of the Smart Port-City Paradigm. *Procedia Computer Science*. 2023. No. 231. P. 323–328. DOI: 10.1016/j.procs.2023.12.211
39. Balbin P. P., Barker J. C., Leung C. K., Tran M., Wall R. P., Cuzzocrea A. Predictive analytics on open big data for supporting smart transportation services. *Procedia Computer Science*. 2019. No. 176. P. 3009–3018. DOI: 10.1016/j.procs.2020.09.202
40. Khemakhem S., Krichen L. A comprehensive survey on an IoT-based smart public street lighting system application for smart cities. *Franklin Open*. 2024. No. 8, 100142 p. DOI: 10.1016/j.fraope.2024.100142
41. Vidović K., Čolić P., Vojvodić S., Blavicki A. Methodology for public transport mode detection using telecom big data sets: Case study in Croatia. *Transportation Research Procedia*. 2021. No. 64. P. 76–83. DOI: 10.1016/j.trpro.2022.09.010
42. Bubyk M., Udovychenko T., Medvid R. Concept of smart specialization in the context of the development of Ukraines economy. *Economics. Ecology. Socium*. 2019. Vol. 3. No 2. P. 55–61. DOI: 10.31520/2616-7107/2019.3.2-6
43. Bubyk M., Matseliukh Y. Small-batteries utilization analysis based on mathematical statistics methods in challenges of circular economy. *CEUR workshop proceedings*. 2021. Vol. 2870, P. 1594–1603. URL: <https://ceur-ws.org/Vol-2870/paper118.pdf> (last accessed: 01.02.2025).
44. Бублик М.І. Модель економічного оцінювання техногенних збитків в національному господарстві. *Black Sea Scientific Journal of Academic Research. Economic Science*. 2014. Vol. 12. No. 05, С. 44–50.
45. Dai Y., Hasanefendic S., Bossink B. A systematic literature review of the smart city transformation process: The role and interaction of stakeholders and technology. *Sustainable Cities and Society*. 2024. Vol. 101, 105112 p. DOI: 10.1016/j.scs.2023.105112
46. Cai J., Luo J., Wang S., Yang S. Feature selection in machine learning: A new perspective. *Neurocomputing*. 2018. No.300. P. 70–79. DOI: 10.1016/j.neucom.2017.11.077
47. Chung S. Applications of smart technologies in logistics and transport: A review. *Transportation Research Part E: Logistics and Transportation Review*. 2021. Vol. 153, 102455 p. DOI: 10.1016/j.tre.2021.102455
48. European Commission. *Sustainable Urban Mobility Package*. URL: <https://ec.europa.eu/transport/themes/urban/> (last accessed: 01.02.2025).
49. Kidmose B. A review of smart vehicles in smart cities: Dangers, impacts, and the threat landscape. *Vehicular Communications*. 2025. No. 51, 100871 p. DOI: 10.1016/j.vehcom.2024.100871
50. Sood S. K. A scientometric analysis of quantum driven innovations in intelligent transportation systems. *Engineering Applications of Artificial Intelligence*. 2024. No. 138, 109258 p. DOI: 10.1016/j.engappai.2024.109258

## References

1. Saxena, A., Prasad, M., Gupta, A., Bharill, N., Patel, O. P., Tiwari, A., Er, M. J., Ding, W., Lin, C. (2017), "A review of clustering techniques and developments", *Neurocomputing*, No. 267, P. 664–681. DOI: <https://doi.org/10.1016/j.neucom.2017.06.053>

2. Isoli, N., Chaczykowski, M. (2025), "Net energy analysis and net carbon benefits of CO2 capture and transport infrastructure for energy applications and industrial clusters", *Applied Energy*, No. 382, 125227 p. DOI: <https://doi.org/10.1016/j.apenergy.2024.125227>
3. Kowalska-Styczeń, A., Bublyk, M., Lytvyn, V. (2023), "Green innovative economy remodeling based on economic complexity", *Journal of Open Innovation: Technology, Market, and Complexity*. No.9(3), 100091 p. DOI: <https://doi.org/10.1016/j.joitmc.2023.100091>
4. Podlesna, L., Bublyk, M., Grybyk, I., Matseliukh, Y., Burov, Y., Kravets, P., Lozynska, O., Karpov, I., Peleshchak, I., Peleshchak, R. (2020), "Optimization model of the buses number on the route based on queueing theory in a Smart City", *CEUR Workshop Proceedings*, Vol. 2631, P. 502–515, available at: <https://ceur-ws.org/Vol-2631/paper37.pdf> (last accessed: 01.02.2025).
5. Bianchini, D., De Antonellis, V., Garda, M. (2023), "A big data exploration approach to exploit in-vehicle data for smart road maintenance", *Future Generation Computer Systems*, No. 149, P. 701-716. DOI: <https://doi.org/10.1016/j.future.2023.08.004>
6. Katrenko, A., Krislata, I. Veres, O., Oborska, O., Basyuk, T., Vasyliuk, A., Rishnyak, I., Demyanovskyi, N., Meh, O. (2020), "Development of traffic flows and smart parking system for smart city", *CEUR Workshop Proceedings*, Vol. 2604, P. 730–745, available at: <https://ceur-ws.org/Vol-2604/paper50.pdf> (last accessed: 01.02.2025).
7. Matseliukh, Y., Bublyk, M., Vysotska, V. (2021), "Development of intelligent system for visual passenger flows simulation of public transport in Smart City based on neural network", *CEUR Workshop Proceedings*, Vol. 2870, P. 1087–1138, available at: <https://ceur-ws.org/Vol-2870/paper82.pdf> (last accessed: 01.02.2025).
8. Visan, M., Negrea, S. L., Mone, F. (2021), "Towards intelligent public transport systems in Smart Cities; Collaborative decisions to be made", *Procedia Computer Science*, No. 199, P. 1221–1228. DOI: <https://doi.org/10.1016/j.procs.2022.01.155>
9. Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., Akinyelu, A. A. (2022), "A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects", *Engineering Applications of Artificial Intelligence*, No. 110, 104743 p. DOI: <https://doi.org/10.1016/j.engappai.2022.104743>
10. Chavent, M., Lechevallier, Y., Briant, O. (2007), "DIVCLUS-T: A monothetic divisive hierarchical clustering method", *Computational Statistics & Data Analysis*, No. 52 (2), P. 687-701. DOI: <https://doi.org/10.1016/j.csda.2007.03.013>
11. Celebi, M. E., Kingravi, H. A., Vela, P. A. (2012), "A comparative study of efficient initialization methods for the k-means clustering algorithm", *Expert Systems With Applications*, No. 40 (1), P. 200–210. DOI: <https://doi.org/10.1016/j.eswa.2012.07.021>
12. Bublyk, M., Kowalska-Styczeń, A., Lytvyn, V., Vysotska, V. (2021), "The Ukrainian economy transformation into the circular based on fuzzy-logic cluster analysis", *Energies*, No. 14 (18), 5951 p. DOI: <https://doi.org/10.3390/en14185951>
13. Singh, J., Singh, D. (2024), "A comprehensive review of clustering techniques in artificial intelligence for knowledge discovery: Taxonomy, challenges, applications and future prospects", *Advanced Engineering Informatics*, No. 62, 102799 p. DOI: <https://doi.org/10.1016/j.aei.2024.102799>
14. Yan, J., Liu, J., Tseng, F. (2020), "An evaluation system based on the self-organizing system framework of smart cities: A case study of smart transportation systems in China", *Technological Forecasting and Social Change*, No. 153, 119371 p. DOI: <https://doi.org/10.1016/j.techfore.2018.07.009>
15. Matseliukh, Y., Vysotska, V., Bublyk, M. (2020), "Intelligent system of visual simulation of passenger flows", *CEUR Workshop Proceedings*, Vol. 2604, P. 906–920, available at: <https://ceur-ws.org/Vol-2604/paper60.pdf> (last accessed: 01.02.2025).
16. Prasetio, E. A., Novizayanti, D., Putri, A. N. A. (2024), "Cluster analysis of potential autonomous vehicle (AV) adopters in Indonesia's new capital", *Transportation Research Interdisciplinary Perspectives*, No. 29, 101318 p. DOI: <https://doi.org/10.1016/j.trip.2024.101318>
17. Singh, J., Singh, D. (2024), "A comprehensive review of clustering techniques in artificial intelligence for knowledge discovery: Taxonomy, challenges, applications and future prospects", *Advanced Engineering Informatics*, No. 62, 102799 p. DOI: <https://doi.org/10.1016/j.aei.2024.102799>
18. Liu, J., Li, J., Chen, Y., Lian, S., Zeng, J., Geng, M., Zheng, S., Dong, Y., He, Y., Huang, P., Zhao, Z., Yan, X., Hu, Q., Wang, L., Yang, D., Zhu, Z., Sun, Y., Shang, W., Wang, D., Chen, X. (2023), "Multi-scale urban passenger transportation CO2 emission calculation platform for smart mobility management", *Applied Energy*, No. 331, 120407 p. DOI: <https://doi.org/10.1016/j.apenergy.2022.120407>
19. Matseliukh, Y., Bublyk, M., Bosak, A., Naychuk-Khrushch, M. (2024), "The role of public transport network optimization in reducing carbon emissions", *CEUR Workshop Proceedings*, Vol. 3723, P. 340–364, available at: <https://ceur-ws.org/Vol-3723/paper19.pdf> (last accessed: 01.02.2025).
20. Bezdek, J. C. (1981), *Pattern Recognition with Fuzzy Objective Function Algorithms*, Bon, Springer, 245 p.
21. Bublyk, M., Vysotska, V., Matseliukh, Y., Mayik, V., Nashkerska, M. (2020), "Assessing losses of human capital due to man-made pollution caused by emergencies", *CEUR Workshop Proceedings*, Vol. 2805, P. 74–86, available at: <https://ceur-ws.org/Vol-2805/paper6.pdf> (last accessed: 01.02.2025).
22. Bublyk, M.I., Babiy, T.I. (2009), "Development of logistic in modern operating of market conditions", *Scientific Bulletin of UNFU*, No. 19 (6), P. 138–142.
23. Ester, M., Kriegel, H.-P., Sander, J., Xu, X. (1996), "A density-based algorithm for discovering clusters in large spatial databases with noise", *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, P. 226–231.

24. Jain, A. K. (2010), "Data clustering: 50 years beyond K-means", *Pattern Recognition Letters*, No. 31 (8), P. 651–666. DOI: <https://doi.org/10.1016/j.patrec.2009.09.011>
25. Kohonen, T. (2001), *Self-Organizing Maps*, 3rd ed., Springer, Bon, 554 p.
26. Koshtura, D., Bublyk, M., Matseliukh, Y., Dosyn, D., Chyrun, L., Lozynska, O., Karpov, I., Peleshchak, I., Maslak, M., Sachenko, O. (2020), "Analysis of the demand for bicycle use in a smart city based on machine learning", *CEUR workshop proceedings*, Vol. 2631, P. 172–183, available at: <https://ceur-ws.org/Vol-2631/paper13.pdf> (last accessed: 01.02.2025).
27. Lytvyn, V., Bublyk, M., Vysotska, V., Matseliukh, Y. (2022), "Visual simulation technology for passenger flows in the public transport field at smart city", *Radio Electronics, Computer Science, Control*, No. 4, P. 106–121. DOI: <https://doi.org/10.15588/1607-3274-2021-4-10>
28. Law, A. M. (2015), *Simulation Modeling and Analysis*. 5th ed., McGraw-Hill, Bon, 495 p.
29. Nath, N., Nitanai, R., Manabe, R., Murayama, A. (2023), "A global-scale review of smart city practice and research focusing on residential neighbourhoods", *Habitat International*, Vol. 142, 102963 p. DOI: <https://doi.org/10.1016/j.habitatint.2023.102963>
30. Sun, L., Zhao, J., Zhang, J., Zhang, F., Ye, K., Xu, C. (2024), "Activity-based individual travel regularity exploring with entropy-space K-means clustering using smart card data", *Physica A: Statistical Mechanics and its Applications*, No. 636, 129522 p. DOI: <https://doi.org/10.1016/j.physa.2024.129522>
31. Tibshirani, R., Walther, G., Hastie, T. (2001), "Estimating the number of clusters in a data set via the gap statistic", *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, No. 63 (2), P. 411–423.
32. Subudhi, S., Panigrahi, S. (2020), "Use of optimized Fuzzy C-Means clustering and supervised classifiers for automobile insurance fraud detection", *Journal of King Saud University – Computer and Information Sciences*, No. 32 (5), P. 568-575. DOI: <https://doi.org/10.1016/j.jksuci.2017.09.010>
33. Duan, Y., Liu, C., Li, S., Guo, X., Yang, C. (2023), "An automatic affinity propagation clustering based on improved equilibrium optimizer and t-SNE for high-dimensional data", *Information Sciences*, No. 623, P. 434-454. DOI: <https://doi.org/10.1016/j.ins.2022.12.057>
34. Bide, P., Shedje, R. (2015), "Improved document clustering using K-means algorithm", *2015 IEEE Int. Conf. on Electrical, Computer and Communication Technologies (ICECCT)*, IEEE, New York, 1048 p.
35. Zhong, C., Miao, D., Wang, R., Zhou, X. (2008), "DIVFRP: An automatic divisive hierarchical clustering method based on the furthest reference points", *Pattern Recognition Letters*, No. 29 (16), P. 2067-2077. DOI: <https://doi.org/10.1016/j.patrec.2008.07.002>
36. Elassy, M., Al-Hattab, M., Takruri, M., Badawi, S. (2024), "Intelligent transportation systems for sustainable smart cities", *Transportation Engineering*, No. 16, 100252 p. DOI: <https://doi.org/10.1016/j.treng.2024.100252>
37. Zhu, W. (2022), "A spatial decision-making model of smart transportation and urban planning based on coupling principle and Internet of Things", *Computers and Electrical Engineering*, No. 102, 108222 p. DOI: <https://doi.org/10.1016/j.compeleceng.2022.108222>
38. Bushuev, S., Inna, L., Alla, B., Alexander, L., Khusainova, M. (2023), "Creating urban transportation networks grounded in the principles of the smart port-city paradigm", *Procedia Computer Science*, No. 231, P. 323–328. DOI: <https://doi.org/10.1016/j.procs.2023.12.211>
39. Balbin, P. P., Barker, J. C., Leung, C. K., Tran, M., Wall, R. P., Cuzzocrea, A. (2019), "Predictive analytics on open big data for supporting smart transportation services", *Procedia Computer Science*, No. 176, P. 3009-3018. DOI: <https://doi.org/10.1016/j.procs.2020.09.202>
40. Khemakhem, S., Krichen, L. (2024), "A comprehensive survey on an IoT-based smart public street lighting system application for smart cities". *Franklin Open*, No. 8, 100142 p. DOI: <https://doi.org/10.1016/j.fraope.2024.100142>
41. Vidović, K., Čolić, P., Vojvodić, S., Blavicki, A. (2021), "Methodology for public transport mode detection using telecom big data sets: Case study in Croatia", *Transportation Research Procedia*, No. 64, P. 76-83. DOI: <https://doi.org/10.1016/j.trpro.2022.09.010>
42. Bublyk, M., Udovychenko, T., Medvid, R. (2019), Concept of smart specialization in the context of the development of Ukraine's economy", *Economics. Ecology. Socium*, Vol. 3, No. 2, P. 55–61. DOI: <https://doi.org/10.31520/2616-7107/2019.3.2-6>
43. Bublyk, M., Matseliukh, Y. (2021), "Small-batteries utilization analysis based on mathematical statistics methods in challenges of circular economy", *CEUR workshop proceedings*, Vol. 2870, P. 1594–1603, available at: <https://ceur-ws.org/Vol-2870/paper118.pdf> (last accessed: 01.02.2025).
44. Bublyk, M.I. (2014), "Model of economic evaluation of man-made damage to the national economy", *Black Sea Scientific Journal of Academic Research. Economic Science*, No. 12 (05), P. 44-50.
45. Dai, Y., Hasanefendic, S., Bossink, B. (2024), "A systematic literature review of the smart city transformation process: The role and interaction of stakeholders and technology", *Sustainable Cities and Society*, Vol. 101, 105112 p. DOI: <https://doi.org/10.1016/j.scs.2023.105112>
46. Cai, J., Luo, J., Wang, S., Yang, S. (2018), "Feature selection in machine learning: A new perspective", *Neurocomputing*, No. 300, P. 70-79. DOI: <https://doi.org/10.1016/j.neucom.2017.11.077>
47. Chung, S. (2021), "Applications of smart technologies in logistics and transport: A review", *Transportation Research Part E: Logistics and Transportation Review*, No. 153, 102455 p. DOI: <https://doi.org/10.1016/j.tre.2021.102455>
48. European Commission, "Sustainable Urban Mobility Package", available at: <https://ec.europa.eu/transport/themes/urban> (last accessed: 01.02.2025).

49. Kidmose, B. (2025), "A review of smart vehicles in smart cities: Dangers, impacts, and the threat landscape. *Vehicular Communications*, 51, 100871 p. DOI: <https://doi.org/10.1016/j.vehcom.2024.100871>
50. Sood, S. K. (2024), "A scientometric analysis of quantum driven innovations in intelligent transportation systems", *Engineering Applications of Artificial Intelligence*, No. 138, 109258 p. DOI: <https://doi.org/10.1016/j.engappai.2024.109258>

Надійшла (Received) 10.02.2025

#### Відомості про авторів / About the Authors

**Мацелюх Юрій Романович** – Національний університет "Львівська політехніка", аспірант кафедри інформаційних систем та мереж, Львів, Україна; e-mail: [indeed.post@gmail.com](mailto:indeed.post@gmail.com); ORCID ID: <https://orcid.org/0000-0002-1721-7703>

**Литвин Василь Володимирович** – доктор технічних наук, професор, Національний університет "Львівська політехніка", завідувач кафедри інформаційних систем та мереж, Львів, Україна; e-mail: [vasyl.v.lytvyn@lpnu.ua](mailto:vasyl.v.lytvyn@lpnu.ua); ORCID ID: <https://orcid.org/0000-0002-9676-0180>

**Matseliukh Yurii** – Lviv Polytechnic National University, PhD Student of Information Systems and Networks Department, Lviv, Ukraine.

**Lytvyn Vasyl** – Doctor of Sciences (Engineering), Professor, Lviv Polytechnic National University, Head of Information Systems and Networks Department, Lviv, Ukraine.

## APPLICATION OF THE K-MEANS CLUSTERING METHOD IN THE ORGANISATION OF PASSENGER TRANSPORT IN A SMART CITY

Every year, big data clustering methods are gaining popularity for decision-making on organizing passenger transportation in a smart city, ensuring the efficiency, adaptability and environmental friendliness of the transport system. Their relevance is due to the growth of data volumes, changing demand and the negative impact of transport on the environment. The object of the study is the process of clustering data sets on organizing passenger transportation. The subject of the study is the principles of studying clustering metrics when calculating the number of clusters for executing transportation schedules. The purpose of the study is to apply the K-means algorithm based on quality metrics for clustering data on organizing passenger transportation in a smart city. The following tasks are solved in the article: study of the features of clustering methods and their metrics; analysis of a large-scale heterogeneous data set on the duration of electric transport trips in an average-sized city; development of an effective algorithm for choosing a method for calculating the number of clusters based on metrics for assessing the quality of data clustering. The methods of analysis, synthesis, generalization, comparison, grouping, cluster analysis, system analysis, K-means method were used. The following results were obtained: It was established that the choice of the clustering method depends on the specifics of the task, data characteristics and the objectives of the analysis of transport flows. A complex, heterogeneous and raw data structure was revealed regarding the duration of electric transport journeys. Cluster analysis using the K-means method was due to the need for accurate data distribution between clusters. An algorithm for choosing a method for calculating the number of clusters based on metrics for assessing the quality of data clustering, including the elbow method, the silhouette method and the Kalinsky-Kharabash index, was proposed. It is recommended to use clustering to create routes with reduced waiting time, fewer transfers and compliance with passenger needs. Conclusions: the K-means method was used to analyze the duration of electric transport journeys. Data analysis revealed sections of routes with different traffic flow intensity, which depends on their location in urban areas, seasonality, etc. An algorithm for choosing a method for calculating the number of clusters based on internal metrics is proposed.

**Keywords:** passenger transport; smart city; clustering analysis; K-means method; systems analysis.

#### Бібліографічні описи / Bibliographic descriptions

Мацелюх Ю. Р., Литвин В. В. Метод *K*-середніх для аналізу даних з організації пасажирських перевезень у розумному місті. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 83–101. DOI: <https://doi.org/10.30837/2522-9818.2025.1.083>

Matseliukh, Y., Lytvyn, V. (2025), "Application of the K-means clustering method in the organisation of passenger transport in a smart city", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 83–101. DOI: <https://doi.org/10.30837/2522-9818.2025.1.083>

В. Поддубний, О. Северінов, Д. Непокритов

## ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ АЛГОРИТМІВ ОБРОБЛЕННЯ ЗОБРАЖЕНЬ У СХЕМАХ НУЛЬОВОГО ВОДЯНОГО ЗНАКА

**Предметом дослідження** є алгоритми перетворення цифрових зображень, що використовуються в нульових водяних знаках у процесі побудови алгоритмів автентифікації. **Мета роботи** – визначення ефективних алгоритмів перетворення цифрових зображень для застосування в нульових водяних знаках. У статті необхідно розв'язати такі **завдання**: дослідити спектр наявних алгоритмів перетворення цифрових зображень; висунути неформальні вимоги до алгоритмів перетворення цифрових зображень з метою їх використання в алгоритмах нульових водяних знаків у процесі побудови схем автентифікації; висунути припущення щодо можливості застосування кожного з розглянутих алгоритмів перетворення цифрових зображень. Для виконання окреслених завдань запроваджено такі **методи**: моделювання – здійснення програмної реалізації кожного з досліджуваних алгоритмів; емпіричні методи – використання алгоритмів і спостереження за результатами перетворень; математичні методи – обчислення показників нормальної кореляції та пікового значення сигнал / шум. **Досягнуті результати**: проаналізовано набір алгоритмів, що можуть бути потенційно придатні для використання в нульових водяних знаках у побудові алгоритмів автентифікації; сформовано методику перевірки алгоритмів, зважаючи на зменшення розмірності зображень унаслідок їх стискання; висунуто вимоги до алгоритмів оброблення цифрових зображень для їх використання в нульових водяних знаках під час побудови алгоритмів автентифікації. **Висновки**. У процесі дослідження потенційних алгоритмів перетворення цифрових зображень для використання нульових водяних знаків у побудові алгоритмів автентифікації виявлено найбільш вдалі алгоритми: *DWT*, *SVD*, *DCT*, *K-means*. Для зображень низької розмірності ймовірно застосування *DCT*. Найкращими поєднаннями запропонованих алгоритмів є комбінації: *DWT + DCT*, *DWT + K-means*. Поєднання цих алгоритмів може забезпечити оптимальну стійкість до шумів та чутливість, щоб розрізнити схожі зображення. Майбутні схеми автентифікації, основані на зазначених алгоритмах, корисні (якщо поєднати з IoT-пристроями), зокрема для автентифікації користувачів на підприємствах і в організаціях.

**Ключові слова**: зображення; нульовий водяний знак; алгоритм; автентифікація.

### Вступ

Одним із методів забезпечення авторського права є використання цифрових водяних знаків (далі – ЦВЗ), що безпосередньо вбудовуються в зображення та слугують маркером для перевірки автора. Проте такі знаки мають декілька недоліків, зокрема: зміна оригінального зображення, можливість вилучення водяного знака, його пошкодження внаслідок зміни формату чи стискання зображення.

Альтернативою ЦВЗ є застосування нульових водяних знаків (інакше – методу сліпого цифрового водяного знака). Такі водяні знаки не вбудовуються безпосередньо в контейнер, а використовують його як "ключ" для створення підпису. Нульові водяні знаки зазвичай необхідні для перевірки авторства зображень та контролю його цілісності (перцептивний геш [1]). Вони також можуть бути застосовані в схемах автентифікації, що робить їх гнучким інструментом. Крім того однією з можливостей їх використання є створення схем автентифікації [2],

зокрема для контейнерів у вигляді текстового документа [3].

Перспективним є застосування моделі автентифікації в індустріальних системах з використанням пристроїв IoT. З розвитком *Industry 4.0* збільшується інтеграція технологій безпеки та автентифікації. Упровадження ЦВЗ в *Industry 4.0* можливе в багатьох категоріях, а саме: автентифікація пристроїв на основі певних характеристик, підтвердження цілісності даних без їх зміни, автентифікація персоналу, доступ до обладнання тощо. Особливо необхідно наголосити на автентифікації персоналу. Контрольно-пропускні системи, що розгортаються на підприємствах, зазвичай містять засоби біометрії чи магнітні / електронні ключі, які видають персоналу. ЦВЗ за умови інтеграції з IoT-пристроями можуть бути заміною таких систем. На відміну від біометрії чи карток, ЦВЗ має такі переваги: дешевизна, можливість вибору користувачем ключа, непомітність (ЦВЗ не є маркером того, що певна інформація є ключовою).

Проте однією з проблем застосування нульових водяних знаків є знаходження оптимальної комбінації алгоритмів для балансування характеристик нульового водяного знака. Зважаючи на новизну нульових водяних знаків та безліч комбінацій різноманітних схем і алгоритмів, розроблення нових нульових водяних знаків та їх застосування в схемах автентифікації є перспективним напрямом досліджень.

### Аналіз проблеми й наявних методів

Нині існує безліч схем водяного знака, основаних на різних перетвореннях, зокрема: *DWT* [4], *SVD* [5], *LBP* [6], залишкові нейронні мережі [7], вихрові перетворення [8], *DCT* [9] тощо. Однією з проблем використання алгоритмів у нульових водяних знаках є знаходження балансу між стійкістю водяного знака та його крихкістю.

Стійкість – властивість, що описує, наскільки водяний знак є стійким (тобто не змінює характеристики) під час модифікації контейнера. Зазвичай вимірюється в максимально допустимому значенні шуму, коли є змога вилучити водяний знак.

Крихкість – це зворотна властивість, що описує, наскільки водяний знак є крихким (чутливим до змін контейнера).

Знаходження балансу необхідне для задоволення такой вимоги (у цьому та в наступних випадках розглядається використання ЦВЗ для автентифікації):

– ЦВЗ має бути стійким для того, щоб відсіювати помилки та шуми, які виникають під час оброблення зображення (наприклад, його візуального зчитування);

– ЦВЗ має знаходити розбіжності між схожими зображеннями.

Одним із прикладів алгоритмів нульового водяного знака для автентифікації є запропонований у роботі алгоритм [10], оснований на *DCT* та *DWT*. Цей алгоритм, безперечно, стабільний до атак, спрямованих на пошкодження контейнера, та забезпечує значну стійкість, проте не усувається проблема використання ЦВЗ за наявності схожих зображень (як, наприклад, у медицині [11]). У застосуванні такого алгоритму ЦВЗ на схожих зображеннях він буде повертати безліч помилок.

Іншими словами, має розв'язуватися проблема мінімізації співвідношення помилок першого та другого роду.

У роботі [2] наведено схему автентифікації з використанням алгоритму нульового знака. У такой схемі ініціалізація відбувається в такой спосіб:

1) користувач обирає ключем довільне зображення (або генерує його засобами системи, в якій інтегрована схема);

2) користувач вигадує пароль доступу;

3) користувач реєструється в системі за допомогою обраного зображення та ключа;

4) під час реєстрації генерується нульовий водяний знак, де вхідні дані – це ключ (або його розгорнутий варіант) та обране зображення;

5) сформований нульовий водяний знак зберігається в системі як еталонна копія.

Процес надання доступу відбувається таким чином:

1) користувач вводить в систему власний пароль та засобами системи зчитує зображення, яке він обрав як ключ;

2) генерується нульовий водяний знак, де вхідні дані – це ключ (або його розгорнутий варіант) та обране зображення;

3) модуль автентифікації порівнює згенерований нульовий водяний знак з еталонним нульовим водяним знаком, повертаючи певне значення подібності  $x$ ;

4) система порівнює коефіцієнт подібності водяного знака з еталонним нульовим знаком ( $x$ ) зі встановленим значенням допустимої похибки ( $y$ ); якщо  $x \leq y$ , то користувачеві блокується доступ до системи, а якщо  $x \geq y$ , то користувачеві надається доступ до системи.

За умови застосування IoT-пристроїв ця схема може контролювати доступ до приміщень або певної інформації. Засобом зчитування зображення можуть бути відеокамери, для перетворення ЦВЗ можна використовувати мікроконтролери. Після обчислення ЦВЗ передається результат на сервер доступу організації, що перевіряє:

1) коректність введеної інформації;

2) чи має користувач з такими даними доступ до певного ресурсу.

Спрощена схема застосування алгоритму нульового водяного знака в запропонованій схемі [2] зображена на рис. 1.

Як бачимо, основним елементом роботи такой схеми автентифікації є нульовий водяний знак.

Також можуть існувати додаткові елементи, такі як центр сертифікації, алгоритми гешування, алгоритми розширення ключа, зчитування зображення, генерації зображення тощо.



Рис. 1. Спрощена схема автентифікації користувача зображення за допомогою нульового водяного знака

У роботі [2] сформована одна з проблем досліджень таких схем: "знаходження балансу між стійкістю та чутливістю алгоритму водяного знака; алгоритм має бути досить стійким, щоб ігнорувати шуми та пошкодження зображення, та достатньо чутливим, щоб реагувати на зміну ключових параметрів".

Загалом схема алгоритму нульового водяного знака передбачає кілька кроків.

1) Оригінальне зображення перетворюється за допомогою першого алгоритму оброблення цифрових зображень (далі – перетворення № 1). Мета перетворення:

- відкинути помилки та шуми в оригінальному зображенні;
- зменшити обсяг інформації способом стиснення зображення для пришвидшення перетворень.

Зазвичай на цьому етапі використовуються перетворення, основані на вейвлет-перетвореннях.

2) Перетворене зображення підлягає трансформації за допомогою другого алгоритму оброблення цифрових зображень (далі – перетворення № 2). Метою алгоритму є вилучення ключових параметрів зображення для подальшого створення водяного знака.

3) Формування водяного знака способом вилучення основної інформації щодо ключа користувача.

Загальна схема алгоритму формування нульового водяного знака продемонстрована на рис. 2 [12].

Тому висуваються цілі щодо знаходження оптимальних параметрів перетворень № 1 та № 2 за умови їх поєднання:

- мають бути досить стійкими (зокрема шумів та пошкоджень зображення) для вилучення водяного знака;

- мають бути досить чутливими для того, щоб розрізнити зображення *A*, яке схоже на зображення *B*.

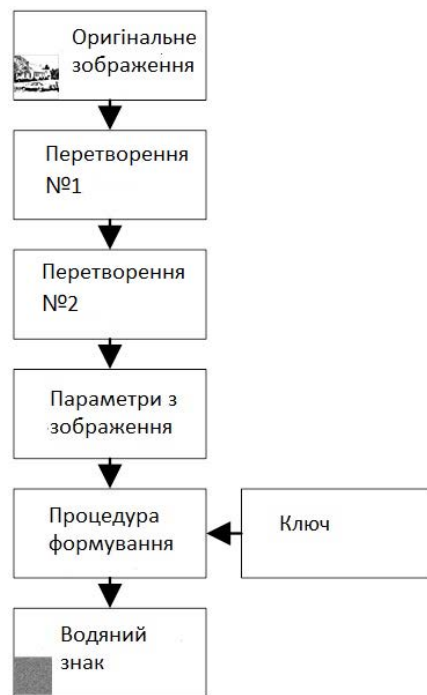


Рис. 2. Спрощена схема алгоритму нульового водяного знака

Додатковими вимогами є:

- швидкодія алгоритмів, оскільки під час кожної автентифікації користувача генерується водяний знак, тобто складність ініціалізації такої схеми дорівнює складності перевірки користувача;
- оборотність алгоритмів, оскільки для подальших схем, основаних на відкритих параметрах, необоротність алгоритмів буде додатковою перевагою, що підвищує надійність схеми.



### Порядок тестування алгоритмів і метрики

Основною властивістю, за якою порівнюватимуться алгоритми, є їх стійкість до шумів (спотворень зображення). Для вимірювання зазначеної властивості використовуються дві метрики визначення шуму:

- *NCC* ;
- *PSTR*.

Термін "пікове відношення сигнал / шум (*PSNR*)" – це вираження співвідношення між максимально можливим значенням (потужністю) сигналу та потужністю спотворювального шуму, що впливає на якість його подання. Оскільки чимало сигналів мають дуже широкий динамічний діапазон (співвідношення між найбільшим і найменшим імовірними значеннями змінної величини), *PSNR* зазвичай виражається в термінах логарифмічної шкали децибелів [13].

Покращення зображення або візуальної якості цифрового зображення може бути суб'єктивним. З цієї причини необхідно встановити кількісні / емпіричні вимірювання для порівняння впливу алгоритмів покращення на якість зображення.

Використовуючи той самий набір тестових зображень, можна систематично порівнювати різні алгоритми покращення зображення, щоб визначити, чи дає певний алгоритм вищі результати. Показником, що досліджується, є пікове відношення сигнал / шум. Якщо можемо показати, що алгоритм або набір алгоритмів покращує деформоване зображення, щоб воно було більш схоже на оригінал, тоді зможемо зробити висновок, що це стійкіший алгоритм.

Математичне подання *PSNR* має вигляд

$$PSNR = 20 \log_{10} \left( \frac{MAX_f}{\sqrt{MSE}} \right), \quad (1)$$

де  $MAX_f$  – максимальне значення сигналу, яке існує у вихідному зображенні;

*MSE* – середня квадратична помилка:

$$MSE = \frac{1}{mn} \sum_0^{m-1} \sum_0^{n-1} \|f(i, j) - g(i, j)\|^2, \quad (2)$$

де  $f$  – подає дані матриці нашого оригінального зображення;

$g$  – подає дані матриці нашого погіршеного зображення, про яке йдеться;

$m$  – подає кількість рядків пікселів зображень, а  $i$  – індекс цього рядка;

$n$  – подає кількість стовпців пікселів зображення, а  $j$  – індекс цього стовпця.

Середня квадратична помилка (*MSE*) для практичних цілей дає змогу порівняти "справжні" значення пікселів вихідного зображення з погіршеним зображенням. *MSE* подає середнє значення квадратів "помилки" між нашим фактичним зображенням і нашим шумовим зображенням. Похибка – це величина, на яку значення вихідного зображення різняться від погіршеного зображення.

Сутність метрики: що вищий *PSNR*, то краще було реконструйовано погіршене зображення, щоб відповідати оригінальному зображенню, і кращим є алгоритм реконструкції. Це сталося тому, що відбувається мінімізація *MSE* між зображеннями щодо максимального значення сигналу зображення.

Значення *NCC* має такий вигляд:

$$NCC = \frac{\sum_{i=1}^n (A_i - \bar{A})(B_i - \bar{B})}{\sqrt{\sum_{i=1}^n (A_i - \bar{A})^2 \sum_{i=1}^n (B_i - \bar{B})^2}}. \quad (3)$$

Значення *NCC* визначає нормальну кореляцію між зображенням  $A$  та  $B$ .

Значення  $\bar{A}$  та  $\bar{B}$  становлять середні значення пікселів зображення  $A$  та  $B$ .

Тестування обраних алгоритмів відбувається в такому порядку:

1) обираються зображення для тестування  $[O_1, O_2 \dots - O_n]$ ;

2) обрані зображення спотворюються, додаючи шуми та графічні артефакти, унаслідок чого отримуємо  $[D_1, D_2 \dots - D_n]$ ;

3) вимірюються параметри *PSTR*, *NCC* між оригінальними  $[O_1, O_2 \dots - O_n]$  та деформованими зображеннями  $[D_1, D_2 \dots - D_n]$ , що становлять  $[K_1, K_2 \dots - K_n]$ ;

4) оригінальні зображення  $[O_1, O_2 \dots - O_n]$  підпадають під перетворення, формуючи набір даних (фото або коефіцієнтів)  $[O_1, O_2 \dots - O_n]$ ;

5) деформовані зображення  $[D_1, D_2 \dots - D_n]$  підпадають під перетворення, формуючи набір даних (фото або коефіцієнтів)  $[D_1, D_2 \dots - D_n]$ ;

6) вимірюються параметри  $PSTR$ ,  $NCC$  між  $[O_1, O_2 \dots - O_n]$  та  $[D_1, D_2 \dots - D_n]$ , що становлять  $[S_1, S_2 \dots - S_n]$ ;

7) значення  $[K_1, K_2 \dots - K_n]$  та  $[S_1, S_2 \dots - S_n]$  порівнюються між собою, внаслідок чого отримуємо коефіцієнт стійкості алгоритму до шуму.

Після тестування для кожного алгоритму буде сформовано розбіжність оцінки та  $PSTR$ ,  $NCC$ , що вказуватиме на стійкість алгоритму до різних

видів шумів. Що більша позитивна різниця, то стійкіший алгоритм до шумів, тобто він "відкинув" частину шумів, наблизивши спотворене фото до оригінального. Що вища негативна різниця, то більш чутливий алгоритм; це значить, що шуми суттєво вплинули на зображення, віддаливши подібність від оригінального зображення.

Для тестування обрано чотири зображення [14, 15] (див. рис. 3).




Рис. 3. Зображення, відібрані для тестування (за часовою стрілкою: *Female, Lake, Galaxy, Jet*)

Зображення обрано з метою тестування алгоритмів на різних розмірностях. Параметри зображень наведено в табл. 1. У таблиці вказані розширення зображення та  $R_c$ ,  $G_c$ ,  $B_c$  – середня яскравість пікселів кожного спектра ( $R_c$  – для червоного спектра,  $G_c$  – зеленого спектра,  $B_c$  – синього спектра).

Таблиця 1. Параметри зображень, обраних для тестування

Фото Параметр	<i>Female</i>	<i>Lake</i>	<i>Jet</i>	<i>Galaxy</i>
Розширення	256×256	512×512	512×512	4080×4080
$R_c$	129,2	131	177,6	71,2
$G_c$	99,3	124,3	177,9	65,7
$B_c$	125,2	114,9	190,2	64,6

Зображення для тестування деформувалися засобами графічного редактора.

Були застосовані засоби з такими параметрами:

- шум;
- вм'ятини;
- накладання текстового напису;
- гауссове розмиття;
- кристалізація.

Приклад деформації зображення наведено на рис. 4.

Між оригінальним і деформованим зображеннями виміряно параметри  $NCC$  та  $PSTR$  (результати подано в табл. 2). Вимірювання проводились для кожного спектра (значення  $R$ ,  $G$ ,  $B$  в таблиці). Значення  $PSTR$  та  $NCC$  вказують на стійкість перетворень до пошкоджень, якщо значення позитивні, то обране перетворення здатне нівелювати значну частку шуму (оскільки що вище значення  $PSTR$  та  $NCC$ , то більша подібність до оригінального неспотвореного зображення, якщо значення  $PSTR$  в безкінечність та  $NCC$  в 1 – зображення ідентичні).



Рис. 4. Спотворення зображення (за часовою стрілкою: "шум", "вм'ятини", "накладання текстового напису", "гауссове розмиття", "кристалізація")

Таблиця 2. Параметри між оригінальним і деформованим зображенням

Спотворення \ Фото	Female	Jet	Lake	Galaxy
1	2	3	4	5
Шум	<i>PSTR</i>			
	<i>R</i> 11,902	<i>R</i> 11,855	<i>R</i> 11,86	<i>R</i> 10,349
	<i>G</i> 11,887	<i>G</i> 11,845	<i>G</i> 11,929	<i>G</i> 10,328
	<i>B</i> 11,884	<i>B</i> 11,873	<i>B</i> 11,94	<i>B</i> 10,317
	<i>NCC</i>			
	<i>R</i> 0,967	<i>R</i> 0,937	<i>R</i> 0,932	<i>R</i> 0,909
<i>G</i> 0,955	<i>G</i> 0,952	<i>G</i> 0,978	<i>G</i> 0,879	
<i>B</i> 0,921	<i>B</i> 0,89	<i>B</i> 0,978	<i>B</i> 0,87	
Вм'ятини	<i>PSTR</i>			
	<i>R</i> 11,575	<i>R</i> 9,593	<i>R</i> 10,681	<i>R</i> 11,516
	<i>G</i> 11,267	<i>G</i> 9,022	<i>G</i> 8,07	<i>G</i> 11,833
	<i>B</i> 12,012	<i>B</i> 10,947	<i>B</i> 8,466	<i>B</i> 11,212
	<i>NCC</i>			
	<i>R</i> 0,959	<i>R</i> 0,797	<i>R</i> 0,868	<i>R</i> 0,941
<i>G</i> 0,936	<i>G</i> 0,804	<i>G</i> 0,866	<i>G</i> 0,93	
<i>B</i> 0,915	<i>B</i> 0,791	<i>B</i> 0,887	<i>B</i> 0,898	
Додавання тексту	<i>PSTR</i>			
	<i>R</i> 8,875	<i>R</i> 9,316	<i>R</i> 9,21	<i>R</i> 9,222
	<i>G</i> 9,205	<i>G</i> 8,717	<i>G</i> 8,882	<i>G</i> 11,562
	<i>B</i> 9,873	<i>B</i> 8,503	<i>B</i> 9,664	<i>B</i> 10,375
	<i>NCC</i>			
	<i>R</i> 0,868	<i>R</i> 0,83	<i>R</i> 0,783	<i>R</i> 0,837
<i>G</i> 0,851	<i>G</i> 0,82	<i>G</i> 0,913	<i>G</i> 0,933	
<i>B</i> 0,834	<i>B</i> 0,664	<i>B</i> 0,939	<i>B</i> 0,874	
Гауссове розмиття	<i>PSTR</i>			
	<i>R</i> 11,822	<i>R</i> 11,603	<i>R</i> 12,564	<i>R</i> 16,863
	<i>G</i> 11,37	<i>G</i> 10,857	<i>G</i> 9,832	<i>G</i> 17,007
	<i>B</i> 12,429	<i>B</i> 12,852	<i>B</i> 10,223	<i>B</i> 16,769
	<i>NCC</i>			
	<i>R</i> 0,965	<i>R</i> 0,926	<i>R</i> 0,946	<i>R</i> 0,995
<i>G</i> 0,942	<i>G</i> 0,923	<i>G</i> 0,945	<i>G</i> 0,994	
<i>B</i> 0,932	<i>B</i> 0,917	<i>B</i> 0,953	<i>B</i> 0,992	

Продовження таблиці 2

1	2	3	4	5
Кристалізація	<i>PSTR</i>			
	<i>R</i> 12,013 <i>G</i> 11,722 <i>B</i> 12,455	<i>R</i> 11,799 <i>G</i> 11,172 <i>B</i> 12,834	<i>R</i> 12,48 <i>G</i> 10,124 <i>B</i> 10,426	<i>R</i> 17,214 <i>G</i> 17,36 <i>B</i> 17,116
	<i>NCC</i>			
	<i>R</i> 0,967 <i>G</i> 0,948 <i>B</i> 0,932	<i>R</i> 0,927 <i>G</i> 0,928 <i>B</i> 0,913	<i>R</i> 0,942 <i>G</i> 0,948 <i>B</i> 0,954	<i>R</i> 0,996 <i>G</i> 0,994 <i>B</i> 0,993

### Алгоритми перетворення цифрових зображень, обраних для тестування

Основні умови, що бралися до уваги у виборі алгоритмів:

– алгоритми мають бути детерміновані, оскільки в процесі застосування в алгоритмі нульового водяного знака користувач має автентифікуватися без впливу випадковостей. Тобто за наявності однакових атрибутів доступу ЦВЗ має виводити однаковий результат;

– алгоритми не мають базуватися на нейронних мережах, оскільки такі алгоритми зазвичай стохастичні (або мають стохастичну частину, що потребує ініціації); крім того, такі алгоритми потенційно вразливі до атак, спрямованих на нейронні мережі (що потребує іншої схеми використання цих алгоритмів);

– реалізація наявних алгоритмів публічна;

– результатом роботи алгоритмів є набір коефіцієнтів або зображення (матриця / матриці значень пікселів), оскільки для роботи нульового

водяного знака необхідне формування "знімка" (набору характеристик, сформованих за ключем) зображення.

Унаслідок аналізу наявних алгоритмів обрано такі алгоритми:

- *DWT* (*Discrete wavelet transform*);
- *SVD* (*Singular-value decomposition*);
- *DCT* (*The Discrete Cosine Transform*);
- *SIFT*;
- *PCA*;
- *CDF97* (*Cohen-Daubechies-Feauveau wavelet*);
- *K-means*;
- *Sobel*;
- *Waterhed*;
- *LBP*;
- *Gabor*;
- *HOG*.

Необхідно зауважити, що це не вичерпний перелік алгоритмів роботи з цифровими зображеннями, оскільки їх кількість є доволі велика.

Стислий опис кожного з обраних алгоритмів подано в табл. 3.

Таблиця 3. Параметри між оригінальним і деформованим зображенням

Алгоритм 1	Стислий опис 2	Тип виведення 3	Робота в спектрі RGB 4	Оборотність 5
<i>DWT</i>	перетворення сигналу (зображення) у частотну ділянку, збереження деталей на різних масштабах	зображення	кожен канал окремо	оборотний / необоротний
<i>SVD</i>	матричне розкладання, що дає змогу виділяти важливі особливості та стискати зображення	набір коефіцієнтів	кожен канал окремо	оборотний
<i>DCT</i>	розкладання зображення на частотні компоненти, широко використовується в JPEG-компресії	набір коефіцієнтів	кожен канал окремо	оборотний
<i>SIFT</i>	алгоритм виявлення та опису ключових точок, інваріантний до масштабу та обертання	набір коефіцієнтів, зображення з контрольними точками	градації сірого	необоротний
<i>PCA</i>	метод зменшення розмірності даних, що виділяє основні компоненти зображення	зображення	так	необоротний

Продовження таблиці 3

1	2	3	4	5
<i>CDF97</i>	біортогональне вейвлет-перетворення, що використовується в компресії JPEG2000	зображення	кожен канал окремо	оборотний
<i>K-means</i>	алгоритм кластеризації, що групує пікселі на основі схожості кольорів або текстур	зображення	так	необоротний
<i>Sobel</i>	оператор градієнта для виділення країв у зображенні	зображення	градації сірого	необоротний
<i>Waterhed</i>	алгоритм сегментації зображень, оснований на імітації заповнення водою заглиблень у градієнтному зображенні	набір коефіцієнтів, зображення з відтвореними зонами	градації сірого	необоротний
<i>LBP</i>	метод текстурного аналізу, що кодує локальні структури пікселів у бінарний вектор	зображення	градації сірого	необоротний
<i>Gabor</i>	фільтр для аналізу частотних і орієнтаційних компонентів зображення, використовується для текстурного аналізу	зображення	градації сірого	необоротний
<i>HOG</i>	метод опису форми об'єктів за допомогою гістограми градієнтів, широко використовується для розпізнавання об'єктів	набір коефіцієнтів	градації сірого	необоротний

### Тестування

Після вибору алгоритмів проведено тестування за методикою, поданою вище (результати наведені в табл. 4). Значення в таблиці показують різницю між оригінальним (недеформованим зображенням) та деформованим (зображенням, що підлягало додаванню шуму) для кожного алгоритму порівняно з еталонним показником шуму (табл. 1). Тобто, якщо значення більше ніж 0, тоді алгоритм відкинув певну

кількість шумів (показники подібності зображення + шум + алгоритм, кращий, ніж типове зображення, + шум), якщо значення менше ніж 0, тоді алгоритм накопичив певну кількість шумів (показники подібності зображення + шум + алгоритм гірший, ніж типове зображення, + шум), за умови значення в 0 алгоритм не змінив загальну кількість шумів. У таблиці наведено середні показники для всіх зображень і типів виведення алгоритмів (якщо їх декілька).

Таблиця 4. Результати тестування алгоритмів

	<i>DWT</i>	<i>SVD</i>	<i>DCT</i>	<i>SIFT</i>	<i>PCA</i>	<i>CDF97</i>	<i>K-means</i>	<i>LBP</i>	<i>HOG</i>	<i>Gabor</i>	<i>Sobel</i>	<i>Watershed</i>
Шум	<i>PSTR</i>											
	+2,9	+1,4	+0,1	-3,1	+1,4	+1,5	-1,6	-8,5	-1,7	-3,5	-4,4	-4
	<i>NCC</i>											
	+0,03	+0,04	+0,04	-0,14	+0,01	+0,04	-0,07	-0,76	-0,43	-0,05	-0,14	-0,25
Вм'ятини	<i>PSTR</i>											
	+1	+3,17	+0,01	-3,7	+0,1	+0,3	-1,5	-8,24	-1,26	-5,26	-2,3	-2,2
	<i>NCC</i>											
	+0,02	+0,06	+0,06	-0,25	+0,01	+0,02	-0,07	-0,8	-0,35	-0,22	-0,35	-0,14
Додавання тексту	<i>PSTR</i>											
	+0,13	+1,34	+0,01	+0,14	+0,8	-0,3	-0,3	-0,46	+2	-1,53	+1,52	-1
	<i>NCC</i>											
	+0,01	+0,13	+0,11	-0,01	+0,1	+0,1	-0,07	+0,07	+0,06	+0	-0,08	+0
Гауссове розмиття	<i>PSTR</i>											
	+0,5	+3,2	-0,12	-2,14	+0,1	+0,2	-1,6	-7,71	-2,18	-5,28	-5,41	-1,89
	<i>NCC</i>											
	+0,01	+0,05	+0,05	+0,05	+0,01	+0,02	-0,08	-0,66	-0,29	-0,25	-0,38	-0,25
Кристалізація	<i>PSTR</i>											
	+1	+2,9	+0,05	-3,1	+0,4	+0,4	-1,5	-8,73	-2	-5,2	-2,7	-2,2
	<i>NCC</i>											
	+0,02	+0,04	+0,02	-0,15	+0,01	+0,01	-0,06	-0,7	-0,4	-0,17	-0,36	-0,15

За поданою таблицею побудовано графіки (див. рис. 5 та 6) (алгоритм *LBP* був пропущений

у зв'язку з критично низькими значеннями для нормалізації зображення).

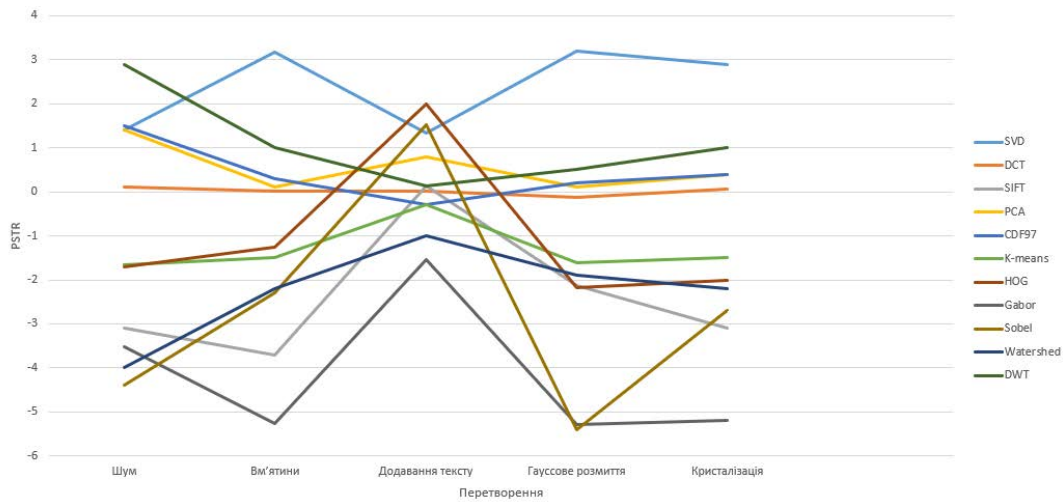


Рис. 5. Результати тестування, значення *PSNR*




Рис. 6. Результати тестування, значення *NCC*

Показники швидкодії алгоритмів не наведені в роботі, оскільки під час тестування була відсутня стандартизація кодування та використовувалися різні бібліотеки, зокрема *Accort.NET* [16], *Emgu.CV* [17], *MathNet.Numerics* [18]. Проте під час тестування вимірювалася швидкодія способом визначення часу виконання кожної функції.

Аналізуючи досягнуті результати, можна зробити висновок щодо можливості використання наведених перетворень для побудови алгоритму нульового знака.

#### 1) *DWT*

– перетворення показало високі результати подібності до шумів і позитивні результати для інших пошкоджень;

– базове перетворення *DWT* довело ефективність та є гарним перетворенням для першого рівня алгоритму. На практиці найбільш часто застосовується в алгоритмах нульового знака.

#### 2) *SVD*

– високі параметри подібності для всіх перетворень;

– алгоритм формує набір коефіцієнтів, що не робить його ефективним рішенням для перетворення першого рівня, коефіцієнти мають високу подібність (зокрема внаслідок частого формування нульових коефіцієнтів). Перетворення доволі часто використовується як алгоритм другого рівня для формування нульового водяного знака, проте внаслідок високої стійкості алгоритму це створює типові недоліки водяного знака: неможливість розрізнити подібні зображення та зображення одного автора. Зважаючи на надвисоку стійкість перетворення, застосування його в майбутньому алгоритмі нульового водяного знака для підтвердження автентифікації сумнівне, проте може бути використане як додатковий алгоритм під час перетворень за наявності високого параметра шуму.

### 3) *DCT*

– високі результати для *NCC*, стабільні, приблизно нульові результати для *PSTR*;

– перетворення має схожу природу з *SVD*, проте є більш перспективним завдяки вищій чутливості.

### 4) *SIFT*

– унаслідок використання виявлення ключових точок зображення нестабільні результати, що залежать від типу змін зображення. Результати погіршуються за умови додавання коефіцієнтів (у роботі вимірювалася лише однакова кількість коефіцієнтів);

– перетворення слабо підходить для використання в нульових водяних знаках, оскільки дуже чутливий до шумів. Проте в системах із нульовим (або низьким) пошкодженням інформації може бути ефективним алгоритмом другого рівня.

### 5) *PCA*

– стабільний алгоритм, що демонстрував характеристики на рівні *CDF97*;

– перетворення надто складне та потребує оптимізації ресурсів. Можливе використання для зображення низьких розмірностей, оскільки на зображенні розміром 512x512 час обчислення досягає декількох секунд.

### 6) *CDF97*

– результати аналогічні *DWT*, оскільки природа перетворень подібна. Для додавання тексту продемонстрував кращі результати, за умови інших пошкоджень – гірші;

– можливість використання *CDF97* аналогічне *DWT*.

### 7) *K-means*

– доволі чутливий до пошкоджень алгоритм, що демонстрував стабільні показники;

– чутливість *K-means* робить його можливим для використання як алгоритму другого рівня.

### 8) *LBP*

– продемонстрував критично низькі показники, що робить алгоритм надчутливим;

– у зв'язку з високою чутливістю є недоцільним для використання як алгоритму першого та другого рівня.

### 9) *HOG*

– продемонстрував посередні показники *PSTR* та низькі *NCC*;

– алгоритм працює із зображеннями в монохромному спектрі, що в поєднанні з не надто високими показниками робить його використання недоцільним.

### 10) *Gabor*

– чутливий, але нестабільний алгоритм; можливе використання як алгоритму другого рівня, проте застосування в монохромному спектрі створює додаткову специфіку роботи.

### 11) *Sobel*

– чутливий, але нестабільний алгоритм; застосування в монохромному спектрі створює додаткову специфіку роботи.

### 12) *Watershed*

– доволі чутливий до пошкоджень алгоритм, що продемонстрував стабільні показники;

– чутливість *Watershed* уможливорює його використання як алгоритму другого рівня, проте досить проблематична інтерпретація результатів його роботи.

## Висновки

Вивчення нульових водяних знаків досить перспективна галузь у зв'язку з їх новизною та гнучкістю, а широкий спектр можливостей цього методу створює потенціал для подальших досліджень. У роботі сформовано вимоги до алгоритмів оброблення цифрових зображень з метою їх використання в нульових водяних знаках для схем автентифікації. Серед досліджених алгоритмів перспективними є *DWT*, *SVD*, *DCT*, *K-means*. Для зображень низької розмірності доцільне використання *DCT* у зв'язку з обчислювальною складністю цього алгоритму. Найкращими поєднаннями запропонованих алгоритмів є такі комбінації: *DWT+DCT*, *DWT+K-means*. *SVD* та *DCT* формують вектор як результат, тому їх упровадження

можливе лише в поєднанні з іншим алгоритмом векторного оброблення сигналу, що не розглядалося в межах цієї статті.

Досягнуті результати можуть бути застосовані для побудови алгоритму нульового знака. Цей алгоритм може використовуватися в схемах автентифікації (зокрема на підприємствах і в організаціях). Перспективні напрями подальших

досліджень: побудова алгоритму нульового водяного знака з використанням описаних алгоритмів, побудова схеми багатофакторної автентифікації із застосуванням розробленого алгоритму нульового водяного знака, розроблення схеми автентифікації з публічними (відкритими) даними з використанням цього алгоритму, дослідження оборотності та стійкості алгоритму.

### Список літератури

1. Tang Z., Dai Y., Zhang X. Perceptual Hashing for Color Images Using Invariant Moments. *Applied Mathematics & Information Sciences*. 2012. Vol. 6, No. 2S. P. 643S–650S. URL: <https://surl.li/tvhbjz>
2. Поддубний В. О., Северінов О. В., Гвоздьов Р. Ю. Використання нульових водяних знаків для підтвердження авторства зображень та багатофакторної автентифікації. *Радіотехніка*. 2024. Вип. 218. С. 35–43. DOI: <https://doi.org/10.30837/rt.2024.3.218.02>
3. Jalil Z., Mirza A. M., Sabir M. Content based Zero-Watermarking Algorithm for Authentication of Text Documents. *International Journal of Computer Science and Information Security*. 2010. Vol. 7, No. 2. DOI:10.48550/arXiv.1003.1796
4. Rani A., Bhullar A. K., Dangwal D., Kumar S. A Zero-Watermarking Scheme using Discrete Wavelet Transform. *Procedia Computer Science*. 2015. Vol. 70. P. 603–609. ISSN 1877-0509. DOI: <https://doi.org/10.1016/j.procs.2015.10.046>
5. Zhou Y., Jin W. A novel image zero-watermarking scheme based on DWT-SVD. *Proceedings of the 2011 International Conference on Multimedia Technology*. Hangzhou, China, 2011. P. 2873–2876. DOI: 10.1109/ICMT.2011.6002066
6. Liu X., Lou J., Wang Y., Du J., Zou B., Chen Y. Discriminative and robust zero-watermarking scheme based on completed local binary pattern for authentication and copyright identification of medical images, *Proceedings of the SPIE*, 2018, Volume 10579. DOI: <https://doi.org/10.1117/12.2292852>
7. Xiang R., Liu G., Li K., Liu J., Zhang Z., Dang M. Zero-watermark scheme for medical image protection based on style feature and ResNet. *Biomedical Signal Processing and Control*. 2023. Vol. 86, Part A. Article 105127. ISSN 1746-8094. DOI: <https://doi.org/10.1016/j.bspc.2023.105127>
8. Li F., Wang Z. A Zero-Watermarking Algorithm Based on Vortex-like Texture Feature Descriptors. *Electronics*. 2024. Vol. 13. Article 3906. DOI: <https://doi.org/10.3390/electronics13193906>
9. Yuan Z., Yang B., Zhao W., Liu Y. A Robust Zero Watermarking Algorithm based on NSCT DCT. *Advances in Engineering Research*. 2017. Vol. 61. DOI:10.1155/2021/4944797
10. Rajkumar M., Babu G. Zero Watermarking and Data Authentication. *Big Data Innovation for Sustainable Cognitive Computing*. May 2024. DOI: [https://doi.org/10.1007/978-3-031-54696-9\\_6](https://doi.org/10.1007/978-3-031-54696-9_6)
11. Roček A., Javorník M., Slaviček K. et al. Zero Watermarking: Critical Analysis of Its Role in Current Medical Imaging. *Journal of Digital Imaging*. 2021. Vol. 34. P. 204–211. DOI:10.1007/s10278-020-00396-0
12. Poddubnyi V., Gvozдов R., Sievierinov O., Sukhoteplyi V., Bulba S., Lysytsia D. A Zero-Watermarking Algorithm for Use in RGB and Monochrome Images. 2024 *IEEE 5th KhPI Week on Advanced Technology (KhPIWeek)*. P. 1–5. DOI: <https://doi.org/10.1109/KhPIWeek61434.2024.10878081>
13. Nadipally M. Optimization of Methods for Image-Texture Segmentation Using Ant Colony Optimization. *Intelligent Data-Centric Systems: Intelligent Data Analysis for Biomedical Applications*. Academic Press, 2019. Ch. 2. P. 21–47. DOI:10.1016/B978-0-12-815553-0.00002-1
14. The USC-SIPI Image Database. URL: <https://sipi.usc.edu/database/>
15. Nasa Image and Video Library. URL: <https://images.nasa.gov/>
16. Accord Framework. URL: <http://accord-framework.net>
17. Emgu CV. Main Page. URL: <https://www.emgu.com/>
18. Math.NET Numerics. URL: <https://numerics.mathdotnet.com/>

### References

1. Tang, Z., Dai, Y. & Zhang, X. (2012), "Perceptual hashing for color images using invariant moments", *Applied Mathematics & Information Sciences*, 6(2S), P. 643S-650S. available at: <https://surl.li/tvhbjz>



2. Poddubnyi, V.O., Sievierinov, O.V., Gvozдов, R.Y. (2024), "Using zero-based watermarks to verify image authorship and multi-factor authentication" ["Vykorystannia nulovykh vodyanykh znakiv dlia pidtverdzhennia avtorstva zobrazhen ta bahatofaktornoї autentifikatsii"], *Radiotekhnika*, (218), P. 35-43. DOI: <https://doi.org/10.30837/rt.2024.3.218.02>
3. Jalil, Z., Mirza, A. M., Sabir, M. (2010), "Content based Zero-Watermarking Algorithm for Authentication of Text Documents, International Journal of Computer Science and Information Security", *International Journal of Computer Science and Information Security*, Vol. 7, No. 2. DOI:10.48550/arXiv.1003.1796
4. Rani, A., Bhullar, A.K., Dangwal, D. Kumar, S. (2015), "A zero-watermarking scheme using discrete wavelet transform", *Procedia Computer Science*, 70, P. 603-609. DOI: <https://doi.org/10.1016/j.procs.2015.10.046>
5. Zhou, Y. Jin, W. (2011), "A novel image zero-watermarking scheme based on DWT-SVD", *2011 International Conference on Multimedia Technology*, Hangzhou, China, P. 2873-2876. DOI: <https://doi.org/10.1109/ICMT.2011.6002066>
6. Liu, X., Lou, J., Wang, Y., Du, J., Zou, B. Chen, Y. (2018), "Discriminative and robust zero-watermarking scheme based on completed local binary pattern for authentication and copyright identification of medical images". *Proceedings of the SPIE*, Volume 10579, DOI: <https://doi.org/10.1117/12.2292852>
7. Xiang, R., Liu, G., Li, K., Liu, J., Zhang, Z. Dang, M. (2023), "Zero-watermark scheme for medical image protection based on style feature and ResNet", *Biomedical Signal Processing and Control*, 86(A), 105127. DOI: <https://doi.org/10.1016/j.bspc.2023.105127>
8. Li, F. Wang, Z. (2024), "A zero-watermarking algorithm based on vortex-like texture feature descriptors", *Electronics*, 13, 3906. DOI: <https://doi.org/10.3390/electronics13193906>
9. Yuan, Z., Yang, B., Zhao, W. Liu, Y. (2017), "A robust zero watermarking algorithm based on NSCT DCT", *International Conference on Mechanical, Electronic, Advances in Engineering Research*, 61. DOI:10.1155/2021/4944797
10. Rajku, M., Babu, G. (2024), "Zero Watermarking and Data Authentication", *Big Data Innovation for Sustainable Cognitive Computing*, May, DOI: [https://doi.org/10.1007/978-3-031-54696-9\\_6](https://doi.org/10.1007/978-3-031-54696-9_6)
11. Roček, A., Javorník, M., Slaviček, K. (2021), "Zero watermarking: Critical analysis of its role in current medical imaging", *Journal of Digital Imaging*, 34, P. 204–211. DOI:10.1007/s10278-020-00396-0
12. Poddubnyi, V., Gvozдов, R., Sievierinov, O., Sukhoteplyi, V., Bulba, S. Lysytsia, D. (2024), "A zero-watermarking algorithm for use in RGB and monochrome images", *2024 IEEE 5th KhPI Week on Advanced Technology (KhPIWeek)*, P. 1-5. DOI: <https://doi.org/10.1109/KhPIWeek61434.2024.10878081>
13. Nadipally, M. (2019), "Optimization of methods for image-texture segmentation using ant colony optimization", *Intelligent Data-Centric Systems: Intelligent Data Analysis for Biomedical Applications*, Academic Press, P. 21-47. DOI:10.1016/B978-0-12-815553-0.00002-1
14. "The USC-SIPI Image Database". available at: <https://sipi.usc.edu/database/>
15. "NASA Image and Video Library". available at: <https://images.nasa.gov/>
16. "Accord Framework". available at: <http://accord-framework.net>
17. "Emgu CV. Main Page". available at: <https://www.emgu.com/>
18. "Math.NET Numerics". available at: <https://numerics.mathdotnet.com/>

Надійшла (Received) 01.03.2025

#### Відомості про авторів / About the Authors

**Поддубний Вадим Олександрович** – Харківський національний університет радіоелектроніки, аспірант кафедри безпеки інформаційних технологій, Харків, Україна; e-mail: [vadym.poddubnyi@nure.ua](mailto:vadym.poddubnyi@nure.ua); ORCID ID: <https://orcid.org/0000-0002-4380-491X>

**Сєверінов Олександр Васильович** – кандидат технічних наук, Харківський національний університет радіоелектроніки, доцент кафедри безпеки інформаційних технологій, Харків, Україна; e-mail: [oleksandr.sievierinov@nure.ua](mailto:oleksandr.sievierinov@nure.ua); ORCID ID: <https://orcid.org/0000-0002-6327-6405>

**Непокритов Дмитро Миколайович** – кандидат технічних наук, Харківський національний університет Повітряних Сил імені Івана Кожедуба, доцент кафедри радіоелектронних систем пунктів управління факультету автоматизованих систем управління та наземного забезпечення польотів авіації, Харків, Україна; e-mail: [ndn\\_ndn@ukr.net](mailto:ndn_ndn@ukr.net); ORCID ID: <https://orcid.org/0000-0003-1752-8496>

**Poddubnyi Vadym** – Kharkiv National University of Radio Electronic, PhD Student at the Department of Information Technology Security, Kharkiv, Ukraine.

**Sievierinov Oleksandr** – PhD (Engineering Sciences), Kharkiv National University of Radio Electronic, Associate Professor at the Department of Information Technology Security, Kharkiv, Ukraine.

**Nepokrytov Dmytro** – PhD (Engineering Sciences), Air Forces of Ivan Kozhedub Kharkiv National Air Force University, Department of Radioelectronic Systems of Control Points of Air Forces, Associate Professor at the Department of Radioelectronic Systems of Control Points, Kharkiv, Ukraine.

## RESEARCH THE EFFICIENCY OF IMAGE PROCESSING ALGORITHMS IN ZERO WATERMARK SCHEMES

**Subject matter:** image transformation algorithms used in zero-watermarking techniques for development authentication algorithm. **Objectives:** identify effective image transformation algorithms for use in zero-watermarking schemes. The study addresses the following **tasks:** examining the range of existing image transformation algorithms, formulating informal requirements for image transformation algorithms to be used in zero-watermarking-based authentication schemes, and making assumptions about the feasibility of using each analyzed image transformation algorithm. To achieve these objectives, the following **methods** are employed: modeling – software implementation of each studied algorithm, empirical methods – application of algorithms and observation of transformation results, mathematical methods – calculation of normal correlation metrics and peak signal-to-noise ratio (PSNR). **Results:** an analysis was conducted on a set of algorithms that could potentially be used in zero-watermarking schemes for authentication purposes. A methodology was developed to evaluate algorithms while considering image dimensionality reduction due to compression. Additionally, requirements for image processing algorithms in zero-watermarking-based authentication were established. **Conclusions:** the study identified the most effective image transformation algorithms for use in zero-watermarking authentication schemes: DWT (Discrete Wavelet Transform), SVD (Singular Value Decomposition), DCT (Discrete Cosine Transform), and K-means clustering. For low-resolution images, DCT is a viable option. The most effective algorithm combinations are DWT + DCT and DWT + K-means, as these combinations ensure optimal robustness to noise while maintaining sensitivity to distinguish similar images. Future authentication schemes based on these algorithms may be useful (in combination with IoT devices), including for user authentication in enterprises and organizations.

**Keywords:** image; zero watermark; algorithm; authentication.

### *Бібліографічні описи / Bibliographic descriptions*

Поддубний В. О., Северінов О. В., Непокритов Д. М. Дослідження ефективності алгоритмів оброблення зображень у схемах нульового водяного знака. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 102–114. DOI: <https://doi.org/10.30837/2522-9818.2025.1.102>

Poddubnyi, V., Sievierinov, O., Nepokrytov, D. (2025), "Research the efficiency of image processing algorithms in zero watermark schemes", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 102–114. DOI: <https://doi.org/10.30837/2522-9818.2025.1.102>

---

O. SITNIKOVA, M. MELNYK, O. SYROTA, S. SEMENOV

## AN INTELLECTUAL METHOD FOR SUPPORTING DECISIONS ON SOFTWARE SECURITY USING HYBRID MODELS

**Objective.** The research is aimed at developing an intelligent decision support method for software security assessment using a hybrid model based on deep learning and gradient boosting. The aim is to improve classification accuracy, interpretability and adaptability in the face of growing cyber threats. **Methods.** The proposed method combines deep neural networks for automated feature extraction and gradient boosting for final decision making. A classification module is built based on calculating the probabilities of software belonging to security classes. In addition, a geometric interpretation of the decision space is used with the calculation of the Euclidean distance to the reference classes (safe, unsafe, uncertain). The probabilities are normalized using the *softmax* function. The model was trained on a labeled dataset and tested using comparative metrics. **Results.** The developed prototype demonstrated improved performance compared to classical classification approaches. The experiments confirmed higher classification accuracy and clearer separation of security zones in the normalized feature space. The method effectively identifies cases requiring expert analysis and reduces the frequency of false positives. Visualization of the decision space increases the interpretability of the model results. **Scientific novelty.** We propose a hybrid intelligent method that integrates two modern machine learning approaches – deep neural networks and gradient boosting – into a single architecture for assessing software security. The decision space is formalized through probabilistic thresholds and geometric interpretation. **Practical significance.** The method can be used in secure software development processes to automatically assess the level of software security. It supports developers and cybersecurity specialists in identifying potentially dangerous modules at the early stages of the software life cycle. The approach can also be integrated into static analysis systems or CI/CD environments to improve security standards.

**Keywords:** software security; deep neural networks; gradient boosting; machine learning; hybrid models; automated security analysis; cybersecurity; vulnerability detection.

### Introduction

Information technology plays a crucial role in the modern world, penetrating all areas of human activity – from the use of everyday applications to complex information systems that manage transportation, finance, energy, and national security. Software has become an integral part of the digital infrastructure, and its security is a key aspect of ensuring the reliable operation of information systems. However, the rapid development of software technologies is accompanied by growing risks of cyber threats, which are becoming more complex and large-scale. The number of vulnerabilities in software is increasing every year, creating potential threats to the confidentiality, integrity and availability of data. This increases the need to create effective software security assessment methods that can not only analyze code for vulnerabilities but also automate the decision-making process for software compliance with modern cybersecurity standards.

Traditional software security assessment methods have a number of drawbacks. The most common tools are manual code review, static and dynamic analysis, and formal software product certification methods. However,

all of these approaches are labor-intensive, require significant human resources, and depend on the level of expertise of the experts. Analyzing software using static source code verification allows you to detect syntax errors, but often does not take into account logical and contextual threats. Dynamic analysis, which involves testing software in real time, is effective in identifying potential vulnerabilities, but it requires considerable computing power and considerable time for verification. Another problem is the expert assessment of security, which often depends on the human factor, which can lead to missed threats or subjective conclusions.

In addition to technical aspects, software security is complicated by external factors. The rapid introduction of new technologies, the use of open source and numerous libraries, the emergence of sophisticated attack methods, and the active development of cybercrime create new challenges. The emergence of zero-day exploits aimed at previously unknown vulnerabilities increases the risk of attacks, as traditional analysis methods cannot respond to such threats immediately. The use of manual testing and certification procedures makes the assessment process lengthy, and the high cost of these checks limits their availability to a wide range of developers.

With the growing complexity of software and constant changes in cybersecurity, it is clear that new approaches to software security analysis are needed. Modern vulnerability detection systems require more flexible and adaptive methods that can take into account complex relationships between software components, automatically learn from new threats, and provide fast decision-making. The introduction of artificial intelligence and machine learning methods opens up new opportunities for solving these problems. Automated approaches based on artificial neural networks allow analyzing large amounts of code, finding hidden patterns, and improving the accuracy of security assessments.

Thus, developing an intelligent method for supporting software security decision-making that automates the security review process, reduces certification time, and increases the accuracy of potential threats is an urgent task.

---

### Literature review

---

Software security is one of the key issues in the field of information technology, as vulnerabilities in the code can be used by attackers to gain unauthorized access, steal confidential information, or disrupt systems. According to the NIST (*National Institute of Standards and Technology*) [1], the number of software vulnerabilities detected is growing every year, which confirms the relevance of research in this area.

Papers [2, 3] examine the current cybersecurity landscape, including the main threats and approaches to overcoming them. The authors emphasize that traditional methods of security analysis, such as static and dynamic code analysis, are not always effective enough due to the complexity of modern software, the presence of many interdependent components, and the use of external libraries that may contain hidden vulnerabilities.

According to a study by OWASP (*Open Web Application Security Project*) [4], the most common types of vulnerabilities are SQL injections, cross-site scripting (XSS), improper access control, and the use of unsafe dependencies. Various approaches are used to detect them, including automated analysis and penetration testing tools.

Thus, there is a clear need to develop automated and intelligent software security assessment systems that can efficiently process large amounts of data, analyze complex architectures, and adapt to new threats.

Existing software security assessment methods can be divided into three main categories: static

analysis, dynamic analysis, and methods based on formal models.

Static analysis involves checking the source code without executing it. One of the most well-known approaches is the signature analysis method used in systems such as *Fortify*, *Checkmarx*, and *SonarQube*. Study [5] examines the effectiveness of static methods for detecting vulnerabilities in code. The authors note that these approaches allow for quick analysis of a large amount of code, but do not always take into account the context of program execution.

Dynamic analysis, on the contrary, involves executing a program in a test environment and monitoring its behavior. The method is used in tools such as *Burp Suite*, *AppScan*, and *OWASP ZAP*. A study [6] shows that dynamic analysis can detect complex vulnerabilities, such as improper memory management or incorrect exception handling. However, the method is resource-intensive and requires a specialized test environment.

Another area is formal certification methods used to test critical software. Paper [7] discusses the use of mathematical models to prove the correctness of software components. Despite their high accuracy, formal methods require significant computing resources and specialized knowledge, which limits their use.

The main drawback of traditional approaches is their static nature and limited ability to adapt to new threats. That's why intelligent security assessment methods that combine machine learning and artificial intelligence techniques are becoming increasingly common.

Intelligent software security assessment methods are based on machine learning, deep neural networks, and combined approaches.

One of the most common approaches is the use of artificial neural networks to classify software by risk level. Paper [8] describes the use of convolutional neural networks (CNNs) for code analysis and vulnerability detection. The authors note that neural network methods significantly outperform traditional algorithms in terms of accuracy, especially when analyzing a large amount of source code.

Another approach is the use of recurrent neural networks (LSTM, GRU) to analyze sequences of actions in the code and identify potential threats. A study [9] shows that LSTM networks can effectively analyze program logic, detecting anomalies in behavior.

In addition to neural network methods, gradient boosting and other methods of ensemble learning are used in the field of security analysis. Study [10] proposes the use of the *XGBoost* algorithm to automatically

classify the risk level of software based on a set of characteristics.

Hybrid methods that combine different technologies show the best results. In [11], an approach is proposed in which deep neural networks are used to extract features from the source code, after which gradient boosting is used to accurately determine the threat level.

Recent studies also demonstrate the promise of graph neural networks (GNNs) for analyzing software structural security. In [12], a method for constructing graphs of interconnections of functions in a program and analyzing them using *GraphSAGE* is considered.

Thus, the use of hybrid models that combine deep neural networks for feature extraction and gradient boosting for classification is a promising direction in the study of software security decision-making methods.

An analysis of the literature leads to the conclusion that traditional methods have significant limitations,

while intelligent approaches based on artificial intelligence demonstrate great potential. Hybrid models that combine neural networks and machine learning can provide high accuracy of security assessment and effective adaptation to new threats.

### Main part of the study

The proposed method of software security verification is based on a hybrid approach that combines the use of deep neural networks (DNNs) for automated extraction of security characteristics and gradient boosting for accurate decision making. This significantly increases the speed and efficiency of the analysis, reducing the likelihood of false positives and false negatives.

Fig. 1 shows a diagram of the software verification process. As you can see, the verification method involves three main stages: preparation of source data, intelligent processing, and decision-making.

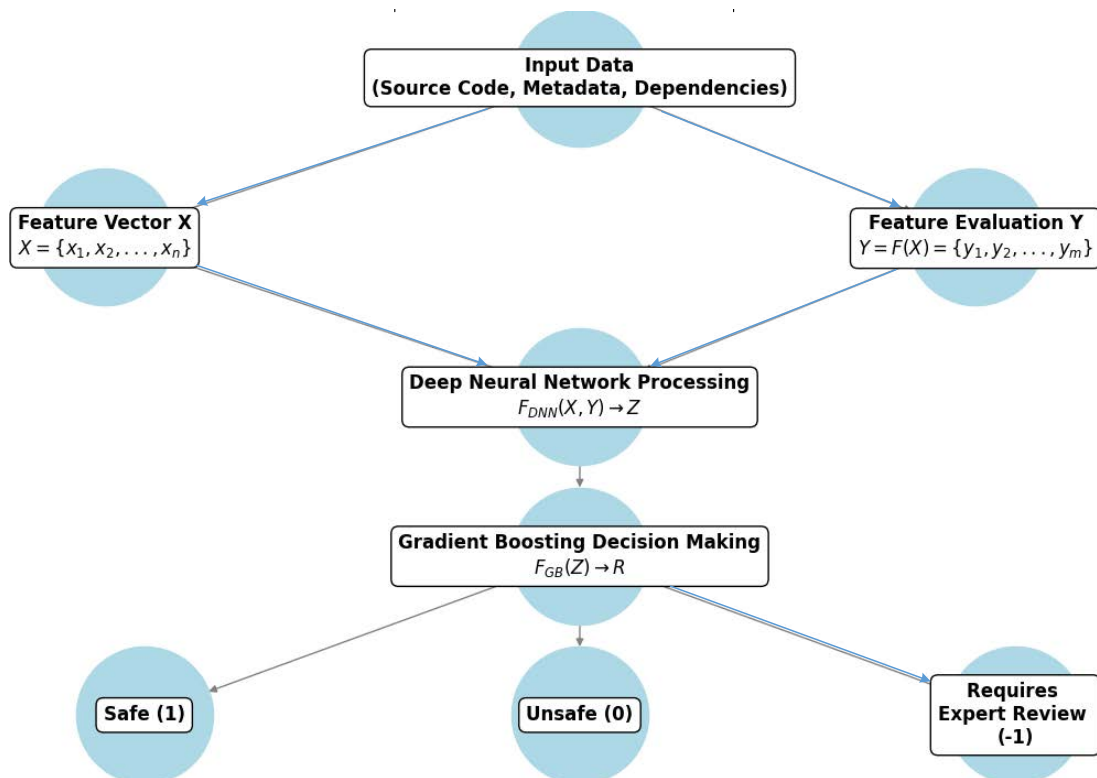


Fig. 1. Scheme of the software verification process for cybersecurity requirements

The first stage involves the formation of a vector of security characteristics that contains structured information about potential risks in the program code. The input data are the software source code, its meta-information, dependencies, and static analysis results. Preliminary processing is performed, which involves

normalizing and cleaning the information, as well as structuring it for further analysis.

The second stage, data mining, is performed using deep neural networks. DNNs analyze the obtained characteristics, identifying key patterns that may indicate the presence of vulnerabilities. The use of neural

networks makes it possible to automatically detect hidden patterns that are difficult to identify using traditional methods. This results in a compact feature vector containing generalized information about potential threats in the software.

At the final stage, a decision is made based on the obtained feature vector. Gradient boosting is used for this purpose, which helps to effectively classify software by risk level. Gradient boosting uses historical data on known vulnerabilities and can adapt to new threats by updating the model.

The decision can have three possible states:

- 1 (meets security requirements) – if the software does not contain critical threats and does not contradict established standards;
- 0 (does not meet security requirements) – if critical violations and potential threats have been identified
- (-1) (requires additional verification by an expert) – if the system could not unambiguously determine the level of software security and additional expert assessment is required.

Formation of a vector of security characteristics is one of the key stages of assessing software compliance with security requirements. This process consists in building a vector containing the characteristics of the program code that directly affect its security level. The resulting vector is used as input information for further intelligent processing, which allows automating the analysis and decision-making process regarding software compliance with the established criteria.

The process of forming a characteristic vector includes several main stages. At the first stage, initial data is received, including analysis of the software source code, its architectural features, imported libraries, communication protocols used, and mechanisms for interacting with system resources. The next stage is the identification of security characteristics, including the correct implementation of authentication mechanisms, access control, exception handling, memory management, and the use of cryptographic algorithms.

The final step is to build a vector of characteristics in mathematical form. The input data is converted into numerical form, which is used for further machine analysis. Formally, the feature vector can be represented as

$$X = \{x_1, x_2, \dots, x_n\},$$

where each element  $x_i$  corresponds to a certain security parameter, represented in numerical format.

Once formed, the vector is passed to the input of a deep neural network, which performs an automated analysis of the dependencies between the characteristics and identifies hidden patterns that may indicate the presence of potential threats in the software.

Evaluation of software security characteristics is the next important stage of analysis, which makes it possible to determine the level of compliance of the software under study with the established security requirements. Within the framework of the proposed intelligent method, the assessment is carried out in two stages.

1. A deep neural network (DNN) extracts security features from the input data and forms a feature vector.
2. Gradient boosting analyzes the resulting vector and classifies software by the level of compliance with security requirements.

Stage 1. *Forming a vector of estimates using a deep neural network*

After forming an input vector of security characteristics  $X$  containing structural parameters of the program code, memory management models, cryptography usage, and other important attributes, the neural network model automatically extracts significant characteristics.

Formally, a deep neural network builds a reconstruction of:

$$Y = F_{DNN}(X),$$

where  $X = \{x_1, x_2, \dots, x_n\}$  – input vector of safety characteristics;  $Y = \{y_1, y_2, \dots, y_m\}$  – the output vector of safety assessments after GNN processing.

The  $FDNN$  function implements the process of extracting features and representing them in a multidimensional space. This allows to reduce the dimensionality of the input data and focus on the key characteristics that have the greatest impact on security.

Stage 2. *Feature analysis and classification using gradient boosting*

At the next stage, the vector of scores  $Y$  obtained at the output of the deep neural network is transferred to the gradient boosting engine, which classifies the security level of the software.

Gradient boosting builds a risk function that determines the probability of software belonging to a certain security class:

$$P(C_k) = F_{GB}(Y) = \sum_{i=1}^m w_{k,i} y_i,$$

where  $P(C_k)$  – probability of software belonging to a security class  $C_k$ ;  $w_{k,i}$  is the weight of the  $i$ -th feature for the  $k$ -th class;  $y_i$  – certain values of the security assessment vector.

Gradient boosting analyzes the results and makes a decision on the security level of the software. The final classification can be presented in the form of:

- $C_{safe}$  – software meets security requirements;
- $C_{unsafe}$  – software does not meet security requirements;
- $C_{uncertain}$  – software needs additional analysis.

Decision-making is the final stage of software security assessment, where, based on the obtained characteristics and their classification, the compliance of the software with the established security requirements is determined.

The purpose of this stage is to form the final decision  $R$  based on the classification results obtained at the previous stage of the evaluation. The proposed method, which combines deep neural networks (DNNs) and gradient boosting, makes the decision in several stages.

1. Receiving input data: the system accepts the security assessment vector  $Y$ , formed after processing by the ANN software.

2. Calculation of the compliance level: probabilistic analysis metrics are used to determine whether the software under investigation meets or does not meet the requirements.

3. Formation of the final decision: the decision is made based on a comparison of the obtained scores with the security benchmarks.

According to the main task, there are three possible solutions:

- software meets the security requirements;
- software does not meet the security requirements;
- software requires additional analysis by an expert.

This can be formally represented by the equation:

$$R = \begin{cases} 1, & \text{if } Y > Y_{safe} \\ 0, & \text{if } Y < Y_{unsafe} \\ -1, & \text{if } Y_{unsafe} \leq Y \leq Y_{safe}, \end{cases}$$

where  $Y_{safe}$  – threshold value of safety compliance;  $Y_{unsafe}$  – a critical value indicating that the software does not meet the requirements.

To determine the software security level more accurately, a distance metric to the reference values is introduced. It is calculated by the following formula:

$$D_{safe} = \sqrt{(y_1 - Y_{safe})^2 + (y_2 - Y_{safe})^2},$$

$$D_{unsafe} = \sqrt{(y_1 - Y_{unsafe})^2 + (y_2 - Y_{unsafe})^2},$$

where  $y_1, y_2$  – the values of the elements of the compliance classifier for the software under investigation.

Based on the calculated values, the system determines which zone the software under investigation belongs to:

- compliance zone – the software is safe;
- non-compliance zone – the software has critical vulnerabilities.
- zone of uncertainty – the system cannot make a final decision and requires expert intervention.

The  $D_{safe}$  value is used to calculate the distance from the test sample to the reference safe condition.  $D_{unsafe}$  and  $D_{uncertain}$  are calculated in the same way. The final solution  $R$  is defined as the class to which the distance is minimal:

$$R = \operatorname{argmin}(D_{safe}, D_{unsafe}, D_{uncertain}).$$

Fig. 2 shows the space of possible solutions, which has three zones: conformity, inconsistency and uncertainty.

Fig. 2 illustrates the scope of possible solutions for software security compliance. It allows you to assess the position of a particular decision in the context of making the final verdict on software security.

The graphic shows three main decision-making zones.

The *Safe Zone* is the area where the software meets the established security criteria. It is indicated by the  $R_{true}$  point (black circle in the lower right corner).

*Unsafe Zone* is the area where the software does not meet the security requirements. It is indicated by  $R_{false}$  (black cross in the upper left corner).

*Uncertainty Zone* is an intermediate area where the system cannot unambiguously determine the level of security. It is shaded in gray.

In the decision space model (Fig. 2), the point  $R_{true} = (1, 0)$  is used as a conditional reference for a safe sample, and  $R_{false} = (0, 1)$  is used as a reference for an unsafe sample. These values correspond to the normalized coordinates of the two key features  $y_1$  and  $y_2$ , which have the greatest impact on the classification.




Fig. 2. Possible solutions space

The decision space is formed based on the distances to these points, and the decision is made based on the minimum Euclidean distance.

For each sample under study, the Euclidean distance to each of the reference points is calculated. The decision is made either on the basis of the minimum distance or on the basis of thresholds:

$$\begin{cases} \text{Safe, if } P(C_{safe}) > \theta_{safe} \\ \text{Unsafe, if } P(C_{unsafe}) > \theta_{unsafe} \\ \text{Uncertain, other,} \end{cases}$$

where  $P(C_k)$  – is the probability of belonging to the class  $C_k$ , calculated through the *softmax*-normalization of the evaluation function

$$P(C_k) = \frac{e^{S(C_k)}}{\sum_j e^{S(C_j)}}.$$

Additionally, Fig. 2 shows the directions of decision-making. The green arrow indicates the direction to the safety compliance area. The red arrow points to the area of non-compliance, signaling risks.

Thus, making a decision on software security compliance is an automated process based on the analysis of a vector of characteristics using machine learning, neural networks, and classification algorithms.

This approach significantly reduces the time required for verification, increases the accuracy of the assessment, and reduces the likelihood of false conclusions.

In the process of software security assessment, there is a need to create an intelligent system capable of analyzing program code and related characteristics to make decisions on compliance with security requirements. The main task is to automate the analysis process, which helps reduce the risk of human error and increase the speed of decision-making.

The proposed hybrid method involves two main stages of data processing.

A deep neural network (DNN) automatically extracts software security features by converting input characteristics into vector representations.

Gradient boosting uses the obtained features to make the final decision on the level of software security.

To build such a model, the following conditions are defined. Input data: program code, meta information, dependencies, API calls, results of static and dynamic analysis. Output data: the security level of software that belongs to one of the categories, including safe (*Safe*), unsafe (*Unsafe*), or requires expert analysis (*Uncertain*).

Limitations: the need to optimize computing resources to process large amounts of program code and the ability to generalize the model for different categories of software.



The main challenge in solving this task is to choose the right features that have the greatest impact on the security level. The use of deep learning at the first stage allows you to get automatically extracted features that are then used for classification. This helps to avoid manual selection of characteristics and allows you to find hidden patterns in the software structure that are difficult to detect using traditional methods.

The development of a neural network architecture for software security analysis is based on the need to create an effective model capable of extracting hidden patterns in the source code and related characteristics. The main task is to build a DNN that accepts a large amount of input data, gradually identifies significant features, and forms a compact vector of characteristics for further analysis.

Let  $X = \{x_1, x_2, \dots, x_n\}$  be an input vector of security characteristics containing a set of parameters such as APIs used, dependencies, code structure, and other critical data. The first layer of the network performs an affine transformation on the input:

$$H_1 = \sigma(W_1 X + b_1),$$

where  $W_1$  is the weight matrix of the first hidden layer (dimensions  $128 \times n$ );  $b_1$  – displacement vector;  $\sigma$  – activation function (ReLU for nonlinear transformation).

The next hidden layer continues feature extraction using the previous layer as input:

$$H_2 = \sigma(W_2 H_1 + b_2),$$

where  $W_2$  is the weighting matrix of the second layer (dimensions  $64 \times 128$ );  $b_2$  – the corresponding offset.

The final hidden layer is formed by the feature vector  $Z$ , which contains a compact representation of the most important software characteristics:

$$Z = W_3 H_2 + b_3,$$

where  $W_3$  – transformation matrix to the space of 32 or 64 features.

The model power is calculated based on the general formula for hidden layers:

$$N_{hidden} = \frac{N_{input} + N_{output}}{2} + C_N,$$

where  $N_{input}$  – number of input features;  $N_{output}$  – dimension of the feature vector;  $C$  – an empirical coefficient that compensates for the complexity of the task.

The feature vector  $Z$  generated by the neural network is a concise representation of data containing key information about the software security level.

The main advantage of this approach is the automatic extraction of significant characteristics without the need for manual selection.

After feature extraction, the network transmits the output vector to a gradient boosting-based classifier that uses a set of decision trees to predict the security level. Classification is performed using a weighted sum of feature values

$$P(C_k) = F_{GB}(Z) = \sum_{i=1}^m w_i z_i,$$

where  $P(C_k)$  – probability of software belonging to the security class  $C_k$ ;  $w_i$  – weighting coefficients of features that are trained during gradient boosting;  $z_i$  – separate elements of the feature vector.

The final decision on the level of security is made based on probability thresholds:

$$R = \begin{cases} 1, & \text{if } P(C_{safe}) > \theta_{safe} \\ 0, & \text{if } P(C_{unsafe}) > \theta_{unsafe} \\ -1, & \text{otherwise,} \end{cases}$$

where  $\theta_{safe}$  and  $\theta_{unsafe}$  – threshold values for decision-making.

The appearance of the neural network architecture model for software security analysis is shown in Fig. 3.

Thus, the developed model allows not only to effectively extract the most important characteristics of software security but also provides highly accurate decision-making by combining the capabilities of deep learning and gradient boosting.

Training a neural network for software security analysis is one of the critical stages of its development, since the right choice of optimization algorithms, loss functions, and approaches to generating training data directly affects the quality of the results achieved. In the proposed architecture, the model is trained in two stages: pre-training of a deep neural network for feature extraction and final training of gradient boosting for decision making.

The deep neural network is trained in a semi-automatic mode using a large dataset containing information about previously tested software products. The input characteristics include statistical indicators, code structure, API calls, libraries used, and other parameters that may affect the level of security. The neural network is trained by minimizing the loss function, which estimates the error of the predicted characteristics relative to the real security labels.

### Optimized Neural Network Architecture for Security Assessment

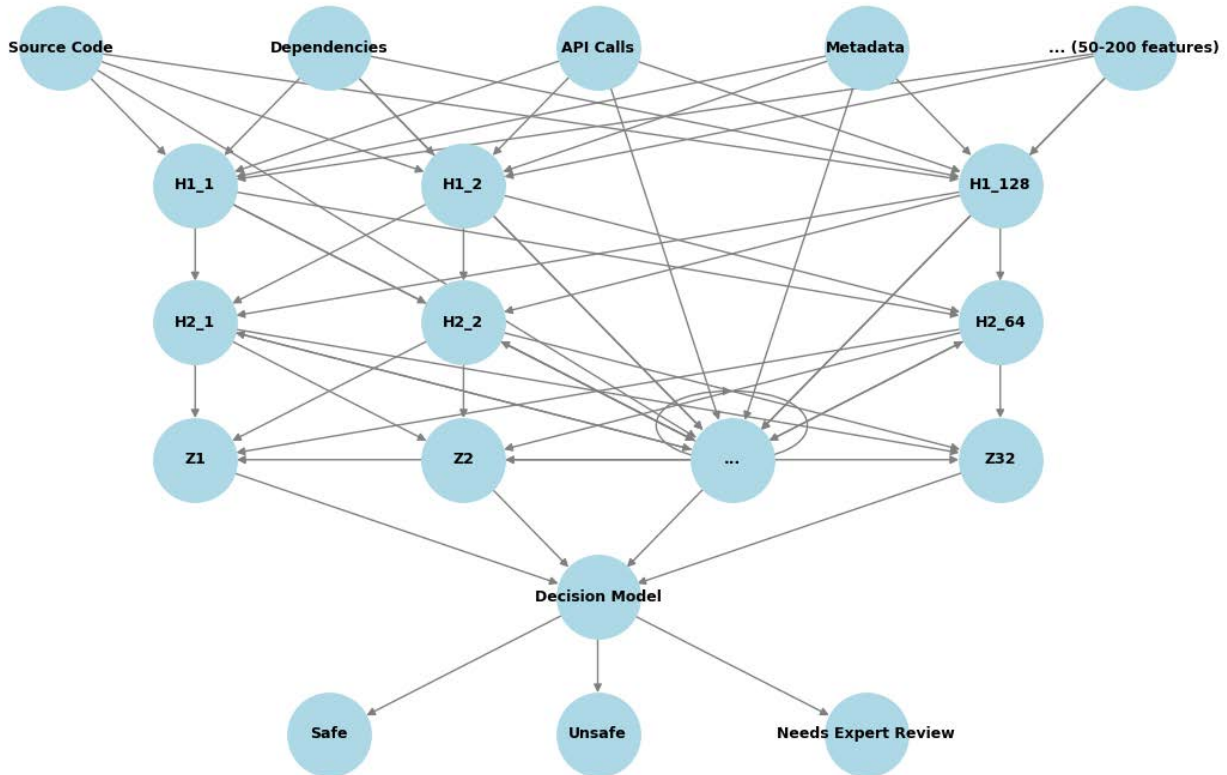


Fig. 3. Neural network architecture model for software security analysis

Formally, the loss function for model training is defined as the mean square error (MSE).

$$L_{DNN} = \frac{1}{N} \sum_{i=1}^N (Z_i - \hat{Z}_i)^2,$$

where  $Z_i$  is the true value of the original feature vector;  $\hat{Z}_i$  – predicted value;  $N$  – is the total number of training examples.

The neural network is optimized using the *Adam* (*Adaptive Moment Estimation*) algorithm, which allows for efficient updating of neuronal weights based on the moment of the last gradient changes. The process of updating the model parameters is given by the equation

$$W^{(t+1)} = W^{(t)} - \eta \cdot \frac{m_t}{\sqrt{v_t + \epsilon}},$$

where  $W^{(t)}$  are the model weights at iteration  $t$ ;  $\eta$  – learning speed;  $m_t$  – gradient estimation;  $v_t$  – mean square value of the gradient;  $\epsilon$  is a small positive constant for computational stability.

After training the neural network and obtaining the optimal feature vector, gradient boosting uses this vector to train the decision-making model. In this case, the loss function is based on the logarithmic error

(*Log Loss*), which ensures maximum accuracy of the probabilistic forecast.

$$L_{GB} = -\frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)),$$

where  $y_i$  – true security class label;  $\hat{y}_i$  – predicted value.

Combined training of the two models improves the quality of classification and reduces the number of false positives, as well as improves the generalizability of the algorithm when analyzing new software.

After training the neural network model and gradient boosting, the results are evaluated to determine the effectiveness of the developed approach. The main criterion is the accuracy of predicting the level of software security, which is assessed using the main classification metrics.

To evaluate the accuracy, standard metrics *Precision*, *Recall*, *F1-score* are used to determine how well the model classifies safe and unsafe software [13, 14].

ROC-AUC curves [15, 16] are also used to show the balance between sensitivity and specificity of the model.

The results of the comparative study can be seen in Figs. 4–6.

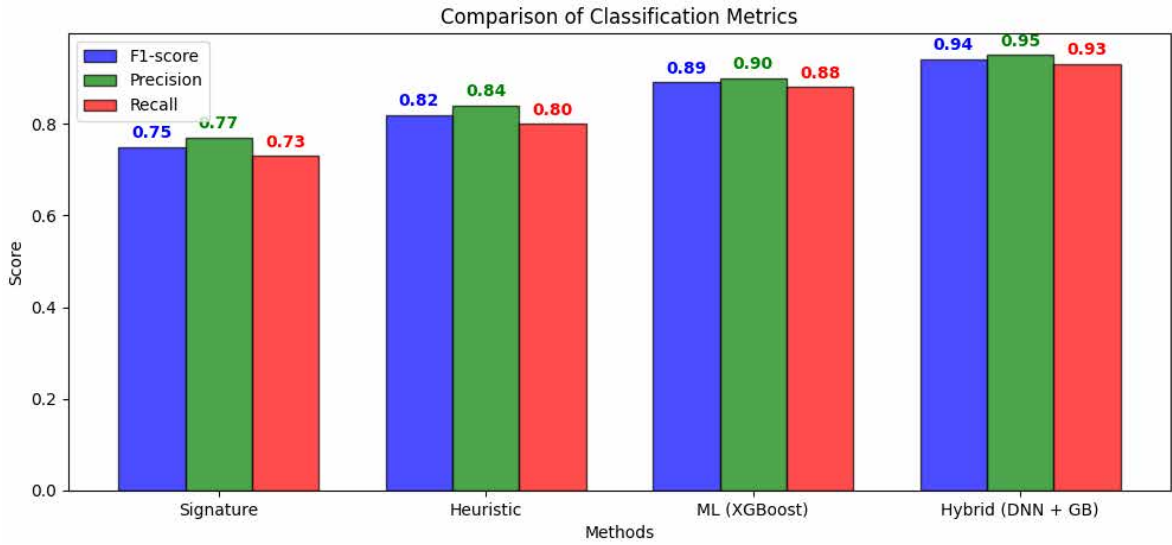


Fig. 4. Histograms comparing classification metrics




Fig. 5. Graphs and results of ROC curve comparison




Fig. 6. Histograms and results of comparing processing time and false predictions

The test was performed on a sample of software that included both known secure applications and those containing vulnerabilities. For the analysis, 5000 samples were selected, divided into training (70%) and test (30%) sets.

The test results showed that the combined model, which uses deep learning for feature extraction and gradient boosting for classification, provides high accuracy compared to classical methods. On average, the model's accuracy is 92.3%, F1-score is 90.8%, and AUC-ROC is 0.9%.

Compared to traditional methods such as signature analysis or heuristic approaches, the model demonstrated a significant improvement in accuracy and generalizability. The model proved to be particularly effective in detecting malware, which reduced the number of *False Negative* (FN) cases where potentially malicious code went undetected.

Thus, the training and testing results confirm the effectiveness of the proposed approach. Thanks to the combined use of deep learning for feature extraction and gradient boosting for decision-making, it was possible to significantly improve the quality of software security assessment and reduce the influence of the human factor in the analysis process.

---

## Conclusions

The article develops an intelligent method for supporting software security decision-making using hybrid models that combine deep neural networks (DNNs) for automated security feature extraction and gradient boosting for risk level classification. The purpose of the study was to create an effective tool for automating the software security assessment process, which would reduce the time for analysis, increase the accuracy of the assessment, and adapt to new threats. To achieve this goal, the task was to develop a hybrid model that would combine the benefits of deep learning to identify complex patterns in program code and gradient boosting to make accurate security decisions.

During the study, a method was developed that included three main stages: preparation of initial data, intelligent processing, and decision-making. At the first stage, a vector of security characteristics is formed,

containing information about the source code, architectural features, dependencies, and the results of static analysis. At the second stage, a deep neural network extracts key security features, and at the third stage, gradient boosting classifies software by risk level. This approach has made it possible to significantly improve the accuracy of security assessment, reduce the number of false conclusions, and automate the decision-making process.

The developed method demonstrates high efficiency compared to traditional methods such as static and dynamic analysis. The test results showed that the model's accuracy is 92.3%, F1-score is 90.8%, and AUC-ROC is 0.94%. This indicates that the proposed method is an effective tool for assessing software security, especially in the context of the rapid development of new types of cyber threats.

The scientific novelty of the study is the integrated implementation of deep learning and gradient boosting for software security analysis. This approach makes it possible to automatically detect hidden patterns in program code that are difficult to identify using traditional methods and to adapt to new threats. In addition, the proposed model significantly reduces the time for analysis and reduces dependence on the human factor, which is an important step towards automating cybersecurity processes.

The practical significance of the developed method lies in its application to assess software security in real-world conditions. The model can be used for automated testing of large amounts of code, which is especially important for companies developing complex software products with high security requirements. By reducing the time for analysis and increasing the accuracy of the assessment, the proposed method can significantly reduce the cost of software testing and certification.

Thus, the developed method is a promising direction for further research in the field of cybersecurity. It helps to effectively solve problems related to software security assessment and provides high accuracy and speed of analysis. In the future, the model can be improved by integrating new machine learning methods and expanding the training data set, which will further improve its effectiveness.

## References

1. Madushan, H.; Salam, I.; Alawatugoda, J. (2022), "A Review of the NIST Lightweight Cryptography Finalists and Their Fault Analyses". *Electronics*, 11, 4199 p. DOI: [10.3390/electronics11244199](https://doi.org/10.3390/electronics11244199)
-

2. Nikitenko, Andrii (2023), "Network intrusion detection systems based on deep learning neural networks". *Scientific papers of Donetsk National Technical University. Series: Informatics, Cybernetics and Computer Science*. №2. P. 15–21. DOI: 10.31474/1996-1588-2023-2-37-15-21
3. El-Hajj, M.; Mirza, Z.A. (2024), "Protecting Small and Medium Enterprises: A Specialized Cybersecurity Risk Assessment Framework and Tool". *Electronics*, 13, 3910 p. DOI: <https://doi.org/10.3390/electronics13193910>
4. Fredj, Ouisssem; Cheikhrouhou, Omar; Krichen, Moez; Hamam, Habib; Derhab, Abdelouahid (2021), "An OWASP Top Ten Driven Survey on Web Application Protection Methods". *Lecture Notes in Computer Science*, P. 235-252. DOI: 10.1007/978-3-030-68887-5\_14
5. Mateo Tudela, F.; Bermejo Higuera, J.R.; Bermejo Higuera, J.; Sicilia Montalvo, J.A.; Argyros, M.I. (2020), "On Combining Static, Dynamic and Interactive Analysis Security Testing Tools to Improve OWASP Top Ten Security Vulnerability Detection in Web Applications". *Appl. Sci.*, 10, 9119 p. DOI: 10.3390/app10249119
6. Kondraciuk, A., Bartos, A., & Pańczyk, B. (2022), "Comparative analysis of the effectiveness of OWASP ZAP, Burp Suite, Nikto and Skipfish in testing the security of web applications". *Journal of Computer Sciences Institute*, 24, P. 176–180. DOI: [10.35784/jcsi.2929](https://doi.org/10.35784/jcsi.2929)
7. Cao, W., Kosenko V., Semenov, S. (2022), "Study of the efficiency of the software security improving method and substantiation of practical recommendations for its use". *Innovative technologies and scientific solutions for industries*, 1 (19), P. 55–64. DOI: [10.30837/ITSSI.2022.19.055](https://doi.org/10.30837/ITSSI.2022.19.055)
8. Aldyafiah, I.M.; Zhao, W.; Yang, S.; Luo, X. (2024), "The Impact of Input Types on Smart Contract Vulnerability Detection Performance Based on Deep Learning: A Preliminary Study". *Information*, 15, 302 p. DOI: 10.3390/info15060302
9. Alshehri, W.; Kammoun Jarraya, S.; Allinjawi, A. (2024), "Software Reliability Prediction Based on Recurrent Neural Network and Ensemble Method". *Computers*, 13, 335 p. DOI: 10.3390/computers13120335
10. Gavrylenko, S., Abdullin, O. (2024), "Improving the quality of payment fraud detection by using a combined approach of transaction analysis". *Innovative technologies and scientific solutions for industries*, 4(30), P. 31–38. DOI: 10.30837/2522-9818.2024.4.031
11. Ullah, F.; Ullah, S.; Naeem, M.R.; Mostarda, L.; Rho, S.; Cheng, X. (2022), "Cyber-Threat Detection System Using a Hybrid Approach of Transfer Learning and Multi-Model Image Representation". *Sensors*, 22, 5883 p. DOI: 10.3390/s22155883
12. Zhang, S.; Chen, R.; Chen, J.; Zhu, Y.; Hua, M.; Yuan, J.; Xu, F. (2024), "L-GraphSAGE: A Graph Neural Network-Based Approach for IoV Application Encrypted Traffic Identification". *Electronics*, 13, 4222 p. DOI: 10.3390/electronics13214222
13. Romenskiy, V., Nevliudova, V., & Persyanova, E. (2020), "Study of the operating time of the protective coating of surfaces of assembly and welding equipment". *Innovative technologies and scientific solutions for industries*, 1 (11), P. 134–146. DOI: 10.30837/2522-9818.2020.11.134
14. Yeremenko, O., Yevdokymenko, M., Sleiman, B. (2020), "Advanced performance-based fast rerouting model with path protection and its bandwidth in software-defined network". *Innovative technologies and scientific solutions for industries*, 1 (11), P. 163–171. DOI: [10.30837/2522-9818.2020.11.163](https://doi.org/10.30837/2522-9818.2020.11.163)
15. Gavrylenko, S., Poltoratskyi, V., Nechyporenko, A. (2024), "Intrusion detection model based on improved transformer". *Advanced Information Systems*, 8(1), P. 94–99. DOI: [10.20998/2522-9052.2024.1.12](https://doi.org/10.20998/2522-9052.2024.1.12)
16. Moskalenko, V.; Kharchenko, V.; Semenov, S. (2024), "Model and Method for Providing Resilience to Resource-Constrained AI-System". *Sensors*, 24, 5951 p. DOI: [10.3390/s24185951](https://doi.org/10.3390/s24185951)

Надійшла (Received) 05.03.2025

*Відомості про авторів / About the Authors*

**Сітнікова Оксана Олександрівна** – кандидат технічних наук, Приватна установа "Університет науки, підприємництва та технологій", Київ, Україна; e-mail: oasitnikova11@gmail.com; ORCID ID: <https://orcid.org/0000-0002-2417-8220>

**Мельник Маргарита Олександрівна** – кандидат технічних наук, доцент, Приватна установа "Університет науки, підприємництва та технологій", Київ, Україна; e-mail: Margaritochek@gmail.com; ORCID ID: <https://orcid.org/0000-0003-0619-7281>

**Сирота Олена Петрівна** – кандидат технічних наук, доцент, Приватна установа "Університет науки, підприємництва та технологій", Київ, Україна; e-mail: [olena.syrota@setuniversity.tech](mailto:olena.syrota@setuniversity.tech); ORCID ID: <https://orcid.org/0000-0003-2198-8241>

**Семенов Сергій Геннадійович** – доктор технічних наук, професор, Приватна установа "Університет науки, підприємництва та технологій", Київ, Україна; Харківський національний економічний університет ім. С. Кузнеця, Харків, Україна; e-mail: s\_semenov@ukr.net; ORCID ID: <http://orcid.org/0000-0003-4472-9234>

**Sitnikova Oksana** – PhD, Private Institution "University of Science, Entrepreneurship and Technology", Kyiv, Ukraine.

**Melnyk Marharyta** – PhD, Assistant Professor, Private Institution "University of Science, Entrepreneurship and Technology", Kyiv, Ukraine.

**Syrota Olena** – PhD, Private Institution "University of Science, Entrepreneurship and Technology", Kyiv, Ukraine.

**Semenov Serhii** – Doctor of Sciences (Engineering), Professor, Private Institution "University of Science, Entrepreneurship and Technology", Kyiv, Ukraine, Simon Kuznets Kharkiv National University of Economics, Kharkiv, Ukraine.

## ІНТЕЛЕКТУАЛЬНИЙ МЕТОД ПІДТРИМКИ УХВАЛЕННЯ РІШЕННЯ ПРО БЕЗПЕКУ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ З ВИКОРИСТАННЯМ ГІБРИДНИХ МОДЕЛЕЙ

**Мета.** Дослідження спрямовано на розроблення інтелектуального методу підтримки прийняття рішень щодо оцінювання безпеки програмного забезпечення з використанням гібридної моделі на основі глибокого навчання та градієнтного бустингу. Мета полягає в підвищенні точності класифікації, інтерпретованості та адаптивності в умовах зростання кіберзагроз. **Методи.** Запропонований метод поєднує глибокі нейронні мережі для автоматизованого вилучення ознак і градієнтний бустинг для остаточного прийняття рішення. Побудовано модуль класифікації на основі обчислення ймовірностей належності програмного забезпечення до класів безпеки. Крім того, використано геометричну інтерпретацію простору рішень із розрахунком евклідової відстані до еталонних класів (безпечного, небезпечного, невизначеного). Імовірності нормалізуються за допомогою *softmax*-функції. Модель навчалася на розміченому наборі даних і перевірялася за допомогою порівняльних метрик. **Результати.** Розроблений прототип продемонстрував покращені характеристики порівняно з класичними підходами до класифікації. Проведені експерименти підтвердили вищу точність класифікації та чіткіше розділення зон безпеки в нормованому просторі ознак. Метод ефективно виявляє випадки, що потребують експертного аналізу, та знижує частоту хибно позитивних рішень. Візуалізація простору рішень підвищує інтерпретованість результатів моделі. **Наукова новизна.** Запропоновано гібридний інтелектуальний метод, що інтегрує два сучасні підходи машинного навчання – глибокі нейронні мережі та градієнтний бустинг – в єдину архітектуру для оцінювання безпеки програмного забезпечення. Простір рішень формалізовано через імовірнісні пороги значення та геометричну інтерпретацію. **Практична значущість.** Метод може бути застосований у процесах безпечного розроблення програмного забезпечення для автоматичного оцінювання рівня його безпеки. Він підтримує розробників і фахівців з кібербезпеки у виявленні потенційно небезпечних модулів на ранніх етапах життєвого циклу ПЗ. Підхід також може бути інтегрований у системи статичного аналізу або середовища CI/CD з метою підвищення стандартів безпеки.

**Ключові слова:** безпека програмного забезпечення; глибокі нейронні мережі; градієнтний бустинг; машинне навчання; гібридні моделі; автоматизований аналіз безпеки; кібербезпека; виявлення вразливостей.

### Бібліографічні опису / Bibliographic descriptions

Сітнікова О. О., Мельник М. О., Сирота О. П., Семенов С. Г. Інтелектуальний метод підтримки ухвалення рішення про безпеку програмного забезпечення з використанням гібридних моделей. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 115–126. DOI: <https://doi.org/10.30837/2522-9818.2025.1.115>

Sitnikova, O., Melnyk, M., Syrota, O., Semenov, S. (2025), "Intelligent method for supporting decision-making on software security using hybrid models", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 115–126. DOI: <https://doi.org/10.30837/2522-9818.2025.1.115>

В. УСАЧОВ, І. ШУБІН

## СТРУКТУРНО-ФУНКЦІОНАЛЬНА МОДЕЛЬ НАВЧАННЯ В КОМП'ЮТЕРИЗОВАНИХ СИСТЕМАХ НАВЧАННЯ

**Предметом статті** є розроблення універсальної структурно-функціональної моделі комп'ютеризованих систем навчання, яка інтегрує моделі студента, навчального процесу та пояснення. Ця модель виконує завдання персоналізації процесу навчання, уваги на індивідуальних особливостях студента та забезпечення довгострокового збереження знань. **Мета роботи** – розроблення універсальної структурно-функціональної моделі системи навчання, яка поєднує сучасні адаптивні алгоритми, інтегрує психологічні та когнітивні аспекти, а також упроваджує нові підходи до довгострокового збереження знань. Особливу увагу зосереджено на гнучкості системи, що дає змогу адаптувати навчальний контент до потреб кожного окремого користувача, зважаючи на динаміку його розвитку та зміну рівня знань. У статті розв'язано такі **завдання**: аналіз наявних моделей навчання, виявлення їх обмежень та розроблення нових підходів для побудови адаптивного навчального процесу. Упроваджено такі **методи**: мережні та векторні моделі для побудови траєкторій навчання, графові структури для візуалізації навчального контенту, алгоритми психологічного профілювання. Крім того, застосовано методи актуалізації знань для оптимізації навчання та зниження рівня забування. **Досягнуті результати**: створено універсальну структурно-функціональну модель комп'ютеризованих систем навчання, яка інтегрує модель суб'єкта навчання, модель навчального процесу та модель пояснення. Модель відтворює структуру адаптивного навчального процесу та взаємозв'язки між його компонентами, що дає змогу персоналізувати навчальні траєкторії з огляду на рівень знань, мотивацію та психологічні особливості суб'єкта навчання. Запропонована модель подає знання за допомогою мережних і векторних структур, що дає змогу систематизувати навчальний матеріал, візуалізувати зв'язки між поняттями та підтримувати адаптивне управління навчальним процесом. Розроблена модель може застосовуватися для аналізу рівня підготовки студентів, підтримки адаптивних стратегій навчання та оцінювання прогресу. Інтеграція механізмів психологічного профілювання та алгоритмів оновлення знань сприяє підвищенню ефективності освітнього процесу. **Висновки**: запропонована структурно-функціональна модель демонструє ефективність у розв'язанні ключових завдань персоналізованого та адаптивного навчання. Інтегруючи психологічні профілі, рівні знань та вдосконалені алгоритми, модель допомагає створювати масштабовані та інтелектуальні освітні системи, здійснювати персоналізоване навчання, ефективне оцінювання та цілеспрямований зворотний зв'язок, забезпечуючи довгострокове збереження знань і сприяючи інноваціям у сучасних освітніх технологіях.

**Ключові слова**: комп'ютеризовані системи навчання; оцінювання знань; модель студента; адаптивні алгоритми навчання.

### Вступ

Сучасні комп'ютеризовані навчальні системи продовжують активно розвиватися, охоплюючи нові технологічні підходи, спрямовані на покращення якості освіти. У зв'язку з цифровізацією освітнього середовища зростає потреба в упровадженні адаптивних моделей навчання, що дають змогу персоналізувати освітній процес, зважаючи на індивідуальні особливості студентів, і забезпечувати ефективне набуття знань. Одним із ключових напрямів удосконалення навчальних систем є використання штучного інтелекту, експертних систем та інтелектуального аналізу даних, що дає змогу автоматизувати процеси адаптації контенту, оцінювання знань і визначення оптимальних навчальних стратегій.

Значний прогрес спостерігається у розвитку веборієнтованих навчальних систем, таких як *ELM-ART*, *CALAT*, *WITS* [1], що забезпечують адаптивне керування навчальними траєкторіями та надання персоналізованого контенту. Проте більшість сучасних платформ мають низку обмежень: вони не завжди беруть до уваги когнітивні особливості студента, його стиль навчання та рівень підготовки, а також часто обмежені лише модулем тестування знань без глибокої інтеграції механізмів пояснення та оновлення знань. Це знижує ефективність навчання та не допомагає повною мірою реалізувати потенціал адаптивної освіти.

Одним із важливих викликів у розробленні інтелектуальних навчальних систем є необхідність комплексного підходу до моделювання освітнього процесу. Більшість наявних підходів спрямовані на окремих аспектах адаптації, таких як підбір

навчального контенту або визначення рівня знань студента, проте не забезпечують узгодженості між різними складниками освітнього середовища. Для розв'язання окресленої проблеми доцільним є використання структурно-функціональної моделі комп'ютеризованих систем навчання, що дає змогу інтегрувати ключові компоненти навчального процесу, зокрема модель суб'єкта навчання, модель навчального процесу та модель пояснення.

Розроблення такої моделі сприяє ефективному управлінню навчальними траєкторіями та забезпеченню персоналізованого підходу до навчання. Використання мережних і векторних структур знань допомагає не лише систематизувати навчальний матеріал, але й забезпечити його актуалізацію, аналізуючи індивідуальний прогрес студента. Крім того, механізми пояснення в навчальній системі відіграють важливу роль у формуванні розуміння навчального матеріалу: вони дають змогу деталізувати навчальні завдання, ідентифікувати помилки студента та забезпечувати їх виправлення в інтерактивному режимі. Окрему роль відіграють алгоритми оновлення знань, що підтримують довгострокове засвоєння матеріалу. Здатність системи прогнозувати освітні потреби студента й підлаштовувати навчальний контент під його індивідуальні можливості значно підвищує ефективність освітнього процесу. Інтеграція когнітивного аналізу та психологічного профілювання забезпечує додаткові можливості для персоналізації навчання, що є важливим фактором у побудові адаптивних освітніх середовищ нового покоління.

Отже, сучасні виклики в галузі комп'ютеризованого навчання вимагають розроблення універсальних моделей, які б поєднували гнучкість, адаптивність і точність у керуванні освітнім процесом. Структурно-функціональна модель, що розробляється в межах цього дослідження, сприяє розв'язанню зазначених проблем, забезпечуючи узгоджену взаємодію між усіма складниками освітнього процесу та відкриваючи нові можливості для персоналізованого навчання.

### **Аналіз останніх досліджень і публікацій**

Сучасні дослідження в галузі комп'ютеризованих систем навчання активно розвиваються, особливо в напрямі адаптивних технологій, інтерактивних навчальних середовищ та розроблення моделей,

адаптованих до індивідуальних потреб студентів [2, 3]. Особливу увагу автори цих досліджень зосереджують на інтеграції психологічних аспектів у навчальний процес, що сприяє створенню ефективних стратегій взаємодії системи та користувача. Зокрема в роботах [2, 3] продемонстровано, як використання персоналізованих підходів і студентоцентризованих моделей сприяє досягненню кращих результатів в опануванні складних дисциплін. Крім того, автори зазначених досліджень наголошують на важливості гнучких механізмів адаптації, що дають змогу коригувати навчальний процес відповідно до рівня підготовки студентів, стилю навчання та когнітивних особливостей.

У дослідженні [4] приділено увагу когнітивним моделям у прогнозуванні успішності студентів. Зокрема зазначено, що сучасні алгоритми машинного навчання можуть ефективно аналізувати великі масиви даних про навчальний процес для побудови точних моделей поведінки здобувачів. Крім цього, наголошується на необхідності зважати на їхні індивідуальні особливості, такі як мотивація, стресостійкість та інші психологічні характеристики.

Інший актуальний напрям досліджень присвячений побудові навчальних траєкторій на основі моделювання компетентностей. У роботі [5] проілюстровано, як мережні моделі можуть застосовуватися для подання знань у вигляді графів, де вершини відповідають поняттям, а ребра – зв'язкам між ними. Такий підхід забезпечує наочне подання навчального матеріалу та спрощує адаптацію контенту відповідно до потреб студентів.

Дослідження в галузі психології навчання також посідають важливе місце в аналізі освітніх систем. У роботі [6] порушено питання мотивації навчання, розвитку пізнавального інтересу, впливу емоційних станів на формування знань. Зазначено, що увага до зазначених факторів у процесі моделювання може значно покращити взаємодію користувача з освітніми системами.

### **Визначення не розв'язаних раніше частин загальної проблеми. Мета роботи й завдання**

Незважаючи на значний прогрес у розвитку комп'ютеризованих систем навчання, чимало нерозв'язаних питань залишаються критично важливими для створення ефективних освітніх платформ. Однією з найактуальніших проблем є відсутність глибокої інтеграції психологічних



профілів студентів у процес адаптації навчального контенту. Більшість наявних систем спираються на узагальнені моделі навчання, що не зважають на індивідуальні особливості студентів, такі як когнітивні здібності, емоційний стан, рівень мотивації та здатність до самостійного виконання завдань. Це створює суттєві перешкоди для персоналізації навчального процесу, особливо під час вивчення складних дисциплін або міждисциплінарних тем.

Іншою критичною проблемою є обмежені можливості сучасних алгоритмів прогнозування успішності студентів. Наявні підходи часто зосереджені на короткострокових результатах та ігнорують складні взаємозв'язки між навичками, поняттями та динамікою навчання, що суттєво впливають на довгостроковий успіх. Ці обмеження перешкоджають розробленню ефективних стратегій навчання, які можуть адаптуватися до мінливих потреб студентів.

Питання збереження знань також залишається нерозв'язаним. Знання, що не застосовуються регулярно, поступово зникають, зменшуючи свою практичну цінність, це призводить до значної втрати інформації з часом. Сучасні системи рідко пропонують механізми регулярного повторення та оновлення даних, що спричиняє інформаційне перевантаження та зниження загальної ефективності навчання.

Крім того, існує неабиякий попит на інструменти для візуалізації складних взаємозв'язків між навчальними матеріалами. Відсутність чіткого графічного подання знань створює труднощі в розумінні концепцій, особливо коли йдеться про складні міждисциплінарні або багаторівневі теми. Це заважає як студентам, так і викладачам формувати цілісне розуміння матеріалу.

Метою цього дослідження є розроблення універсальної структурно-функціональної моделі системи навчання, що поєднує сучасні адаптивні алгоритми, інтегрує психологічні та когнітивні аспекти, а також упроваджує нові підходи до довгострокового збереження знань. Особлива увага зосереджена на гнучкості системи, що дає змогу адаптувати навчальний контент до потреб кожного окремого користувача з огляду на динаміку його розвитку та зміну рівня знань.

Розроблення таких систем вимагає багатоступового підходу, що передбачає аналіз наявних моделей, виявлення їх обмежень і створення нових алгоритмів. У цьому контексті важливого значення набуває створення інтерактивних навчальних траєкторій.

Ці траєкторії допоможуть студентам ефективніше орієнтуватися в навчальних матеріалах, виявляти слабкі місця та поступово покращувати свої результати. Навчальні траєкторії ґрунтуватимуться на мережних моделях, що розкривають зв'язки між поняттями та забезпечують візуальну підтримку освітнього процесу.

Окремої уваги заслуговує питання актуалізації знань. Розроблення алгоритмів, що підтримують повторне вивчення матеріалів, допоможе знизити рівень забування та забезпечити стабільність набутих знань. Ці алгоритми мають брати до уваги не тільки частоту повторення, але й індивідуальні особливості кожного студента, зокрема попередній досвід, тип мислення та рівень когнітивного навантаження.

Упроваджуючи запропоновані підходи, навчальні системи можуть вийти на новий рівень ефективності, забезпечити якісну адаптацію до потреб кожного студента й покращити загальні освітні результати. Це відкриє нові перспективи для розвитку навчальних технологій, зробить їх більш доступними та ефективними для широкого кола користувачів. Такий підхід не лише підвищить якість освітнього процесу, а й сприятиме розвитку інноваційних методів навчання, що відповідають викликам сучасного суспільства та технологічного прогресу.

### Евристична модель завдання навчання

Завдання навчання є найменш формалізованим у класі "типових завдань" задачно-орієнтованої методології побудови комп'ютерних навчальних систем [7], що пов'язано зі слабкою розробкою педагогічних і психологічних теорій здобуття знань, формування понять, побудови умовиводів та з іншими питаннями. Однак завдання навчання можна декомпонувати на послідовність більш простих завдань, таких як діагностика, інтерпретація, планування, проектування, що йдуть одне за одним у чітко визначеному порядку [8], та пов'язати розв'язання перелічених завдань із побудовою відповідних моделей – моделі суб'єкта навчання (діагностика), моделі навчального процесу (планування, проектування, адаптація) та моделі пояснення (інтерпретація).

Тому модель типового завдання навчання  $M_T$  передбачає побудову трьох підмоделей (рис. 1):

- модель суб'єкта навчання ( $M_1$ );
- модель навчання ( $M_2$ );
- модель пояснення ( $M_3$ ).

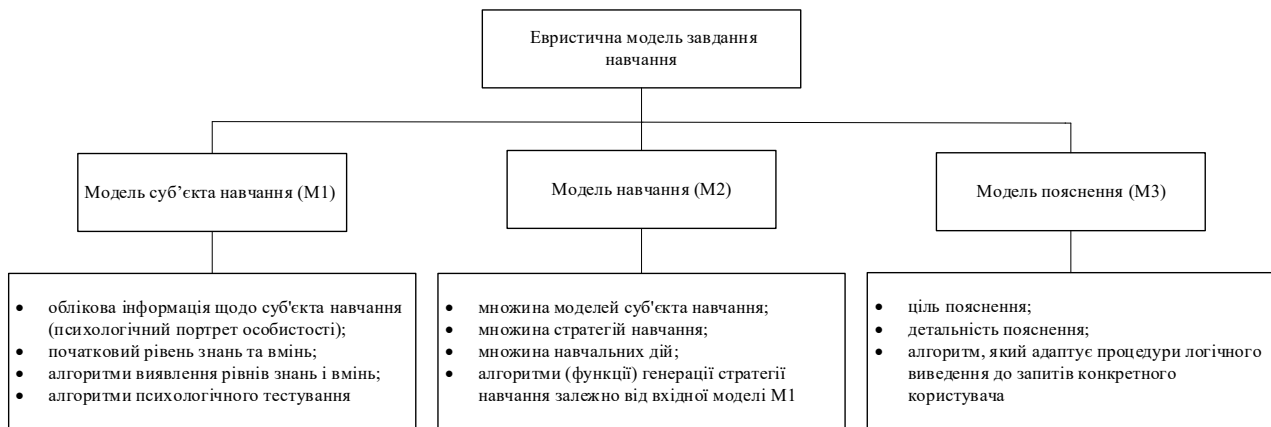


Рис. 1. Модель навчання

### Розроблення моделі суб'єкта навчання ( $M_1$ )

Під час досліджень було розглянуто близько 50 різних моделей управління навчальним процесом з метою визначення їх типів і виявлення найпоширеніших із них, а також параметрів, що впливають на результат і якість навчання.

Унаслідок цього встановлено, що нині найчастіше спостерігаються векторні та мережні моделі – 45 % і 48 % відповідно. У мережних моделях інформація про користувача відтворюється, як правило, за допомогою графа знань, вершини якого відповідають квантам навчальної інформації, а дуги демонструють відношення між ними. Також моделі проаналізовано за параметрами, що застосовуються для відтворення інформації про суб'єкт навчання.

Найпоширенішими параметрами, що беруться до уваги в моделях студента, є:

- 1) рівень знань;
- 2) психологічні характеристики (тип особистості тощо);
- 3) швидкість / стиль навчання (засвоєння, вивчення);
- 4) виконання завдань;
- 5) здатність до навчання (дуже / середньо / мало уважний);
- 6) рівень умінь і навичок;
- 7) метод / стратегія навчання;
- 8) структура курсу.

Оскільки одна з основних цілей навчання – формування навичок у користувача застосовувати надану інформацію для розв'язання конкретних завдань або ситуацій, а базою для цього слугують раніше набуті знання, то такий параметр, як

"рівень знань", додано в усі моделі користувача. Щодо засвоєння предметної галузі не менш важливим є рівень навичок і вмінь, проте моделей, які беруть до уваги цей параметр, досить мало (близько 15 % досліджених). Нині часто спостерігаються мережні моделі, що відтворюють структуру курсу. Цей параметр один із найпоширеніших – використовується приблизно в 32 % систем [9].

Також із класифікації наявних видів моделей користувача можна виокремити фіксувальні та імітаційні моделі суб'єктів навчання.

Перші є набором величин, що визначають стан знань і вмінь суб'єкта навчання, а другі відтворюють погляди суб'єкта навчання на предметну галузь (ПрГ), що вивчають, і механізми розв'язання завдань. Найпростішим варіантом моделі типу  $M_1$ , що фіксує, є оверлейна векторна модель, яка кожному досліджуваному поняттю та/або вмінню ставить у відповідність елемент, що набуває значень "знає / не знає", тоді стан знань суб'єкта навчання визначається набором значень елементів вектора.

Перевагою векторної моделі є її простота, а недоліком – те, що вона не тільки не відтворює когнітивні процеси та методи розв'язання завдань суб'єкта навчання, а й ігнорує зв'язки між поняттями. Конкретні реалізації векторної моделі  $M_1$  описано в [10]. Більш гнучка форма моделі  $M_1$  – мережна оверлейна модель, що є графом, вузли якого відповідають поняттям і/або вмінням, а дуги – відношенням між ними. Кожному вузлу та дузі зіставляється деяка величина або набір величин, що визначають ступінь володіння студента певним поняттям або вмінням, до того ж допускається успадкування величин. Отже, модель  $M_1$  містить такі

компоненти: у найпростішому випадку – облікову інформацію про студента (прізвище, номер навчальної групи, дата роботи  $P_i$  тощо), а в складніших – психологічний портрет особистості суб'єкта навчання ( $P_h$ ) відповідно до [11]; початковий рівень знань і вмінь суб'єкта навчання ( $M_{\text{рез.}}^{\text{поч.}}$ ); остаточний рівень знань і вмінь суб'єкта навчання ( $\pi$ ); алгоритми виявлення рівнів знань і вмінь суб'єкта навчання ( $A$ ); алгоритми психологічного тестування для виявлення

особистісних властивостей, на підставі яких формують психологічний портрет особистості суб'єкта навчання ( $A_{ph}$ ). Під терміном "знання" розуміють теоретичну підготовленість суб'єкта навчання (декларативні знання), а під терміном "уміння" – уміння застосовувати теорію під час розв'язування практичних завдань (процедурні знання) [12]. Узагальнена класифікація моделей суб'єктів навчання наведена на рис. 2.

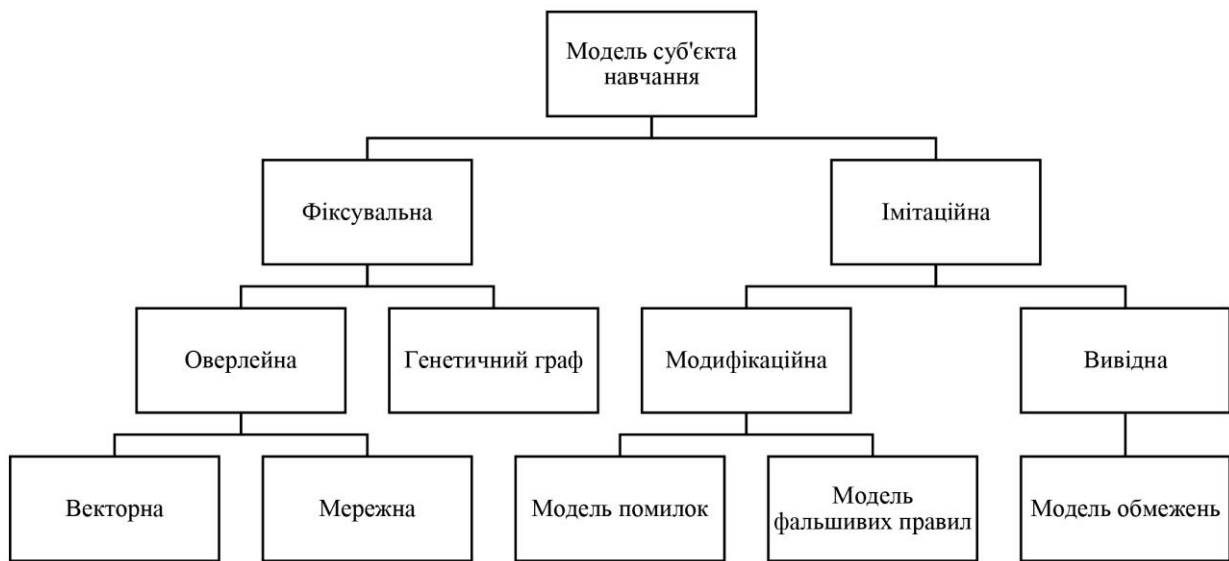


Рис. 2. Класифікація моделей суб'єктів навчання

Для реалізації алгоритмів  $A$  і  $A_{ph}$  під час формування моделі  $M_1$  використано такий набір процедур тестування суб'єкта навчання: процедура введення вихідної інформації (контрольних запитань, вектора правильних відповідей і вагових коефіцієнтів за кожним запитанням); процедура виведення запитань і варіантів відповідей у процесі контролю знань; процедура формування оцінки; процедура обчислення підсумкової оцінки. Модель  $M_1$  містить інформацію про стан знань суб'єкта навчання ( $M_{\text{рез.}}^{\text{поч.}}, M_{\text{рез.}}^{\text{ост.}}$ ) як загальні інтегровані властивості, так і ті, що відтворюють засвоєння ним поточного навчального матеріалу.

Загалом мережна модель суб'єкта навчання – це кінцевий орієнтований граф, що можна описати у такому вигляді:

$$M_{\text{сн}} = V_{\text{сн}}, U_{\text{сн}}, \quad (1)$$

де  $V_{\text{сн}} = V^1, V^2$  – множина вершин, що зі свого боку поділяються на такі підмножини:  $V^1 = \{v_1^1, \dots, v_n^1\}$  – множина досліджуваних понять;  $n$  – кількість досліджуваних понять. У цьому разі елемент:

$$v_i^1 = N_i, T_i, W_i, (i = 1, \dots, n), \quad (2)$$

де  $N_i$  – досліджуване поняття;  $T_i = (0,1)$  набуває значення "знає / не знає";  $W_i = (0, \dots, 10)$  – вага вершини;  $V^2 = \{v_j^2, \dots, v_m^2\}$  – множина вмінь, що належать до цієї моделі;  $m$  – кількість відповідних умінь. У цьому разі елемент:

$$v_j^2 = L_j, D_j, I_j, (j = 1, \dots, m), \quad (3)$$

де  $L_j$  – уміння, що формується;  $D_j = (0,1)$  набуває значення "вміє / не вміє";  $I_j = (0, \dots, 10)$  – вага вершини.

$$U_{\text{сн}} = \{u_1, \dots, u_q\}, \quad (4)$$

де  $U_{\text{сн}}$  – множина зв'язків між вершинами;  $q$  – кількість зв'язків між вершинами. У цьому разі елемент:

$$u_s = \langle V_k, V_l, R_s \rangle, \quad (s = 1, \dots, q),$$

де  $V_k$  – батьківська вершина;  $V_l$  – дочірня вершина;  $R = \{R_z\}$  – тип зв'язку:  $R_1$  – зв'язок типу "частина – ціле" (агрегація) показує, що поняття / уміння дочірньої вершини є частиною складеного поняття / уміння батьківської вершини, до того ж якщо  $V_k \rightarrow V^1$ , тоді  $V_l \rightarrow V^1$ ;  $R_2$  – зв'язок типу "асоціація" означає, що для володіння поняттям / умінням необхідно оволодіти поняттям / умінням дочірньої вершини;  $R_3$  – "слабкий" зв'язок, тобто для володіння поняттям / умінням батьківської вершини володіння поняттям / умінням дочірньої вершини бажане, але не є необхідним.

Для формування мережної моделі  $M_1$  на ранніх стадіях дослідження було реалізовано доволі нескладний метод підрахунку загальної суми балів за попереднє тестування: перевіряли знання поняття або володіння вмінням лише кінцевих вершин; бал за кожне конкретне запитання (завдання) нараховували таким, що дорівнював добутку  $W_i * t_i$ , тобто ваги вершини  $i$ , параметр, що фіксує виконання / невиконання завдання вершини  $i$ . Некінцева вершина вважається зарахованою, якщо виконана така умова: сума всіх зарахованих вершин, дочірніх щодо поданої, більша від половини суми всіх її дочірніх вершин (вагу цієї вершини додавали до загальної суми балів); якщо вершина  $V_1$  пов'язана з вершиною  $V_2$  зв'язком типу "асоціація" і якщо вершину  $V_1$  зараховано, а вершину  $V_2$  не зараховано, тоді від загальної суми балів віднімали вагу вершини  $V_1$ .

Однак проведені експерименти засвідчили, що цей алгоритм доволі слабо виявляв кореляцію між окремими темами (підтемами) конкретного курсу, для якого формується модель  $M_1$ , унаслідок чого було запроваджено поняття ієрархічної структури курсу, що формується на основі аналізу навчальних планів із відповідних дисциплін.

Наразі розроблено бібліотеку оцінювальних алгоритмів, що гнучко використовують під час

тестування студентів залежно від особливостей дисципліни та контингенту здобувачів.

Наприклад, ефективно застосовують метод, що ґрунтується на збалансованій оцінці [13] для запитань закритого типу та доповнений можливістю довільного задавання ступеня суворості оцінювання, а також зважуванням запитань коефіцієнтами складності, які отримують на основі експертного оцінювання. Під збалансованістю в цьому разі розуміють незалежність математичного очікування оцінки від кількості правильних і неправильних відповідей, отриманих на це запитання випадковим чином.

Для формування моделі суб'єкта навчання  $M_1$  використовують еталонну модель  $M_e$ , яка відповідає рівню знань викладача про конкретний розділ курсу, що вивчають, і з якою порівнюватимуть досягнуті на етапі побудови  $M_1$  результати.

Формально еталонна модель  $M_e$ , як і мережна модель суб'єкта навчання, є орієнтованим графом, тобто сукупністю:

$$M_e = V_e, U_e, \quad (5)$$

де  $V_e$  – множина вершин, які можна подати як  $V_e = \{v_{e1}, \dots, v_{en}\}$  і які описують множину тем, що вивчають у розділі  $P_{ei}$ ;  $n$  – кількість тем, що вивчають. У цьому разі кожен елемент:

$$v_{ei} = T_{ei}, W_{ei}, Q_{ei}, \quad (i = 1, \dots, n), \quad (6)$$

де  $T_{ei}$  – досліджувана тема поточного розділу  $P_{ei}$ ;  $W_{ei} = [0, \dots, 10]$  – вага вершини  $v_{ei}$  поточного розділу  $P_{ei}$ ;  $Q_{ei}$  – множина запитань, що подається у такому вигляді:

$$Q_{ei} = F_{ei}, S_{ei}, I_{ei}, \quad (i = 1, \dots, n), \quad (7)$$

де  $F_{ei}$  – формулювання запитання;  $S_{ei} = \{S_1, \dots, S_n\}$  – множина відповідей;  $I_{ei}$  – ідентифікатор правильної відповіді;

$$U_e = \{u_1, \dots, u_x\}, \quad (8)$$

де  $U_e$  – множина зв'язків між вершинами;  $x$  – кількість зв'язків між вершинами. У цьому разі елемент:

$$u_y = \langle V_k, V_l, R_y \rangle, \quad (y = 1, \dots, x), \quad (9)$$

де  $V_k$  – батьківська вершина;  $V_l$  – дочірня вершина;  $R_y = \{R_z\}$  – тип зв'язку; у цьому разі:  $R_1$  – зв'язок типу "частина – ціле" (агрегація) означає, що дочірня вершина є частиною батьківської вершини;  $R_2$  –

зв'язок типу "асоціація" означає, що для володіння поняттям батьківської вершини необхідно володіти поняттям дочірньої вершини;  $R_3$  – "слабкий" зв'язок означає, що для володіння поняттям батьківської вершини володіння поняттям дочірньої вершини бажане, але не є необхідним.

Процес формування  $M_e$  у межах цієї роботи здійснювався у вигляді такої послідовності дій:

- формування списку тем з кожного розділу дисципліни, для якого формується  $M_e$  і зважування всіх тем за допомогою вагового коефіцієнта  $W$  ;
- формування запитань до тем, тобто вибір підмножини тем, для яких будуть поставлені запитання, і побудова формулювань варіантів відповідей до них із визначенням правильного варіанта відповіді (відповідей);
- формування зв'язків між темами;
- складання можливих  $M_e$  у межах курсу.

Побудова мережної моделі суб'єкта навчання  $M_1$  здійснюється способом порівняння поточної  $M_1$  з попередньо побудованою викладачем еталонною моделлю  $M_e$ . Важливо зазначити, що на цьому етапі, поряд із виявленням рівня знань і вмінь, здійснюється побудова психологічного портрета особистості на основі необхідних у цьому разі особистісних характеристик. Розширення діапазону особистісних характеристик психологічного портрета й використання їх в алгоритмах побудови моделей суб'єкта навчання дає змогу повніше зважати на індивідуальні особливості суб'єкта навчання, і формувати більш ефективні стратегії навчання студентів освітніх установ. У цьому комплексі спеціальна БД налічує близько десяти іменних тестів для виявлення особистісних характеристик здобувача. Для створення психологічного портрета особистості перед етапом формування поточної моделі суб'єкта навчання викладачеві пропонується скомпонувати набір тестів.

Передбачено двоетапне тестування суб'єкта навчання з метою виявлення поточного рівня знань, а саме: тестування з тем, де студентів пропонується відповісти на тест, складений з обраних викладачем запитань  $Q_k$  до тем розділу  $v_{ei}$ ; тестування на відмінні ознаки тем, коли суб'єкту навчання, пропонується оцінити всі теми  $v_{ei}$  за виявленими викладачем конструктами  $K_j$ .

Множина відповідей, отриманих під час тестування, порівнюється з елементом  $Q_k$  моделі  $M_e$ , і виявляється тип зв'язку  $R_z$  між темами  $v_{ei}$ , на основі чого формується поточна модель  $M_1$ . Формується оцінка за конкретну тему (вершину) за однією з визначених викладачем методик, а потім виявляють зв'язки між темами  $v_{ei}$  за допомогою спеціальної процедури генерації ознак, на основі чого позначають конкретні вершини та зв'язки у графі, за допомогою якого описано мережну модель суб'єкта навчання, тобто формують поточну модель суб'єкта навчання  $M_1$ . Оскільки в застосовуваному методі оцінювання в контрольних тестах використовуються запитання  $q_i$  з різних тем, то спочатку обирають підмножину запитань  $\tilde{Q}$  множини  $Q$ , що належить до конкретної теми  $T_j$ , а відповідна підсумкова оцінка  $R_j$  містить оцінки за кожним запитанням  $R_i$ , зваженим коефіцієнтом складності  $C_i$ , з подальшим відтворенням на відрізок  $[0,1]$ .

$$R_j = \frac{\sum_{i \in \tilde{Q}} R_i * C_i}{\sum_{i \in \tilde{Q}} C_i}, \quad (10)$$

де  $R_i$  – оцінка за запитання  $q_i$ ;  $C_i$  – коефіцієнт складності  $q_i$ ;  $\tilde{Q}$  – підмножина запитань, що належать до теми  $T_j$ ;  $\tilde{Q} \in Q$ ;  $R_j$  – підсумкова оцінка за конкретну тему  $T_j$ ;  $Q = \{q_i\}$  – множина усіх запитань ( $i = 1, \dots, n$ );  $T = \{T_j\}$  – множина всіх тем ( $j = 1, \dots, m$ );  $R = \{R_j\}$  – множина всіх оцінок з теми ( $j = 1, \dots, m$ ).

### Розроблення моделі навчання суб'єкта навчання ( $M_2$ ) навчальної системи

Загалом модель навчання містить знання про планування та організацію (проектування) навчального процесу, загальні та окремі методики навчання, тому запропонована модель  $M_2$  має такі компоненти:

- сукупність моделей  $M_1$ ;
- сукупність стратегій навчання й навчальних впливів;

– функцію вибору стратегій навчання або генерації стратегій навчання залежно від вхідної моделі  $M_1$  (для адаптивної моделі  $M_2$ ).

Керування освітнім процесом здійснюється на основі деякої множини навчальних траєкторій, яку обирають із бібліотеки траєкторій (стратегій навчання і правил навігації), або генерують  $M_1$  автоматично на основі параметрів  $M_1$ , до того ж кожна стратегія навчання містить певну послідовність навчальних впливів. Навчальними впливами можуть бути коментарі, тестові завдання, тренінг, пояснення досягнутих результатів, фрагмент, підказка, локалізація помилкових дій, контроль правильності розв'язання тощо. Кожна стратегія навчання має свій набір і порядок застосування навчальних впливів, зміст яких визначається ступенем конкретизації поставленого завдання, що залежить від рівня знань і вмінь студента, його психологічного портрета, тобто від моделі  $M_1$ . Функція вибору стратегії навчання забезпечує налаштування психологічного портрета, тобто від моделі  $M_1$ . Функція вибору стратегії навчання забезпечує налаштування на відповідну стратегію залежно від стану моделі  $M_1$ , а вхідними параметрами для цієї функції є: початковий рівень знань і вмінь суб'єкта навчання, а також тип сценарію

$$B_i \Rightarrow \Phi_1 \Rightarrow O_1 \Rightarrow K_1 \Rightarrow B_2 \Rightarrow \Phi_2 \Rightarrow O_2 \Rightarrow K_2 \Rightarrow \dots B_i \Rightarrow \Phi_i \Rightarrow O_i \Rightarrow K_i \Rightarrow \dots B_n \Rightarrow \Phi_n \Rightarrow O_n \Rightarrow K_n, (i = 1, \dots, n) \quad (12)$$

де  $n$  – кількість кроків набуття знань;  $B_i$  – сприйняття еталона знань (ЕТЗ) на кроці  $i$ ;  $\Phi_i$  – формування суб'єктивного образу еталона на кроці  $i$ ;  $O_i$  – відтворення суб'єктивного образу еталона (помилка на кроці  $i$ );  $K_i$  – порівняння (компарація) еталона знань із відтвореним суб'єктивним образом еталона на кроці  $i$ .

Будь-яка послідовність дій, спрямованих на досягнення певної мети, за визначенням є алгоритмом, у нашому випадку таку послідовність називатимемо алгоритмом навчання (АН). Графічне подання алгоритму навчання зображено на рис. 3. Цей АН є алгоритмом циклічного типу, що містить деяку послідовність дій, спрямованих на досягнення позитивного результату в процесі навчання.

Послідовність дій, спрямовану на набуття знань (запам'ятовування), називатимемо алгоритмом

діалогу, який залежить від рівня знань і вмінь суб'єкта навчання та виду навчального матеріалу.

### Вибір стратегій адаптації навчання залежно від вхідної моделі ( $M_2$ )

Теоретико-множинний опис адаптивної моделі  $M_2$  є сукупністю такого вигляду:

$$M_2 = \langle M_1, S, I, F \rangle, \quad (11)$$

де  $M_1 = \{M_{11}, \dots, M_{1n}\}$  – множина поточних моделей суб'єкта навчання;  $S = \{S_1, \dots, S_m\}$  – множина стратегій навчання  $S_i$  ( $i = 1, \dots, m$ ) у вигляді впорядкованих підмножин множини навчальних впливів для тієї чи іншої моделі суб'єкта навчання;  $I = \{I_1, \dots, I_z\}$  – множина навчальних впливів  $I_j$  ( $I_j = \{t_k i_l\}$ );  $t_k$  – тип навчального впливу;  $i_l$  – зміст впливу ( $j = 1, \dots, z$ ;  $k = 1, \dots, c$ ;  $l = 1, \dots, v$ );  $F$  – функції (алгоритми) генерації стратегій навчання залежно від вхідної моделі суб'єкта навчання, тобто  $M_2 = F(M_1, M_e, I)$ , де  $M_e$  – еталонна модель курсу (дисципліни), задана викладачем.

Формально процес набуття знань може бути поданий у вигляді такого запису послідовності дій:

запам'ятовування (АЗ). Графічне подання цього алгоритму зображено на рис. 4.

АЗ – це алгоритм циклічного типу, що передбачає певні дії.

1. Надання індексу кроку навчання  $i$  значення, що дорівнює 1 ( $i := 1$ ).

2.  $B_i$  – сприйняття еталона знань  $M_e$  на  $i$ -му кроці запам'ятовування.

3.  $\Phi_i$  – формування суб'єктивного образу  $x_i = f(M_e)$  еталона знань  $M_e$  на  $i$ -му кроці запам'ятовування.

4.  $O_i$  – відтворення суб'єктивного образу  $x_i$  на  $i$ -му кроці запам'ятовування у вигляді  $i$ -го наближення  $M_i = \varphi(x_i)$  до еталона знань  $M_e$ .

5.  $K_i$  – порівняння відтвореного суб'єктивного образу  $x_i$  у вигляді  $i$ -го наближення  $M_i$  з еталонном

знань  $M_{ei}$ . Цей блок алгоритму є блоком логічного порівняння та реалізує перевірку значення предиката  $E(M_{1i}; M_{ei})$ . Якщо предикат  $E(M_{1i}; M_{ei}) = 0$ , тоді здійснюється перехід до пункту алгоритму запам'ятовування. Якщо предикат  $E(M_{1i}; M_{ei}) = 1$ , то відбувається перехід у кінець алгоритму запам'ятовування.

6. Значення індексу кроку навчання  $i$  збільшується на 1 ( $i := i + 1$ ) і здійснюється перехід до пункту 2 алгоритму запам'ятовування.




Рис. 3. Графічне подання алгоритму навчання

Навчальні програми мають проектуватися таким чином, щоб суб'єкт навчання міг відтворювати знання в тому вигляді, у якому вони зафіксовані в його пам'яті (так звані залишкові знання), і порівнювати їх з еталоном знань  $M_e$ . Людську пам'ять можна порівняти зі стеком. Знання, що

не застосовуються, поступово витісняються новими знаннями на дно стека пам'яті. Знання, що перебувають на дні стека пам'яті, з часом спотворюються і втрачаються (предикат  $E(M_1; M_e)$  набуває значення, близького до 0). У цьому разі кажуть, що ступінь толерантності відтвореного образу еталона знань  $M_1$  і еталона знань  $M_e$  наближається до нуля.




Рис. 4. Графічне подання алгоритму запам'ятовування

Визначення відношення толерантності має такий вигляд: якщо відношення  $T$  на множині  $M$  має властивості рефлексивності та симетричності, то воно є відношенням толерантності [14]. Відношення еквівалентності – окремий випадок відношення толерантності. Толерантність – це відношення подібності.

Запропонуємо поняття ступеня толерантності знань. Ступінь толерантності знань  $S(M_1, M_e)$  –

це відношення потужності множини  $M_1$  елементів знань відтвореного образу еталона знань  $M_{1i}$  на кроці навчання  $i$  до потужності множини  $M_e$  елементів знань еталона знань  $M_{ei}$ .

$$S(M_1, M_e) = |M_{1i}| / |M_{ei}|. \quad (13)$$

Значення ступеня толерантності  $S(M_1, M_e)$  перебуває в інтервалі  $[0, 1]$ . Знання, що відтворюються, порівнюються з еталоном і сприймаються повторно, знову потрапляють на початок стека пам'яті. Ступінь толерантності цих знань щодо еталона знань набуває значення близького до 1 ( $S(M_1, M_e) \approx 1$ ). Згодом ступінь толерантності  $M_{1i}$  і  $M_e$  поступово знижується і, якщо знання не відтворюються (не використовуються), значення ступеня толерантності  $S(M_1, M_e)$  знову наближається до деякого мінімального значення, що визначає рівень залишкових знань. Тобто з часом спочатку набуті знання втрачаються (забуваються). Залежність ступеня толерантності від часу можна отримати з рівняння зберігання інформації [15].

$$U(t) = \varphi + (U_0 - \varphi)e^{-t/T}, \quad (14)$$

де  $U(t)$  – обсяг інформації в пам'яті;  $U_0$  – початкове значення обсягу інформації в пам'яті;  $\varphi$  – деяке граничне значення інформації, що може зберігатися в пам'яті тривалий час;  $T$  – постійна часу перероблення інформації;  $t$  – час.

Якщо обидві частини рівняння (13) розділити на  $U_0$ , тоді отримаємо

$$\frac{U(t)}{U_0} = \frac{\varphi}{U_0} + \left(1 - \frac{\varphi}{U_0}\right)e^{-t/T}. \quad (15)$$




Рис. 5. Графік залежності ступеня толерантності від часу за умови періодичного відтворення залишкових знань

Відношення  $U(t)/U_0$  можна розглядати як відношення потужності множини  $M_{1i}$  елементів знань відтвореного образу еталона знань  $M_{ei}$  на кроці навчання  $i$  до потужності множини  $M_e$  елементів знань еталона знань  $M_e$  у момент часу  $t$ . Тоді ліва частина рівняння не що інше, як ступінь толерантності в момент часу  $t$ :

$$U(t)/U_0 = S(t), \quad (16)$$

і з огляду на (16) рівняння (15) можна переписати у вигляді

$$S(t) = \bar{\varphi} + (1 - \bar{\varphi})e^{-\bar{t}}, \quad (17)$$

де  $\bar{\varphi} = \varphi/U_0$ ;  $\bar{t} = t/T$ .

Рівняння (17) можна подати у вигляді експоненціальної кривої, що асимптотично наближається до  $\bar{\varphi}$ , оскільки:

$$\lim_{t \rightarrow \infty} S(t) = \lim_{t \rightarrow \infty} (\bar{\varphi} + (1 - \bar{\varphi})e^{-\bar{t}}) = \bar{\varphi}. \quad (18)$$

У цьому разі  $\bar{\varphi}$  – це ступінь толерантності відобутих залишкових знань  $M_{33}$  і еталона знань  $M_e$ . Експериментальні результати показують, що  $\bar{\varphi} \approx 0,1$  [16]. Це означає, що обсяг залишкових знань  $M_{33}$  становить близько 10 % від первісно набутих знань за умови  $t \rightarrow \infty$ . Якщо за деякий проміжок часу  $\Delta t$  знання будуть відтворені, зіставлені з еталоном  $M_e$  і сприйняті повторно, тоді їх ступінь толерантності знову набуває значення, близького до 1. Очевидно, що менший проміжок часу  $\Delta t$ , то більш згладженою буде крива залежності ступеня толерантності від часу. За умови досить малого інтервалу  $\Delta t$  значення ступеня толерантності незначно відрізнятиметься від 1 (рис. 5).



Як уже було сказано, знання, що не відтворюються, поступово витісняються новими та оновленими знаннями. Ці знання потрапляють на початок стека пам'яті, та їх ступінь толерантності в початковий момент часу близький до 1. Відомо, що в навчанні спостерігаються як процеси набуття знань, так і їх втрата (забування). Для відновлення втрачених знань їх необхідно періодично оновлювати. Процес оновлення знань прийнято називати "повторенням", і суб'єкти навчання часто чинять у відповідний спосіб – повторно сприймають еталон знань  $M_e$ . У цьому разі в пам'яті студента формується ще один образ  $M_{li}'$  еталона знань  $M_e$ . А це означає, що в пам'яті суб'єкта навчання утворюється "зайвий" образ  $M_{li}'$  еталона знань  $M_e$ , шлях доступу до первинного образу  $M_{li}$  еталона знань  $M_e$  не активується та відбувається подальше зменшення ступеня толерантності образу  $M_{li}$  і еталона знань  $M_e$ . Унаслідок цього в пам'яті зберігатимуться два образи  $M_{li}$  і  $M_{li}'$  одного й того самого еталона знань  $M_e$ . А якщо зважати, що "повторення" є основним методичним прийомом, використовуваним для поновлення знань, тоді впродовж усього періоду навчання в школі та виші в пам'яті суб'єктів освітнього процесу утворюється стільки "зайвих" образів еталонів знань, що їхня пам'ять виявляється настільки перевантаженою цими "зайвими" образами, що вільного місця в пам'яті до кінця періоду навчання практично не залишається. Ось чому дорослим, навіть добре освіченим людям, важче освоювати нові технології, здобувати нові знання, ніж, наприклад, дітям. Пояснити це можна тим, що в дітей пам'ять ще не заповнена "зайвими" відбитками (енграмами) одних і тих самих знань. Щоб уникнути подібного явища, необхідно чітко дотримуватися алгоритму оновлення знань, наведеного нижче.

У процесі оновлення знань необхідно спочатку відтворити образ еталона знань  $M_{li}$  у вигляді залишкових знань, потім порівняти його з еталоном  $M_e$ , тобто реалізувати предикат  $E(M_{li}; M_e)$ , і тільки після цього повторно здійснити сприйняття еталона  $M_e$ , якщо  $E(M_{li}; M_e) \neq 1$ . У цьому разі активується шлях до образу  $M_{li}$  еталона знань і за умови повторного сприйняття еталона

знань  $M_e$  не утворюється "зайвий" образ еталона знань, оскільки він потрапляє туди, де зберігався колишній образ  $M_{li}$  еталона знань  $M_e$ , тим самим підвищуючи ступінь толерантності образу  $M_{li}$  еталона знань  $M_e$ .

Алгоритм оновлення знань можна подати у вигляді певної послідовності кроків.

1. Надання індексу кроку оновлення знань  $i$  значення, що дорівнює 1 ( $i := 1$ ).
2.  $O_i$  – відтворення суб'єктивного образу еталона знань на кроці  $i$ .
3.  $K_i$  – порівняння (компарація) еталона знань із відтвореним суб'єктивним образом еталона знань на кроці  $i$ . Якщо відтворений образ еталона знань  $M_{li}$  збігається з еталоном знань  $M_e$  (предикат  $E(M_{li}; M_e)$ ) – перехід у кінець алгоритму оновлення знань, інакше – перехід до наступного пункту алгоритму.
4.  $B_i$  – сприйняття еталона знань  $M_e$  на кроці  $i$ .
5.  $\varphi_i$  – оновлення суб'єктивного образу еталона знань на кроці  $i$ .
6. Надання індексу кроку оновлення знань  $i$  значення, що дорівнює  $i+1$  ( $i := i+1$ ), і перехід до пункту 2 алгоритму оновлення знань.

Графічне подання алгоритму оновлення знань продемонстровано на рис. 6. З огляду на сказане вище, можемо зробити висновок, що ті навчальні програми, які ініціюють операції відтворення образу еталона знань у вигляді відтвореного образу еталона  $M_{li} = \varphi(M_{li})$  і реалізацію предиката  $E(M_{li}; M_e)$ , є найефективнішими, і, зважаючи на це, необхідно проєктувати всі сучасні комп'ютерні навчальні програми.

Далі, під час формування адаптивної моделі  $M_2$ , генерація стратегії навчання  $S_i$  здійснюється навігаційними методами способом порівняння поточної моделі суб'єкта навчання  $M_{li}$  з еталонною моделлю курсу  $M_e$ , використовуючи коефіцієнт толерантності. У процесі порівняння двох моделей із множини навчальних впливів  $I$  формується підмножина впливів  $\tilde{I} (\tilde{I} \in I)$ , вивчення яких необхідне для успішного навчання. Потім аналізують психологічний портрет особистості суб'єкта

навчання, на підставі якого впорядковують цю підмножину  $\tilde{I}$ , тобто передусім застосовуватимуть ті навчальні впливи, вивчення яких дається студентові легше. На цьому формування  $M_2$  завершується та починається процес навчання відповідно до  $S_i$ , що триває до так званого "рубіжного контролю" (тип  $I_j$ ). Після цього здійснюється перехід на наступний шабелі ітерації з модернізацією моделі  $M_2$  і адаптацією під неї моделі  $M_2$ . Процес триває до досягнення необхідного рівня засвоєння матеріалу.

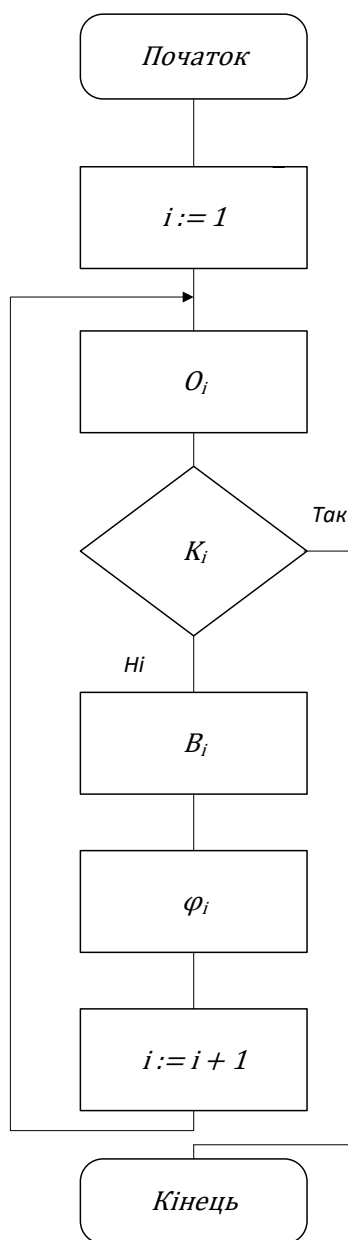


Рис. 6. Графічне подання алгоритму оновлення знань

Навчальний вплив  $I_j$  можна подати як

$$I_j = \{t_k, i_l\}, \quad (19)$$

де  $t_k$  – тип навчального впливу;  $i_l$  – зміст впливу ( $j = 1, \dots, z$ ;  $k = 1, \dots, c$ ;  $l = 1, \dots, v$ ).

Тип навчального впливу можна подати у такому вигляді:

$$t = \langle N, H, P, W, I_n \rangle, \quad (20)$$

де  $N$  – назва навчального впливу;  $H = \{h_1, h_2\}$  – характер навчального впливу:  $h_1$  – теоретичне вивчення матеріалу;  $h_2$  – практичне засвоєння;  $P = \{0, \dots, 10\}$  – показник сприйнятливості, наприклад, показує, для якого типу мислення більше підходить навчальний вплив: 0 – інтуїтивний тип, 1 – логічний тип;  $W = \{w_1, \dots, w_n\}$  – ступінь важливості (показує, наскільки важливо, щоб студент засвоїв цей матеріал);  $I_n = \{l_0, i_n\}$  – ступінь інтегральності впливу (сфера застосовності впливу), де  $l_0$  – вплив, пов'язаний тільки з відповідною темою;  $i_n$  – вплив охоплює положення, які розглядаються в попередніх одиницях навчального матеріалу.

Зі свого боку зміст навчального впливу  $i$  – це конкретний вид навчального впливу:

$$i = \{C_h, P_r, T_r, E_x, P_a\}, \quad (21)$$

де  $C_h = \{M_1, M_2\}$  – розділ підручника, де  $M_1$  – HTML-модель,  $M_2$  – XML-модель;  $P_r = \{S, R\}$  – презентація;  $S = \{S_1, \dots, S_n\}$  – спосіб подання інформації:  $S_1$  – послідовність;  $S_2$  – відеоролик (*avi, mpeg*);  $S_3$  – виконуваний файл (*exe*);  $R = \{n, y\}$  – можливість повернення до попереднього "екрана" (якщо презентація створюється за допомогою вбудованого редактора):  $n$  – немає можливості повернення;  $y$  – можливість повернення передбачена;  $E_x$  – тренінг;  $T_r = \langle D_a, C, V, V_u, O_v, P_a \rangle$  – навчально-тренувальне завдання (НТЗ), де  $D_a$  – вихідні дані,  $C$  – обмеження, що мають бути взяті до уваги під час виконання НТЗ,  $V$  – правильні відповіді,  $V_u = \{V_1, \dots, V_u\}$  – опис способу введення результату, де  $V_1$  – чисельне значення чи інтервал,  $V_2$  – набір альтернативних варіантів,  $V_3$  – набір варіантів,  $V_4$  – заповнення пропусків у текстах,

$V_5$  – вибір компонентів розв'язку з переліку,  $V_6$  – маркування тексту,  $V_7$  – побудова зв'язків між елементами графічного подання;  $O_v$  – функція оцінювання результату  $O_v(V_s, V) \rightarrow R$ , де  $R$  – множина оцінок,  $V_s$  – введений результат;  $P_a = \{P_{a1}, \dots, P_{an}\}$  – робота з прикладними програмами (ПП) розрахункового та графічного характеру:  $P_{ai}$  – конкретний вид ПП, інтеграцію з яким підтримує комплекс, наприклад,  $P_{a1}$  – калькулятор тощо.

### Розроблення моделі пояснення ( $M_3$ ) навчальної системи

Розроблення моделі пояснення  $M_3$  впливає з того, що наявні способи реалізації методів пояснення в традиційних КСН не повною мірою відповідають цілям навчання, зокрема, моделям  $M_1$  і  $M_2$ , тому поточна версія моделі  $M_3$ , орієнтована на продукційні моделі подання знань, містить такі компоненти:  $M_{3g}$  – цільові процедури, що забезпечують пояснення перебігу розв'язання задачі за допомогою генерації на екрані дисплея текстів пояснень, які містять описи правил, використаних у виведенні (записані пояснення), а також локалізацію помилок суб'єкта навчання в процесі розв'язання поточної задачі;  $M_{3d}$  – процедури детальності пояснення, що дають змогу залежно від рівня знань суб'єкта навчання візуально ілюструвати перебіг розв'язання задачі з різним ступенем деталізації;  $M_{3a}$  – алгоритми інтерпретації результатів процесів виявлення вмінь суб'єкта навчання реалізовувати механізми прямого / зворотного виведення, зокрема з можливістю надавати додаткову інформацію про об'єкти ПрГ та їх зв'язки.

Отже, моделі  $M_1$ ,  $M_2$  і  $M_3$  разом з моделлю предметної галузі повністю специфікують типове завдання навчання за допомогою конкретних процедур і функцій, а також вказують на наявність певних взаємозв'язків, до того ж із різною глибиною вкладеності (наприклад, використання фрагментів гіпертексту й виконання спеціальних обчислень під час формування тієї чи іншої стратегії навчання).

### Висновки

У дослідженні запропоновано комплексну структурно-функціональну модель комп'ютеризованих систем навчання, що відповідає нагальній потребі в адаптивних та персоналізованих освітніх методологіях. За допомогою декомпозиції навчальних завдань на окремі компоненти – діагностику, планування, інтерпретацію та адаптацію – у статті наголошується на важливості інтеграції моделей студента, навчання та пояснення для досягнення ефективних результатів навчання.

Модель студента призначена для динамічного відтворення його психологічного профілю, рівня знань і навичок із використанням мережного й векторного подання для визначення взаємозв'язків між поняттями та навичками. Також модель містить адаптивні алгоритми для відстеження та покращення прогресу суб'єкта навчання.

Модель навчального процесу впроваджує адаптивні стратегії навчання, пристосовані до поточного стану студента, і є структурованою основою для планування навчальних траєкторій. Вона використовує поєднання еталонних моделей знань і психологічного профілювання для забезпечення оптимальної послідовності навчального впливу, зокрема тестів, вправ, пояснень та зворотного зв'язку.

Модель пояснення доповнює процес навчання, аналізуючи механізми мислення студента, виявляючи помилки та надаючи цільовий, контекстно-чутливий зворотний зв'язок. Вона використовує динамічну адаптацію для коригування глибини та деталізації пояснень відповідно до рівня розуміння студента, сприяючи цим глибшому розумінню. У дослідженні також розглянуто динаміку збереження знань, алгоритми оновлення та запам'ятовування знань, що дають змогу протидіяти природному занепаду інформації з часом. Моделюючи ступінь толерантності між залишковими знаннями студента й стандартом знань, дослідження пропонує стратегії оптимізації довгострокового утримання та зменшення перевантаження пам'яті, спричиненого надлишковою інформацією.

Отже, запропонована структурно-функціональна модель інтегрує передові алгоритми, психологічні погляди й методи динамічної адаптації для створення надійної основи для інтелектуальних освітніх систем. Модель пропонує масштабовані рішення для персоналізованого навчання, ефективного

оцінювання знань і стійких результатів, що позиціонує її як цінний внесок в еволюцію сучасних освітніх технологій.

Подальші дослідження можуть зосередитись на вдосконаленні адаптивних алгоритмів у контексті реальних умов навчального середовища, де можуть виникати додаткові чинники, такі як соціальні впливи або змінні мотиваційні фактори. Крім цього, доцільно розробити більш ефективні методи для інтеграції різних джерел інформації, наприклад, з відкритих

онлайн-курсів або інших навчальних платформ, що дасть змогу покращити персоналізацію навчальних траєкторій. Наступні роботи можна також присвятити впливу різних рівнів адаптації на ефективність навчання в реальних умовах з огляду на різноманітні студентські групи й особливості різних дисциплін. Також важливим є дослідження інтеграції системи з наявними технологіями збереження та управління даними для забезпечення стійкості та довгострокового використання моделей в освітніх організаціях.

## Список літератури

1. Omran P. G., Wang Z., Wang K. Scalable rule learning via learning representation, *Twenty-Seventh International Joint Conference on Artificial Intelligence. IJCAI-18*. 2018, P. 2149–2155. DOI:10.24963/ijcai.2018/297
2. Omran P. G., Wang K., Wang Z. An Embedding-based Approach to Rule Learning in Knowledge Graphs, *IEEE Transactions on Knowledge and Data Engineering*. Vol. 33(4), P. 1348–1359. DOI: <http://doi.org/10.1109/TKDE.2019.2941685>
3. Zhou B., Bao J., Liu Y., Song D. BA-IKG: BiLSTM Embedded ALBERT for Industrial Knowledge Graph Generation and Reuse, *IEEE 18th International Conference on Industrial Informatics (INDIN)*, Warwick, United Kingdom, 2020, P. 63–69. DOI: <http://doi.org/10.1109/INDIN45582.2020.9442198>
4. Pellissier-Tanon T., Weikum G., Suchanek F. F. YAGO 4: A Reasonable Knowledge Base, *17th International Conference, ESWC 2020*, Heraklion, Crete, Greece, May 31–June 4. 2020, P. 583–596. DOI:10.1007/978-3-030-49461-2\_34
5. Kyrychenko I., Malikin D. Research of Methods for Practical Educational Tasks Generation Based on Various Difficulty Levels, *6th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2022)*, May 12–13, 2022, Gliwice, Poland. CEUR Workshop Proceedings 3171, Volume I: Main, 2022, P. 1030–1042. URL: <https://ceur-ws.org/Vol-3171/paper74.pdf>
6. Sharonova N., Kyrychenko I., Tereshchenko G. Application of big data methods in E-learning systems, *5th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2021)*, CEUR Workshop Proceedings, Vol-2870, P. 1302–1311. URL: <https://ceur-ws.org/Vol-2870/paper96.pdf>
7. Sapra D., Pimentel A. D. Deep Learning Model Reuse and Composition in Knowledge Centric Networking, *29th International Conference on Computer Communications and Networks (ICCCN)*, Honolulu, HI, USA, 2020, P. 1–11. DOI: <http://doi.org/10.1109/ICCCN49398.2020.9209668>
8. Khudhair A. T. The intelligence theory mathematical apparatus formal base, *Advanced Information Systems*, 1(1), P. 38–43. DOI: <https://doi.org/10.20998/2522-9052.2017.1.07>
9. He L., P. Jiang P-SaaS: knowledge service-oriented manufacturing workflow model for knowledge collaboration and reuse, *IEEE 16th International Conference on Automation Science and Engineering (CASE)*, Hong Kong, China, 2020, P. 570–575. DOI: <http://doi.org/10.1109/CASE48305.2020.9216974>
10. Karataiev O., Shubin I. Formal Model of Multi-Agent Architecture of a Software System Based on Knowledge Interpretation, *Radioelectronic and Computer Systems*. No 4 (108), P. 53–64. DOI: <http://doi.org/10.32620/reks.2023.4.05>
11. Dudar Z., Shubin I., Kozyriev A. Individual Training Technology in Distributed Virtual University, *Lecture Notes in Networks and Systems*. 2021, 212 LNNS, P. 379–399. DOI: [http://doi.org/10.1007/978-3-030-76343-5\\_20](http://doi.org/10.1007/978-3-030-76343-5_20)
12. Jarrahi, M. H., Lutz, C. & Newlands, G. Artificial intelligence, human intelligence and hybrid intelligence based on mutual augmentation. *Big Data and Society*, SAGE Publications Ltd. 2022, July no. 1. DOI: <http://doi.org/10.1177/20539517221142824>
13. Sharonova N., Doroshenko A., Cherednichenko O. Issues of Fact-based Information Analysis, *5th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2021) CEUR Workshop Proceedings*, 2021, Vol. 2870, URL: <https://ceur-ws.org/Vol-2136/10000011.pdf>
14. Svato M., Schockaert S., Davis J. STRIKE: Rule-Driven Relational Learning Using Stratified k-Entailment, in: ECAI, 2020, URL: <https://ida.fel.cvut.cz/~kuzelka/pubs/ecai2020.pdf>
15. Kamide N. Sequential Fuzzy Description Logic: Reasoning for Fuzzy Knowledge Bases with Sequential Information, *IEEE 50th International Symposium on Multiple-Valued Logic (ISMVL)*, Miyazaki, Japan, 2020, P. 218–223. DOI: <http://doi.org/10.1109/ISMVL49045.2020.000-2>
16. Karataiev O., Sitnikov D., Sharonova N. A Method for Investigating Links between Discrete Data Features in Knowledge Bases in the Form of Predicate Equations, *7th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2023)*. CEUR Workshop Proceedings, 2023, P. 224–235, URL: <https://ceur-ws.org/Vol-3387/paper17.pdf>

## References

1. Omran, P. G., Wang, Z., Wang, K. (2018), "Scalable rule learning via learning representation", *Twenty-Seventh International Joint Conference on Artificial Intelligence. IJCAI-18*. P. 2149–2155. DOI:10.24963/ijcai.2018/297
2. Omran, P. G., Wang, K., Wang, Z. (2021), "An Embedding-based Approach to Rule Learning in Knowledge Graphs", *IEEE Transactions on Knowledge and Data Engineering*. Vol. 33(4), P. 1348–1359. DOI: <http://doi.org/10.1109/TKDE.2019.2941685>
3. Zhou, B., Bao, J., Liu, Y., Song, D. (2020), "BA-IKG: BiLSTM Embedded ALBERT for Industrial Knowledge Graph Generation and Reuse", *IEEE 18th International Conference on Industrial Informatics (INDIN)*, Warwick, United Kingdom, 2020, P. 63–69. DOI: <http://doi.org/10.1109/INDIN45582.2020.9442198>
4. Pellissier-Tanon, T., Weikum, G., Suchanek, F. (2020), "F. YAGO 4: A Reasonable Knowledge Base", *17th International Conference, ESWC 2020*, Heraklion, Crete, Greece, May 31–June 4, 2020, P. 583–596. [http://doi.org/DOI:10.1007/978-3-030-49461-2\\_34](http://doi.org/DOI:10.1007/978-3-030-49461-2_34)
5. Kyrychenko, I., Malikin, D. (2022), "Research of Methods for Practical Educational Tasks Generation Based on Various Difficulty Levels", *6th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2022)*, May 12–13, 2022, Gliwice, Poland. CEUR Workshop Proceedings 3171, Volume I: Main, 2022, P. 1030–1042, available at: <https://ceur-ws.org/Vol-3171/paper74.pdf>
6. Sharonova, N., Kyrychenko, I., Tereshchenko, G. (2021), "Application of big data methods in E-learning systems", *5th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2021)*, CEUR Workshop Proceedings, Vol-2870, P. 1302–1311, available at: <https://ceur-ws.org/Vol-2870/paper96.pdf>
7. Sapra, D., Pimentel, A. D. (2020), "Deep Learning Model Reuse and Composition in Knowledge Centric Networking", *29th International Conference on Computer Communications and Networks (ICCCN)*, Honolulu, HI, USA, 2020, P. 1–11. DOI: <http://doi.org/10.1109/ICCCN49398.2020.9209668>
8. Khudhair, A. T. (2017), "The intelligence theory mathematical apparatus formal base", *Advanced Information Systems*, 1(1), P. 38–43. DOI: <https://doi.org/10.20998/2522-9052.2017.1.07>
9. He, L., Jiang, P. (2020), "P-SaaS: knowledge service-oriented manufacturing workflow model for knowledge collaboration and reuse", *IEEE 16th International Conference on Automation Science and Engineering (CASE)*, Hong Kong, China, 2020, P. 570–575. DOI: <http://doi.org/10.1109/CASE48305.2020.9216974>
10. Karataiev, O., Shubin, I. (2023), "Formal Model of Multi-Agent Architecture of a Software System Based on Knowledge Interpretation", *Radioelectronic and Computer Systems*. No 4 (108), P. 53–64. DOI: <http://doi.org/10.32620/reks.2023.4.05>
11. Dudar, Z., Shubin, I., Kozyriev, A. (2021), "Individual Training Technology in Distributed Virtual University", *Lecture Notes in Networks and Systems*. 2021, 212 LNNS, P. 379–399. DOI: [http://doi.org/10.1007/978-3-030-76343-5\\_20](http://doi.org/10.1007/978-3-030-76343-5_20)
12. Jarrahi, M. H., Lutz, C. Newlands, G. (2022), "Artificial intelligence, human intelligence and hybrid intelligence based on mutual augmentation. Big Data and Society", *SAGE Publications Ltd*. 2022, July no. 1. DOI: <http://doi.org/10.1177/20539517221142824>
13. Sharonova, N., Doroshenko, A., Cherednichenko, O. (2021), "Issues of Fact-based Information Analysis", *5th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2021) CEUR Workshop Proceedings*, 2021, Vol. 2870, available at: <https://ceur-ws.org/Vol-2136/10000011.pdf>
14. Svato, M., Schockaert, S., Davis, J. (2020), "STRiKE: Rule-Driven Relational Learning Using Stratified k-Entailment", in: *ECAI, 2020*, available at: <https://ida.fel.cvut.cz/~kuzelka/pubs/ecai2020.pdf>
15. Kamide, N. (2020), "Sequential Fuzzy Description Logic: Reasoning for Fuzzy Knowledge Bases with Sequential Information", *IEEE 50th International Symposium on Multiple-Valued Logic (ISMVL)*, Miyazaki, Japan, 2020, P. 218–223. DOI: <http://doi.org/10.1109/ISMVL49045.2020.000-2>
16. Karataiev, O., Sitnikov, D., Sharonova, N. (2023), "A Method for Investigating Links between Discrete Data Features in Knowledge Bases in the Form of Predicate Equations", *7th International Conference on Computational Linguistics and Intelligent Systems (COLINS-2023)*. CEUR Workshop Proceedings, 2023, P. 224–235, available at: <https://ceur-ws.org/Vol-3387/paper17.pdf>

*Відомості про авторів / About the Authors*

**Усачов Володимир Олександрович** – Харківський національний університет радіоелектроніки, аспірант кафедри програмної інженерії, Харків, Україна; e-mail: [volodymyr.usachov1@nure.ua](mailto:volodymyr.usachov1@nure.ua); ORCID ID: <https://orcid.org/0009-0001-6264-2039>

**Шубін Ігор Юрійович** – кандидат технічних наук, доцент, Харківський національний університет радіоелектроніки, професор кафедри програмної інженерії, Харків, Україна; e-mail: [igor.shubin@nure.ua](mailto:igor.shubin@nure.ua); ORCID ID: <https://orcid.org/0000-0002-1073-023X>

**Usachov Volodymyr** – Kharkiv National University of Radio Electronics, Postgraduate Student at the Department of Software Engineering, Kharkiv, Ukraine.

**Shubin Ihor** – PhD (Engineering Sciences), Kharkiv National University of Radio Electronics, Professor at the Software Department, Kharkiv, Ukraine.

## A STRUCTURAL-FUNCTIONAL MODEL OF LEARNING IN COMPUTERIZED LEARNING SYSTEMS

The **subject matter** of the article is the development of a universal structural-functional model of computerized learning systems that integrates learner, learning, and explanation models. This model addresses the task of personalizing the learning process, considering the individual characteristics of the learner, and ensuring long-term knowledge retention. The **goal** of the work is to develop a universal structural-functional learning system model that combines modern adaptive algorithms, integrates psychological and cognitive aspects, and introduces new approaches to long-term knowledge retention. Special emphasis is placed on the system's flexibility, allowing the adaptation of educational content to each user's needs while considering the dynamics of their development and changes in their level of knowledge. The following **tasks** were solved in the article: analyzing existing learning models, identifying their limitations, and developing new approaches to building an adaptive learning process. The following **methods** used are – network and vector models for constructing learning trajectories, graph structures for visualizing educational content, and psychological profiling algorithms. Additionally, knowledge actualization methods were applied to reduce the forgetting rate and optimize the learning process. The following **results** were obtained – a universal structural-functional model of computerized learning systems was created, integrating the learner model, the learning process model, and the explanation model. This model reflects the structure of the adaptive learning process and the interconnections between its components, enabling the personalization of learning trajectories based on the learner's knowledge level, motivation, and psychological characteristics. The proposed model represents knowledge using network and vector structures, which allows for the systematization of educational materials, visualization of relationships between concepts, and adaptive management of the learning process. The developed model can be applied to analyze students' preparedness levels, support adaptive learning strategies, and assess progress. The integration of psychological profiling mechanisms and knowledge renewal algorithms enhances the efficiency of the educational process. **Conclusions:** The proposed structural-functional model demonstrates its effectiveness in addressing key challenges of personalized and adaptive learning. By integrating psychological profiles, knowledge levels, and advanced algorithms, the model enables the creation of scalable and intelligent educational systems. It facilitates personalized learning, effective assessment, and targeted feedback while ensuring long-term knowledge retention and fostering innovation in modern educational technologies.

**Keywords:** computerized learning systems; knowledge assessment; learner model; adaptive learning algorithms.

*Бібліографічні описи / Bibliographic descriptions*

Усачов В. О., Шубін І. Ю. Структурно-функціональна модель навчання в комп'ютеризованих системах навчання. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 127–142. DOI: <https://doi.org/10.30837/2522-9818.2025.1.127>

Usachov, V., Shubin, I. (2025), "A structural-functional model of learning in computerized learning systems", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 127–142. DOI: <https://doi.org/10.30837/2522-9818.2025.1.127>

D. CHERNYSHOV

## A COMPARATIVE FRAMEWORK FOR ANALYZING DISTANCE METRICS IN HIGH-DIMENSIONAL SPACES

**Subject of the research** – developing a comprehensive framework to measure and analyze the relationships between different distance metrics in high-dimensional spaces. **Aim of the research** – to create a comparative framework that quantifies the "distance" between various distance metrics in high-dimensional settings. This framework aims to provide deeper insights into the interrelationships of these metrics and to guide practitioners in selecting the most appropriate metric for specific data analysis tasks. The research **tasks** include a theoretical formulation of methods to measure the "distance between distances", enabling a systematic comparison of different metrics. We conduct a thorough analysis of how these relationships evolve with increasing dimensionality. This involves developing mathematical models and employing visualization techniques to illustrate and interpret the relationships between metrics like the Manhattan distance, Euclidean distance, and others in high-dimensional spaces. A series of experiments are conducted on synthetic datasets to validate the theoretical findings and demonstrate the practical utility of the proposed framework. These datasets are carefully selected to cover a wide range of dimensionalities and data characteristics, ensuring a comprehensive evaluation of the framework's effectiveness. The **methodology** includes statistical analyses and visualization methods such as multidimensional scaling and heatmaps to represent the relationships between distance metrics clearly. The findings of the research are significant, revealing that the relationships between different distance metrics change notably as dimensionality increases. The results show patterns of convergence or divergence among certain metrics, providing valuable insights into their behavior in high-dimensional spaces. These insights are crucial for improving the accuracy and efficiency of data analysis techniques that rely on distance computations. **The conclusions** indicate that the proposed framework successfully quantifies the relationships between various distance metrics in high-dimensional spaces. By enhancing the understanding of how these metrics relate to one another, the research offers a valuable tool for selecting appropriate distance measures in high-dimensional data analysis. This contributes to more accurate and efficient analytical processes across various fields, including machine learning, data mining, and pattern recognition.

**Keywords:** distance metrics; high-dimensional spaces; metric comparison;  $L_1$  norm;  $L_2$  norm; data analysis; machine learning.

### Introduction

Distance metrics are fundamental tools in data analysis, machine learning, and pattern recognition, serving as the basis for various algorithms in clustering, classification, and information retrieval [1]. The choice of an appropriate distance metric is crucial, as it directly influences the performance and accuracy of these algorithms. In the era of big data, high-dimensional datasets have become increasingly common across fields such as image processing, genomics, finance, and social network analysis. These datasets present unique challenges due to the "curse of dimensionality", where the volume of the space increases so rapidly that the available data become sparse, making traditional analysis techniques less effective [2].

In high-dimensional spaces, the behavior of distance metrics can change dramatically. Phenomena such as the concentration of measure imply that in very high dimensions, distances between data points tend to become uniform regardless of the metric used. This effect can diminish the discriminative power of distance-based algorithms, leading to degraded performance [2]. Moreover, different distance metrics may exhibit varying

sensitivities to specific data characteristics, such as scale, correlation, and noise, further complicating the analysis.

A significant challenge in this context is the lack of a systematic understanding of how different distance metrics relate to each other in high-dimensional spaces. While metrics like the Manhattan ( $L_1$ ) and Euclidean ( $L_2$ ) distances are well-understood in low-dimensional settings, their relationships and relative effectiveness in high-dimensional contexts are not fully explored [3, 4]. This gap in knowledge can hinder the ability of practitioners to select the most appropriate metric for their specific applications, potentially leading to suboptimal results.

Previous studies have investigated the asymptotic behavior of the Manhattan distance as dimensionality increases, highlighting its statistical properties and implications for empirical experiments [3]. For instance, Silva [3] analyzed the theoretical properties and statistical behavior of the Manhattan distance through mathematical derivations and computational simulations, revealing how its mean and variance exhibit predictable trends as dimensionality increases. Other research has focused on approximations of the Euclidean distance in multi-

dimensional spaces to reduce computational complexity while maintaining acceptable accuracy [5].

Additionally, efforts have been made to establish approximate relations between Manhattan and Euclidean distances, particularly in the context of experimental design using Latin hypercube sampling [4]. Das et al. [4] explored the relations and bounds between these distances, providing insights into which measure offers better space-filling properties in design of experiments (DoEs).

Despite these contributions, there remains a need for a comprehensive framework that systematically compares different distance metrics and quantifies their relationships in high-dimensional settings. Such a framework would provide deeper insights into how metrics like  $L_1$ ,  $L_2$ , and others compare and contrast as dimensionality increases, offering a more nuanced understanding than traditional pairwise comparisons.

This research aims to address this challenge by developing a comprehensive framework for measuring and analyzing the relationships between various distance metrics in high-dimensional spaces. By introducing a method to quantify the "distance between distances", we seek to provide deeper insights into metric behavior in high dimensions. The framework is designed to capture the nuances of metric behavior, offering practical guidance for data analysts and machine learning practitioners.

The successful development of this comparative framework involves a detailed theoretical investigation coupled with extensive empirical validation. The theoretical component focuses on deriving mathematical formulations that define the relationships between different metrics, considering the effects of high dimensionality. The empirical component includes experiments on both synthetic and real-world datasets to demonstrate the practical implications of the theoretical findings. Visualization techniques such as multidimensional scaling and heatmaps are employed to illustrate the complex interrelationships between metrics clearly.

Integrating theoretical analysis with empirical experimentation is expected to yield a robust framework that not only enhances our understanding of distance metrics in high-dimensional spaces but also provides practical guidance for selecting appropriate metrics in various applications. This integrated approach is particularly relevant in fields where the choice of distance metric can significantly impact the performance of algorithms, such as clustering, classification, and nearest neighbor search [1, 2].

In the realm of distance metric analysis, various approaches have been proposed to compare and select

appropriate metrics, ranging from heuristic methods based on domain knowledge to more systematic techniques involving metric learning [1]. However, these methods often focus on low-dimensional settings or specific applications, lacking generality in high-dimensional contexts. Our research fills this gap by providing a generalizable framework applicable across different domains and types of data.

By systematically analyzing and quantifying how distance metrics relate to each other in high-dimensional spaces, we aim to enhance the effectiveness of data analysis techniques that rely on these metrics. This contribution has the potential to improve the accuracy and efficiency of various machine learning algorithms, ultimately advancing the fields of data mining and pattern recognition.

The **objective** of this research is not only to develop a theoretical understanding of metric relationships but also to translate this understanding into practical tools and guidelines. By systematically analyzing and quantifying how distance metrics relate to each other in high-dimensional spaces, we aim to enhance the effectiveness of data analysis techniques that rely on these metrics. This contribution has the potential to improve the accuracy and efficiency of various machine learning algorithms, ultimately advancing the fields of data mining and pattern recognition. Through this research, we aspire to make a significant contribution to the understanding of distance metrics in high-dimensional data analysis. By providing both theoretical insights and practical tools, we hope to enable more informed decisions regarding metric selection, leading to improved outcomes in a wide range of applications where high-dimensional data are prevalent.

---

### Analysis of the problem and Existing Methods

---

Comparing and selecting appropriate distance metrics in high-dimensional spaces is a complex challenge that has significant implications for the effectiveness of machine learning algorithms [1, 2]. High-dimensional data often leads to phenomena such as the concentration of distances, where the distinction between the nearest and farthest points diminishes, making it difficult for algorithms like  $k$ -nearest neighbors ( $k$ - $NN$ ) to perform effectively [1].

Aggarwal et al. [2] conducted a seminal study on the behavior of distance metrics in high-dimensional spaces, revealing that the choice of metric significantly impacts the meaningfulness of proximity measures. They found



that metrics such as the Manhattan distance ( $L_1$  norm) can be more preferable than the Euclidean distance ( $L_2$  norm) in high-dimensional applications due to their sensitivity to the dimensionality of the data.

Silva [3] investigated the asymptotic behavior of the Manhattan distance as the number of dimensions increases, providing insights into its statistical properties through mathematical derivations and computational simulations. The study highlighted predictable trends in the mean and variance of the Manhattan distance, emphasizing the need to understand how distance metrics behave as dimensionality grows.

Das et al. [4] explored approximate relations between the Manhattan and Euclidean distances in the context of Latin hypercube experimental design. Their work established bounds and relations between these distances, offering insights into which measure may provide better space-filling properties in design of experiments.

Research on approximating the Euclidean distance in multi-dimensional spaces has been conducted to reduce computational complexity while maintaining acceptable accuracy [5].

Comparative studies have also been carried out in specific applications. For instance, in clustering analysis for determining the spread of COVID-19 in Bekasi City, researchers compared the Euclidean and Manhattan distance calculations within the K-means clustering algorithm [6]. They found that the choice of distance metric affected the number of iterations and processing time, with the Manhattan distance leading to faster convergence [6]. This underscores the practical importance of selecting an appropriate distance metric based on the specific characteristics of the data and the analysis objectives.

Despite these studies, there remains a lack of a comprehensive framework that systematically compares different distance metrics and quantifies their relationships in high-dimensional settings. Existing methods often focus on specific metrics or applications, without providing a generalizable approach to measure the "distance between distances" across various metrics and dimensions.

Some studies have proposed methods for secure computation of distance metrics [7], and have analyzed the minimum Manhattan distance in permutations [8], but these works do not directly address the comparative analysis of distance metrics in high-dimensional spaces.

In the field of  $k$ -NN algorithms, recent reviews have highlighted the need for enhanced methods to

improve performance in high-dimensional data [1]. Modifications to exact  $k$ -NN techniques have been proposed, but they often rely on heuristic approaches or are tailored to specific applications, rather than providing a systematic framework for metric comparison.

Overall, the challenge lies in developing a method that can quantify and analyze the relationships between different distance metrics as dimensionality increases, providing practical guidance for selecting appropriate metrics in high-dimensional data analysis.

### Problem solution

У цьому дослідженні коли ми розглядаємо граничну область  $B(X)$  для множини  $X$ , ми маємо на увазі різницю між верхньою та нижньою апроксимацією  $X$ . Математично це може бути виражено так:

To address the challenge of systematically comparing distance metrics in high-dimensional spaces, we propose a framework that utilizes statistical sampling and correlation analysis to quantify the relationships between different distance metrics. Our method involves generating synthetic datasets with varying dimensionalities and analyzing how different distance metrics correlate in these high-dimensional settings.

We generate synthetic data by sampling points from a standard multivariate normal distribution. Specifically, we sample  $n$  data points  $x_i \in \mathbb{R}^d$ , where component  $x_i$  is drawn independently from a standard normal distribution  $N(0,1)$ . This approach ensures that the data are centered at the origin with identity covariance, providing an isotropic distribution equally spread in all directions. By varying the dimensionality  $d$  from 2 to 1000, we investigate how the relationships between distance metrics evolve as the number of dimensions increases.

We focus on the family of Minkowski distance metrics, defined by the  $L_p$  norm (1):

$$\|x\|_p = \left( \sum_{i=1}^d |x^i|^p \right)^{1/p}, \quad (1)$$

where  $p \in \mathbb{R}$ . We extend our analysis to include all computable values of  $p$ , including negative values and  $p = \infty$ , which corresponds to the Chebyshev distance. This comprehensive consideration of  $p$  values allows us to examine a wide spectrum of distance metrics within the Minkowski family.

For each sampled point  $x_i$ , we compute its distance to the origin using various  $L_p$  norms. This results in a set of distance measurements  $\{\|x_i\|_p\}$  for each value of  $p$ . By focusing on distances from the origin, we eliminate pairwise dependencies and simplify the analysis while still capturing the essential characteristics of the distance metrics.

To quantify the relationships between different distance metrics, we perform a correlation analysis of the distance measurements obtained for different  $pp$  values. Specifically, we calculate the Spearman rank correlation coefficient between pairs of distance metrics  $L_{p_1}$  and  $L_{p_2}$ .

The Spearman rank correlation coefficient measures the monotonic relationship between two variables without assuming a linear relationship or normality, making it suitable for our analysis of non-linear dependencies between distance metrics.

By computing this correlation for various combinations of  $p_1$  and  $p_2$ , we obtain a metric-pair correlation matrix that reflects how similar or dissimilar the distance metrics are in high-dimensional spaces. A higher correlation coefficient indicates that two metrics rank the distances of points similarly, implying they are more alike in their behavior.

We examine how the correlations between different distance metrics change as a function of dimensionality  $dd$ . By varying  $dd$  from 2 to 1000, we observe the impact of increasing dimensions on the relationships between metrics. Our preliminary results indicate that after a certain dimensionality threshold, the correlations stabilize and reach a plateau. This suggests that in very high dimensions, the relative behavior of different distance metrics becomes consistent.

While our approach is primarily empirical, it is grounded in the understanding that in high-dimensional spaces, the geometry of data changes significantly. For instance, it is known that distances tend to concentrate in high dimensions, a phenomenon related to the concentration of measure [2]. Although we do not derive new theoretical results, our empirical observations align with known theoretical behaviors, such as the stabilization of metric relationships at high dimensions.

### Research results

To investigate how the relationship between different distance metrics evolves with increasing

dimensionality, we conducted experiments measuring the Spearman rank correlation coefficient between the  $L_1$  (Manhattan) and  $L_2$  (Euclidean) norms of data points sampled from a standard normal distribution. The dimensionality  $d$  varied from 2 to 100, allowing us to observe trends over a wide range of dimensions (fig. 1).





Fig. 1. Relationship between dimensionality and correlation

The initial decrease in correlation can be attributed to the increasing complexity of the high-dimensional space. In low dimensions, the  $L_1$  and  $L_2$  norms are more closely related because the geometry of the space allows for less variation in the paths measured by these norms. Despite the decreasing trend, the correlation stabilizes around 0.94 in higher dimensions. This plateau indicates that while the norms are not perfectly correlated, they maintain a strong monotonic relationship even as dimensionality increases. This consistent correlation suggests that, in high-dimensional spaces, the relative rankings of distances from the origin according to the  $L_1$  and  $L_2$  norms remain similar.

In the next experiment, we investigate how the Spearman rank correlation between the  $L_2$  norm (Euclidean distance) and various  $L_p$  norms changes as we vary the value of  $p$ . By fixing  $p_1 = 2$  (corresponding to the  $L_2$  norm) and altering  $p$  over a specified range, we aim to understand how different  $L_p$  norms relate to the  $L_2$  norm in high-dimensional spaces (fig. 2).

This experiment demonstrates that the Spearman rank correlation between the  $L_2$  norm and  $L_p$  norms varies non-linearly with  $p$ . The correlation is highest at  $p = 2$  and decreases for both lower and higher  $p$  values. These findings highlight the importance of carefully

selecting the  $p$  value in  $L_p$  norms to match the specific needs of high-dimensional data analysis tasks.



**Fig. 2.** Correlation between  $l_2$  norm and  $p_2$  norms on  $x$  axis

In this experiment, we explore the relationships between the  $L_1$ ,  $L_2$ ,  $L_\infty$ , and norms to understand how these distance metrics correlate with one another in high-dimensional spaces. Specifically, we aim to investigate whether the "distance" (as measured by dissimilarity or correlation) between  $L_1$  and  $L_2$  norms is approximately equal to that between  $L_2$  and  $L_\infty$  norms. Additionally, we examine how the correlation between  $L_2$  and  $L_p$  norms changes as  $p$  approaches infinity (table 1).

**Table 1.** Correlation table between  $L_1$ ,  $L_2$ , and  $L_\infty$  metrics

	$L_1$	$L_2$	$L_\infty$
$L_1$	1	0.95	0.89
$L_2$	0.95	1	0.95
$L_\infty$	0.89	0.95	1

The correlations  $\rho_{1,2}$  and  $\rho_{2,\infty}$  are very close in value, suggesting that the "distance" or dissimilarity between  $L_1$  and  $L_2$  norms is approximately equal to that between  $L_2$  and  $L_\infty$  norms. This suggests a kind of symmetry in the relationships among these norms in high-dimensional spaces, which may not be as apparent in lower dimensions.

When comparing  $L_p$   $L_2$ , as  $p$  approaches infinity, the  $L_p$  norm increasingly emphasizes the largest components of the vectors. This results in the  $L_p$  norm converging to the  $L_\infty$  norm.

## Practical Implications

The comparative framework presented in this study has significant potential for real-world implementation, particularly in fields where high-dimensional data analysis is a core challenge. In e-commerce recommendation systems, where vast amounts of user and product attributes are generated daily, practitioners often rely on distance-based methods to measure similarities between items or users [9, 10]. Implementing the proposed framework can help them determine which distance metric is best suited for capturing meaningful relationships in datasets containing thousands of features, such as product descriptions, user demographics, and behavioral logs. By systematically quantifying the relationships among metrics like Manhattan, Euclidean, and other Minkowski norms, companies can more confidently select a metric that preserves essential characteristics of user-item interactions, thus improving recommendation accuracy and user satisfaction.

In the financial sector, high-dimensional data arise in areas such as portfolio optimization [11], fraud detection, and algorithmic trading [12], where feature spaces range from historical price series to textual sentiment indicators. A robust, data-driven evaluation of distance metrics helps identify the most appropriate norm to capture subtle patterns in time series and complex relationships among assets. When dealing with high-frequency trading scenarios or large-scale risk modeling, the correct choice of distance metric can also reduce computational overhead and minimize latency.

In image recognition and computer vision applications, large volumes of pixel information and extracted feature vectors are often managed in domains ranging from autonomous driving to medical imaging [13]. When selecting the most effective distance metric for tasks like image retrieval or similarity-based classification, analyzing correlations among norms under different dimensional settings allows teams to anticipate performance trade-offs. This becomes especially critical in medical contexts where even minor improvements in classification accuracy can translate into earlier detection of diseases. Moreover, integrating this framework into workflow pipelines can streamline the process of feature extraction by aligning metric choice with specific datasets, reducing the trial-and-error phase that often burdens data science projects.

Sensor networks and Internet of Things deployments also stand to benefit [14, 15]. Industrial

monitoring systems produce high-dimensional data encompassing sensor readings, event logs, and contextual information. Employing this comparative framework enables the identification of norms that robustly differentiate normal operational conditions from anomalies, helping to prevent downtime or safety incidents in factories, power plants, or transportation systems. By exploiting the insights into how metric relationships evolve with dimensionality, it becomes easier to design anomaly detection pipelines that remain effective at scale. In terms of practical implementation, the development of user-friendly libraries that encapsulate the proposed framework's functionalities can lower the barrier to entry for data scientists who may not have a strong mathematical background in norm analysis.

Such tools can integrate with popular machine learning libraries, automatically generating correlation heatmaps or multidimensional scaling visualizations to guide metric selection. An organization interested in adopting the framework could embed these utilities in its data engineering platform, thereby incorporating distance metric analysis into routine data processing steps. Adapting the framework to specialized hardware accelerators like GPUs can further reduce computation time, particularly when sampling from large datasets or exploring many pairs of distance metrics. Finally, the advances in interpretability provided by the proposed framework have value in regulated industries like healthcare or finance, where practitioners must justify their methods to stakeholders. Demonstrating that a chosen distance metric aligns with the intrinsic geometry of the data helps address concerns regarding fairness, bias, and other ethical considerations. Through these avenues of application – from recommendation systems and algorithmic trading to medical image classification and industrial monitoring – the proposed comparative framework offers a practical means of improving the accuracy, efficiency, and reliability of high-dimensional data analysis.

### Conclusions

This research has presented a comprehensive framework for analyzing and quantifying the relationships between different distance metrics in high-dimensional spaces. By employing statistical sampling from a standard multivariate normal distribution and performing correlation analyses between various  $L_p$  norms, we have gained valuable insights into how these metrics behave and relate to each other as dimensionality increases.

Our findings reveal that the Spearman rank correlation between the  $L_1$  and  $L_2$  norms decreases with increasing dimensionality but stabilizes at a strong positive correlation in high-dimensional spaces. Specifically, the correlation coefficient decreases from approximately 0.98 in two dimensions to around 0.94 in dimensions beyond ten, indicating that despite the initial decline, the  $L_1$  and  $L_2$  norms maintain a consistent relationship in higher dimensions. This suggests that, for high-dimensional data, the relative rankings of distances according to these norms remain similar, which has practical implications for algorithm performance and computational efficiency in data analysis tasks.

Further exploration into the correlation between the  $L_2$  norm and various  $L_p$  norms across a wide range of  $p$  values demonstrated a non-linear relationship. The correlation peaks at  $p = 2$ , as expected, since we are comparing the  $L_2$  norm with itself, and decreases for both lower and higher  $p$  values. Notably, as  $p$  approaches infinity, corresponding to the  $L_\infty$  norm, the correlation with the  $L_2$  norm decreases, reflecting the increasing emphasis on the largest components in the data vectors. This behavior highlights the importance of selecting appropriate  $p$  values in  $L_p$  norms based on the specific characteristics of the data and the analysis objectives.

The comparison among the  $L_1$ ,  $L_2$ , and  $L_\infty$  norms revealed that the "distance" or dissimilarity between  $L_1$  and  $L_2$  norms is approximately equal to that between  $L_2$  and  $L_\infty$  norms. The strong correlations observed among these norms suggest a form of symmetry in their relationships within high-dimensional spaces. This symmetry indicates that transitioning from one norm to another involves similar changes in how the norms aggregate component information, which can inform decisions when selecting distance metrics for high-dimensional data analysis.

These insights contribute to a deeper understanding of the behavior of distance metrics in high-dimensional settings. They underscore the necessity for practitioners to consider the implications of their choice of distance metric, especially in applications where the dimensionality of data is high. Selecting a metric that aligns with the desired sensitivity to data features can enhance algorithm performance, improve computational efficiency, and ultimately lead to more accurate and reliable results in machine learning and data mining tasks.

However, it is important to acknowledge the limitations of this study. The experiments were conducted using synthetic data sampled from a standard normal distribution with independent and identically distributed components. While this approach provides a controlled environment for analysis, real-world data often exhibit correlations, non-normal distributions, and other complexities not captured in our synthetic datasets. Consequently, the findings may not directly generalize to all types of data distributions. Additionally, the focus on distances from the origin simplifies the analysis but may not capture all aspects relevant in practical applications where pairwise distances between data points are crucial.

Future research could extend this framework to include different data distributions, incorporate real-world datasets, and explore the effects of feature correlations and other data characteristics. The development of theoretical models to explain and

predict the observed relationships between distance metrics in high-dimensional spaces would further enhance the utility of this framework. Such advancements would provide more comprehensive guidance for selecting appropriate distance measures, thereby improving the effectiveness of algorithms that rely on distance computations across various domains.

In conclusion, this study offers a valuable contribution to the understanding of distance metrics in high-dimensional spaces by providing both empirical evidence and practical insights. The proposed framework enables a systematic comparison of different distance metrics, highlighting the nuanced ways in which they relate to each other as dimensionality increases. By informing the selection of distance metrics, this work has the potential to enhance the accuracy and efficiency of high-dimensional data analysis techniques, ultimately advancing the fields of machine learning, data mining, and pattern recognition.

## References

- Halder, R. K., Uddin, M. N., Uddin, Md. A., Aryal, S., and Khraisat, A. (2024), "Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications". *Journal of Big Data, Springer Science and Business Media LLC*. Vol. 11, No. 1. Aug. 11. DOI: 10.1186/s40537-024-00973-y
- Aggarwal, C. C., Hinneburg, A., and Keim, D. A. (2001), "On the Surprising Behavior of Distance Metrics in High Dimensional Space". *Lecture Notes in Computer Science, Springer Berlin Heidelberg*. Vol. 1973. P. 420–434. DOI: 10.1007/3-540-44503-x\_27
- Silva, E. C. de M. (2024), "Asymptotic behavior of the Manhattan distance in n-dimensions: Estimating multidimensional scenarios in empirical experiments". *arXiv*. DOI: 10.48550/ARXIV.2406.15441
- Jamali, A. R. M. J. U. U., and Alam, Md. A. (2019), "Approximate relations between Manhattan and Euclidean distance regarding Latin hypercube experimental design". *Journal of Physics: Conference Series, IOP Publishing*. Vol. 1366, No. 1. Nov. 1, 012030 p. DOI: 10.1088/1742-6596/1366/1/012030
- Cardarilli, G. C., Di Nunzio, L., Fazzolari, R., Nannarelli, A., Re, M., and Spano, S. (2020), "NN-Dimensional Approximation of Euclidean Distance". *IEEE Transactions on Circuits and Systems II: Express Briefs, IEEE*. Vol. 67, No. 3. Mar., P. 565–569. DOI: 10.1109/tcsii.2019.2919545
- Cahya, F. N., Mahatma, Y., and Rohimah, S. R. (2023), "Perbandingan Metode Perhitungan Jarak Euclidean dengan Perhitungan Jarak Manhattan pada K-Means Clustering Dalam Menentukan Penyebaran Covid di Kota Bekasi". *JMT: Jurnal Matematika dan Terapan, Universitas Negeri Jakarta*. Vol. 5, No. 1. Feb. 28, P. 43–55. DOI: 10.21009/jmt.5.1.5
- Liu, W., and Zhang, W. (2020), "A Quantum Protocol for Secure Manhattan Distance Computation". *IEEE Access, IEEE*. Vol. 8. P. 16456–16461. DOI: 10.1109/access.2020.2966800
- Blackburn, S. R., Homberger, C., and Winkler, P. (2019), "The minimum Manhattan distance and minimum jump of permutations". *Journal of Combinatorial Theory, Series A, Elsevier BV*. Vol. 161. Jan., P. 364–386. DOI: 10.1016/j.jcta.2018.09.002
- Fkih, F. (2022), "Similarity measures for Collaborative Filtering-based Recommender Systems: Review and experimental comparison", *Journal of King Saud University - Computer and Information Sciences*, Vol. 34, no. 9, Elsevier, P. 7645–7669, Oct. 2022, DOI: 10.1016/j.jksuci.2021.09.014
- Vančura, V.; Kordík, P., Straka, M. (2024), "beeFormer: Bridging the Gap Between Semantic and Interaction Similarity in Recommender Systems", *arXiv*, DOI: 10.48550/ARXIV.2409.10309
- Yang, J. (2025), "DF: Decision-Focused Fine-tuning for Smarter Predict-then-Optimize with Limited Data," *arXiv*, DOI: 10.48550/ARXIV.2501.01874
- Monteiro, T. (2024), "AI-Powered Energy Algorithmic Trading: Integrating Hidden Markov Models with Neural Networks", *arXiv*, DOI: 10.48550/ARXIV.2407.19858
- Samantaray, A. K., Rahulkar, A. D. (2019), "Comparison of Similarity Measurement Metrics on Medical Image Data", in *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT), IEEE*, P. 1–5, DOI: 10.1109/icccnt45670.2019.8944781

14. Maudet, G., Batton-Hébert, M., Maillé, P., Toutain, L. (2022), "Emission Scheduling Strategies for Massive-IoT: Implementation and Performance Optimization", in *NOMS 2022 IEEE/IFIP Network Operations and Management Symposium, IEEE*, P. 1–4, Apr. 25, DOI: 10.1109/noms54207.2022.9789769
15. Shafique, A., Asad, M., Aslam, M., Shaukat, S., Cao, G. (2022), "Multi-hop similarity-based-clustering framework for IoT-oriented software-defined wireless sensor networks", *IET Wireless Sensor Systems*, Vol. 12, No. 2, Institution of Engineering and Technology (IET), P. 67–80, DOI: 10.1049/wss2.12037

Надійшла (Received) 05.02.2025

#### Відомості про авторів / About the Authors

**Чернишов Дмитро Владиславович** – Харківський національний університет радіоелектроніки, аспірант комп'ютерних наук, кафедра системотехніки, Харків, Україна; e-mail: dmytro.chernyshov@nure.ua; ORCID ID: <https://orcid.org/0009-0003-2773-7467>

**Chernyshov Dmytro** – Kharkiv National University of Radio Electronics, Department of System Engineering, PhD of Computer Science, Kharkiv, Ukraine.

## ПОРІВНЯЛЬНА СИСТЕМА ДЛЯ АНАЛІЗУ МЕТРИК ВІДСТАНІ У ВИСОКОВИМІРНОМУ ПРОСТОРИ

**Предмет дослідження** – розроблення комплексної рамкової методології для вимірювання та аналізу взаємозв'язків між різними метриками відстані у багатовимірних просторах. **Мета дослідження** – створити порівняльну методологію, яка кількісно оцінює "відстань" між різними метриками відстані в умовах високої розмірності. Ця методологія має на меті надати глибше розуміння взаємозв'язків між зазначеними метриками та допомогти фахівцям у виборі найбільш відповідної метрики для конкретних завдань аналізу даних. **Завдання дослідження** охоплюють теоретичне формулювання методів вимірювання "відстані між відстанями", що дає змогу систематично порівнювати різні метрики. Необхідно ґрунтовно проаналізувати зміни цих взаємозв'язків залежно від зростання розмірності. Для цього передбачено розробити математичні моделі та застосувати методи візуалізації з метою ілюстрації та інтерпретації взаємозв'язків між такими метриками, як манхеттенська відстань, евклідова відстань та інші у високорозмірних просторах. Серію експериментів заплановано провести на синтетичних наборах даних для верифікації теоретичних висновків і демонстрації практичної корисності запропонованої **методології**. Ці набори даних ретельно обрано таким чином, щоб охопити широкий спектр розмірностей і характеристик даних, що забезпечує всебічну оцінку ефективності методології. У межах дослідження застосовано статистичні аналізи та методи візуалізації (зокрема багатовимірне шкалювання і теплові карти), які дають змогу чітко подати взаємозв'язки між метриками відстані. **Досягнуті результати** свідчать про те, що взаємозв'язки між різними метриками відстані суттєво змінюються зі зростанням розмірності. Спостерігаються як збіги, так і розбіжності між окремими метриками, що дає важливі знання про їх поведінку у високорозмірних просторах. Ці висновки мають вирішальне значення для підвищення точності й ефективності методів аналізу даних, заснованих на обчисленні відстані. **Висновки** демонструють, що запропонована рамкова методологія успішно дає кількісну оцінку взаємозв'язків між різними метриками відстані у високорозмірних просторах. Розширене розуміння того, як ці метрики взаємопов'язані, дає змогу обґрунтовано обрати потрібну метрику у високорозмірному аналізі даних, сприяючи більш точним і ефективним аналітичним процедурам у сферах машинного навчання, інтелектуального аналізу даних та розпізнавання образів.

**Ключові слова:** метрики відстані; багатовимірні простори; порівняння метрик; норма  $L_1$ ; норма  $L_2$ ; аналіз даних; машинне навчання.

#### Бібліографічні описи / Bibliographic descriptions

Чернишов Д. В. Порівняльна система для аналізу метрик відстані у високорозмірному просторі. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 143–150. DOI: <https://doi.org/10.30837/2522-9818.2025.1.143>

Chernyshov, D. (2025), "Comparative framework for analyzing distance metrics in high-dimensional spaces", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 143–150. DOI: <https://doi.org/10.30837/2522-9818.2025.1.143>

О. КИРСАНОВ, С. КРИВЕНКО

## МОДЕЛЬ *ML* ДЛЯ АНАЛІЗУ ВЛАСТИВОСТЕЙ РЕЧОВИНИ НА ОСНОВІ ЇЇ ФІЗИКО-ХІМІЧНИХ ОСОБЛИВОСТЕЙ

**Предмет статті** – розширення попередніх результатів бінарної класифікації на багатокласову за допомогою моделі *ML* для аналізу властивостей речовини на основі її фізико-хімічних особливостей. **Мета дослідження** – розроблення нової моделі *ML* і показників для порівняння якості аналізу різних моделей, зокрема для аналізу якості вина за його складом. **Завдання:** підготовка даних, вибір типу моделі, її навчання, налаштування, оцінювання, розгортання та моніторинг. У дослідженні використовується **метод *AWS SageMaker*** для підготовки даних, розроблення моделі, її навчання, налаштування, оцінювання, розгортання та моніторингу, а дані обробляються за допомогою блоків *Jupyter* і *Pandas*. **Досягнуті результати.** Аналіз даних передбачає описову статистику, кореляційні матриці та візуалізації, як-от гістограми та діаграми розсіювання, щоб зрозуміти взаємозв'язки та якість даних. Моделі було навчено за допомогою *XGBoost*, дані розподілено на набори для навчання, перевірки, тестування та оцінювання за допомогою матриць невідповідності та показників *AUC-ROC*. Матриці невідповідності для двох моделей показали змішані результати, доводячи складність порівняння продуктивності моделі та необхідність подальших досліджень незбалансованих класів. Автоматичне налаштування гіперпараметрів *Amazon SageMaker* було використано для оптимізації продуктивності моделі за допомогою баєсівської оптимізації та регресії процесу Гаусса. У дослідженні застосовувалися показники *ROC-AUC* для оцінювання продуктивності моделі з підходами мікро- та макроусереднення, що показують різні значення *AUC* для двох моделей. Друга модель продемонструвала трохи кращу продуктивність на основі показників *AUC*, але аналіз матриці невідповідності показав потребу в моделях, адаптованих до незбалансованих класів. **Висновки:** у дослідженні успішно розроблено нову модель *ML* з метою багатокласової класифікації, продемонстровано її потенціал для покращення передбачення якості вина та запропоновано майбутні напрями досліджень.

**Ключові слова:** модель *ML*; хмара; матриця; матриця невідповідності; передбачена якість; фактична якість; *ROC-AUC*; дані; параметри; усереднення.

### 1. Вступ.

#### Перетворення бізнес-проблеми на *ML*-проблему

Завданням статті є поширення нових результатів [1], що досягли автори в попередніх роботах для бінарної класифікації, на багатокласову класифікацію, а саме дослідження можливостей порівняння впливу змін моделі на якість аналізу. Класифікацію виконує модель *ML*. Для штучного інтелекту (*ML*) це завдання є класичним завданням аналізу та містить два елементи: набір даних і безпосередньо модель. Модель є сукупністю типових елементів, які на наступному рівні абстрагування розглядаються як системи, що потребують розроблення під час робочого процесу *MLOps*, який передбачає типову серію конвеєрних завдань: підготовка даних, розроблення моделі, її навчання та налаштування, оцінювання, розгортання та моніторинг. У межах цього завдання досліджуються метрики, що дають змогу порівнювати різні моделі багатокласової класифікації щодо якості аналізу. У цьому разі розробляється нова модель на основі аналізу проблеми й наявних методів, а саме

створюється нова система – конвеєр з використанням *AWS SageMaker* та бібліотеки *Pandas* для підготовки даних, створення, навчання та оцінювання точності, експлуатації моделі.

Бізнес-проблема аналізу властивостей речовини на основі її фізико-хімічних особливостей перетворюється на *ML*-проблему. Цю логіку створення нової системи, а саме моделі *ML*, можна аргументувати за аналогією з дизелем. Історично дизель – це нова система, що містить елементи, застосовані в інших типах двигунів. Але сукупність цих елементів надає системі певні властивості, завдяки чому вона названа прізвиськом винахідника. Цю аналогію можна розглядати як спрощене загальне визначення системи (моделі). За цією логікою побудована стаття. Перший розділ присвячений перетворенню бізнес-проблеми аналізу властивостей речовини на основі її фізико-хімічних особливостей на *ML*-проблему, що дає змогу сформулювати мету дослідження. У другому розділі розглянуто матеріали й методи. Для розв'язання проблеми *ML* було отримано дані, необхідні для навчання моделі *ML*. Хоча в *AWS* доступні керовані інструменти для

маніпулювання даними, сценарій був записаний у блокнот *Jupyter* для оброблення інформації. У третьому розділі наведено результати досліджень та їх обговорення, оцінено точність різних моделей.

Бізнес-проблема аналізу властивостей речовини на основі її фізико-хімічних особливостей перетворена на *ML*-проблему. Отримано надійну постановку проблеми бізнесу та її важливість на основі набору даних, що містить числову інформацію про склад вина разом з його якістю з огляду на склад напою. Розв'язання *ML*-проблеми вирішує бізнес-проблему передбачення якості, а отже, і ціни.

### Аналіз публікацій. Мета дослідження

Набори даних отримано в репозиторії машинного навчання Каліфорнійського університету в Ірвіні [2]. Набір даних містить числову інформацію про склад вина разом з його якістю та використовується для досягнення мети аналізу – відповісти на запитання: чи можна, зважаючи на склад вина, передбачити якість напою, а отже, і ціну. Тобто цей набір даних дає змогу перетворити бізнес-проблему аналізу властивостей речовини на основі її фізико-хімічних особливостей на проблему *ML*-навчання з учителем.

Зазначений набір даних також застосовується для перегляду статистики, роботи з викидами та масштабування числової інформації. Два набори даних пов'язані з червоним і білим варіантами португальського вина *Portuguese Vinho Verde*. Через проблеми конфіденційності та логістики доступні лише фізико-хімічні (вхідні) та сенсорні (вихідні) змінні. Відсутня інформація про тип винограду, марку чи ціну продажу вина [3]. Це дослідження має важливе значення, оскільки правильно структуровані дані підвищують точність моделей, що особливо актуально для застосування в медицині, де правильність передбачень є критичною.

Досягнення технологій, хмарних обчислень та розроблення алгоритмів сприяли зростанню можливостей і використанню навчання машин *ML*. Керовані сервіси, наприклад *AWS SageMaker*, спрощують навчання машин. Вони надають спеціальні інструменти для автоматизації цих процесів, допомагаючи командам оптимізувати свої робочі процеси та застосовувати найкращі практики для створення моделі навчання машин.

Хоча в *AWS* доступні керовані інструменти для маніпулювання даними, сценарій був записаний у блокнот *Jupyter* для оброблення інформації. Сценарій вилучення та завантаження містить три розділи *ETL*: імпорт і змінні (бібліотека *boto3*); завантаження та вилучення (вебзапит та збереження байтів з URL в архів ZIP); завантаження на *Amazon S3*.

Однією з найпопулярніших бібліотек *Python* з відкритим кодом є *pandas* [4]. Вона була розроблена для переформатування інформації з різних форматів, зокрема *CSV*, *JSON*, *Excel*, *Pickle* тощо, у табличне подання даних у рядках і стовпцях. Було також передбачено функції для аналізу та оброблення інформації, що застосовується в цьому модулі. *Pandas* забезпечує можливість завантаження даних у різних форматах, таких як *CSV*, *JSON*, *Excel* та *Pickle*. Було реалізовано зручний спосіб завантаження даних.

Під час завантаження даних у *Pandas* вони зберігаються в структурі *DataFrame* (таблиця *Pandas*). *DataFrame* описується як загальна двовимірна таблична структура з мітками, розмір якої можна змінювати, з потенційно неоднорідно типізованими стовпцями [5]. Структуру *DataFrame* було запропоновано у вигляді аналогії з електронною таблицею або таблицею *SQL* з екземплярами (рядками) та атрибутами (стовпцями).

Атрибут *shape DataFrame* було призначено для опису кількості екземплярів (рядків) і атрибутів (стовпців). Кожен стовпець у *DataFrame* є серією – одновимірним масивом із мітками, що здатний зберігати інформацію будь-якого типу.

$$df_{wine}.shape = (1599, 12) \quad (1)$$

Разом із даними було завантажено *DataFrame* з індексом (мітками рядків) та стовпцями (мітками стовпців) [6]. За замовчуванням у процесі завантаження інформації із *CSV*-файлу, що містить рядок-заголовков, стовпці створюються на основі першого рядка файлу. Однак можна змінювати цю поведінку.

$$df_{wine}.columns = Index(['fixed acidity', 'volatile acidity', 'citric acid', 'residual sugar', 'chlorides', 'free sulfur dioxide', 'total sulfur dioxide', 'density', 'pH', 'sulphates', 'alcohol', 'quality'], dtype = 'object') \quad (2)$$

$$df_{wine}.index = RangeIndex(start = 0, stop = 1599, step = 1) \quad (3)$$



У разі, якщо у вихідному файлі відсутні назви стовпців, їх можна передати як параметр. Якщо мітки осей не вказані, стовпці автоматично впорядковуються відповідно до вставки (для версій *Python* від 3.6 та версій *Pandas* від 0.23). У попередніх версіях упорядкування стовпців відбувалося за лексичним порядком ключів словника.

Для аналізу даних було взято до уваги необхідність використання правильних типів даних [7]. Здебільшого типи даних було визначено автоматично бібліотекою *Pandas* під час завантаження, що дало змогу продовжити роботу без додаткових змін. Однак за наявності знань у предметній галузі або доступу до експерта було проведено додаткову перевірку для виявлення можливих проблем з типами даних.

Для отримання інформації про типи даних у стовпцях було використано або атрибут *dtypes*, або метод *info()*. Якщо типи даних виявлялися некоректними, рекомендовано з'ясувати причину. Це часто пов'язано з відсутніми значеннями в числових стовпцях або наявністю одиничного текстового значення.

Після аналізу інформації виконувалося перетворення типу даних за допомогою методу *python astype()*.

**Метою роботи** є розроблення нової моделі *ML* та її метрик, що поширюють досягнення попередньої моделі бінарної класифікації на модель багатокласової класифікації та дають змогу порівнювати різні моделі щодо якості аналізу.

## 2. Матеріали й методи

Після надання даним зручного для читання формату було запропоновано застосувати описову статистику для глибшого їх розуміння [8]. Описова статистика забезпечує цінну інформацію, що дає змогу ефективніше обробляти дані та готувати їх для використання в моделях машинного навчання. Далі розглянуто застосування описової статистики та її значущість.

Було залучено загальну статистику, що містить кількість рядків (екземплярів) і кількість стовпців (ознак або атрибутів) у наборі даних. Ця інформація відтворює розмірність даних, що є важливим аспектом, оскільки надмірна кількість ознак може призвести до високої розмірності, негативно впливаючи на продуктивність моделі.

Статистика атрибутів була зосереджена на числових атрибутах, що дало змогу краще уявити форму розподілу даних, зокрема середнє значення, стандартне відхилення, дисперсію, мінімальні та максимальні значення.

Мультиваріативна статистика застосована для аналізу взаємозв'язків між кількома змінними, зокрема для визначення кореляцій та зв'язку між атрибутами.

Особливу увагу було приділено кореляції між атрибутами, оскільки висока кореляція між двома атрибутами може іноді погіршувати продуктивність моделі. Виявлення тісно пов'язаних ознак, що використовуються разом в одній моделі для аналізу вихідної змінної, сприяє уникненню можливих проблем, зокрема складнощів із досягненням мінімізації втрат моделі.

Середнє значення (*mean*) та медіану (*median*) розглянуто як дві різні міри центральної тенденції, що описують зосередженість інформації навколо певного значення або позиції. Середнє значення виявилось корисним для аналізу даних із симетричним розподілом. Однак у разі асиметричного розподілу або наявності вибірок із викидами (*outliers*) рекомендовано використовувати медіану як більш стійку до таких викидів міру. Наприклад, у разі присутності великих значень-викидів, які можуть зміщувати середнє, медіана забезпечує більш точне подання реального центру даних. Подальший аналіз викидів було заплановано для глибшого розуміння їх впливу на інформацію [9].

Для отримання статистичних показників для числових даних було використано метод *describe()*, що надає загальну інформацію про розподіл значень у стовпцях. Також можна переглядати статистику для окремих стовпців за допомогою методів *mean()*, *median()*, *min()*, *max()*, *skew()* та *describe()*.

Отже, розглянуто різні способи обчислення та аналізу статистичних показників для ефективнішого розуміння структури даних.

Для візуалізації числових ознак було використано гістограми як ефективний інструмент для оцінювання загальної поведінки даних. За допомогою гістограм проаналізовано такі аспекти: нормальність розподілу даних, кількість піків та наявність асиметрії.

Гістограми групують значення ознак у певні інтервали (*bins*), що дало змогу оцінити частотність значень у кожному інтервалі. Вищі піки на гістограмі вказували на найбільш поширені значення.

Ця техніка групування (*binning*) також була визначена як корисна в контексті інженерії ознак.

Крім гістограм, для числових ознак було використано графіки щільності (*density plots*) та ящиківі діаграми (*box plots*). Ці інструменти допомогли оцінити діапазон даних, визначити пік розподілу, ідентифікувати викиди та виявити особливості ознаки. Наприклад, графіки щільності показували розподіл даних у вигляді безперервної кривої, тоді як ящиківі діаграми забезпечували подання даних за квантилями.

У ящиківій діаграмі [10] було зображено діапазон значень між  $Q_1$  (першим квантилем) і  $Q_3$  (третім квантилем), із медіаною ( $Q_2$ ), яка позначалася лінією всередині ящика. Вуса (*whiskers*) простягалися за межі ящика на відстань, що не перевищувала  $1,5 * IQR$  (діапазону між квантилями,  $IQR = Q_3 - Q_1$ ). Дані, що виходили за межі вусів, позначалися як викиди (*outliers*).

Такі візуалізації сприяли глибшому розумінню структури даних, а також допомогли визначити, чи потрібне додаткове оброблення для корекції особливостей або викидів.

Для аналізу взаємозв'язків між числовими змінними використано діаграми розсіювання. Цей метод допоміг візуалізувати зв'язки між змінними, навіть якщо кореляція між ними була низькою через розсіяність даних. Наприклад, для змінних "сульфати" та "алкоголь" діаграма розсіювання дала змогу ідентифікувати потенційні позитивні зв'язки, що не були очевидними під час розгляду статистичних показників.

Було також розглянуто можливість аналізу кількох змінних одночасно за допомогою матриць діаграм розсіювання [11]. У бібліотеці *Pandas* реалізовано простий спосіб створення таких матриць, що дає змогу оцінити парні зв'язки між будь-якими двома змінними з обраного набору стовпців. Наприклад, за наявності трьох стовпців можна отримати всі припустимі парні діаграми розсіювання.

Цей підхід забезпечив ефективний інструмент для візуального аналізу числових ознак, що сприяло кращому розумінню їх взаємозв'язків і потенційного впливу на подальше моделювання.

З допомогою діаграми розсіювання [12] було виявлено особливі регіони, до яких належить певна підмножина даних. Визначено зв'язок між алкоголем, сульфатами та якістю. Ці значення

для хорошого (якість  $> 5$ ) та поганого (якість  $\leq 5$ ) вина зображені на діаграмі.

Побудова діаграм дала змогу уявити, наскільки корисними є певні змінні для задачі класифікації.

Було визначено, як можна кількісно оцінити лінійний зв'язок між змінними, розміщеними на діаграмі розсіювання. Кореляційна матриця [13] є корисним інструментом для визначення як сильного, так і слабого лінійного зв'язку між числовими змінними.

Розглянуто використання теплових карт для візуалізації даних, що значно полегшує аналіз числових показників. Найвищий показник (1) позначено темно-зеленим кольором, а найнижчий (-1) – темно-коричневим. Колір відтворює як напрямок (позитивний чи негативний), так і силу кореляції.

Основною метою теплової карти (рис. 1) є виявлення кореляцій за кольором, навіть якщо текст на діаграмі не зчитується. Для створення такої візуалізації використано функцію теплової карти з бібліотеки *Seaborn*.

На графіку виявлено певну кореляцію між лимонною кислотою та фіксованою кислотністю. Два найбільші коефіцієнти лінійного зв'язку для якості вина демонструють кореляцію з алкоголем та сульфатами, вони мають коефіцієнти кореляції, відповідно, 0.48 та 0.25 в нижньому рядку теплової карти. На тепловій карті має місце деяка кореляція 0.67 між лимонною кислотою та фіксованою кислотністю, незначна кореляція -0.68 між фіксованою кислотністю та рН. Такий зв'язок пояснюється тим, що лимонна кислота впливає на загальну кислотність вина. Водночас між фіксованою кислотністю та рН визначено низьку кореляцію. Це пояснюється різницею між показниками: рН вимірює силу кислот, тоді як фіксована кислотність – їх кількість. У наборі даних явної залежності між цими двома властивостями не виявлено.

Розглянуто необхідність очищення даних через можливу наявність викидів. Викиди – це точки, розташовані на аномально великій відстані від інших значень у наборі даних. Вилучення викидів не завжди є обов'язковим, оскільки вони можуть додати цінності набору даних. Проте викиди здатні ускладнювати отримання точних передбачень через зміщення значень щодо інших, більш нормальних даних. Також зазначено, що викиди можуть свідчити про те, що точка даних помилково належить до іншого стовпця.

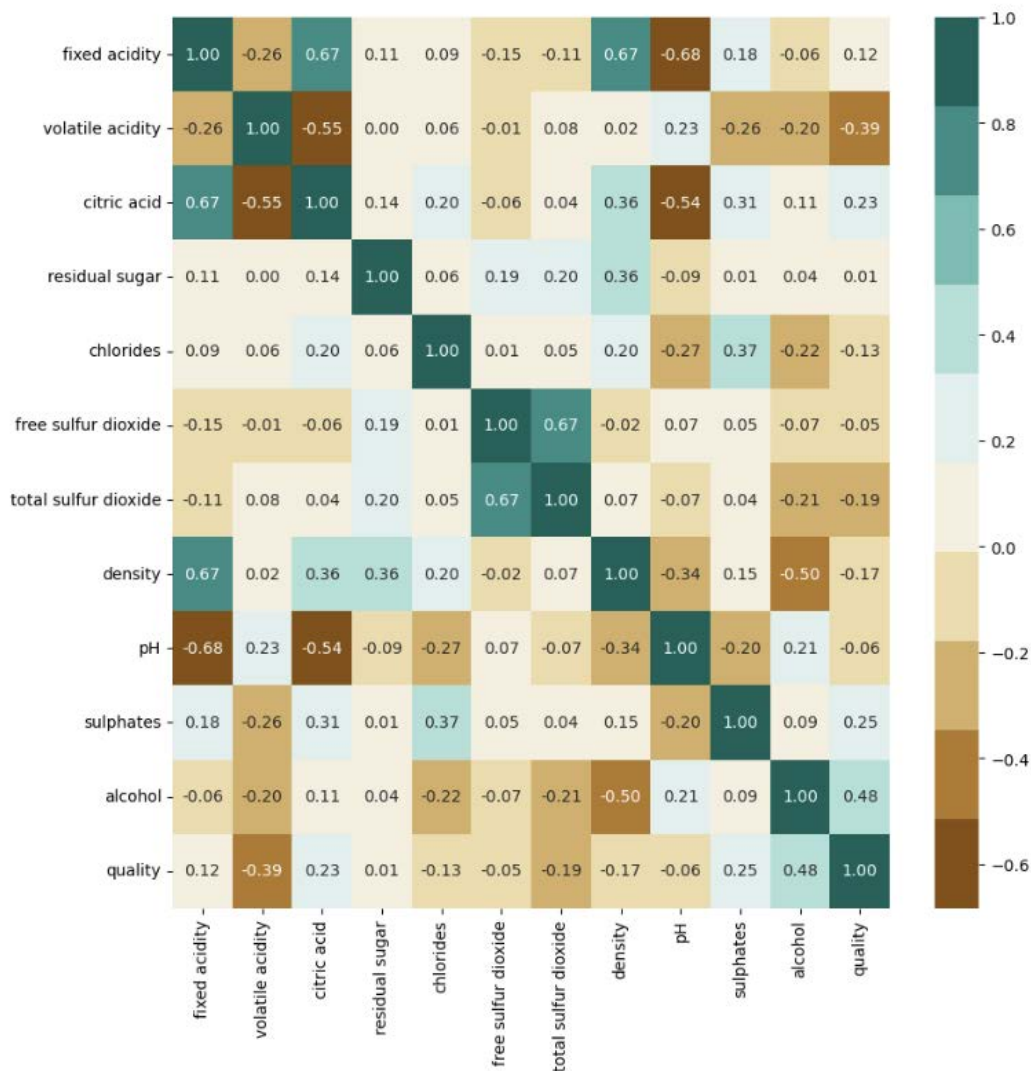


Рис. 1. Теплова карта кореляційної матриці

Запропоновано поділити викиди на дві категорії: уніваріантні (стосуються однієї змінної) та мультіваріантні (стосуються двох або більше змінних).

Одним із найбільш поширених способів знайти уніваріантні викиди є використання коробчастої діаграми (*box plot*), яка показує, наскільки далеко точка даних розташована від середнього значення для цієї змінної. Коробка на діаграмі показує значення даних у межах двох кватилів від середнього значення.

Точкова діаграма (*scatter plot*) може бути ефективним способом виявлення мультіваріантних викидів. Наприклад, у цій діаграмі показано кількість сульфатів і алкоголю в колекції вин. За допомогою точкової діаграми можна швидко побачити, чи існують мультіваріантні викиди для двох змінних.

Бізнес-проблема аналізу властивостей речовини на основі її фізико-хімічних особливостей перетворена на *ML*-проблему. Отримано надійну постановку проблеми бізнесу та її важливість на основі набору даних, що містить числову інформацію про склад вина разом з його якістю з огляду на склад напою. Розв'язання *ML*-проблеми вирішує бізнес-проблему передбачення якості, а отже, і ціни. Більшість бізнес-проблем підпадають під одну з двох категорій: класифікація чи регресія. Зазначена *ML*-проблема належить до категорії багатозначної класифікації. Ціль належить шістьом класам 0–5.

Проведено очищення та підготовку даних, однак вони все ще можуть не відповідати вимогам для навчання алгоритму. Деякі алгоритми потребують даних в особливому форматі. Визначено кроки форматування для підготовки до навчання моделі.

Деякі алгоритми не працюють із даними у форматі *DataFrame*. Дані для навчання *ML* зберігаються в різних форматах залежно від обраного алгоритму. Наприклад, багато алгоритмів *Amazon SageMaker* підтримують формат файлів *CSV* для навчання [14]. Файли *CSV*, які використовуються з *Amazon SageMaker*, не можуть містити заголовків, а цільова змінна має бути в першому стовпці.

Досліджено, що більшість алгоритмів *Amazon SageMaker* працюють найефективніше з оптимізованим форматом *protobuf recordIO*. У цьому форматі кожен екземпляр у наборі даних перетворюється на бінарне подання як набір 4-байтних чисел із рухомою точкою, після чого завантажується в поле значень *protobuf*.

Визначено, що цей формат дає змогу застосовувати режим *Pipe* для алгоритмів, що його підтримують. У режимі *Pipe* дані передаються безпосередньо з *Amazon S3*, тоді як у режимі *File* вся інформація завантажується з *Amazon S3* на томи екземплярів навчання. Поточкова передача в режимі *Pipe* забезпечує швидший запуск навчальних завдань і кращу пропускну здатність, а також допомагає зменшити розмір томів *Amazon Elastic Block Store (Amazon EBS)*, оскільки потрібно лише зберігати кінцеві артефакти моделі. Водночас режим *File* потребує більше дискового простору для зберігання як кінцевих артефактів, так і повного набору даних.

Цільова змінна в наборі навчальних даних має розташовуватися в першому стовпці ліворуч, а ознаки – у стовпцях праворуч. У використанні формату *CSV* важливо, щоб перший стовпець був цільовою змінною.

Тому цільова змінна в навчальному наборі даних була переміщена в перший стовпець ліворуч, у цьому разі ознаки розміщені праворуч від стовпця цільової змінної.

Оцінка моделі на тих самих даних, на яких вона навчалася, спричиняє перенавчання. Перенавчання виникає, коли модель надто добре запам'ятовує особливості навчального набору даних замість того, щоб вивчати зв'язки між ознаками та мітками. Як наслідок, модель не здатна застосовувати ці зв'язки та шаблони до нових даних у майбутньому.

Реалізовано метод утримання, що передбачає розподіл даних на кілька наборів: навчальні, валідаційні та тестові [15].

Навчальні дані, що містять ознаки та мітки, було подано на вхід обраному алгоритму для створення

моделі. Потім модель використано для аналізу на валідаційному наборі даних. На етапі роботи з валідаційним набором виявлено аспекти, що потребують коригування, налаштування чи вдосконалення. Після внесення змін модель було протестовано на тестовому наборі даних, що передбачає лише ознаки, оскільки мітки мають бути передбачені.

Застосовано такі рекомендації щодо розподілу даних: 80 % – для навчання, 10 % – для валідації та 10 % – для тестування. Для великих обсягів даних альтернативний розподіл: 70 % – на навчання, 15 % – на валідацію та 15 % – на тестування.

Виявлено, що дані, розташовані в певному порядку, можуть призводити до упереджень у моделях, і це особливо актуально, коли використовуються структуровані дані. Зазначено, що дані можуть бути упорядковані, наприклад, за стовпцем якості. У разі, якщо запущено модель на тестових даних, цей упорядкований патерн застосовується, що створює упередження для моделі. Також деякі цілі можуть бути відсутні в навчальних даних.

Як правило, рекомендовано рандомізувати набір даних перед розподілом, і багато бібліотек надають функції для рандомізації [16]. Для менших наборів застосовується стратифікований вибірковий відбір. Він гарантує, що в навчальному й тестовому наборах збережено приблизно однаковий відсоток зразків кожного класу цілей, як і в повному наборі.

Функція *train\_test\_split* з *sklearn* дає змогу найпростішим чином виявити способи перемішування та розподілу даних [17].

Було застосовано *stratify*, щоб гарантувати збереження співвідношення у стовпці цілей під час розподілу даних.

*Amazon SageMaker* надає готові контейнери для підтримки фреймворків глибокого навчання, таких як *Apache MXNet*, *TensorFlow*, *PyTorch* і *Chainer*. Він також підтримує бібліотеки *ML*, зокрема *scikit-learn* і *SparkML*, надаючи попередньо зібрані образи *Docker*. Було використано *Amazon SageMaker Python SDK*, вони розгортаються за допомогою відповідного класу *Amazon SageMaker SDK Estimator*. Створено код *Python*, що реалізує алгоритм, і налаштовано попередньо зібране зображення для доступу до коду як точки входу.

*XGBoost* – це популярна та ефективна реалізація з відкритим кодом алгоритму градієнтного бустингу

дерев. Градієнтний бустинг – це алгоритм контрольованого навчання, який намагається точно передбачити цільову змінну. Він досягає свого передбачення внаслідок комбінування ансамблю оцінок з набору більш простих, слабших моделей. *XGBoost* добре зарекомендував себе на змаганнях з машинного навчання. Він стійко обробляє різні типи даних, відношення та розподіли, а також чимало гіперпараметрів, що можна ефективно налаштувати та підігнати. Ця гнучкість робить *XGBoost* хорошим вибором для проблем регресії, багато класової класифікації, тобто аналізу властивостей речовини за допомогою інтелектуального аналізу даних на основі її фізико-хімічних особливостей способом хмарної інтеграції

Щоб навчити модель в *Amazon SageMaker*, створено навчальне завдання, що містить таку інформацію: URL-адресу сегмента *Amazon S3*, де збережено навчальні дані; обчислювальні ресурси, які *Amazon SageMaker* має використовувати для навчання моделі. Обчислювальні ресурси – це екземпляри обчислень *ML*, якими керує *Amazon SageMaker*. *Amazon SageMaker* надає вибір типів екземплярів, оптимізованих для різних випадків використання машинного навчання. Типи екземплярів передбачають різні комбінації центрального процесора, оперативної пам'яті, сховища та мережевої ємності. Було обрано відповідне поєднання ресурсів для створення, навчання та розгортання моделей *ML*. Кожен тип екземпляра має один або кілька розмірів екземпляра, і ця функція дає змогу масштабувати ресурси відповідно до вимог цільового робочого навантаження.

Завантаження в *Amazon S3* відбувається після розпакування файлів у папку, виконано перебір файлів папки та завантажено кожен файл у *Amazon S3*.

Після того, як модель була навчена, налаштована та протестована, вона готова до розгортання. У наступному розділі налаштування моделі змінюються. Може скластися враження, що фази конвеєра *ML* не в порядку. Щоб перевірити та отримати показники продуктивності запропонованої моделі, були зроблені висновки або передбачення на основі моделі, що зазвичай вимагає розгортання. Розгортання для тестування відрізняється від виробництва, хоча механіка однакова. *Amazon SageMaker* надає все необхідне для розміщення моделі для простого тестування та оцінювання. Оцінювання може передбачати будь-що: від кількох запитів до розгортань, що обробляють десятки тисяч запитів.

Модель можна розгорнути двома способами. Для окремих передбачень модель розгорнуто за допомогою послуг хостингу *Amazon SageMaker*. Він розгортає кілька обчислювальних екземплярів, які запускають модель за кінцевою точкою із збалансованим навантаженням. Програми можуть викликати *API* у кінцевій точці, щоб робити передбачення. За допомогою цієї моделі можна збільшити або зменшити кількість екземплярів залежно від попиту. Щоб отримати передбачення для всього набору даних, було застосовано пакетне перетворення *Amazon SageMaker*. Замість розгортання та підтримки постійної кінцевої точки *Amazon SageMaker* запускає модель і виконує передбачення для всього наданого набору даних. Він зберігає результати в *Amazon S3* перед тим, як вимкнеться та припинить роботу інстанцій. Виконання пакетних передбачень під час тестування моделі є корисним, оскільки можна швидко запустити весь набір перевірки на моделі. Не потрібно писати жодного коду для оброблення та зіставлення окремих результатів.

Метою етапу розгортання є створення керованого середовища для розміщення моделей для забезпечення безпечного виходу з низькою затримкою. Після розгортання у виробництві здійснювався контроль виробничих даних. Модель перенавчалась, оскільки нові розгорнуті моделі мають відтворювати поточні виробничі дані. Нові дані накопичуються з часом, і вони потенційно можуть визначити альтернативні або нові результати. Тому розгортання моделі є безперервним процесом, а не одноразовою справою.

Для високої доступності та резервування було перевірено розгортання моделі для автоматичного масштабування екземплярів *Amazon ML* у кількох зонах доступності. Було вказано тип екземпляра, а також максимальну та мінімальну кількість, *Amazon SageMaker* подбав про інше. Він запускає екземпляри, розгортає модель і налаштовує безпечну кінцеву точку *HTTPS* для програми. Програма містила виклик *API* до цієї кінцевої точки, щоб досягти низької затримки та високої пропускну здатності. Ця архітектура дає змогу інтегрувати нові моделі в програму за лічені хвилини, оскільки зміни моделі більше не потребують змін коду програми. *Amazon SageMaker* керує виробничою обчислювальною інфраструктурою від імені клієнта. Він перевіряє працездатність, застосовує виправлення безпеки та проводить інше планове обслуговування. *Amazon SageMaker* виконує всі ці завдання за допомогою

вбудованого моніторингу та журналювання *Amazon CloudWatch*.

Після того, як навчено модель, створена кінцева точка в кодї за допомогою консолї *Amazon SageMakerSDK*. Оскільки передбачено розміщення двох моделей, була створена багатомодельна кінцева точка.

Багатомодельні кінцеві точки забезпечують масштабоване та економічно ефективне рішення для розгортання значної кількості моделей. Використовується спільний контейнер обслуговування, що дає змогу розміщувати кілька моделей. Цей підхід знижує витрати на розміщення внаслідок підвищення використання кінцевих точок порівняно з одномодельними кінцевими точками. Також оптимізовано витрати на розгортання завдяки тому, що *Amazon SageMaker* завантажує моделі в пам'ять і масштабує їх відповідно до шаблонів трафіку.

Коли розгортаються моделі навчання машин у виробництві, для передбачень нових даних узгодженість важлива. Було перевірено, що ті самі кроки оброблення даних, які використовувалися під час навчання, також застосовувалися до кожного запиту на вихід. Інакше можна отримати неправильні результати передбачення. Використовуючи конвеєри виходу, можна повторно впроваджувати етапи оброблення даних, які застосовувалися під час навчання моделі для логічного виходу. Немає необхідності підтримувати дві окремі копії одного коду. Таке повторне використання коду сприяє точності передбачень і знижує витрати на розроблення. Оскільки *Amazon SageMaker* є керованою службою, конвеєрами виходів можна повністю керувати. Коли розгортається модель конвеєра, служба встановлює та запускає послідовність контейнерів у кожному екземплярі *EC2* у кінцевій точці або в завданні пакетного перетворення. Крім того, послідовність оброблення функцій і виходів виконується з низькою затримкою, оскільки контейнери розташовані в тих самих екземплярах *EC2*.

### 3. Результати досліджень та їх обговорення.

#### Оцінювання точності моделі

Після того, як було навчено й налаштовано дві моделі, щоб прийняти рішення щодо того, яка з них найкраще підходить для бізнес-проблеми, вони обидві були оцінені. Було визначено, чи будуть моделі ефективними в передбаченні мети на нових

і майбутніх даних. Оскільки майбутні екземпляри мають невідомі цільові значення, було оцінено, як модель працює на даних, для яких невідома цільова відповідь. Потім ця оцінка використовувалась як проксі для продуктивності майбутніх даних. З цієї причини було надано зразок даних для оцінювання чи тестування.

Важливою частиною цього етапу є вибір показника, що найбільше підходить для бізнес-ситуації, яка досліджується. Під час цього етапу на основі визначення бізнес-проблеми та її результату розроблена бізнес-метрика для оцінювання успіху. Показник моделі, обраний на цьому етапі, тісно пов'язаний із бізнес-метрикою. Ці два показники мають високу кореляцію. Крім розгляду бізнес-проблеми та показника успіху, тип проблеми *ML*, яка досліджувалась, впливає на метрику обраної моделі. У цьому розділі наведені загальні показники, що застосовувалися в задачах класифікації. Бізнес-проблема визначена як проблема багатокласової класифікації.

У випадку багатокласової класифікації ключові поняття *TPR* (*true positive rate*) або *FPR* (*false positive rate*) отримуються лише після бінарного виходу. Це можна зробити двома способами: схема *OvR* (*One-vs-Rest*) порівнює кожен клас з усіма іншими (які вважаються одним); схема "один проти одного" *OvO* порівнює кожну унікальну попарну комбінацію класів. У дослідженні застосовано схему *OvR*.

Імпортовано набір даних про вино, що містить шість класів, кожен з яких відповідає якості напою (0, 1, ..., 5). Один клас лінійно відділяється від інших п'яти; останні не є лінійно віддільними один від одного. Тут ми бінаризували вихід. Були навчені дві моделі *XGBoost*, що можуть природним чином обробляти багатокласові проблеми.

Ключові поняття *TPR* або *FPR* на основі спрощеної моделі бінарної класифікації вина, яка позначає дані як "гарне" або "негарне". Після того, як модель навчена, можна використовувати тестовий набір даних, який був прихований, з метою виконання передбачення. Щоб допомогти перевірити продуктивність моделі, можна порівняти передбачені значення з фактичними. Крім того, можна подати значення в таблиці, щоб уявити, наскільки добре працює модель.

У матриці невідповідності можна отримати порівняння на високому рівні того, як передбачені класи збігаються з фактичними. Припустимо, що

фактичною міткою або класом є "гарне", що ідентифікується як  $P$  для позитивного значення в матриці невідповідності. І припустимо, що передбачена мітка або клас також є "гарне". Це означає, що отримано справді позитивний результат  $TP$  (*true positive*), який є хорошим для моделі. Так само припустимо, що є фактична мітка "негарне", яка ідентифікується як  $N$  для негативного значення в матриці невідповідності. І припустимо, що передбачена мітка або клас також не є "негарне". Тоді маємо справжній негативний результат  $TN$  (*true negative*), що також є хорошим для моделі. В обох цих випадках модель, використовуючи дані тестування, передбачила правильний результат. Можливі два інші результати, обидва з яких не ідеальні. Перший – коли фактичний клас негативний, тобто "негарне", але передбачений клас позитивний, отже, "гарне". Цей результат називається хибно позитивним  $FP$  (*false positive*), оскільки передбачення є позитивним, але неправильним. Помилково негативний результат  $FN$  (*false negative*) виникає, коли фактичний клас позитивний, тобто "гарне", але передбачений клас негативний, отже, "негарне".

Аналіз матриці невідповідності сформованих на основі роботи двох різних моделей на тих самих даних не дає змогу визначити, яка модель краща. Чи доцільніше переконатися, що модель – всі гарні проби вина, навіть якщо це означає багато помилкових спрацьовувань? Або краще переконатися, що модель найточніша? Це важко зрозуміти, зважаючи на дві матриці невідповідності. Навіть важко уявити, що буде, якщо виникне необхідність порівняти багато моделей.

З метою порівняння досліджуваних моделей визначено додаткові показники. Першим показником є чутливість  $TPR$ .

$$TPR = \frac{TP}{TP + FN}. \quad (4)$$

Цей показник є часткою позитивних ідентифікацій. У прикладі про вино це означає, який відсоток напою було правильно ідентифіковано. Для обчислення чутливості кількість справжніх позитивних результатів (позитивних ідентифікацій проб вина) поділено на загальну кількість фактичних проб.

Специфічність  $FPR$ , яку іноді називають селективністю, – це частка правильно визначених негативів.

$$FPR = \frac{TN}{TN + FP}. \quad (5)$$

У нашому прикладі про вино кількість неякісних проб визначена як "негарне". Для обчислення специфічності кількість справжніх негативів розділена на загальну кількість фактичних негативів. У цьому прикладі це значення – кількість правильно визначених проб неякісного вина, поділена на загальну кількість фактичних проб неякісного вина.

Щоб допомогти перевірити продуктивність моделі, порівняно передбачені значення з фактичними значеннями (табл. 1), що дає деяку уяву про ефективність роботи моделі [18].

Таблиця 1. Матриця невідповідності першої моделі

Фактична якість	Кількість передбачень для якості					
	0	1	2	3	4	5
0	0	0	0	1	0	0
1	0	0	2	3	0	0
2	0	1	43	23	1	0
3	0	0	17	44	3	0
4	0	0	2	5	13	0
5	0	0	0	1	1	0

Для 2-го класу якості напою отримано 43 правильних передбачення з 68 проб вина 2-го класу якості.

Для 3-го класу якості напою отримано 44 правильних передбачення з 64 проб вина 3-го класу якості.

Процес налаштування гіперпараметрів для першої моделі був трудомісткий і виконаний штатними автоматичними засобами *Amazon SageMaker (tuning job)*. У табл. 2 подано інформацію щодо ефективності роботи другої моделі.

Таблиця 2. Матриця невідповідності другої моделі

Фактична якість	Кількість передбачень для якості					
	0	1	2	3	4	5
0	0	0	0	1	0	0
1	0	0	3	2	0	0
2	0	1	49	18	1	0
3	0	0	19	40	5	0
4	0	0	5	4	11	0
5	0	0	0	1	1	0

Для 2-го класу якості вина отримано 49 правильних передбачень з 68 проб напою 2-го класу якості, що на шість передбачень більше, ніж у запропонованій моделі.

Для 3-го класу якості вина отримано 40 правильних передбачень з 64 проб напою 3-го класу якості, що на чотири передбачення менше, ніж у першій моделі.

Отже, з матриці невідповідності не можна зробити висновок, яка модель *ML* краще передбачає якість вина. Однак аналіз матриць демонструє проблему суттєво різної кількості екземплярів у кожному класі, що дає змогу запропонувати напрям майбутніх досліджень – розроблення моделей для незбалансованих класів.

Налаштування гіперпараметрів розглядається як інструмент для створення складних рішень машинного навчання та його додано до частини процесу застосування наукового методу.

*Amazon SageMaker* дає змогу виконувати автоматичне налаштування гіперпараметрів. Автоматичне налаштування моделі *Amazon SageMaker* (відоме також як налаштування гіперпараметрів) знаходить найкращу версію моделі за допомогою виконання багатьох навчальних завдань на наборі даних. Він використав вказані алгоритми й діапазони гіперпараметрів, потім обрав значення гіперпараметрів, що приводять до найкращої моделі, виміряної обраною метрикою. Він застосовує регресію процесу Гаусса, щоб передбачити, які значення гіперпараметрів можуть бути найбільш ефективними для покращення відповідності, а також упроваджує баєсівську оптимізацію, щоб збалансувати дослідження простору гіперпараметрів і використання їх певних значень, коли це доречно. І що важливо, автоматичне налаштування моделі можна застосовувати із вбудованими алгоритмами *Amazon SageMaker*.

У дослідженні використано метрики робочої характеристики *ROC* (*receiver operator curve*) для оцінювання якості багатокласових класифікаторів. Площа під кривою *AUC* (*Area under the curve*) робочої характеристики приймача (*AUC-ROC*) є ще одним показником оцінки. Площа під кривою оператора приймача (*AUC-ROC*) – ще один показник оцінки. Частина *AUC* в аббревіатурі – це площа під нанесеною лінією. Що більша площа *AUC*, то краще модель передбачає властивості речовини за допомогою інтелектуального аналізу даних на основі її фізико-хімічних особливостей. У дослідженні було застосовано площу *AUC* для швидкого порівняння моделей між собою.

Криві *ROC* зазвичай містять чутливість *TPR* на осі *Y* і специфічність *FPR* на осі *X*. Це означає, що верхній лівий кут графіка є "ідеальною" точкою – *FPR* дорівнює нулю, а *TPR* – одиниці. Це не дуже реалістично, але це означає, що більша площа

під кривою *AUC* зазвичай є кращою. Крутизна кривих *ROC* також важлива, оскільки ідеально максимізувати *TPR* за умови мінімізації *FPR*.

Застосована в дослідженні багатокласова стратегія "один проти решти" *OvR* (також відома як "один проти всіх") полягає в обчисленні кривої *ROC* для кожного із шести класів якості вина. На кожному кроці цей клас розглядається як позитивний, а решта класів – як негативні. Не потрібно плутати стратегію *OvR*, що використовується для оцінювання багатокласових класифікаторів, зі стратегією *OvR*, яка застосовується для навчання багатокласового класифікатора способом підлаштування набору бінарних класифікаторів (наприклад, за допомогою метаоцінювання *OneVsRestClassifier*). Оцінювання *OvR ROC* можна використовувати для ретельного вивчення будь-яких моделей класифікації незалежно від того, як вони були навчені.

У дослідженні використано *LabelBinarizer* для бінаризації цілі внаслідок однократного кодування в режимі *OvR*. Це означає, що цільова форма (*n\_samples*) зіставляється із цільовою формою (*n\_samples, n\_classes*). Було перевірено кодування певного класу. Побудовано криву *ROC*, що показує певний клас.

Побудовано графік, що демонструє результуючу криву *ROC*, для третього класу якості вина проти всіх інших. Побудовано криву *ROC* з використанням мікроусередненого *OvR*.

Мікроусереднення виконує агрегування внесків від усіх класів (за допомогою *numpy.ravel*) для обчислення середніх показників таким чином:

$$TPR = \frac{\sum_c TPc}{\sum_c (TPc + FNc)}; \quad (6)$$

$$FPR = \frac{\sum_c FPc}{\sum_c (FPc + TNc)}. \quad (7)$$

Виконана демонстрація ефекту *numpy.ravel*.

У багатокласовій системі класифікації з дуже незбалансованими класами мікроусереднення є кращим, ніж макроусереднення. У таких випадках можна альтернативно використати зважене макроусереднення. У разі, коли основним інтересом є не графік, а сама оцінка *ROC-AUC*, можна відтворити значення, показане на графіку, за допомогою методу *roc\_auc\_score()* [19]. Це еквівалентно обчисленню кривої *ROC* із застосуванням методу *roc\_curve()*,



а потім площі під кривою за допомогою методу  $auc()$  для незбалансованих (*raveled*) фактичних і передбачених класів.

Обчислення кривої  $ROC$  додає одну точку за умови максимальної частоти помилкових позитивних результатів за допомогою лінійної інтерполяції та корекції Маккліша [20].

Побудовано криву  $ROC$  з використанням макросереднього  $OvR$ .

Отримання макросереднього вимагає обчислення метрики незалежно для кожного класу, а потім узяття середнього за ними, отже, розгляду всіх класів однаково апіорі. Спочатку підумовуємо істинні / хибні позитивні результати для кожного класу. Це обчислення еквівалентне простому виклику методу  $roc\_auc\_score()$ .

Усі криві  $OvR ROC$  для першої моделі були побудовані разом (рис. 2).




Рис. 2.  $OvR ROC$  для першої моделі

Для першої моделі концепція мікроусереднення як один із способів узагальнення інформації багатокласових кривих  $ROC$  демонструє значення  $AUC$  0.89 проти значення  $AUC$  0.80 для концепції макросереднення.

Усі криві  $OvR ROC$  для другої моделі також були побудовані разом (рис. 3).

Концепція мікроусереднення інформації багатокласових кривих  $ROC$  демонструє значення  $AUC$  0.91 проти значення  $AUC$  0.83 для концепції макросереднення.

## Висновки

Мета роботи досягнута: розроблена нова модель  $ML$  та її метрики, що поширюють досягнення

попередньої моделі бінарної класифікації на модель багатокласової класифікації та дають змогу порівнювати різні моделі щодо якості аналізу.

Бізнес-проблема аналізу властивостей речовини на основі її фізико-хімічних особливостей перетворена на  $ML$ -проблему. Отримано надійне визначення проблеми бізнесу та її важливості на основі набору даних, що містить числову інформацію про склад вина разом із його якістю з огляду на склад напою.

Розв'язання  $ML$ -проблеми розв'язує бізнес-проблему передбачення якості, а отже, і ціни. Більшість бізнес-проблем підпадають під одну з двох категорій: класифікація чи регресія.  $ML$ -проблему додано до категорії багатозначної класифікації. Ціль належить шістьом класам 0–5.




Рис. 3. OvR ROC для другої моделі

Для розв'язання проблем *ML* було отримано дані, необхідні для навчання моделі. Хоча в *AWS* доступні керувані інструменти для маніпулювання даними, сценарій був записаний у блокнот *Jupyter* для оброблення інформації. Сценарій вилучення та завантаження містить три розділи *ETL*: імпорт та змінні (бібліотека *boto3*); завантаження та вилучення (вебзапит та збереження байтів з URL в архів ZIP); завантаження на *Amazon S3*.

За допомогою *Pandas*, бібліотеки *Python* з відкритим кодом дані переформатовано з формату *CSV* в табличне подання в рядках і стовпцях. Отримано атрибут *shape DataFrame* (1599,12). Завдяки доменним знанням розв'язано проблеми з типом даних. Діаграма розсіювання допомогла візуалізувати зв'язок між сульфатами та алкоголем. Крім того, діаграма розсіювання допомогла виявити два спеціальні регіони, пов'язані з якісними й неякісними винами. Кореляційна матриця показала високу кореляцію, лінійний зв'язок між алкоголем, сульфатами та якістю напою, коефіцієнти кореляції, відповідно, 0.47 та 0.25. На тепловій карті має місце деяка кореляція 0.67 між лимонною кислотою та фіксованою кислотністю, незначна кореляція  $-0.68$  між фіксованою кислотністю та рН.

Інженерія функцій, яка передбачає вибір або вилучення найкращих функцій для навчання машин, не розглядається, оскільки вона описана в попередніх роботах.

Для перевірки точності моделей дані розділені на набори навчання, перевірки та тестування в такій пропорції: 80 %, 10 % та 10 % відповідно. Використано алгоритм *XGBoost* навчання з учителем і навчальні завдання *AWS SageMaker*.

Навчені моделі розгорнуті за допомогою *AWS SageMaker* для оброблення викликів *API* з програм та для аналізу за допомогою пакетного перетворення, яке використовувалось для отримання характеристики якості передбачення властивостей речовини на основі її фізико-хімічних особливостей, тобто якості передбачень для розв'язання проблеми бізнесу. Застосовувались кінцеві точки однієї моделі.

Для оцінювання якості моделей використано дані, які модель не передбачила через набір утримання. Застосовано матриці невідповідності та *AUC-ROC*. Матриці невідповідності не дали змогу порівняти дві моделі щодо якості передбачення. Однак аналіз матриць сприяв вибору напрямку майбутніх досліджень – розробленню моделей для незбалансованих класів. Значення *AUC* 0.89 та 0.91

для концепції мікроусереднення і 0.80 та 0.83 для Тьюнінг моделі важливий для того, щоб знайти концепції макроусереднення дали змогу зробити найкращий розв'язок бізнес-проблеми. однозначний вибір на користь другої моделі.

## Список літератури

1. Кирсанов О., Кривенко С. Конструювання ознак для застосування навчання машин при обробці клінічних даних. *ICTEE*. 2024. Т. 4. № 2. 2024. С. 162–171. DOI: <https://doi.org/10.23939/ictee2024.02.162>
2. Dua D., Graff C. UCI Machine Learning Repository. *University of California, School of Information and Computer Science*, Irvine, CA. 2019. URL: <http://archive.ics.uci.edu/ml> (accessed: 07.11.2024)
3. Cortez P., Cerdeira A., Almeida F., Matos T., Reis J. Modeling wine preferences by data mining from physicochemical properties. *Decision Support Systems*. Vol. 47. No. 4. 2009. P. 547–553. DOI: 10.1016/j.dss.2009.05.016
4. Bhatlawande S., Srivastava S., Shilaskar S. Information extraction from digital receipts and bank transactions using machine learning. *2023 International Conference on Integration of Computational Intelligent System (ICICIS)*. Pune, India. 2023. P. 1–5. DOI: 10.1109/ICICIS56802.2023.10430289
5. Wu Z., Pulido V. Statistical analyses for fantasy sports. *2022 IEEE Integrated STEM Education Conference (ISEC)*. Princeton, NJ, USA. 2022. P. 269–269. DOI: 10.1109/ISEC54952.2022.10025111
6. Fu W., Widagdo T. E. SQL interface development for spatial data retrieval on Cassandra. *2022 International Conference on Data and Software Engineering (ICoDSE)*. Denpasar, Indonesia. 2022. P. 138–143. DOI: 10.1109/ICoDSE56892.2022.9971942
7. Chatziantoniou D., Kantere V., Antoniou N., Gantzia A. Data virtual machines: simplifying data sharing, exploration & querying in big data environments. *2022 IEEE International Conference on Big Data (Big Data)*. Osaka, Japan. 2022. P. 373–380. DOI: 10.1109/BigData55660.2022.10020508
8. Geetha V., Sujatha N. An overview of descriptive analytics and data visualization. *2024 5th International Conference on Smart Electronics and Communication (ICOSEC)*. Trichy, India. 2024. P. 1158–1163. DOI: 10.1109/ICOSEC61587.2024.10722273
9. Du B., Deng F. The method of network intrusion detection based on descriptive statistics model and Logistic model. *2022 International Conference on Machine Learning and Knowledge Engineering (MLKE)*. Guilin, China. 2022. P. 160–163. DOI: 10.1109/MLKE55170.2022.00037
10. Cuartero A., Paoletti M. E., García-Rodríguez P., Haut J. M. PyCircularStats: a Python-based tool for remote sensing circular statistics and graphical analysis. *IGARSS 2022 -- 2022 IEEE International Geoscience and Remote Sensing Symposium*. Kuala Lumpur, Malaysia. 2022. P. 2876–2879. DOI: 10.1109/IGARSS46834.2022.9884758
11. Camacho J., Wasielewska K., Bro R., Kotz D. Interpretable feature learning in multivariate big data analysis for network monitoring. *IEEE Transactions on Network and Service Management*. Vol. 21. No. 3. 2024. P. 2926–2943. DOI: 10.1109/TNSM.2024.3368501
12. Wang Q., Mazor T., Harbig T. A., Cerami E., Gehlenborg N. ThreadStates: state-based visual analysis of disease progression. *IEEE Transactions on Visualization and Computer Graphics*. Vol. 28. No. 1. 2022. P. 238–247. DOI: 10.1109/TVCG.2021.3114840
13. Baes M., Herrera C., Neufeld A., Ruysen P. Low-rank plus sparse decomposition of covariance matrices using neural network parametrization. *IEEE Transactions on Neural Networks and Learning Systems*. Vol. 34. No. 1. 2023. P. 171–185. DOI: 10.1109/TNNLS.2021.3091598
14. Burgueño-Romero A. M., Benítez-Hidalgo A., Barba-González C., Aldana-Montes J. F. Towards an open-source MLOps architecture. *IEEE Software*. 2024. DOI: 10.1109/MS.2024.3421675
15. Muralikrishna B. S. R. Clinical diagnosis of Alzheimer's disease employing support vector machine. *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*. Ballari, India. 2022. P. 1–5. DOI: 10.1109/ICDCECE53908.2022.9792897
16. Ghorbani R., Ghousi R., Makui A., Atashi A. A new hybrid predictive model to predict the early mortality risk in intensive care units on a highly imbalanced dataset. *IEEE Access*. Vol. 8. 2020. P. 141066–141079. DOI: 10.1109/ACCESS.2020.3013320
17. Charitha C., Devi Chaitrasree A., Varma P. C., Lakshmi C. Type-II diabetes prediction using machine learning algorithms. *2022 International Conference on Computer Communication and Informatics (ICCCI)*. Coimbatore, India. 2022. P. 1–5. DOI: 10.1109/ICCCI54379.2022.9740844
18. Bezruk V. M., Krivenko S. A., Kyrsanov O. O., Kryvenko S. S., Kryvenko L. S. Training the machine learning model for clinical IoT data and device interoperability. *2023 12th Mediterranean Conference on Embedded Computing (MECO)*. Budva, Montenegro. 2023. P. 1–6. DOI: 10.1109/MECO58584.2023.10154963
19. Smith M. L., Kwembe T. A. Application of machine learning classifiers interfacing Google Colab and Sklearn to intrusion detection CSE-CIC-IDS2018 dataset. *2023 Congress in Computer Science, Computer Engineering, & Applied Computing (CSCE)*. Las Vegas, NV, USA. 2023. P. 1884–1890. DOI: 10.1109/CSCE60160.2023.00311
20. McClish D. K. Analyzing a portion of the ROC curve. *Medical Decision Making*. Vol. 9. No. 3. 1989. P. 190–195. DOI: 10.1177/0272989X8900900307

## References

1. Kyrsanov, O., Kryvenko, S. (2024), "Feature construction for machine learning application in clinical data processing" ["Konstruivannja oznak dlja zastosuvannja navchannja mashyn pry obrobcu klinichnyx danux"], *ICTEE.2024*, Vol. 4, No. 2, P. 162–171. DOI: <https://doi.org/10.23939/ictee2024.02.162>
2. Dua, D., Graff, C. (2019), "*UCI Machine Learning Repository*, University of California, School of Information and Computer Science", Irvine, CA, available at: <http://archive.ics.uci.edu/ml> (last accessed 07.11.2024)
3. Cortez, P., Cerdeira, A., Almeida, F., Matos, T., Reis, J. (2009), "Modeling wine preferences by data mining from physicochemical properties", *Decision Support Systems*, Vol. 47, No. 4, P. 547–553. DOI: 10.1016/j.dss.2009.05.016
4. Bhatlawande, S., Srivastava, S., Shilaskar, S. (2023), "Information extraction from digital receipts and bank transactions using machine learning", *2023 International Conference on Integration of Computational Intelligent System (ICICIS)*, Pune, India, P. 1–5. DOI: 10.1109/ICICIS56802.2023.10430289
5. Wu, Z., Pulido, V. (2022), "Statistical analyses for fantasy sports", *2022 IEEE Integrated STEM Education Conference (ISEC)*, Princeton, NJ, USA, P. 269–269. DOI: 10.1109/ISEC54952.2022.10025111
6. Fu, W., Widagdo, T. E. (2022), "SQL interface development for spatial data retrieval on Cassandra", *2022 International Conference on Data and Software Engineering (ICoDSE)*, Denpasar, Indonesia, P. 138–143. DOI: 10.1109/ICoDSE56892.2022.9971942
7. Chatziantoniou, D., Kantere, V., Antoniou, N., Gantzia, A. (2022), "Data virtual machines: simplifying data sharing, exploration & querying in big data environments", *2022 IEEE International Conference on Big Data (Big Data)*, Osaka, Japan, P. 373–380. DOI: 10.1109/BigData55660.2022.10020508
8. Geetha, V., Sujatha, N. (2024), "An overview of descriptive analytics and data visualization", *2024 5th International Conference on Smart Electronics and Communication (ICOSEC)*, Trichy, India, P. 1158–1163. DOI: 10.1109/ICOSEC61587.2024.10722273
9. Du, B., Deng, F. (2022), "The method of network intrusion detection based on descriptive statistics model and Logistic model", *2022 International Conference on Machine Learning and Knowledge Engineering (MLKE)*, Guilin, China, P. 160–163. DOI: 10.1109/MLKE55170.2022.00037
10. Cuartero, A., Paoletti, M. E., García-Rodríguez, P., Haut, J. M. (2022), "PyCircularStats: a Python-based tool for remote sensing circular statistics and graphical analysis", *IGARSS 2022 – 2022 IEEE International Geoscience and Remote Sensing Symposium*, Kuala Lumpur, Malaysia, P. 2876–2879. DOI: 10.1109/IGARSS46834.2022.9884758
11. Camacho, J., Wasielewska, K., Bro, R., Kotz, D. (2024), "Interpretable feature learning in multivariate big data analysis for network monitoring", *IEEE Transactions on Network and Service Management*, Vol. 21, No. 3, P. 2926–2943. DOI: 10.1109/TNSM.2024.3368501
12. Wang, Q., Mazor, T., Harbig, T. A., Cerami, E., Gehlenborg, N. (2022), "ThreadStates: state-based visual analysis of disease progression", *IEEE Transactions on Visualization and Computer Graphics*, Vol. 28, No. 1, P. 238–247. DOI: 10.1109/TVCG.2021.3114840
13. Baes, M., Herrera, C., Neufeld, A., Ruyssen, P. (2023), "Low-rank plus sparse decomposition of covariance matrices using neural network parametrization", *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 34, No. 1, P. 171–185. DOI: 10.1109/TNNLS.2021.3091598
14. Burgueño-Romero, A. M., Benítez-Hidalgo, A., Barba-González, C., Aldana-Montes, J. F. (2024), "Towards an open-source MLOps architecture", *IEEE Software*, DOI: 10.1109/MS.2024.3421675
15. Muralikrishna, B. S. R. (2022), "Clinical diagnosis of Alzheimer's disease employing support vector machine", *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*, Ballari, India, P. 1–5. DOI: 10.1109/ICDCECE53908.2022.9792897
16. Ghorbani, R., Ghousi, R., Makui, A., Atashi, A. (2020), "A new hybrid predictive model to predict the early mortality risk in intensive care units on a highly imbalanced dataset", *IEEE Access*, Vol. 8, P. 141066–141079. DOI: 10.1109/ACCESS.2020.3013320
17. Charitha, C., Devi Chaitrasree, A., Varma, P. C., Lakshmi, C. (2022), "Type-II diabetes prediction using machine learning algorithms", *2022 International Conference on Computer Communication and Informatics (ICCCI)*, Coimbatore, India, P. 1–5. DOI: 10.1109/ICCCI54379.2022.9740844
18. Bezruk, V. M., Krivenko, S. A., Kyrsanov, O. O., Kryvenko, S. S., Kryvenko, L. S. (2023), "Training the machine learning model for clinical IoT data and device interoperability", *2023 12th Mediterranean Conference on Embedded Computing (MECO)*, Budva, Montenegro, P. 1–6. DOI: 10.1109/MECO58584.2023.10154963
19. Smith, M. L., Kwembe, T. A. (2023), "Application of machine learning classifiers interfacing Google Colab and Sklearn to intrusion detection CSE-CIC-IDS2018 dataset", *2023 Congress in Computer Science, Computer Engineering, & Applied Computing (CSCE)*, Las Vegas, NV, USA, P. 1884–1890. DOI: 10.1109/CSCE60160.2023.00311
20. McClish, D. K. (1989), "Analyzing a portion of the ROC curve", *Medical Decision Making*, Vol. 9, No. 3, P. 190–195. DOI: 10.1177/0272989X8900900307

*Відомості про авторів / About the Authors*

**Кирсанов Олександр Олександрович** – Харківський національний університет радіоелектроніки, аспірант кафедри інформаційно-мережної інженерії, Харків, Україна; e-mail: [oleksandr.kyrsanov@nure.ua](mailto:oleksandr.kyrsanov@nure.ua); ORCID ID: <https://orcid.org/0009-0001-5987-4728>

**Кривенко Станіслав Анатолійович** – кандидат технічних наук, доцент, Харківський національний університет радіоелектроніки, доцент кафедри інформаційно-мережної інженерії, Харків, Україна; e-mail: [stanislav.kryvenko@nure](mailto:stanislav.kryvenko@nure); ORCID ID: <https://orcid.org/0000-0002-5244-1276>

**Kyrsanov Oleksandr** – Kharkiv National University of Radio Electronics, Postgraduate Student at the Department of Information and Network Engineering, Kharkiv, Ukraine.

**Kryvenko Stanislav** – PhD (Engineering Sciences), Associate Professor, Kharkiv National University of Radio Electronics, Associate Professor at the Department of Information and Network Engineering, Kharkiv, Ukraine.

## MACHINE LEARNING MODEL FOR PREDICTING SUBSTANCE PROPERTIES BASED ON ITS PHYSICOCHEMICAL PROPERTIES

**Subject matter.** The article focuses on extending previous binary classification results to multi-class classification using an ML model to analyze substance properties based on physicochemical characteristics. **Goal.** The primary objective is to develop a new ML model and metrics to compare different models' analysis quality, particularly in predicting wine quality from its composition. **Tasks** are data preparation, model development, training, tuning, evaluation, deployment, and monitoring. **Methods.** The study uses AWS SageMaker for data preparation, model development, training, tuning, evaluation, deployment, and monitoring, with data processed using Jupyter notebooks and pandas. **Results.** Data Analysis: The analysis includes descriptive statistics, correlation matrices, and visualizations like histograms and scatter plots to understand data relationships and quality. Model Training and Evaluation: The models were trained using XGBoost, with data split into training, validation, and testing sets, and evaluated using confusion matrices and AUC-ROC metrics. Confusion Matrix Analysis: Confusion matrices for two models showed mixed results, highlighting the challenge of comparing model performance and the need for further research on unbalanced classes. Hyperparameter Tuning: Amazon SageMaker's automatic hyperparameter tuning was used to optimize model performance, employing Bayesian optimization and Gaussian process regression. ROC-AUC Metrics: The study utilized ROC-AUC metrics to evaluate model performance, with micro-averaging and macro-averaging approaches showing different AUC values for the two models. Key Findings: The second model showed slightly better performance based on AUC metrics, but confusion matrix analysis suggested the need for models tailored to unbalanced classes. **Conclusions.** The research successfully developed a new ML model for multi-class classification, demonstrating its potential for improving wine quality prediction and suggesting future research directions.

**Keywords:** ML model; cloud; Confusion Matrix Analysis; predicted quality; actual quality; ROC-AUC; data; parameters; averaging.

*Бібліографічні описи / Bibliographic descriptions*

Кирсанов О. О., Кривенко С. А. Модель ML для аналізу властивостей речовини на основі її фізико-хімічних особливостей. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 151–165. DOI: <https://doi.org/10.30837/2522-9818.2025.1.151>

Kyrsanov, O., Kryvenko, S. (2025), "Machine learning model for predicting substance properties based on its physicochemical properties", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 151–165. DOI: <https://doi.org/10.30837/2522-9818.2025.1.151>

І. НЕВЛЮДОВ, С. НОВОСЕЛОВ, О. СИЧОВА

## МЕТОД ДЕЦЕНТРАЛІЗОВАНОГО УПРАВЛІННЯ ТЕХНОЛОГІЧНИМИ ПРОЦЕСАМИ НА ІНТЕЛЕКТУАЛЬНОМУ ВИРОБНИЦТВІ

Технологія цифрових двійників передбачає створення віртуальної моделі фізичного об'єкта, процесу або системи, яка може бути використана для моделювання, моніторингу, тестування та прогнозування можливого розвитку подій на основі інформації від розподіленої мережі сенсорів технологічного обладнання. Упровадження цифрових двійників у систему автоматизованого управління технологічними процесами дасть змогу підвищити ефективність виробничих процесів на інтелектуальних виробництвах. **Предметом дослідження** є архітектура автоматизованої системи управління технологічними процесами (АСУ ТП) на інтелектуальному заводі з інтеграцією технології промислового Інтернету речей та цифрового двійника виробничого процесу. **Мета роботи** – вдосконалення методів децентралізованого управління ТП для підвищення ефективності виробничого процесу на інтелектуальному виробництві за допомогою інтеграції цифрових двійників в АСУ. **Завдання:** розробити архітектуру розподіленої АСУ ТП на інтелектуальному заводі з інтеграцією технології промислового Інтернету речей та цифрового двійника виробничого процесу; проаналізувати поняття "цифровий двійник" у контексті поєднання цієї технології з процесами сталого розвитку й трансформації виробничої галузі; дослідити запропонований метод інтеграції цифрового двійника в задачу управління ТП. У процесі досліджень упроваджено такі **методи:** комп'ютерне моделювання, теорія автоматичного управління, аналіз і синтез децентралізованих виробничих систем. Досягнуто таких **результатів:** розроблено архітектуру автоматизованої системи з використанням цифрового двійника як еталона, що описує ідеальний розвиток процесу керування об'єктом автоматизації із застосуванням цифрового ПД-регулятора. Результати моделювання продемонстрували, що фізичний макет досить точно відтворює поведінку математичної моделі ПД-регулятора із заданими параметрами. **Висновки.** Результати експериментального дослідження показали, що інтеграція цифрових двійників в АСУ дає змогу вдосконалити методи децентралізованого управління ТП та підвищити ефективність виробничого процесу на інтелектуальному виробництві. Успішне впровадження технології цифрових двійників у інтелектуальне виробництво в поєднанні з хмарними обчисленнями та машинним навчанням спрямоване на досягнення цілей сталого розвитку.

**Ключові слова:** промисловість; інновації; *Industry 5.0*; Інтернет речей; інтелектуальне виробництво; цифровий двійник.

### Вступ

Інтелектуальне виробництво поєднує передові технології автоматизованого управління технологічними процесами (ТП), інформаційні мережі та технології, роботизовані засоби й системи, технології організації зв'язку та передавання даних, технології захисту інформації від кібератак, технології доповненої та віртуальної реальності, технології збирання та оброблення великих даних, технології 3D-друку та швидкого прототипування, інтелектуальні логістичні системи та планування маршрутів [1–3]. Особливу роль у цьому переліку відіграють цифрові двійники (рис. 1).

Цифрові двійники в інтелектуальному виробництві використовують для розв'язання значної кількості завдань: моніторингу стану технологічного процесу; моделювання та оптимізації виробничого процесу; оптимізації технологічного процесу та прогнозування його стану для запобігання відмовам обладнання; підвищення ефективності та якості виробництва [4, 5].

Також цифровий двійник можна застосовувати для оптимізації роботи кіберфізичної системи за допомогою моделювання її поведінки та виявлення сфер, де можна використати запропоновані ним вдосконалення [5].

Для застосування цифрових двійників потрібно розв'язувати комплекс завдань: отримання даних від кіберфізичної системи; зберігання та оброблення отриманих даних; виконання обчислень відповідно до математичної моделі системи або процесу, що моделюється. На рис. 2 подано схему, що пояснює принцип інтеграції цифрових двійників у децентралізовану автоматизовану систему управління технологічними процесами на інтелектуальному виробництві [6].

Для інтеграції цифрових двійників у автоматизовану систему управління технологічними процесами на інтелектуальному виробництві необхідно забезпечити цифровий простір потрібною інформацією. Завдяки застосуванню концепції *Industry 4.0* на сучасному

виробництві можна отримати доступ до кожного датчика та виконавчого пристрою безпосередньо з хмарного середовища [7]. Промисловий Інтернет речей (IIoT) – це концепція, яка ґрунтується на інтеграції виконавчих пристроїв, механізмів верстатів із ЧПК, що становлять основу виробничого

простору з мережевими датчиками, технологією передачі даних та програмним забезпеченням [8]. Інтернет-технології разом з промисловими мережами та протоколами слугують каналом, яким проходить інформація і завдяки якому пов'язуються між собою об'єкти на інтелектуальному заводі [9].



Рис. 1. Технології на інтелектуальному виробництві

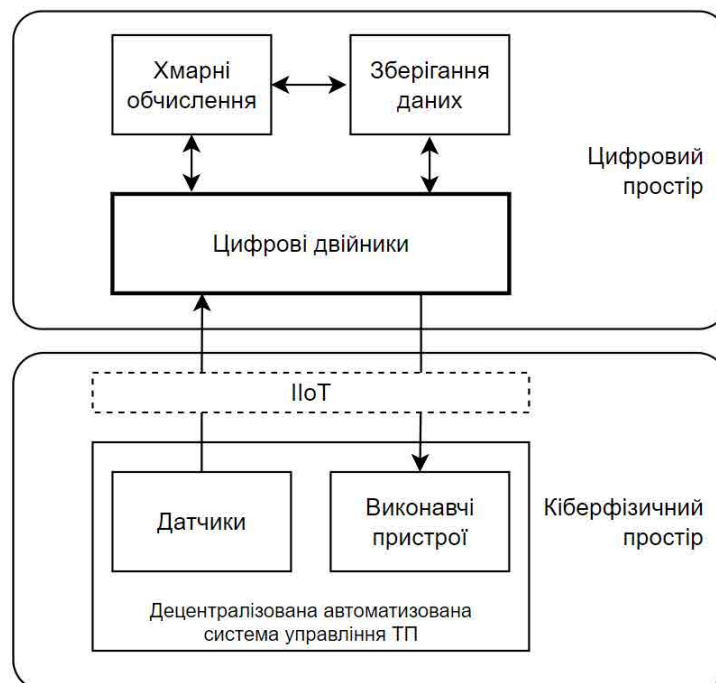


Рис. 2. Інтеграція цифрових двійників у децентралізовану автоматизовану систему управління технологічними процесами на інтелектуальному виробництві

IIoT керується комп'ютерними науками як розширення концепції Інтернету речей (IoT). Він оснований на стандартах сенсорних

і розподілених мереж. Кіберфізичні системи ґрунтуються на інженерних аспектах і фізичних системах реального світу, що становлять основу технологічного процесу сучасного виробництва, часто в системі замкнутого циклу управління.

*Актуальність дослідження* полягає в необхідності підвищення ефективності процесів інтелектуальних виробництв за допомогою впровадження цифрових двійників у систему автоматизованого управління технологічними процесами. Використання технології промислового Інтернету речей в інтеграції із сучасними технологіями зв'язку та оброблення великих даних у хмарному середовищі дає змогу впровадити розподілену систему управління інтелектуальним заводом відповідно до концепції *Industry 4.0* та *Industry 5.0*.

Технологія цифрових двійників – це новітній підхід, що передбачає створення віртуальної моделі фізичного об'єкта, процесу або системи, яка може бути використана для моделювання, моніторингу, тестування та прогнозування можливого розвитку подій на основі інформації від розподіленої мережі сенсорів технологічного обладнання.

Успішне впровадження технології цифрових двійників у інтелектуальне виробництво в поєднанні з хмарними обчисленнями та машинним навчанням спрямоване на досягнення цілей сталого розвитку, що наближає галузь індустрії до людини, щоб задовольнити потреби сучасних поколінь без шкоди для майбутніх поколінь [10].

*Об'єкт дослідження* – децентралізоване управління виробничими процесами на інтелектуальному виробництві. *Предмет дослідження* – архітектура розподіленої автоматизованої системи управління технологічним процесом на інтелектуальному заводі з інтеграцією технології промислового Інтернету речей та цифрового двійника виробничого процесу.

*Метою дослідження* є вдосконалення методів децентралізованого управління технологічними процесами для підвищення ефективності виробничого процесу на інтелектуальному виробництві внаслідок інтеграції цифрових двійників в автоматизовану систему управління.

---

#### Аналіз останніх досліджень і публікацій

Автори роботи [9] визначають, що особливістю взаємодії між технічними засобами автоматизації сучасного виробництва в межах концепцій

*Industry 4.0* та *Industry 5.0* є злиття цифрових і фізичних процесів. Переваги, що випливають з цифровізації та технологій, пов'язаних з *Big Data*, можуть бути успішно використані в промислових середовищах лише за умови поєднання подання фізичних об'єктів та засобів генерації даних – розумних датчиків та технології промислового Інтернету речей. Одним із підходів до отримання такого подання фізичних об'єктів у вигляді цифрового двійника є моделювання та оцифрування процесів, що виникають в кіберфізичних виробничих системах (CPPS).

У роботі [6] автори пропонують поняття цифрового двійника, віртуальної симуляції фізичної системи або процесу, що використовується для моніторингу, контролю та оптимізації його реального аналога. У контексті розумного виробництва цифровий двійник застосовується для створення віртуального подання заводу або виробничої лінії, що дає змогу виробникам моделювати та оптимізувати свої виробничі процеси, виявляти потенційні проблеми й можливості для вдосконалення, а також приймати обґрунтовані рішення щодо планування виробництва та розподілу ресурсів.

Цифровий двійник для інтелектуального виробництва зазвичай передбачає використання датчиків та інших інструментів для збору даних у режимі реального часу про фізичну систему або процес, такі як продуктивність машини, температура, тиск та інші параметри [6]. Потім ця інформація подається в цифрову модель, що моделює поведінку фізичної системи та дає змогу виробникам візуалізувати й аналізувати їхню роботу в режимі реального часу.

У праці [11] розглянуто цифрові двійники, які є основною концепцією в автоматизованих системах управління технологічними процесами та відіграють ключову роль в реалізації структури інтелектуального заводу. Автори показали, що за допомогою цифрових двійників можна отримати цифрові копії фізичних систем для того, щоб вони відтворювали внутрішню поведінку реальних систем. У роботі показано, що синхронізація необхідна з метою підтримання відповідності стану цифрових двійників і стану їх фізичних аналогів. Автори розглянули три різні архітектури для цифрових двійників, а також дослідили їх здатність стежити за поведінкою фізичної системи.

У статті [12] визначено концепцію цифрових двійників, показано еволюцію та розвиток цифрових

---



двійників, розглянуто їх базові характеристики, визначено роль IoT як опори цифрових двійників, досліджено тенденції розвитку цифрових двійників і методи їх застосування у виробничому процесі у впровадженні концепції *Industry 4.0*. Автори дають визначення концепції *Industry 5.0* як розвитку передових технологій цифровізації та технологій на основі штучного інтелекту з метою підвищення ефективності та адаптивності виробництва до принципів соціальної справедливості та сталого розвитку.

*Industry 4.0* пропонує потенціал для підвищення гнучкості та ефективності виробництва, зниження витрат на вихід штучної продукції та збільшення конкурентних переваг виробничих потужностей [13]. У цій роботі показано, що сучасні тенденції до *Industry 5.0* є додатковим поглядом, спрямованим на сталий розвиток індустрії, що орієнтована на людину. Концепція *Industry 5.0* є ще більш комплексною стратегією в галузі науки, технологій та інновацій, забезпечуючи водночас ефективне реагування на зростання економічних, технологічних і соціальних викликів [14].

Цифрові двійники перебувають в авангарді промислової революції та концепції *Industry 4.0/5.0*, чому сприяють розширені підходи до аналітики даних та інтеграція з промисловим Інтернетом речей [14, 15]. Багате даними середовище IoT у поєднанні з аналітикою великих даних забезпечує необхідний ресурс для розв'язання різних проблем на рівні цифро-фізичного інтерфейсу, зокрема прогнозоване обслуговування та вчасне виявлення небезпечних ситуацій на інтелектуальному виробництві [13].

### **Інтеграція цифрових двійників у автоматизовану систему управління технологічними процесами**

*Цифровий двійник* – це цифрове подання фізичної системи або процесу, за допомогою якого можна виконувати моніторинг стану ТП, аналіз та оптимізацію виробництва в режимі реального часу [6].

Цифровий двійник дає змогу забезпечити точне подання фізичного об'єкта або системи в цифровому середовищі, зважаючи на його поведінку, продуктивність і взаємодію з навколишнім середовищем кіберфізичної системи [16].

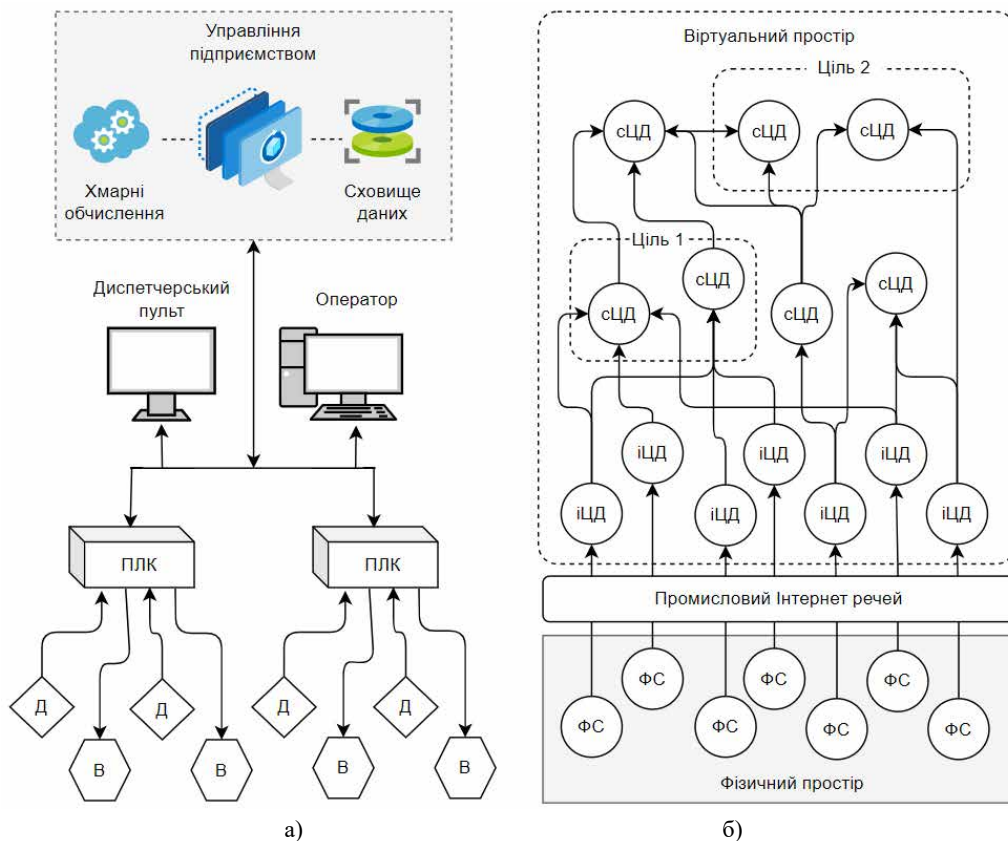
Для виконання цього завдання цифрові двійники використовують машинне навчання, технологію оброблення великих даних, математичні моделі та засоби моделювання для того, щоб відтворити та проаналізувати різні умови роботи обладнання, поведінку процесу та інші фактори, що впливають на протікання виробничих процесів на інтелектуальному виробництві.

Аналізуючи дані з фізичного об'єкта в реальному часі, цифровий двійник може виконувати обчислення відповідно до математичної моделі та надавати зворотний зв'язок у вигляді очікуваних даних для порівняння їх з тими, що отримані від датчиків реального обладнання. Це дає змогу контролювати ефективність і продуктивність виробничого процесу, виявляти потенційні проблеми на різних етапах технологічного процесу, ще до того, як вони можуть виникнути.

Розподілена система управління – це спеціально розроблена децентралізована система, яка використовується для управління складними, великими та територіально розподіленими застосунками в промислових процесах. У цьому разі контролери розподілені по всій площі заводу (рис. 3, а).

Пристрої польового рівня, такі як датчики (Д) та виконавчі пристрої (В) (рис. 3, а), безпосередньо під'єднуються до модулів контролера входу та виходу через шину зв'язку. Ці польові пристрої або розумні прилади здатні обмінюватися даними з програмованими логічними контролерами (ПЛК) або іншими контролерами, взаємодіючи з реальними параметрами, такими як температура, тиск тощо. Контролери територіально розподілені по різній ділянці диспетчерської зони й під'єднані до діючих та інженерних станцій, які використовуються для моніторингу й реєстрації даних, сигналізації та управління по іншій шині високошвидкісного зв'язку.

Децентралізована система управління з використанням цифрових двійників зображена на рис. 3, б [17]. У цій архітектурі промисловий простір поділяється на два основні сегменти: фізичний простір та віртуальний простір. Фізичний простір містить фізичні сутності (ФС), тоді як віртуальний простір є цифровим середовищем, де реалізовані цифрові двійники. Інтерфейс між ними організують промислові комунікаційні шлюзи, здатні обробляти різні промислові протоколи (наприклад, *OPC-UA*, *Modbus* і *MQTT*).



**Рис. 3.** Запропонована архітектура розподіленої АСУ ТП на інтелектуальному заводі:

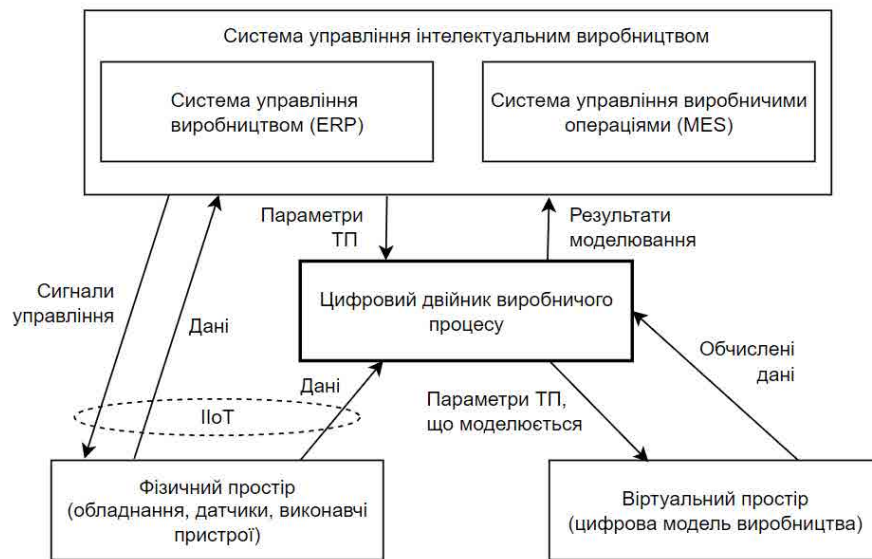
- архітектура розподіленої системи управління виробничим процесом;
- децентралізована система управління з використанням цифрових двійників

У віртуальному просторі набір основних компонентів відіграє важливу роль в організації безшовного об'єднання та нагляду за цифровими двійниками й пов'язаними з ними послугами. Ґрунтуючись на принципах сервіс-орієнтованої архітектури (SOA) та мікросервісів, ці компоненти забезпечують гнучку систему, що задовольняє складні потреби сучасного промислового середовища [17]. Реєстр цифрових двійників (РЦД) слугує репозиторієм, що сприяє ефективній каталогізації цифрових двійників та їх відповідних служб у межах архітектури. Він дотримується принципів SOA, сприяючи слабким зв'язкам між цифровими двійниками та послугами, унаслідок чого здійснюється компонування цілеспрямованих цифрових двійників. РЦД розширює концепцію реєстру послуг у SOA, не лише керуючи кінцевими точками служби, але й інкапсулюючи детальну інформацію про цифрових двійників, що сприяє ефективному виявленню та управлінню у віртуальному просторі.

На рис. 3, б запропоновано такі позначки: індивідуальний цифровий двійник (іЦД) і складений

цифровий двійник (сЦД). Індивідуальні цифрові двійники адаптовані для індивідуального відтворення окремих фізичних сутностей у відповідні цифрові аналоги. Охоплюючи сутність окремих фізичних сутностей, іЦД формують основу для створення промислового ландшафту, орієнтованого на програмне забезпечення. Складені цифрові двійники, на відміну від сЦД, створюються зі складу кількох іЦД. Ці структури використовують стратегію відношення "багато до багатьох", об'єднуючи кілька іЦД для створення всеосяжного та багатогранного цифрового подання. Вони слугують конкретним цілеспрямованим рішенням, реалізуючи спільну роботу різноманітних промислових елементів. Наприклад, сЦД може подавати цілу виробничу лінію за допомогою об'єднання іЦД складників технічних засобів автоматизації, датчиків і систем управління.

На рис. 4 подано запропоновану архітектуру автоматизованої системи управління технологічним процесом на інтелектуальному заводі з інтеграцією технології промислового Інтернету речей та цифрового двійника виробничого процесу.



**Рис. 4.** Запропонована архітектура автоматизованої системи управління технологічним процесом на інтелектуальному заводі з інтеграцією технології промислового Інтернету речей та цифрового двійника виробничого процесу

Запропонована архітектура інтеграції цифрових двійників у автоматизовану систему управління технологічними процесами містить такі компоненти:

- система управління інтелектуальним виробництвом, складниками якої є система управління ресурсами підприємства (ERP) та система управління виробничими операціями (MES);
- обладнання, датчики, виконавчі пристрої та інші технічні засоби автоматизації, що становлять фізичний простір;
- цифровий двійник виробничого процесу;
- цифрова модель виробництва, що становить віртуальний простір;
- сенсорні мережі та технології передавання даних, що належать до промислового Інтернету речей [18].

Фізичний простір генерує великий набір даних, що відтворюють поточний стан виробничого процесу. За допомогою технології промислового Інтернету речей створюється розподілена мережа датчиків і виконавчих пристроїв. Інформація збирається та передається в режимі реального часу, використовуючи комунікаційні протоколи та інтерфейси *Ethernet*, *Wi-Fi*, *LoRa*, *NB-IoT*, *5G*, *Bluetooth* тощо [19, 20].

Зібрані дані потрапляють як безпосередньо в систему управління інтелектуальним виробництвом, так і до цифрового двійника виробничого процесу. Основна мета системи управління інтелектуальним виробництвом полягає в досягненні максимальної автоматизації процесів, мінімізації втручання людини та забезпеченні можливості реагування на зміни

у виробничому середовищі з мінімальними затратами часу й ресурсів.

Для ефективного управління виробничим процесом загальна система інтегрується з іншими інформаційними системами, такими як система управління ресурсами підприємства (ERP) та система управління виробництвом (MES). Така інтеграція дає змогу з'єднати бізнес-процеси з виробничими, забезпечуючи безперервний обмін інформацією про запаси, ресурси, замовлення та інші ключові показники діяльності підприємства.

Запропонована архітектура передбачає застосування цифрового двійника як додаткового компонента загальної системи управління виробничим процесом. Цифровий двійник отримує таку саму інформацію від датчиків, що й загальна система, накопичує та обробляє її відповідно до математичної моделі цього процесу [21]. Для виконання обчислень, крім даних із датчиків, цифровий двійник отримує також і задані параметри технологічного процесу, що надаються системою управління.

Для моделювання поведінки технологічного процесу за умови різних вхідних параметрів використовується цифрова модель виробництва (віртуальний простір), що містить цифрові моделі обладнання, опис ланцюжків постачання сировини та перевезення заготівель між технологічним устаткуванням.

На основі симуляції виробничого процесу у віртуальному просторі генерується потік обчислених

даних, що є додатковою інформацією для цифрового двійника. У такий спосіб формуються результати моделювання, що передаються далі в систему управління інтелектуальним виробництвом.

Аналізуючи отримані дані з різних джерел, система управління порівнює результати обчислень із реальним станом технологічного процесу. На основі порівняння приймається рішення про вплив на виконавчі пристрої фізичного простору через розподілену мережу промислового Інтернету речей.

Отже, цифровий двійник відіграє роль ідеального виробничого середовища, з яким порівнюють стан фізичних процесів, що протікають на реальному

виробництві. Раннє виявлення проблем допомагає уникнути збоїв, здатних знизити якість виробництва. Завдяки інтегруванню цифрових двійників можна передбачити, коли виникне проблема та розв'язати питання технічного обслуговування обладнання до того, як воно вийде з ладу.

### Експериментальні дослідження

Для проведення експерименту інтеграції цифрового двійника в управління технологічними процесами використовується архітектура автоматизованої системи (рис. 5).

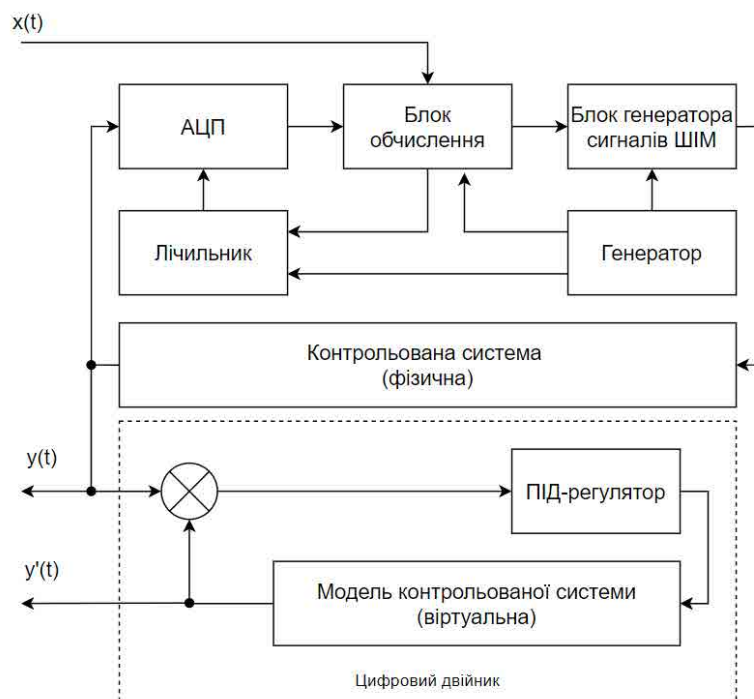


Рис. 5. Архітектура автоматизованої системи з використанням цифрового двійника

У цій автоматизованій системі виробляється два сигнали управління:

- $y(t)$  – сигнал на виході контрольованої системи;
- $y'(t)$  – сигнал на виході цифрового двійника контрольованої системи.

Зазначені два сигнали надходять на вхід глобальної системи управління виробничим процесом, як це зображено на рис. 4. На основі порівняння сигналів  $y(t)$  та  $y'(t)$  глобальна система управління приймає рішення про зміну режимів управління блока обчислень унаслідок зміни вхідного сигналу  $x(t)$ , що надходить від системи прийняття рішень.

Прикладом контрольованої системи може бути RC-ланцюг, що отримує на вхід сигнали ШІМ від блока обчислень та на виході формує напругу, пропорційну частоті ШІМ. Блок обчислень працює за принципом ПІД-регулятора. Залежно від параметрів налаштування ПІД-регулятора блок обчислень виробляє сигнали управління для блока ШІМ-генератора.

Замкнена система отримана внаслідок поєднання виходу RC-ланцюга з блоком аналого-цифрового перетворювача. Цей блок перетворює вхідну напругу в цифровий сигнал, щоб передати його на блок виконання обчислень. Лічильник потрібен для підрахунку імпульсів від генератора та управління АЦП.

Зовнішній вигляд макета для досліджень подано на рис. 6.




Рис. 6. Зовнішній вигляд макета для досліджень

Макет зібрано на основі *Arduino* (1), у який завантажено програмний цифровий ПІД-регулятор. Усі деталі макета поєднані за допомогою макетної

плати (4). Перша RC-ланка (2) реалізована на постійному резисторі з опором 1 кОм та змінному резисторі з опором 100 кОм, а також з використанням конденсатора ємністю 47 мкФ. Змінний резистор дає змогу змінювати параметри RC-ланки, змінюючи цим перехідну характеристику виконавчого елемента схеми. Друга RC-ланка (3) має схожу реалізацію, але постійний резистор має номінал 4,7 кОм. Змінний резистор і конденсатор мають такі самі номінали, що й у першій RC-ланці (2).

Функціональна схема макета на основі *Arduino Nano* зображена на рис. 7. RC-ланки під'єднані до виходу мікроконтролера, на якому реалізовано виведення ШІМ-сигналу. За структурною схемою це вихід  $u(t)$ . Вихід з RC-ланок, відповідно до функціональної схеми, – це вихід  $y(t)$ , він під'єднується до аналогового входу контролера під номером A0.

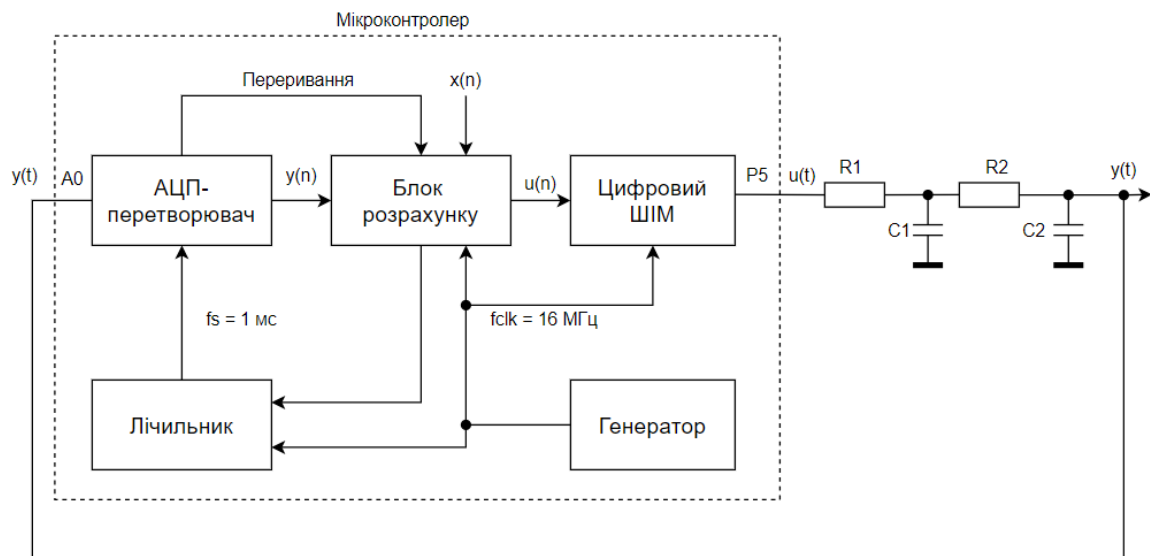


Рис. 7. Функціональна схема контролера

На рис. 8 подана загальна блок-схема системи автоматичного керування, що реалізована в макеті [22]. Система містить регулятор з передавальною функцією  $G(s)$ , об'єкт (об'єкт, керована система,

система) з передавальною функцією  $H(s)$  і вузла підсумовування, у якому задане значення  $X(s)$  порівнюється з вихідним сигналом  $Y(s)$  [11].




Рис. 8. Загальна блок-схема системи автоматичного керування, що реалізована в макеті

Для цієї системи управління можна записати таку систему рівнянь:

$$\begin{cases} Y(s) = E(s)G(s)H(s) \\ E(s) = X(s) - Y(s) \end{cases}, \quad (1)$$

де  $X(s)$  – бажане значення процесу або задане значення;  $E(s)$  – значення похибки як різниця між бажаним заданим значенням  $X(s)$  і вимірним значенням процесу  $Y(s)$ ,  $E(s) = X(s) - Y(s)$ ;  $G(s)$  – передатна функція регулятора;  $H(s)$  – передатна функція керованої системи (об'єкта);  $Y(s)$  – вимірне значення процесу;  $U(s)$  – контрольна змінна.

Із системи рівнянь (1) можна визначити передатну функцію замкненої системи керування

$$\frac{Y(s)}{X(s)} = \frac{G(s)H(s)}{1 + G(s)H(s)}. \quad (2)$$

Передатна функція аналогового ПІД-регулятора, що реалізована в макеті, визначається рівнянням

$$G(s) = \frac{U(s)}{E(s)} = k_c \left( 1 + \frac{1}{T_i s} + T_d s \right), \quad (3)$$

де  $k_c$  – підсилення регулятора, параметр налаштування;

$T_d$  – час похідної, параметр налаштування;

$T_i$  – інтегральний час, параметр налаштування.

Для ПІД-регулятора керуюче значення  $U(s)$  містить три члени:

–  $U_p(s)$  – пропорційний член;

$$U(z) = E(z)k_c + k_c \frac{T_s}{2T_i} (E(z) + E(z)z^{-1}) + U_i(z)z^{-1} + k_c \frac{T_d}{T_i} (E(z) - E(z)z^{-1}). \quad (6)$$

Тепер значення змінної цифрового керування можна розрахувати за допомогою різничевого рівняння

$$u(n) = k_c e(n) + k_c \frac{T_s}{2T_i} (e(n) + e(n+1)) + u_i(n-1) + k_c \frac{T_d}{T_i} (e(n) - e(n+1)). \quad (7)$$

Цифрова керуюча змінна  $u(n)$  перетворюється в аналогову форму цифро-аналоговим перетворювачем. У цьому разі ШІМ-модулятор також використовується як ЦАП [25].

Перед цифро-аналоговим перетворенням керуюча змінна  $u(n)$  має бути масштабована до діапазону ЦАП і приведена до цілого типу:

$$u_N(n) = (\text{int})((1 + u(n))0,5N_L), \quad (8)$$

–  $U_i(s)$  – інтегральний член;

–  $U_d(s)$  – диференційний член.

Отже, значення керуючої змінної ПІД-регулятора можна визначити за допомогою рівняння

$$U(s) = E(s)k_c + \frac{k_c}{T_i} \frac{1}{s} E(s) + k_c T_d E(s)s. \quad (4)$$

Інтегральний член (4) переводиться в цифрову форму за допомогою білінійного перетворення.  $Z$ -перетворення є цифровим аналогом безперервного перетворення Лапласа й використовується для аналізу дискретних систем. Після застосування білінійного перетворення зв'язок між змінною  $s$  (у домені Лапласа) і  $z$  (у домені  $z$ -перетворення) задається так:

$$s = \frac{T_s}{2} \frac{z+1}{z-1}, \quad (5)$$

де  $T_s$  – період вибірки;

$z$  – змінна в ділянці  $z$ -перетворення (для цифрових систем);

$s$  – змінна в ділянці Лапласа (для безперервних систем).

Цей перехід дає змогу перетворити безперервні передатні функції та рівняння регулятора на цифрові, щоб їх можна було використовувати в дискретних системах управління, таких як програмовані контролери або цифрові фільтри.

Унаслідок перетворення формула (4) матиме такий вигляд [23, 24]:

де  $N_L$  – кількість станів цифрового ШІМ-модулятора або цифро-аналогового перетворювача.

Діапазон змінної  $u_N(n)$  становить  $0 \dots N_L - 1$ .

Для моделювання динамічних об'єктів використовується послідовне увімкнення двох інтегрованих RC-ланок. На рис. 9 подано двоступеневий RC-ланцюг, що утворює керовану систему другого порядку.




Рис. 9. Послідовне увімкнення двох інтегрованих RC-ланок

Ця схема обмежена, оскільки її добротність  $Q$  завжди менша ніж 0,5, з  $R_1 = R_2$  і  $C_1 = C_2$ ,  $Q = 1/3$ . У цій схемі  $Q$  наближається до максимального значення  $1/2$ , коли опір другого каскаду RC набагато більший, ніж перший.

Передавальна функція RC-ланки може бути записана у вигляді

$$H(s) = \frac{1}{1 + s(R_1 C_1 + R_2 C_2 + R_1 C_2) + s^2 (R_1 C_1 R_2 C_2)}. \quad (9)$$

Для виконання моделювання встановимо такі параметри подвійної RC-ланки:

- $R_1 = 11,6$  кОм;

- $C_1 = 47$  мкФ;

- $R_2 = 9,4$  кОм;

- $C_2 = 47$  мкФ.

Отже, перехідна характеристика подвійної RC-ланки, відповідно до (9), після виконання арифметичних операцій запишеться у вигляді

$$H(s) = \frac{1}{1 + 1,53s + 0,24s^2}. \quad (10)$$

Виконаємо моделювання ПІД-регулятора за допомогою *Simulink*. Для цього побудуємо наступну структурну схему замкненої системи, як подано на рис. 10.

Після першого запуску симуляції роботи ПІД-контролера на виході осцилографа отримуємо графік  $y(t)$  (рис. 11). З поданого рисунка можна бачити, що система має властивості перерегулювання.

У процесі моделювання використовувались такі параметри:  $K_p = 2$ ;  $T_i = 3$ ;  $T_d = 0$ .





Рис. 10. Структурна схема модельованої системи

Рис. 11. Графік функції  $y(t)$ 

Наступним кроком виконаємо порівняння результатів роботи фізичного макета з програмною моделлю цифрового двійника. На рис. 12 подані значення коефіцієнтів регулятора.

```
const float Kc = 10.0; // controller gain
const float Ti = 3.0; // 2.5; // integral time
volatile float x = 0.6; // setpoint value, range 0...1
const float Td = 1.0; // derivative time
```

Рис. 12. Значення коефіцієнтів ПІД-регулятора

За наведеними параметрами отримуємо наступний графік  $y(t)$  (рис. 13).



Рис. 13. Графік  $y(t)$  ПІД-регулятора для першої спроби налаштування

З поданого графіка можна бачити ознаки перерегулювання, але зовнішній вигляд вихідного сигналу відповідає його цифровій моделі. Результати моделювання показали, що фізичний макет досить точно відтворює поведінку математичної моделі ПІД-регулятора із заданими параметрами.

### Висновки

У роботі запропоновано архітектуру розподіленої автоматизованої системи управління технологічним процесом на інтелектуальному підприємстві з інтеграцією технології промислового Інтернету речей та цифрового двійника виробничого процесу. Надано тлумачення поняття "цифровий двійник" у контексті поєднання цієї технології з процесами сталого розвитку та трансформації виробничої галузі.

Досліджено запропонований метод інтеграції цифрового двійника в управління технологічними процесами. Наведено архітектуру автоматизованої системи з використанням цифрового двійника як еталона, що описує розвиток процесу керування об'єктом автоматизації із застосуванням цифрового ПІД-регулятора.

У процесі моделювання структури автоматичної системи управління розглянуто реакцію кола інтегруючого типу на одиничний вхідний перепад із заданою амплітудою та залежність часу досягнення стійкості системи від параметрів ПІД-регулятора. Для реалізації цифрового ПІД-регулятора використано внутрішній 10-розрядний аналого-цифровий перетворювач для перетворення сигналу  $y(t)$ , а ШІМ-модулятор було застосовано як 8-розрядний цифро-аналоговий перетворювач для перетворення сигналу керуючої змінної. За результатами експерименту можна бачити ознаки перерегулювання, але зовнішній вигляд вихідного сигналу відповідає його цифровій моделі. Результати моделювання показали, що фізичний макет досить точно відтворює поведінку математичної моделі ПІД-регулятора із заданими параметрами.

Отже, інтеграція цифрових двійників у автоматизовану систему управління дасть змогу вдосконалити методи децентралізованого керування технологічними процесами та підвищити ефективність інтелектуального виробництва.



## Список літератури

1. Nevliudov I., Novoselov S., Sychova O. Decentralized information systems in intelligent manufacturing management tasks. *Advanced Information Systems*. 2024. Vol. 8, No. 3. P. 100–110. DOI: <https://doi.org/10.20998/2522-9052.2024.3.12>
2. Nevliudov I., Novoselov S., Sychova O. Control automation of assembly operations using a computer vision system in intelligent production. *Journal of natural sciences and technologies*. 2023. Vol. 2(2). P. 173–182. DOI: 10.5281/zenodo.8098567
3. Nevliudov I., Novoselov S., Sychova O. Modeling and practical implementation of the optimal wireless security gateway for the industrial automation network. *Serbian Journal of Electrical Engineering*. 2022. Vol. 19, No. 3. P. 303–327. DOI: <https://doi.org/10.2298/sjee2203303n>
4. Eckhart M., Ekelhart A. Digital twins for cyber-physical systems security: State of the art and outlook. *Security and Quality in CyberPhysical Systems Engineering*. Springer. 2019. P. 383–412. DOI: [https://doi.org/10.1007/978-3-030-25312-7\\_14](https://doi.org/10.1007/978-3-030-25312-7_14)
5. Soori M., Arezoo B., Dastres R. Digital twin for smart manufacturing, A review. *Sustainable Manufacturing and Service Economics*. 2023. Vol. 2. 100017 p. DOI: <https://doi.org/10.1016/j.smse.2023.100017>
6. Integration of Blockchain and Digital Twins in the Smart Built Environment Adopting Disruptive Technologies / H. Sadri et al. *A Systematic Review*. *Sustainability*, 2023. Vol. 15(4). 3713 p. DOI: <https://doi.org/10.3390/su15043713>
7. Goudarzi M., PAGER Sh., Buuya R. Cloud Computing and Internet of Things: Recent Trends and Directions. *New Frontiers in Cloud Computing and Internet of Things*. Internet of Things. Cham: Springer. 2022. DOI: [https://doi.org/10.1007/978-3-031-05528-7\\_1](https://doi.org/10.1007/978-3-031-05528-7_1)
8. Technopolis Group. URL: <https://www.technopolis-group.com/wp-content/uploads/2020/05/internet-of-things.pdf> (дата звернення: 16.02.2025).
9. Industrial Internet of Things / ed. by S. Jeschke et al. Cham: Springer International Publishing. 2017. DOI: 10.1007/978-3-319-42559-7
10. The 17 goals. *Sustainable Development*. URL: <https://sdgs.un.org/goals> (дата звернення: 18.02.2025).
11. Akbarian F., Fitzgerald E., Kihl M. Synchronization in Digital Twins for Industrial Control Systems. *Systems and Control*. 2020. URL: <https://arxiv.org/pdf/2006.03447> (дата звернення: 15.01.2025).
12. Attaran Sh., Attaran M., Celik B. Digital Twins and Industrial Internet of Things: Uncovering operational intelligence in industry 4.0. *Decision Analytics Journal*. 2024. Vol. 10. DOI: <https://doi.org/10.1016/j.dajour.2024.100398>
13. Digital Twins Approach for Sustainable Industry / L. Xu et al. *Lecture Notes in Business Information Processing*. 2022. P. 126–134. DOI: 10.1007/978-3-031-07478-3\_11
14. Industry 5.0. *Research and innovation*. URL: [https://research-and-innovation.ec.europa.eu/research-area/industrial-research-and-innovation/industry-50\\_en](https://research-and-innovation.ec.europa.eu/research-area/industrial-research-and-innovation/industry-50_en) (дата звернення: 18.02.2025).
15. Timperi M., Kokkonen K., Hannola L. Digital twins for environmentally sustainable and circular manufacturing sector: visions from industry professionals. *Production & Manufacturing Research*. 2024. Vol. 12(1). DOI:10.1080/21693277.2024.2428249
16. Невлюдов І. Ш., Новоселов С. П., Сичова О. В. Застосування цифрових двійників технічних засобів автоматизації для розроблення програмно-технічних комплексів АСУ ТП: Навчальний посібник. Харків: Видавництво Іванченка І. С., 2023. 267 с. ISBN 978-617-8059-95-8. DOI: 10.30837/978-617-8059-95-8
17. Distributed Digital Twins as Proxies – Unlocking Composability & Flexibility for Purpose-Oriented Digital Twins / A. Aziz et al. *IEEE Access*. 2023. P. 1-17. DOI:10.1109/ACCESS.2023.3340132
18. Novoselov S. Wireless Sensor Network for Communication Between Base Stations in the Local Positioning System. *International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*. 2018, P. 383–386, DOI: 10.1109/INFOCOMMST.2018.8632140
19. Leite J., Martins P., Ursini E. Internet of Things: An Overview of Architecture, Models, Technologies, Protocols and Applications. *Emerging Trends and Challenges in Technology*. 2019. DOI: 10.1007/978-3-319-93112-8\_8
20. New Technological Waves Emerging in Digital Transformation: Internet of Things IoT/IoE, 5G/6G Mobile Networks and Industries 4.0/5.0. / L. Emiliano et al. *Smart Innovation*. 2023. P. 329–339. DOI: 10.1007/978-3-031-31007-2\_30
21. Nevliudov I., Novoselov S., Sychova O. Modeling of a Decentralized System for Maintenance of Production Equipment Based on Transport Robots. *IEEE 5th International Conference on Modern Electrical and Energy System (MEES)*. 2023. P. 1–6. DOI: 10.1109/MEES61502.2023.10402485
22. Enhancing Industrial Process Control: Integrating Intelligent Digital Twin Technology with Proportional-Integral-Derivative Regulators / A. Dapkute et al. *Machines*. 2024. Vol. 12(5), No 319. DOI: <https://doi.org/10.3390/machines12050319>
23. Sozański K. Low Cost PID Controller for Student Digital Control Laboratory Based on Arduino or STM32 Modules. *Electronics*. 2023. Vol 12, No. 3235. DOI: <https://doi.org/10.3390/electronics12153235>
24. Astrom K. J., Wittenmark B. Computer Controlled System, Theory and Design. Electronics and Power. 2013. ISBN: 0131643193. URL: [https://www.academia.edu/37044747/Computer\\_Controlled\\_Systems\\_Astrom\\_3rdEdition](https://www.academia.edu/37044747/Computer_Controlled_Systems_Astrom_3rdEdition)
25. Ibrahim D. PID-based Practical Digital Control with Raspberry Pi and Arduino Uno. Elektor International Media B.V. 2022. 238 p. ISBN: 978-3-89576-520-9.

## References

1. Nevliudov, I., Novoselov, S., Sychova, O. (2024), "Decentralized information systems in intelligent manufacturing management tasks", *Advanced Information Systems*, Vol. 8, No. 3, P. 100–110. DOI: <https://doi.org/10.20998/2522-9052.2024.3.12>
2. Nevliudov, I., Novoselov, S., Sychova, O. (2023), "Control automation of assembly operations using a computer vision system in intelligent production", *Journal of natural sciences and technologies*, Vol. 2(2), P. 173–182. DOI: 10.5281/zenodo.8098567
3. Nevliudov, I., Novoselov, S., Sychova, O. (2022), "Modeling and practical implementation of the optimal wireless security gateway for the industrial automation network", *Serbian Journal of Electrical Engineering*, Vol. 19, No. 3, P. 303–327. DOI: <https://doi.org/10.2298/sjee2203303n>
4. Eckhart, M., Ekelhart, A. (2019), "Digital twins for cyber-physical systems security: State of the art and outlook", *Security and Quality in CyberPhysical Systems Engineering*. Springer, P. 383–412. DOI: [https://doi.org/10.1007/978-3-030-25312-7\\_14](https://doi.org/10.1007/978-3-030-25312-7_14)
5. Soori, M., Arezoo, B., Dastres, R. (2023), "Digital twin for smart manufacturing, A review", *Sustainable Manufacturing and Service Economics*, Vol. 2, 100017 p. DOI: <https://doi.org/10.1016/j.smse.2023.100017>
6. "Integration of Blockchain and Digital Twins in the Smart Built Environment Adopting Disruptive Technologies" / H. Sadri et al. (2023), *A Systematic Review. Sustainability*, Vol. 15(4), 3713 p. DOI: <https://doi.org/10.3390/su15043713>
7. Goudarzi, M., Ilager, Sh., Buyya, R. (2022), "Cloud Computing and Internet of Things: Recent Trends and Directions", *New Frontiers in Cloud Computing and Internet of Things. Internet of Things. Cham: Springer*, DOI: [https://doi.org/10.1007/978-3-031-05528-7\\_1](https://doi.org/10.1007/978-3-031-05528-7_1)
8. "Technopolis Group". available at: <https://www.technopolis-group.com/wp-content/uploads/2020/05/internet-of-things.pdf> (last accessed: 16.02.2025).
9. "Industrial Internet of Things / ed. by S. Jeschke et al." (2017), *Cham: Springer International Publishing*. DOI: 10.1007/978-3-319-42559-7
10. "The 17 goals". *Sustainable Development*. available at: <https://sdgs.un.org/goals> (last accessed: 18.02.2025).
11. Akbarian, F., Fitzgerald, E., Kihl, M. (2020), "Synchronization in Digital Twins for Industrial Control Systems", *Systems and Control*. available at: <https://arxiv.org/pdf/2006.03447> (last accessed: 15.01.2025).
12. Attaran, Sh., Attaran, M., Celik, B. (2024), "Digital Twins and Industrial Internet of Things: Uncovering operational intelligence in industry 4.0", *Decision Analytics Journal*, Vol. 10. DOI: <https://doi.org/10.1016/j.dajour.2024.100398>
13. "Digital Twins Approach for Sustainable Industry / L. Xu et al." (2022), *Lecture Notes in Business Information Processing*, P. 126–134. DOI: 10.1007/978-3-031-07478-3\_11
14. "Industry 5.0. Research and innovation". available at: [https://research-and-innovation.ec.europa.eu/research-area/industrial-research-and-innovation/industry-50\\_en](https://research-and-innovation.ec.europa.eu/research-area/industrial-research-and-innovation/industry-50_en) (last accessed: 18.02.2025).
15. Timperi, M., Kokkonen, K., Hannola, L. (2024), "Digital twins for environmentally sustainable and circular manufacturing sector: visions from industry professionals", *Production & Manufacturing Research*, Vol. 12(1). DOI: 10.1080/21693277.2024.2428249
16. Nevlyudov, I. Sh., Novoselov, S. P., Sychova, O. V. (2023), "Application of digital twins of technical automation tools for the development of software and hardware complexes of automated control systems:" Textbook. [Zastosuvannya tsyfrovyykh divyinykhiv tekhnichnykh zasobiv avtomatyzatsiyi dlya rozrobky prohramno-tekhnichnykh kompleksiv ASU TP] Kharkiv: Ivanchenko I. S. Publishing House, 267 p. ISBN 978-617-8059-95-8. DOI: 10.30837/978-617-8059-95-8
17. "Distributed Digital Twins as Proxies - Unlocking Composability & Flexibility for Purpose-Oriented Digital Twins / A. Aziz et al. (2023) *IEEE Access*. P. 1-17. DOI:10.1109/ACCESS.2023.3340132
18. Novoselov, S. (2018), "Wireless Sensor Network for Communication Between Base Stations in the Local Positioning System", *International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*, P. 383–386, DOI: 10.1109/INFOCOMMST.2018.8632140
19. Leite, J., Martins, P., Ursini, E. (2019), "Internet of Things: An Overview of Architecture, Models, Technologies, Protocols and Applications", *Emerging Trends and Challenges in Technology*. DOI: 10.1007/978-3-319-93112-8\_8
20. "New Technological Waves Emerging in Digital Transformation: Internet of Things IoT/IoE, 5G/6G Mobile Networks and Industries 4.0/5.0. / L. Emiliano et al." (2023), *Smart Innovation*, P. 329–339. DOI: 10.1007/978-3-031-31007-2\_30
21. Nevliudov, I., Novoselov, S., Sychova, O. (2023), "Modeling of a Decentralized System for Maintenance of Production Equipment Based on Transport Robots", *IEEE 5th International Conference on Modern Electrical and Energy System (MEES)*, P. 1–6. DOI: 10.1109/MEES61502.2023.10402485
22. "Enhancing Industrial Process Control: Integrating Intelligent Digital Twin Technology with Proportional-Integral-Derivative Regulators / A. Dapkute et al." (2024), *Machines*, Vol. 12(5), No 319. DOI: <https://doi.org/10.3390/machines12050319>
23. Soza'nski, K. (2023), "Low Cost PID Controller for Student Digital Control Laboratory Based on Arduino or STM32 Modules", *Electronics*, Vol 12, No. 3235. DOI: <https://doi.org/10.3390/electronics12153235>
24. Astrom, K. J., Wittenmark, B. (2013), "Computer Controlled System, Theory and Design", *Electronics and Power*. ISBN: 0131643193. available at: [https://www.academia.edu/37044747/Computer\\_Controlled\\_Systems\\_Astrom\\_3rdEdition](https://www.academia.edu/37044747/Computer_Controlled_Systems_Astrom_3rdEdition)
25. Ibrahim, D. (2022), "PID-based Practical Digital Control with Raspberry Pi and Arduino Uno", *Elektor International Media B.V.*, 238 p. ISBN: 978-3-89576-520-9.

*Відомості про авторів / About the Authors*

**Невлюдов Ігор Шакирович** – доктор технічних наук, професор, Харківський національний університет радіоелектроніки, завідувач кафедри комп'ютерно-інтегрованих технологій, автоматизації та робототехніки, Харків, Україна; e-mail: [igor.nevliudov@nure.ua](mailto:igor.nevliudov@nure.ua); ORCID ID: <https://orcid.org/0000-0002-9837-2309>

**Новоселов Сергій Павлович** – кандидат технічних наук, доцент, Харківський національний університет радіоелектроніки, професор кафедри комп'ютерно-інтегрованих технологій, автоматизації та робототехніки, Харків, Україна; e-mail: [sergiy.novoselov@nure.ua](mailto:sergiy.novoselov@nure.ua); ORCID ID: <https://orcid.org/0000-0002-3190-0592>

**Сичова Оксана Володимирівна** – кандидат технічних наук, Харківський національний університет радіоелектроніки, доцент кафедри комп'ютерно-інтегрованих технологій, автоматизації та робототехніки, Харків, Україна; e-mail: [oksana.sychova@nure.ua](mailto:oksana.sychova@nure.ua); ORCID ID: <https://orcid.org/0000-0002-0651-557X>

**Nevlyudov Igor** – Doctor of Sciences (Engineering), Professor, Kharkiv National University of Radio Electronics, Head at the Department of Computer-Integrated Technologies, Automation and Robotics, Kharkiv, Ukraine.

**Novoselov Sergiy** – PhD (Engineering Sciences), Associate Professor, Kharkiv National University of Radio Electronics, Professor at the Department of Computer Integrated Technologies, Automation and Robotics, Kharkiv, Ukraine.

**Sychova Oksana** – PhD (Engineering Sciences), Kharkiv National University of Radio Electronics, Associate Professor at the Department of Computer-Integrated Technologies, Automation and Robotics, Kharkiv, Ukraine.

## METHOD OF DECENTRALIZED CONTROL OF TECHNOLOGICAL PROCESSES IN INTELLIGENT MANUFACTURING

The technology of digital twins involves the creation of a virtual model of a physical object, process, or system that can be used for modeling, monitoring, testing, and predicting possible future developments based on information from a distributed network of sensors of technological equipment. The implementation of digital twins in the system of automated control of technological processes will allow increasing the efficiency of production processes in intelligent manufacturing. The **subject** of the research is the architecture of an automated process control system of technology process (ACS TP) in an intelligent factory with the integration of the Industrial Internet of Things technology and a digital twin of the production process. The **aim** of the research is to improve decentralized control methods for technological processes to enhance the efficiency of production processes in intelligent manufacturing by integrating digital twins into automated control systems. **Task**: to develop the architecture of a distributed ACS TP in an intelligent factory with the integration of the Industrial Internet of Things technology and a digital twin of the production process. To review the concept of "Digital Twin" in the context of combining this technology with the processes of sustainable development and transformation of the manufacturing industry. To conduct research on the proposed method of integrating a digital twin into the TP management task. In the research, the following **methods** were used: computer modeling, methods of automatic control theory, methods of analysis, and synthesis of decentralized production systems. The following **results** were obtained: an architecture of an automated system was developed using a digital twin as a reference model, which describes the ideal development of the control process of the automation object using a digital PID controller. The simulation results showed that the physical model quite accurately reproduces the behavior of the mathematical model of the PID controller with the given parameters. **Conclusions**: the results of the experimental research showed that the integration of digital twins into automated control systems improves decentralized control methods for technological processes and enhances the efficiency of production processes in intelligent manufacturing. The successful implementation of digital twin technology in intelligent manufacturing, in combination with cloud computing and machine learning, is aimed at achieving sustainable development goals, specifically addressing task 9.5.

**Keywords**: industrial; innovation; Industry 5.0; Internet of Things; intelligent manufacturing; digital twin.

*Бібліографічні опису / Bibliographic descriptions*

Невлюдов І. Ш., Новоселов С. П., Сичова О. В. Метод децентралізованого управління технологічними процесами на інтелектуальному виробництві. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 166–179. DOI: <https://doi.org/10.30837/2522-9818.2025.1.166>

Nevlyudov, I., Novoselov, S., Sychova, O. (2025), "Method of decentralized control of technological processes in intelligent manufacturing", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 166–179. DOI: <https://doi.org/10.30837/2522-9818.2025.1.166>

Г. ПАСТУШЕНКО

## РОЗРОБЛЕННЯ МЕТОДУ ПІДВИЩЕННЯ ТОЧНОСТІ ЛОКАЛІЗАЦІЇ БЕЗДРОТОВИХ СЕНСОРНИХ МЕРЕЖ

**Предметом дослідження** в статті є методи підвищення точності локалізації в бездротових сенсорних мережах в умовах відкритого середовища. Особливу увагу приділено методам налаштування потужності передачі сигналу для визначення діапазонів зв'язку між опорними й невідомими вузлами, а також методам оптимізації локалізації за допомогою багатокрокового звуження зони пошуку можливих місць розташування вузлів. **Мета роботи** – розроблення ефективного методу, що підвищує точність локалізації вузлів бездротових сенсорних мереж унаслідок налаштування потужності передачі сигналів для поступового звуження зони пошуку, використання багатораундового вимірювання для покращення результатів локалізації та статистичного аналізу для прогнозування місця розташування вузлів. У статті розв'язуються такі **завдання**: 1) розроблення методу адаптивного налаштування потужності сигналу; 2) створення алгоритму багатораундового звуження зони пошуку; 3) використання статистичних методів для прогнозування позицій вузлів. **Методи**, що застосовуються в дослідженні: адаптивне налаштування потужності сигналу; алгоритм багатораундового звуження зони пошуку; статистичний аналіз для прогнозування місця розташування вузла. **Досягнуті результати**. Запропоновано метод, що дає змогу значно підвищити точність локалізації в бездротових сенсорних мережах. У процесі експериментів було показано, що, на відміну від традиційних методів, новий підхід знижує похибки позиціонування на 30–40 %, що є значним досягненням для мереж, які працюють в умовах відкритого середовища. У деяких випадках метод допомагає точно визначити місце розташування вузла вже на пізньому етапі вимірювань. Це сприяє зменшенню витрат енергії, оскільки кількість необхідних вимірювань і перевірок істотно скорочується. Розроблений підхід демонструє ефективність (навіть у ситуаціях, коли сигнали зазнають значних перешкод) завдяки адаптивному налаштуванню потужності передачі сигналу. **Висновки**. Застосування методу підвищує точність локалізації в бездротових сенсорних мережах, що важливо для IoT-застосунків. Це знижує енергоспоживання завдяки меншій потребі у вимірюваннях. Подальші дослідження можуть зосередитися на адаптації до складніших умов, як-от міські середовища чи внутрішні простори.

**Ключові слова**: локалізація; бездротові сенсорні мережі; налаштування потужності передачі сигналу; точність локалізації; багатокрокова оптимізація; IoT; прогнозування місця розташування; енергоефективність.

### Вступ

У сучасних бездротових сенсорних мережах (WSN), особливо в контексті Інтернету речей (IoT), точна локалізація вузлів є важливим складником для забезпечення ефективності мережі та її функціональності. Локалізація бездротових вузлів дає змогу визначити їх точне місце розташування, що є критично важливим для різноманітних застосунків, від моніторингу навколишнього середовища до управління розподіленими системами. Однак традиційні методи локалізації, такі як триангуляція або використання GPS, можуть бути обмежені в умовах внутрішніх середовищ або за низької енергоефективності [1–3].

### Визначення завдань

У бездротових сенсорних мережах (WSN) точна локалізація вузлів є ключовим фактором для забезпечення ефективної роботи мережі, особливо

в контексті застосування в Інтернеті речей (IoT). Завдання полягає в розробленні методу, що допомагає точно визначити місце розташування вузлів мережі внаслідок визначення діапазонів зв'язку між опорними й невідомими вузлами з огляду на налаштування потужності передачі сигналів. Традиційні методи локалізації, такі як GPS або триангуляція, мають обмеження в умовах відкритого середовища, де є перешкоди та обмеження енергоефективності. У зв'язку з цим постає завдання вдосконалення методів локалізації внаслідок оптимізації налаштування потужності сигналу й поступового звуження можливих місць розташування вузлів за допомогою багатокрокового вимірювання.

Завданням статті є розроблення методу, що дає змогу підвищити точність локалізації вузлів завдяки адаптивному налаштуванню потужності сигналу для визначення діапазонів зв'язку, і впровадження багатораундового уточнення можливих позицій вузлів. Основною метою є створення такого алгоритму, що здатний на основі кількох раундів

вимірювань звужити список можливих місць розташування вузлів до мінімального діапазону й точно визначити їх координати.

У межах цього дослідження необхідно розв'язати такі завдання:

1) запропонувати метод налаштування потужності сигналу для оптимізації діапазону зв'язку між опорними й невідомими вузлами;

2) розробити алгоритм багатокрокової локалізації, що поступово звужує зону пошуку місця розташування вузлів способом використання кількох раундів вимірювань;

3) використати статистичні методи для обчислення середнього значення позицій у кожному раунді та визначення прогнозованого місця розташування вузла.

Завдання передбачає також випробування й аналіз результатів вимірювань на основі результатів експериментів для оцінювання точності запропонованого методу в реальних умовах відкритого середовища.

### Аналіз сучасних публікацій

У сучасних бездротових сенсорних мережах (BSM) точність локалізації вузлів є критично важливою для ефективного функціонування та широкого спектра застосувань. Дослідники пропонують різні підходи до підвищення точності локалізації.

В. Власов та Ю. Скорик у статті "Моделювання бездротової сенсорної мережі для оцінки точності позиціонування методом RSSI" [4, 5] досліджують імітаційне моделювання точності позиціонування в бездротових сенсорних мережах на основі методу RSSI (*Received Signal Strength Indicator*). Цей метод застосовується для оцінювання рівня прийнятого сигналу для визначення відстані між вузлами. Важливим аспектом є аналіз точності локалізації на етапі ініціалізації мережі. Стаття дає практичні рекомендації щодо покращення точності в контексті впровадження цього методу в реальних умовах.

Автори роботи "Інструменти для моделювання та перевірки розташування нодів у бездротових сенсорних мережах" [6, 7] розробляють програмне забезпечення для моделювання розташування нодів у бездротових сенсорних мережах, зосереджуючи увагу на точності позиціонування залежно від кількості контрольних нодів, щільності мережі та методу

обчислення відстаней. Це дає змогу ефективно прогнозувати вплив різних параметрів на точність локалізації, що має вагоме значення для створення стабільних і точних мереж.

У статті "Аналіз застосування сенсорних мереж у складних умовах" [8, 9] розглянуто методи енергозбереження в бездротових сенсорних мережах, що можуть вплинути на точність локалізації. Оскільки енергетична ефективність є критично важливою в бездротових мережах, використання методів машинного навчання для оптимізації енергоспоживання може допомогти в досягненні кращої точності без надмірних енерговитрат.

Автори праці "Метод локалізації об'єктів на основі вимірювання потужності сигналу" [10, 11] аналізують різні алгоритми локалізації об'єктів у бездротових сенсорних мережах, зокрема методи, основані на вимірюванні потужності сигналу. Оскільки точність локалізації безпосередньо залежить від якості сигналу й точності вимірювання, стаття надає важливу інформацію щодо поліпшення точності внаслідок використання потужності сигналу для вимірювання відстаней.

У статті "Дослідження точності локалізації в сенсорних мережах" [12, 13] запропоновано метод мультилатерації для завдання локалізації в сенсорних мережах. Цей метод використовує вимірювання відстаней до кількох точок для визначення місця розташування об'єкта. Мультилатерація є одним із найбільш точних методів для визначення координат в умовах бездротових сенсорних мереж. Отже, стаття є важливим внеском у покращення точності локалізації.

У дисертації "Методи побудови адресного простору безпроводних сенсорних мереж" [14, 15] порушено основні проблеми побудови бездротових сенсорних мереж, зокрема описано методи підвищення достовірності інформації в таких мережах, що напряму впливають на точність локалізації. Дослідження доводить важливість правильної побудови адресного простору для забезпечення точності та надійності локалізації в складних мережах.

### Опис методу

Запропонований метод ґрунтується на налаштуванні потужності передачі для різних значень з метою визначення діапазонів зв'язку між опорними вузлами. Деякі використовуються як базові точки з

відомими координатами (X, Y), що зберігаються в пам'яті. Інші вузли розподіляються випадковим чином для визначення їх місця розташування за допомогою зв'язку з вузлами, що розміщуються

в межах діапазону. Для початкового налаштування необхідно вручну розташувати кілька опорних вузлів, після чого решта вузлів розподіляється випадковим чином (рис. 1).




Рис. 1. Налаштування мережі. Білі вузли – це випадкові вузли, чорні вузли – опорні вузли

Вимірювання проводилися в чотирьох раундах, кожен з яких дає змогу звузити список можливих позицій невідомого вузла (рис. 2). Після цього середнє значення [16, 17] останнього списку

використовуватиметься як прогнозоване місце розташування. Коли вузол завершує цей процес, він стає опорним вузлом, щоб допомогти іншим нелокалізованим вузлам визначити свої позиції.

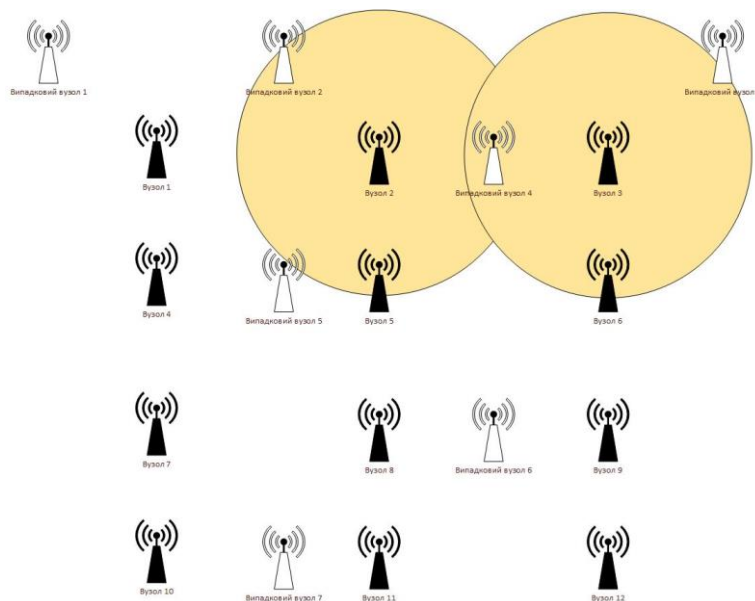


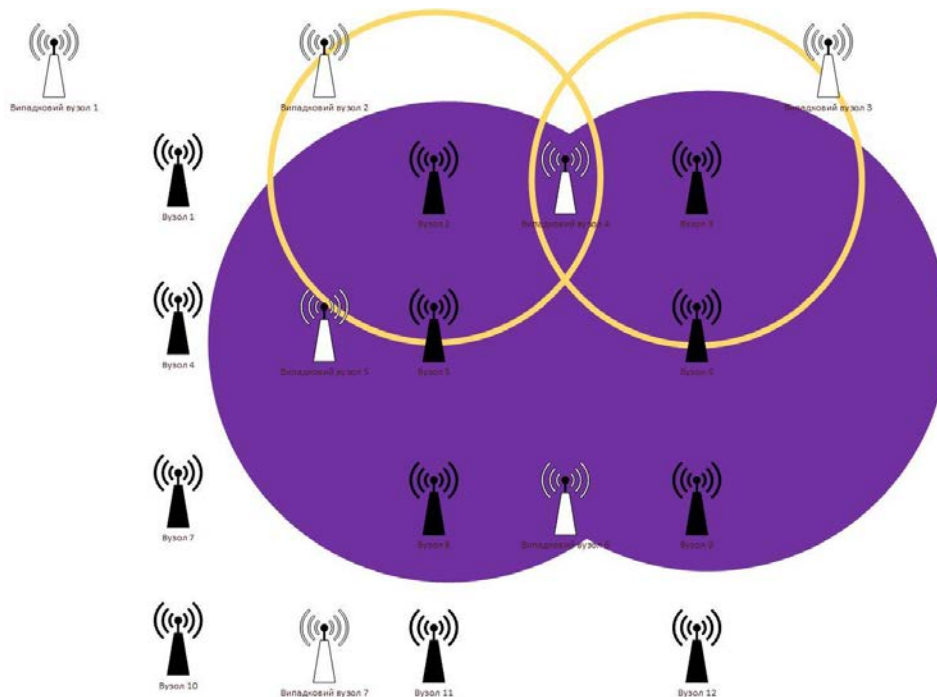
Рис. 2. Можливі розташування всередині обраного діапазону

**Раунд 1**

Спочатку потужність передачі була встановлена на рівні 10 дБм для всіх вузлів, що забезпечило дальність передачі та прийому сигналу до 100 м. Опорні вузли починають надсилати ширококомвні повідомлення з інформацією про своє місце розташування у вигляді координат (X, Y) [18, 19] та ідентифікатором вузла. Кожен невідомий вузол намагається отримати якомога більше повідомлень від опорних вузлів, розміщених у межах діапазону, щоб визначити всі можливі позиції через перетин сигналів з опорних вузлів. Для цього необхідно, щоб як мінімум два опорні вузли перебували в діапазоні (рис. 2). Перший раунд дає список усіх можливих позицій, а також середнє значення цих позицій, що пропонується як прогнозоване місце для цього раунду.

**Раунд 2**

У цьому раунді невідомі вузли налаштовують потужність передачі на 12 дБм, що дає дальність зв'язку до 130 м, і надсилають ширококомвні повідомлення опорним вузлам у межах досяжності, чекаючи на їх відповіді. Невідомі вузли надсилають повідомлення, що містять їх ID та Mac-адресу [20, 21], і всі опорні вузли, що отримують ці повідомлення, відповідають з інформацією про свої координати (X, Y) та ID. Отримавши відповіді, невідомі вузли беруть до уваги тільки ті опорні вузли, що розташовані на відстані від 100 до 130 м. Для зменшення кількості можливих розташувань, отриманих у першому раунді, використовується класичне рівняння для визначення відстані між точками [22, 23]. Розраховується відстань між кожною можливою позицією, отриманою на попередньому етапі, і всіма опорними вузлами, що відповіли в другому раунді.



**Рис. 3.** Результати раунду 1 передбачають усі можливі розташування та середнє значення можливих вузлів як запропоновані місця для цього раунду

**Раунд 3**

Невідомі вузли налаштовують потужність передачі на 14 дБм, що дає змогу збільшити дальність до 180 м для передачі та прийому сигналу. Вони починають надсилати ширококомвні повідомлення, що містять їх ID та Mac-адресу. Усі опорні вузли, що отримують ці повідомлення, відповідають із своїми координатами (X, Y) та ID. Невідомі вузли отримують ці відповіді та використовують лише ті

опорні вузли, що розташовані на відстані від 130 до 180 м. Для зменшення кількості можливих позицій, отриманих після другого раунду, використовується рівняння для обчислення відстані між кожною потенційною позицією з другого раунду та всіма опорними вузлами, що відповіли в третьому раунді. Середнє значення цих можливих позицій буде визначено як прогнозоване місце розташування для цього етапу.

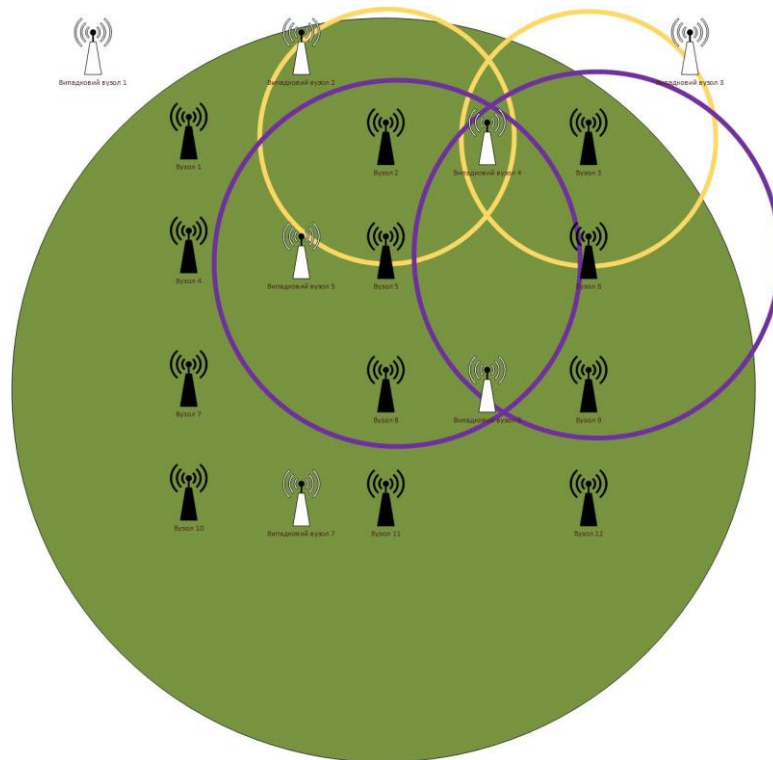


Рис. 4. Можливе розташування всередині обраних опорних вузлів діапазону перетину раунду 1, раунду 2 і раунду 3

#### Раунд 4

Невідомі вузли налаштовують потужність передачі на 16 дБм, що дає змогу збільшити дальність до 260 м для передачі та прийому сигналів. Вони починають надсилати широкомовні повідомлення, що містять їх ID та Mac-адресу. Всі опорні вузли, що отримують ці повідомлення, відповідають з інформацією про свої координати (X, Y) та ID. Невідомі вузли отримують відповіді та беруть до уваги лише ті опорні вузли, що розташовані на відстані від 180 до 260 м. Для зменшення кількості можливих позицій, отриманих після третього раунду, використовується рівняння [24, 25] для визначення відстані між кожною можливою позицією з цього раунду та всіма опорними вузлами, що відповіли на попередньому етапі. Середнє значення цих можливих позицій буде використовуватись для розрахунку прогнозованого місця розташування вузла.

Загальний алгоритм методу поданий на рис. 5.

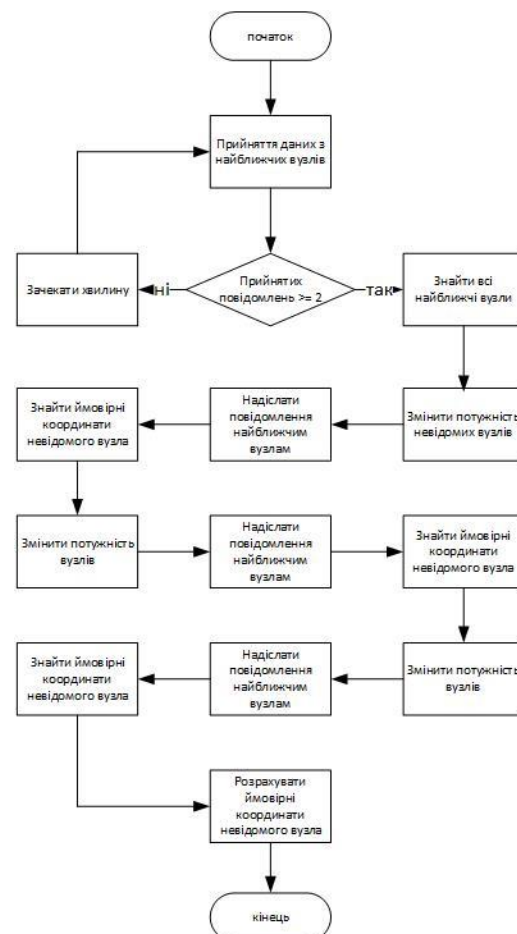


Рис. 5. Алгоритм методу



## Результати

Випробування проводились у відкритому просторі, де діапазон зв'язку визначався вручну. Вузли були розміщені на ділянці площею 250×250 м, з яких дев'ять були опорними, а 11 випадковим чином розподілені (рис. 6). Результати кожного раунду наведені в табл. 1 і 2.

Із добутих результатів видно, що похибки в раундах 1 і 2 коливалися від 10 до 51 м, у раунді 3 – від 7 до 26 м, а в раунді 4 – від 0 до 22 м. Варто зауважити, що деякі вузли змогли точно визначити своє місце розташування з нульовою похибкою.




Рис. 6. Розподіл вузлів

Таблиця 1. Фактичні вузли та виміряні місця в чотирьох раундах

Тип вузла	ID вузла	Дійсний X	Дійсний Y	Раунд 1			Раунд 2			Раунд 3			Раунд 4		
				X	Y	Можлива локація	X	Y	Можлива локація	X	Y	Можлива локація	X	Y	Можлива локація
Визначений	1	100	100	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	2	200	100	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	3	300	100	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	4	100	200	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	5	200	200	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	6	300	200	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	7	100	300	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	8	200	300	–	–	–	–	–	–	–	–	–	–	–	–
Визначений	9	300	300	–	–	–	–	–	–	–	–	–	–	–	–
Випадковий	10	130	140	150	150	37	*	*	*	153	153	20	130	140	1
Випадковий	11	190	150	200	150	127	200	150	9	195	155	2	190	150	1
Випадковий	12	260	140	250	150	37	*	*	*	246	153	18	246	153	18
Випадковий	13	120	270	142	257	48	120	280	10	113	266	3	113	286	3
Випадковий	14	270	270	250	250	37	*	*	*	247	247	23	270	270	1
Випадковий	15	334	147	300	150	127	*	*	*	346	152	21	340	150	15
Випадковий	16	315	239	300	250	127	298	252	30	316	233	3	*	*	*
Випадковий	17	145	62	150	100	127	*	*	*	152	53	21	150	60	15
Випадковий	18	194	74	150	100	127	182	91	7	186	88	5	186	88	5
Випадковий	19	229	347	250	300	127	*	*	*	247	346	21	250	340	15
Випадковий	20	267	238	252	257	48	280	280	10	286	266	3	286	266	3

Таблиця 2. Середня похибка в метрах у кожному раунді

	10	11	12	13	14	15	16	17	18	19	20
раунд 1	22,36	10	14,14	25,55	28,28	34,13	18,6	38,32	51,1	51,47	35,12
раунд 2	22,36	10	14,14	10	28,28	34,13	21,4	38,32	20,8	51,47	7
раунд 3	26,41	7,07	19,1	8,06	32,52	13	6,08	11,4	16,12	18,02	6,08
раунд 4	0	0	19,1	8,06	0	6,7	6,08	5,38	16,12	22,13	6,08

## Висновки

Розроблений метод локалізації бездротових сенсорних мереж, оснований на поступовому збільшенні потужності передачі сигналу, продемонстрував ефективність у визначенні місця

розташування вузлів у відкритому середовищі. Проведене випробування в чотирьох раундах дало змогу значно зменшити похибки в процесі локалізації, поступово звужити можливі варіанти позицій завдяки покращенню точності на кожному етапі. Як наслідок, в останньому раунді вдалося досягти помітного

зменшення похибок, зокрема деякі вузли змогли визначити своє місце розташування з нульовою похибкою. Розміщення опорних вузлів на початковому етапі, а також коректне налаштування потужності передачі на кожному з раундів дало змогу успішно локалізувати вузли навіть у випадковому їх розподілі. Метод, що використовує зменшення кількості можливих позицій на кожному етапі, забезпечує більш точне визначення місця розташування та підвищує надійність процесу локалізації в мережах IoT.

Подальші дослідження можна присвятити оптимізації енергоспоживання методу для підвищення автономності мереж, інтеграції з іншими технологіями, такими як GPS або LoRa, для покращення точності, а також адаптації до динамічних середовищ.

Важливими напрямками є використання алгоритмів машинного навчання для автоматичної корекції помилок, тестування методу у великих масштабованих мережах і оцінювання його ефективності в реальних умовах. Дослідження стійкості до кіберзагроз і аналіз роботи в різних середовищах, наприклад у густих лісах або підземних тунелях, також сприятимуть удосконаленню запропонованого підходу.

Описана методика є ефективним підходом для покращення точності локалізації в бездротових сенсорних мережах, особливо в умовах відкритого простору, і може бути використана для впровадження в IoT-застосунки, що потребують точного визначення місця розташування вузлів.

## Список літератури

1. Власова В.О., Скорик Ю.В. Моделювання бездротової сенсорної мережі для оцінки точності позиціонування методом RSSI. *Міжнародна науково-практична конференція High-Technologies in infocommunications*. 2019. С. 104–105 с. URL: <http://openarchive.nure.ua/handle/document/10848>
2. Семенюк О. М., Процах Н. П. Інструменти для моделювання та перевірки розташування нодів у бездротових сенсорних мережах. *Scientific Bulletin of UNFU*, № 34(8). 2024. С. 136–141. URL: <https://doi.org/10.36930/40340816>
3. Делембовський М., Корнійчук Б. Аналіз застосування сенсорних мереж у складних умовах. *Grail of Science*, № (39). 2024. С. 353–359. URL: <https://doi.org/10.36074/grail-of-science.10.05.2024.053>
4. Melnyk V., Bahniuk N., Zdolbitska N., Yakimchuk T. Methods for constructing the address space for wireless sensor networks. *Computer-integrated technologies: education, science, production*, № (43). 2021. P. 206–211. URL: <https://doi.org/10.36910/6775-2524-0560-2021-43-34>
5. Khlaponin Y., Selyukov O. Underwater radio device. *International scientific journal. Underwater technologies: industrial and civil engineering*. № (10). 2020. С. 39–49. DOI: <https://doi.org/10.32347/uwt2020.09.1501>
6. Dyachenko D., Kaida V., Levchenko A., Mikhal O., Methods of iot devices operation using machine learning, Control, Navigation and Communication Systems. *Collection of Scientific Papers*. Volume 2 № 76. 2024. С. 78–81. DOI: 10.26906/SUNZ.2024.2.078
7. Khan R., Pathan A. The state-of-the-art wireless body area sensor networks: A survey. *International Journal of Distributed Sensor Networks*. 2018. 14 p. DOI: 10.1177/1550147718768994
8. Guerrero-Ibáñez J., Zeadally S., Contreras-Castillo J. Sensor technologies for intelligent transportation systems. *Sensors* 18(4). 2018. 1212 p. DOI: 10.3390/s18041212
9. Hilmani A., Maizate A., Hassouni L. Designing and managing a smart parking system using. *Wireless Sensor Networks. Journal of Sensor and Actuator Networks*. 2018. 24 p. DOI: 10.3390/jsan7020024
10. Alkhatib A., Hnaif A., Kanan T. Proposed simple system for Road Traffic Counting. *International Journal of Sensors, Wireless Communications and Control*. № 9(2). 2019. P. 269–277. DOI: 10.2174/2210327908666181107110441
11. Nguyen L. N., Vy T. D., Shin Y. An efficient hybrid RSS-AoA localization for 3D wireless. *Sensor Networks. Sensors*. № 19(9). 2019. P. 2121. DOI: <https://doi.org/10.3390/s19092121>
12. Pita R., Utrilla R., Rodriguez-Zurrunero R., Araujo A. Experimental evaluation of an RSSI-Based localization algorithm on IoT End-Devices. *Sensors*. № 19(18). 2019. 3931 p. DOI: <https://doi.org/10.3390/s19183931>
13. Tomic S., Beko M., Dinis R., Bernardo L. On target localization using combined RSS and AoA measurements. *Sensors*. № 18. 2018. 1266 p. DOI: <https://doi.org/10.3390/s18041266>
14. Alkhatib A., Alia M., Hnaif A., Yousef S. A novel method for localising a randomly distributed wireless sensor network. *International Journal of System Assurance Engineering and Management*, Springer № 9(2). 2018. P. 354–361. DOI: 10.1007/s13198-017-0670-0

15. Xiaoyang L., Chao L. Wireless sensor network dynamic mathematics modeling and node localization. *Wireless Communications and Mobile Computing*. 2018. 141 p. DOI: <https://doi.org/10.1155/2018/1082398>
16. Cama-Pinto A., Piñeres-Espitia G., Caicedo-Ortiz J., Ramírez-Cerpa E., Betancur-Agudelo L., Gómez-Mula F. Received strength signal intensity performance analysis in wireless sensor network using Arduino platform and XBee wireless modules. *International Journal of Distributed*. 2018. P. 1–9. DOI: 10.1177/1550147717722691
17. Sandeli M., Bouanaka M. A., Kitouni I. An efficient localization approach in wireless sensor networks using chicken swarm optimization. 2021 *International Conference on Information Systems and Advanced Technologies (ICISA)*. 2021. P. 1–6. DOI: 10.1109/ICISAT54145.2021.9678446
18. Avareddy S., Biradar R. V. Comparative analysis of localization techniques and security mechanisms in WSN. 2021 *IEEE International Conference on Mobile Networks and Wireless Communications (ICMNWC)*. 2021. P. 1–4. DOI: 10.1109/ICMNWC52512.2021.9688549
19. Padhy S., Dash S., Malla P. P., Routray S., Qi Y. An energy efficient node localization algorithm for wireless sensor network. *IEEE 2nd International Conference on Applied Electromagnetics, Signal Processing, & Communication (AESPC)*. 2021 P. 1–5. DOI: 10.1109/AESPC52704.2021.9708459
20. Khobragade P., Ghutke P., Kalbande V. P., Purohit N. Advancement in Internet of things (iot) based solar collector for thermal energy storage system devices: a review. *nd International Conference on Power Electronics & IoT Applications in Renewable Energy an its Control (PARC)*. 2022. P. 1–5. DOI: 10.1109/PARC52418.2022.9726651
21. Lachouri A., Ardjouni A. Aeroelastic stability of combined plunge-pitch mode shapes in a linear compressor cascade. *Advances in the Theory of Nonlinear Analysis and Its Applications*. № 6 (1). 2022. P. 101–117. DOI: 10.3390/ijtpp7010007
22. Panwar A., Morwal R., Kumar S. Fixed points of  $\rho$ -nonexpansive mappings using MP iterative process. *Advances in the Theory of Nonlinear Analysis and Its Applications*. № 6 (2). 2022. P. 229–245. DOI: 10.31197/atnaa.980093
23. Bhattacharya S., Pandey M. Deploying an energy efficient, secure and high-speed sidechain-based TinyML model for soil quality monitoring and management in agriculture. *Expert Systems with Applications*, Volume 242. 2024. 122735 p. DOI: 10.1016/j.eswa.2023.122735
24. Shivadekar S., Kataria B., Limkar S., S. Wagh K., Lavate S., Mulla R. A. Design of an efficient multimodal engine for preemption and post-treatment recommendations for skin diseases via a deep learning-based hybrid bioinspired process. *Soft Computing*. 2023. P. 1–19. DOI: 10.1007/s00500-023-08709-5
25. Boutebba H., Lakhali H., Slimani K., Belhadi T. The nontrivial solutions for nonlinear fractional Schrödinger-Poisson system involving new fractional operator. *Advances in the Theory of Nonlinear Analysis and Its Applications*. № 7(1). 2023. P. 121–132. DOI: 10.31197/atnaa.1141136

## References

1. Vlasova, V.O., Skoryk, Y.V. (2019), "Modeling of a wireless sensor network for assessing positioning accuracy using the RSSI method", *International Scientific and Practical Conference High-Technologies in infocommunications*, P. 104–105. available at: <http://openarchive.nure.ua/handle/document/10848>
2. Semenyuk, O. M., Protsakh, N. P. (2024), "Tools for modeling and checking the location of nodes in wireless sensor networks", *Scientific Bulletin of UNFU*. № 34 (8), P. 136–141. DOI: 10.36930/40340816
3. Delembovsky, M., Korniychuk, B. (2024), "Analysis of the application of sensor networks in complex conditions". *Grail of Science*. № (39), P. 353–359. DOI: 10.36074/grail-of-science.10.05.2024.053
4. Melnyk, V., Bahniuk, N., Zdolbitska, N., Yakimchuk, T. (2021), "Methods for constructing the address space for wireless sensor networks", *Computer-integrated technologies: education, science, production*. № (43), P. 206–211. DOI: 10.36910/6775-2524-0560-2021-43-34
5. Khlaponin, Y., Selyukov, O. (2020), "Underwater radio device". *International scientific journal Underwater technologies: industrial and civil engineering*. № (10), P. 39–49. DOI: <https://doi.org/10.32347/uwt2020.09.1501>
6. Dyachenko D., Kaida V., Levchenko A., Mikhal O. (2024), "Methods of iot devices operation using machine learning". *Control, Navigation and Communication Systems. Collection of Scientific Papers*: Volume 2 No, P. 76. 78–81. DOI: 10.26906/SUNZ.2024.2.078
7. Khan, R., Pathan, A. (2018), "The state-of-the-art wireless body area sensor networks: A survey". *International Journal of Distributed Sensor Networks*, 14 p. DOI: 10.1177/1550147718768994

8. Guerrero-Ibáñez, J., Zeadally, S., Contreras-Castillo, J. (2018), "Sensor technologies for intelligent transportation systems", *Sensors*. № 18 (4), 1212 p. DOI: 10.3390/s18041212
9. Hilmani, A., Maizate, A., Hassouni, L. (2018), "Designing and Managing a Smart Parking System Using Wireless Sensor Networks", *Journal of Sensor and Actuator Networks*. 24 p. DOI: 10.3390/jsan7020024
10. Alkhatib, A., Hnaif, A., Kanan, T. (2019), "Proposed simple system for Road Traffic Counting". *International Journal of Sensors, Wireless Communications and Control*. № 9(2), P. 269–277. DOI: 10.2174/2210327908666181107110441
11. Nguyen, L. N., Vy, T., D., Shin, Y. (2019), "An efficient hybrid RSS-AoA localization for 3D wireless sensor networks", *Sensors*. № 19 (9), 2121 p. DOI: 10.3390/s19092121
12. Pita, R., Utrilla, R., Rodriguez-Zurrunero, R., Araujo, A. (2019), "Experimental evaluation of an RSSI-Based localization algorithm on IoT end-devices", *Sensors*. № 19(18), 3931 p. DOI: 10.3390/s19183931
13. Tomic, S.; Beko, M.; Dinis, R.; Bernardo, L. (2018), "On target localization using combined RSS and AoA measurements", *Sensors*. №18, 1266 p. DOI: 10.3390/s18041266
14. Alkhatib, A., Alia, M., Hnaif, A., Yousef, S. (2018), "A novel method for localizing a randomly distributed wireless sensor network". *International Journal of System Assurance Engineering and Management*. Springer № 9 (2), P. 354–361. DOI: 10.1007/s13198-017-0670-0
15. Xiaoyang, L. and Chao, L. (2018), "Wireless sensor network dynamic mathematical modeling and node localization", *Wireless Communications and Mobile Computing*. 141 p. DOI: 10.1155/2018/1082398
16. Cama-Pinto, A., Piñeres-Espitia, G., Caicedo-Ortiz, J., Ramírez-Cerpa, E., Betancur-Agudelo, L., Gómez-Mula, F. (2018), "Received strength signal intensity performance analysis in wireless sensor network using Arduino platform and XBee wireless modules", *International Journal of Distributed*, P. 1–9. DOI: 10.1177/1550147717722691
17. Sandeli, M., Kitouni, I. (2021), "An Efficient Localization Approach in Wireless Sensor Networks Using Chicken Swarm Optimization". *International Conference on Information Systems and Advanced Technologies (ICISA)*, P. 1–6. DOI: 10.1109/ICISAT54145.2021.9678446
18. Avareddy, S., Biradar, R. V. (2021), "Comparative Analysis of Localization Techniques and Security Mechanisms in WSN". *IEEE International Conference on Mobile Networks and Wireless Communications (ICMNWC)*, P. 1–4. DOI: 10.1109/ICMNWC52512.2021.9688549
19. Padhy, S., Dash, S., Malla, P. P., Routray, S., Qi, Y. (2021), "An energy efficient node localization algorithm for wireless sensor network", *IEEE 2nd International Conference on Applied Electromagnetics, Signal Processing, & Communication (AESPC)*, P. 1–5. DOI: 10.1109/AESPC52704.2021.9708459
20. Khobragade, P., Ghutke, P., Kalbande, V. P., Purohit, N. (2022), "Advancement in internet of things (IoT) based solar collector for thermal energy storage system devices: a review", *2nd International Conference on Power Electronics & IoT Applications in Renewable Energy and its Control (PARC)*, P. 1–5. DOI: 10.1109/PARC52418.2022.9726651
21. Lachouri, A., Ardjouni, A. (2022), "Aeroelastic stability of combined plunge-pitch mode shapes in a linear compressor cascade". *Advances in the Theory of Nonlinear Analysis and Its Applications*. № 6 (1), P. 101–117. DOI: 10.3390/ijtpp7010007
22. Panwar, A., Morwal, R., Kumar, S. (2022), "Fixed points of  $\rho$ -nonexpansive mappings using MP iterative process". *Advances in the Theory of Nonlinear Analysis and Its Applications*. № 6 (2), P. 229–245. DOI: 10.31197/atnaa.980093
23. Bhattacharya, S., Pandey, M. (2024), "Deploying an energy efficient, secure and high-speed sidechain-based TinyML model for soil quality monitoring and management in agriculture". *Expert Systems with Applications*, Volume 242. 122735 p. DOI: 10.1016/j.eswa.2023.122735
24. Shivadekar, S., Kataria, B., Limkar, S., S. Wagh, K., Lavate, S., Mulla, R. A. (2023), "Design of an efficient multimodal engine for preemption and post-treatment recommendations for skin diseases via a deep learning-based hybrid bioinspired process". *Soft Computing*, P. 1–19. DOI: 10.1007/s00500-023-08709-5
25. Boutebba, H., Lakhhal, H., Slimani, K., Belhadi, T. (2023), "The nontrivial solutions for nonlinear fractional Schrödinger-Poisson system involving new fractional operator". *Advances in the Theory of Nonlinear Analysis and Its Applications*. № 7 (1), P. 121–132. DOI: 10.31197/atnaa.1141136

*Відомості про авторів / About the Authors*

**Пастушенко Ганна Олександрівна** – Вінницький національний технічний університет, аспірантка кафедри інформаційних радіоелектронних технологій і систем, факультет інформаційних електронних систем, Вінниця, Україна; e-mail: Anya.past16@gmail.com; ORCID ID: <https://orcid.org/0009-0008-1736-0981>

**Pastushenko Hanna** – Vinnytsia National Technical University, Graduate Student at the Department of Information Radio Electronic Technologies and Systems, Faculty of Information Electronic Systems, Vinnytsia, Ukraine.

## DEVELOPMENT OF THE METHOD FOR INCREASING THE ACCURACY OF LOCALIZATION OF WIRELESS SENSOR NETWORKS

**The subject** of the study in the article is methods for increasing the localization accuracy in wireless sensor networks in open environments. Particular attention is paid to methods for adjusting the signal transmission power to determine the communication ranges between reference and unknown nodes, as well as methods for optimizing localization through multi-step narrowing of the search area of possible node locations. **The purpose** of the work is to develop an effective method that increases the localization accuracy of wireless sensor network nodes by adjusting the signal transmission power to gradually narrow the search area, using multi-round measurement to improve localization results, and statistical analysis to predict the location of nodes. **The following tasks** are solved in the article: 1) development of a method for adaptively adjusting the signal power; 2) development of an algorithm for multi-round narrowing the search area; 3) use of statistical methods for predicting node positions. **Methods** used in the study: adaptive signal power adjustment method; algorithm for multi-round narrowing the search area; statistical analysis for predicting the location of a node. **Results.** A method is proposed that allows to significantly increase the localization accuracy in wireless sensor networks. **As a result** of experiments, it was shown that, compared to traditional methods, the new approach reduces positioning errors by 30–40%, which is a significant achievement for networks operating in open environments. In some cases, the method allows to accurately determine the location of a node already at a late stage of measurements. This allows to reduce energy consumption, since the number of necessary measurements and checks is significantly reduced. The developed approach demonstrates its effectiveness even in cases where signals are subject to significant interference, thanks to adaptive adjustment of the signal transmission power. **Conclusions.** The use of the method increases the localization accuracy in wireless sensor networks, which is important for IoT applications. This reduces energy consumption due to the lower need for measurements. Further research may focus on adaptation to more complex conditions, such as urban environments or indoor spaces.

**Keywords:** localization, wireless sensor networks; signal power tuning; localization accuracy; multi-step optimization; IoT; location prediction; energy efficiency.

*Бібліографічні описи / Bibliographic descriptions*

Пастушенко Г. О. Розроблення методу підвищення точності локалізації бездротових сенсорних мереж. *Сучасний стан наукових досліджень та технологій в промисловості*. 2025. № 1 (31). С. 180–189. DOI: <https://doi.org/10.30837/2522-9818.2025.1.180>

Pastushenko, H. (2025), "Development of the method for increasing the accuracy of localization of wireless sensor networks", *Innovative Technologies and Scientific Solutions for Industries*, No. 1 (31), P. 180–189. DOI: <https://doi.org/10.30837/2522-9818.2025.1.180>

**АЛФАВІТНИЙ ПОКАЖЧИК**

Герасимук Д. В.	5
Дашенков Д. С.	20
Долгий А. І.	32
Єна М. В.	49
Каргін А. О.	61
Кирсанов О. О.	151
Кривенко С. А.	151
Кузьменко Р. С.	61
Литвин В. В.	83
Ляшенко О. С.	73
Мацелюх Ю. Р.	83
Мельник М. О.	115
Михайліченко І. В.	73
Невлюдов І. Ш.	166
Непокритов Д. М.	102
Новоселов С. П.	166
Пастушенко Г. О.	180
Поддубний В. О.	102
Поляков А. О.	5
Семенов С. Г.	115
Сєверінов О. В.	102
Сирота О. П.	115
Сичова О. В.	166
Сітнікова О. О.	115
Смеляков К. С.	20
Усачов В. О.	127
Федорченко В. М.	5
Чернишов Д. В.	143
Шубін І. Ю	32, 127

**ALPHABETICAL INDEX**

Herasymuk Denys	5
Dashenkov Dmytro	20
Dolhyi Andrii	32
Yena Maksym	49
Kargin Anatolii	61
Kyrsanov Oleksandr	151
Kryvenko Stanislav	151
Kuzmenko Roman	61
Lytvyn Vasyl	83
Liashenko Oleksii	73
Matseliukh Yurii	83
Melnyk Marharyta	115
Mykhailichenko Ihor	73
Nevlyudov Igor	166
Nepokrytov Dmytro	102
Novoselov Sergiy	166
Pastushenko Hanna	180
Poddubnyi Vadym	102
Poliakov Andrii	5
Semenov Serhii	115
Sievierinov Oleksandr	102
Syrota Olena	115
Sychova Oksana	166
Sitnikova Oksana	115
Smelyakov Kirill	20
Usachov Volodymyr	127
Fedorchenko Volodymyr	5
Chernyshov Dmytro	143
Shubin Ihor	32, 127

НАУКОВЕ ВИДАННЯ

SCIENTIFIC PUBLICATION

**Сучасний стан  
наукових досліджень  
та технологій  
в промисловості**

**Innovative  
technologies and  
scientific solutions  
for industries**

*Щоквартальний науковий журнал*

*Quarterly scientific journal*

**№ 1 (31), 2025**

**No. 1 (31), 2025**

Відповідальний секретар журналу *І.Г. Перова*  
Відповідальний за випуск *А.А. Коваленко*  
Відповідальний за ліцензування *В.В. Косенко*  
Редактор *Л.В. Кузьміна*  
Комп'ютерна верстка *Л.Ю. Светайло*

Responsible secretary of journal *I. Perova*  
Responsible for release *A. Kovalenko*  
Responsible for licensing *V. Kosenko*  
Editor *L. Kuzmina*  
Computer layout *L. Svietailo*

Формат 60×84/8. Умов. друк. арк. 22,1.  
Тираж 150 прим.

Format 60×84/8. Conventional printed sheets 22,1.  
Edition of 150 copies.

Віддруковано з готових оригінал-макетів  
в типографії ФОП Андреев К.В.  
Єдиний державний реєстр юридичних осіб  
та фізичних осіб-підприємців.  
Запис №24800170000045020 від 30.05.2003.

Printed from ready-made original layouts  
in the printing house  
of Individual Entrepreneur Andreev K.V.  
Unified State Register of Legal Entities  
and Individual Entrepreneurs.  
Entry No. 24800170000045020 of 30.05.2003.

61157, Харків, вул. Акад. Богомольця, 9, кв. 50,  
тел. +38 (063) 993-62-73  
e-mail: ep.zakaz@gmail.com

fl. 50, 9, Acad. Bogomolets Str., Kharkiv, 61157,  
тел. +38 (063) 993-62-73  
e-mail: ep.zakaz@gmail.com