

13. R. Kurzweil, *The Singularity is Near*. Viking Publ., 2005.
14. I. Prigogine, and C. George, «The Second Law as a Selection Principle: The Microscopic Theory of Dissipative Processes in Quantum Systems», *Proceeding of the National Academy of Science*, vol. 80, pp. 4590-45945, 1983. doi: 10.1073/pnas.80.14.4590.

Стаття надійшла 08.10.2024

Стаття прийнята 05.11.2024

УДК 004.9:004.65:004.71: 654.9

doi: 10.31498/2225-6733.49.1.2024.321206

© Грицук В.Ю.¹, Пронін С.В.²

АНАЛІЗ ТА ОБҐРУНТУВАННЯ ВИБОРУ МОДЕЛІ ДЛЯ МОНІТОРИНГУ ПАРАМЕТРІВ ТРАНСПОРТНОГО ЗАСОБУ ТА ПРОГНОЗУВАННЯ ТЕХНІЧНОГО ОБСЛУГОВУВАННЯ

Сьогодні обладнання транспортних засобів надають величезні масиви даних для контролю технічного стану. Процес експлуатації транспортного засобу (ТЗ) постійно пов'язаний з природнім зносом вузлів та компонентів, що, в свою чергу, призводить до погіршення технічних та експлуатаційних характеристик. Для надійності роботи ТЗ потрібен якісний моніторинг компонентів при технічному обслуговуванні (ТО) та діагностування несправностей. Під моніторингом та діагностуванням мається на увазі процес технічного обслуговування з майбутнім виявленням дефектів у системах ТЗ. Аналітика отриманої інформації з використанням технологій Big Data стає вкрай важливою для аналізу та обробки більших обсягів даних, особливо для прогнозування виходу з ладу механізмів. Прогнозоване технічне обслуговування працює краще, ніж ремонт або профілактичне ТО. Відповідно, прогнозування на основі аналізу даних є набагато ефективнішим з точки зору оцінювання експлуатаційної стійкості вузлів в реальному часі та попередження можливих збоїв у їх роботі. Для більш якісного виявлення можливих дефектів доцільно використовувати нейронні мережі, завдяки яким можна отримати більше даних відповідно до технічного стану ТЗ, до показників, що передаються з бортового комп'ютеру. Використовуючи реальні дані з багатьох датчиків і звіти про несправності в роботі вузлів та агрегатів ТЗ, моделі машинного навчання можуть досліджувати патерни інформації і створювати прогнозовані моделі несправностей на основі моніторингу стану в реальному часі. Така інформація передана до системи від ТЗ обробляється за допомогою нейронних мереж та на виході отримуємо більш якісний аналіз стану ТЗ на предмет несправностей, що підвищує якість технічного обслуговування. У статті розглянуто особливості діагностування сучасних ТЗ, наведено можливі варіанти отримання даних з ТЗ та приклад розробки нейронної мережі з налаштуванням оптимальних параметрів машинного навчання і для прогностичної діагностики за допомогою наявних даних.

Ключові слова: прогностичне технічне обслуговування, моніторинг, нейронні мережі, прогнозування ремонту, Big Data.

V.Yu. Hritsuk, S.V. Pronin. Analysis and justification of model selection for vehicle parameters monitoring and maintenance prediction. Today, vehicle equipment provides huge amounts of data for technical condition monitoring. The process of vehicle operation

¹ аспірант, Харківський національний автомобільно-дорожній університет, м. Харків, ORCID: 0000-0002-3780-7815, valeri.gritsuk@gmail.com

² канд. техн. наук, доцент, Харківський національний автомобільно-дорожній університет, м. Харків, ORCID: 0000-0002-7475-621X

is constantly associated with the natural wear and tear of components, which in turn leads to a deterioration in technical and operational characteristics. For the reliability of the vehicle operation, high-quality component monitoring during maintenance and fault diagnosis is required. Monitoring and diagnostics mean the process of maintenance with the future detection of defects in vehicle systems. Analytics of the information obtained using Big Data technologies are becoming extremely important for analyzing and processing large amounts of data, especially for predicting the failure of mechanisms. Predictive maintenance works better than repair or preventive maintenance. Accordingly, data-driven forecasting is much more effective in terms of assessing the operational stability of units in real time and preventing possible failures in their operation. For better detection of possible defects, it is advisable to use neural networks, which can provide more data on the compliance of the technical condition of the vehicle with the indicators transmitted from the on-board computer. Using real data from multiple sensors and reports on malfunctions in the operation of vehicle components and assemblies, machine learning models can explore patterns of information and create predictive fault models based on real-time condition monitoring. Such information transmitted to the system from the vehicle is processed using neural networks and the output is a better analysis of the vehicle's condition for faults, which improves the quality of maintenance. The article discusses the peculiarities of diagnosing modern vehicles, provides possible options for obtaining data from vehicles and an example of developing neural networks with the setting of optimal machine learning parameters and for predictive diagnostics using available data.

Keywords: predictive maintenance, monitoring, neural networks, repair prediction, Big Data.

Постановка проблеми. Типовим рішенням для запобігання виходу з ладу компонентів транспортних засобів (ТЗ) є проведення профілактичного обслуговування або запланованих технічних обслуговувань [1-4]. На основі використання статистичних даних можна реалізувати профілактичне технічне обслуговування (ТО) таким чином, що критичні вузли будуть замінюватись ще до того, як вони почнуть відмовляти. Втім, через індивідуальні характеристики кожного окремого ТЗ важко реалізувати такий підхід до всього автопарку, а також економічно неефективно проводити ремонт кожного окремого компонента за певним планом. На даний момент ТЗ є одними з найбільш просунутими у використанні Інтернету речей (IoT). Ця технологія дозволяє розглядати всі додатки, пов'язані з контролем та обслуговуванням транспортних засобів, дає можливість аналізувати параметри транспортного засобу і попереджати водіїв про будь-які критичні проблеми.

Існує дві основні стратегії технічного обслуговування, що активно застосовуються в управлінні транспортними засобами, а саме: експлуатація до відмови та профілактичне технічне обслуговування. Технічне обслуговування до відмови – це техніка оперативного реагування. Технічне обслуговування не проводиться до тих пір, поки не станеться несправність. Прогнозоване технічне обслуговування розглядається як орієнтована на час стратегія технічного обслуговування. При застосуванні профілактичного обслуговування автомобіль проходить планову перевірку через певний проміжок часу. Складність прогностичного технічного обслуговування полягає у тому, що важко передбачити періодичність планових ТО. Якщо його виконувати занадто часто, витрати на ТО зростуть і буде втрачено частину корисного ресурсу ТЗ. Прогнозування напрацювання до відмов може принести відчутні результати для ефективності технічного обслуговування. Завдяки такому прогнозуванню можна вчасно здійснити технічне обслуговування, що дасть змогу запобігти виникненню несправностей та знизить фінансові витрати на технічне обслуговування.

Як техніка статистичної обробки даних, так і машинне навчання є важливими для прогнозування технічного обслуговування. У ретроспективі, коли обсяг даних був невеликим і низько розмірним, переважали статистичні методи. У добу великих даних, зі збільшенням обсягу і підвищенням структури даних, машинне навчання дозволяє отримати більше рішень завдяки інтелектуальному аналізу даних.

Аналіз останніх досліджень і публікацій У роботах [5-7] система моніторингу транспортного засобу використовує ELM327 як зчитувач OBD-II для отримання потрібних даних

(наприклад, частота обертання двигуна, швидкість транспортного засобу, температура охолоджуючої рідини та прискорення педаль) та їх передачі на смартфон користувача через Bluetooth.

Та ж сама платформа може використовувати окремий додаток для отримання даних для подальшого аналізу поведінки водія на основі даних ТЗ [8].

Також було виявлено, що для збору даних для подальшого використання краще використовувати моделі IoV та Штучного інтелекту (ШІ), оскільки основною структурою IoT є інтегрування багатьох розумних сенсорів, датчиків, пристроїв збору даних і процесорів периферійних обчислень [9-11].

Дослідниками у роботах [12-15] було запропоновано використання IoT датчиків та пристроїв, що збирають у режимі реального часу дані про технічні параметри системи ТЗ. Потім ці дані надходять на центральний сервер або хмарну платформу, де вони можуть бути оброблені і використані для моніторингу загального стану транспортного засобу.

У роботі [16] для прогнозування експлуатаційної надійності автомобільних двигунів запропоновано модель дерев умовного виводу. У цьому дослідженні деревоподібна регресійна модель була поєднана з моделлю пропорційної небезпеки Кокса. Представлена в цій роботі гібридна модель може запропонувати просту інтерпретацію та дозволяє виявляти важливі параметри.

Мета та постановка задачі. Одна з найбільш ефективних стратегій для підтримки ТЗ у справному стані – технічне обслуговування. Але її неможливо застосовувати без діагностичних робіт та засобів для проведення такої роботи, щоб дізнатись повну індивідуальну інформацію про ТЗ (цілком, окремо по вузлах чи системах). Ключовим у цій роботі є вирішення задачі зменшення витрат та оптимізація діагностування теперішніх та майбутніх поломок за рахунок впровадження нейромережевої моделі аналізу даних, отриманих з ТЗ.

Виклад основного матеріалу. У будь-якому сучасному ТЗ знаходиться більше сотні датчиків, за допомогою яких можна проводити моніторинг. Завдяки використанню цифрових електронних систем можна постійно відстежувати найважливіші параметри системи (тиск масла, температуру охолоджуючої рідини, рівень вихлопних газів) і повідомляти про відхилення від норми. Коли дані з датчиків відстежуються і виконується моніторинг, то можна спрогнозувати, в якому стані перебуває транспортний засіб [17]. Відповідно, основним завданням системи експлуатації автомобілів є підтримання їхнього технічного стану та надійності на рівні, достатньому для здійснення ними заданих функцій. Для правильного ТО збираються дані про продуктивність, щоб вивчати їх в автономному режимі і при необхідності відправляти транспортні засоби на обслуговування.

Широкий діапазон умов і режимів експлуатації, а також варіація початкових показників якості машини, призводять до значної дисперсії її напружень до граничного стану (рис. 1). Тому досить важливо мати методи і засоби для оцінки технічного стану машини, тобто отримання індивідуальної інформації про приховані і назріваючі відмови, залишковий ресурс, причини порушення працездатності тощо [6, 8]. Засобом отримання такої інформації буде технічна діагностика. Технічна діагностика безпосередньо поєднується з теорією надійності, оскільки головною її метою є своєчасне виявлення непрацездатного стану ТЗ, прогнозування залишкового ресурсу, що, зрештою, спрямовано на підвищення надійності та ефективності експлуатації техніки.




Рис. 1 – Схема керування технічним станом об'єкту

З цього випливає, що діагностуванням називається процес визначення технічного стану об'єкта без його розбирання шляхом вимірювання величин, що характеризують його стан, і зіставлення їх із нормативами. Діагностування не є самостійним технологічним процесом, воно є елементом системи ТО і ремонту, що забезпечує індивідуальну інформацію про технічний стан об'єкта. Наявність таких даних дає змогу для оптимізації режимів регламентного контролю, своєчасного виявлення потреби об'єкта в ремонті та ТО, перевірці якості їх виконання, тобто для комплексного управління технічним станом [5, 18-20].

Діагностування є якісно досконалішою формою контрольно-вимірювальних робіт і відрізняється такими ознаками:

- об'єктивністю і достовірністю оцінки технічного стану складних об'єктів без їхнього розбирання;
- можливістю визначення технічного стану за вихідними параметрами;
- появою умов для прогнозування технічного стану об'єкта, його залишкового ресурсу.

Алгоритм діагностування являє собою структурну послідовність діагностичних, регулювальних і ремонтних операцій. Він визначає виведення об'єкта на тестовий режим, постановку первинного діагнозу, перехід до наступного елемента, регулювальні та ремонтні операції, повторні та заключні перевірки [7].

Діагностування включає в себе три основних етапи:

- фіксування відхилень діагностичних параметрів від їх номінальних значень;
- аналіз характеру і причин походження цих відхилень;
- встановлення розміру запасу ресурсу працездатної експлуатації [21].

Діагностичні засоби можна класифікувати як бортові (вбудовані) та небортові (зовнішні) (рис. 2). Серед загальновідомих сучасних методів діагностування переважне місце займає комп'ютерна діагностика, що дозволяє виконувати тестування електронних і виконавчих систем автомобіля, що впливають на функціонування бортових комплексів, а також виявляють несправності, пов'язані з експлуатацією системи електроніки автомобіля [22]. На підставі одержаних даних формується діагностична карта несправностей для подальшого ремонту та усунення неполадок, пов'язаних з обладнанням та механізмами.




Рис. 2 – Класифікація засобів діагностики ТЗ

Електронні бортові комплекси автомобіля обладнані системами для самодіагностики. Такі системи потрібні для управління виконавчими механізмами автомобіля, безперервного функціонування в момент запуску та роботи двигуна. Електронні системи інформують про можливі поломки вузлів і агрегатів, а також інформують про можливі дефекти в вузлах і агрегатах, а крім того, відстежують міжсервісні інтервали і попереджають про необхідність своєчасного проходження технічного обслуговування ТЗ [18, 23].

Дії з прогнозованим моніторингом та діагностуванням можна планувати на основі віку або стану (рівня деградації) ТЗ. У системі кожен транспортний засіб повинен мати набір радіочастотних ідентифікаційних датчиків-міток, прикріплених до них [24]. Кожного разу коли ТЗ

під'єднується до Інтернету через мережу, то процесор для обробки даних отримує дані про ТЗ та перевіряє їх на наявність передбачених типів порушень. Далі ці записи передаються в БД та порівнюються з записами в хмарі, які були передані до того. Дані будуть зчитуватися з датчиків і синхронізуватися з хмарними даними. Використання хмарних сховищ для збереження даних додає пропонованій системі таких переваг, як масштабованість, зручність та гнучкість. Дані про транспортні засоби та водіїв зберігаються в центрі обробки даних.

Збір даних є ключовим етапом та разом з цим потрібно звернути увагу на попередню обробку даних, виділення особливостей, побудову класифікаційної схеми та їх аналіз [25]. Для впровадження ефективного прогностичного моніторингу (рис. 3) потрібен точний набір даних. Точні та якісні дані дозволять отримати якісний результат, що буде відображати ефективність запропонованої моделі. Дані будуть збиратися з багатьох джерел, таких як регулярні дані з датчиків, звіти про технічне обслуговування ТЗ та інші. Після збору даних необхідна попередня обробка даних. Попередня обробка даних передбачає маркування даних, їх очищення та конвертацію [26-28].




Рис. 3 – Структурна схема побудови прогностичного моніторингу

Доступ до більшості інформації, що описує особливості стану ТЗ, можна отримати через CAN-шину транспортного засобу. CAN (Controller Area Network) – це внутрішня мережа, що з'єднує усі датчики автомобіля і через яку вони взаємодіють одне з одним. Безпосередньо під'єднатися до неї дуже проблематично: тому зазвичай використовується інтерфейс OBD, що надає змогу отримувати дані з CAN-шини. Процес збору даних полягає у підключенні до мережі CAN портативного комп'ютера (або датчика OBD II) з метою отримання даних під час експериментів [29-32].

Основними етапами при зборі даних є:

- Налаштування ініціювання зв'язку – встановлення конкретного шляху до СОМ-порту, до якого підключено зчитувач даних, а також швидкості передачі даних.
- Налаштування конфігурації – встановлення формату відповідей на запити даних.

- Запити параметрів і фіксація відповідей – зациклення кожні декілька секунд для безперервного надсилання запитів параметрів до зчитувача і збереження відповідей необроблених даних [27, 33].

Коли мікропроцесор (мікрокомп'ютерний блок) виявляє наявність інтернет-з'єднання, необроблені дані з EBU автоматично передаються на веб-сервер за допомогою пост-запитів. Відповідно, необхідна підпрограма, яка у фоновому режимі роботи основної програми реєстрації даних періодично здійснює перевірку наявності з'єднання з мережею, оскільки мікропроцесор не завжди може бути під'єднаний до Інтернету.

У зв'язку з тим, що останнім часом багато виробників обирають CAN в якості основної шини у внутрішній системі автомобіля, CAN може бути встановлений як основний комунікаційний протокол між автомобілем і зовнішнім OBD-інтерфейсом. Інтеграція протоколів зв'язку шини CAN передбачає ідентифікацію протоколу зв'язку, який використовується у відповідній моделі автомобіля. Однак при визначенні комунікаційних властивостей шини CAN для визначення режиму зв'язку помилкові пакети можуть спричинити перехід шини CAN у вимкнений стан, що призведе до втрати зв'язку з автомобілем і, як результат, до аварійного завершення роботи системи [31, 34, 35].

Для отримання даних аналізуються чотири основні системи автомобіля: система запалювання, паливна система, вихлопна система та система охолодження. Ці системи відстежуються складними комп'ютерними системами управління. Датчики передають інформацію про несправності в блок управління електронікою (ECU). ECU – це мікрокомп'ютер, який складається з безлічі електронних компонентів і схем, включаючи багато напівпровідникових приладів. Його вхідний пристрій отримує вхідні дані у вигляді електричних сигналів. Ці сигнали збираються від датчиків, розташованих у різних місцях двигуна. Блок обробки порівнює вхідні дані з даними, що знаходяться в пам'яті. Блок пам'яті містить базову інформацію про роботу двигуна. Пристрій передачі імпульсів подає електричні сигнали на електромагнітний клапан впорскування. Основна функція ECU в електричній системі впорскування палива полягає в управлінні пульсацією через форсунку, частотою обертання холостого ходу, моментом запалювання і паливним насосом. Блок управління може швидко пристосуватись до зміни умов, використовуючи запрограмовану карту характеристик, що зберігається в блоці пам'яті. Мета роботи блоку управління – максимізувати потужність двигуна з мінімальним рівнем викидів вихлопних газів і мінімальною витратою палива. Інструменти сканера OBD II завантажують коди несправностей бортової мережі, зв'язуючись з блоком управління, щоб визначити, який саме датчик не відповідає [36-43].

У сучасних транспортних засобах зі збільшенням кількості електронних блоків керування зростає і рівень складності бортових мереж, оскільки кожен окремий компонент має власні вимоги до швидкості передачі даних і затримок. Кількість електронних блоків управління в сучасних інтелектуальних транспортних засобах постійно зростає, щоб забезпечити транспортний засіб різноманітними новими функціональними можливостями для безпеки, захисту, зручності і т.д. [39]. Крім того, для з'єднання великої кількості електронних блоків управління було розроблено кілька автомобільних протоколів, і дослідження все ще тривають з метою створення більш досконалих функцій. Крім того, ECU (рис. 4) зазвичай підключаються до більш ніж однієї шини через їх диверсифіковану функціональність, включаючи управління та моніторинг транспортного засобу [40].

Однак у практичних випадках діагностики існує багато станів несправності для одного і того ж механічного обладнання. Тоді для побудови послідовної системи діагностування для ідентифікації несправностей і розпізнавання типів несправностей застосовується теорія можливостей [44]. Теорія можливостей – це математична теорія для отримання нечіткого висновку при обробці нечіткої інформації [45], яку можна представити у вигляді:

$$p(x_i) = \sum_{k=1}^N \min\{\lambda_i, \lambda_k\}, (i, k = 0, 1, 2, \dots, N),$$

$$\lambda_i = \int_{x_{i-1}}^{x_i} \frac{m}{\eta} \left(\frac{x - x_0}{\eta}\right)^{m-1} \exp\left\{-\frac{(x - x_0)^m}{\eta}\right\} dx, x_i = \bar{x} + \frac{i - N}{N} \sigma,$$

$$\lambda_k = \int_{x_{k-1}}^{x_k} \frac{m}{\eta} \left(\frac{x - x_0}{\eta}\right)^{m-1} \exp\left\{-\frac{(x - x_0)^m}{\eta}\right\} dx, x_k = \bar{x} + \frac{k - N}{N} \sigma.$$




Рис. 4 – Внутрішня конфігурація ECU [32]

Звідси можна отримати функції можливостей для відомих станів та стану діагностування. Ці стани, які були точно діагностовано, будуть використовуватися для визначення стандартів діагностування в якості зразків. Варто враховувати, що існують деякі несправності, які ще не виникали, і тоді ці стани називаються «невідомими станами». Таким чином, не існує жодного способу обчислити безпосередньо функцію ймовірності невідомого стану. Для того, щоб підвищити діагностичні можливості та покращити чутливість ідентифікації, в роботі [44] був запропонований наступний непрямий метод для отримання функції ймовірності невідомого стану:

$$M_{un} = \max \left\{ 1 - \sum_{i=1}^N M_i, 0 \right\}, (i = 1, 2, \dots, N),$$

де M_i – функції можливості стану, а N – загальна кількість станів.

Для побудови системи прогностичного моніторингу доцільно використати платформу машинного навчання та візуального аналізу даних Orange Data Mining [46]. Після аналізу інформації, яка поступає з OBD II сканера, буде побудовано інформаційну БД, в яку будуть завантажуватись всі параметри з ТЗ. Після цього за допомогою no-code засобів можливо побудувати прогностичну систему, яка використовує кілька алгоритмів (Random Forest, Neural Network, Logistic Regression). На прикладі даних про технічний стан ТЗ [26, 47] побудуємо аналітичну і прогностичну модель, за допомогою якої нейронна мережа буде навчатись.

Точне прогнозування виходу з ладу та залишкового ресурсу обладнання допомагає розробити адекватне планування технічного обслуговування. Для прогнозування використовуються джерела даних і відповідні методи моніторингу продуктивності обладнання, якості продукції та прогнозування можливої відмови обладнання. Моніторинг допомагає забезпечити раннє виявлення несправностей і дозволяє виявити проблеми, що виникають, до того, як станеться відмова [48].

До набору даних можуть входити ознаки та параметри, пов'язані з роботою двигуна транспортного засобу, такі як оберти двигуна, температура, тиск та інші дані, отримані з датчиків. Він також може включати метадані про транспортний засіб, такі як марка, модель, рік випуску і пробіг. Далі ці дані (рис. 5) розділяються на ті, що будуть використовуватись для навчання

(тренувальний набір) та тестування (тестувальний набір). Обрані дані для побудови діляться на ці набори за фіксованим принципом 80/20.

80 19	
Data Sample:	1-100: 80 instances, 7 variables
	Features: 6 numeric (no missing values)
	Target: categorical
Remaining Data:	1-100: 19 instances, 7 variables
	Features: 6 numeric (no missing values)
	Target: categorical

Рис. 5 – Результат розділення даних

Основним алгоритмом навчання, який використовується для навчання штучної нейронної мережі (ШНМ) з навчанням під контролем, є зворотне поширення, яке має дві робочі фази: пряме поширення та зворотне поширення [49, 50]. Він базується на алгоритмі градієнтного спуску (GD), який обчислює градієнти по всьому набору даних, так як легко поміщається в пам'яті і є швидким в обчисленнях. Це призводить до великої кількості ітерацій і збільшує ризик потрапити в пастку локальних оптимумів з ранньою збіжністю. У зв'язку з цими проблемами в роботі [50] було запропоновано метод міні-пакетного градієнтного спуску. Навчальний набір даних розбивається на партії фіксованого розміру для використання в процесі навчання в цьому методі. Обчислюється загальна похибка і ваги для кожної підпачки оновлюються. Коли значення міні-партії дорівнює «1», використовується алгоритм стохастичного градієнтного спуску. У цьому випадку похибка обчислюється для однієї вибірки за раз і ваги також оновлюються, що призводить до швидшої збіжності за рахунок прямої векторизації даних. Значення помилки потім поширюється назад через мережі, а ваги оновлюються за допомогою GD у зворотному напрямку кривизни. Параметри мережі, що підлягають оптимізації, оновлюються відповідно як

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} J(\theta_t),$$

де η – швидкість навчання, $\nabla_{\theta} J(\theta_t)$ – градієнт функції втрат $J(\theta_t)$ відносно θ_t .

Алгоритм стохастичного градієнтного спуску (SGD) обчислює втрачену функцію для однієї навчальної вибірки за раз, замість того, щоб розглядати всі навчальні вибірки даних. Таким чином можна уникнути проблем дефіциту пам'яті. SGD був створений для усунення недоліків алгоритму пакетного градієнтного спуску. Проблема використання SGD полягає у визначенні правильного значення швидкості навчання, щоб уникнути коливань і досягти глобального оптимуму. Для оновлення параметрів використовується наступне рівняння [47]

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)}),$$

де η – швидкість навчання, $\nabla_{\theta} J(\theta_t)$ – градієнт функції втрат $J(\theta_t)$ відносно θ_t . Також $x^{(i)}$ та $y^{(i)}$ представляють навчальні дані у вигляді пар входів-виходів. Якщо крива функції втрат має перегини, де один вимір має нахил вгору, а інший – вниз, алгоритм SGD працює погано.

Інший варіант – градієнтний спуск з імпульсом. Крок навчання в методах градієнтного спуску бажано збільшувати, щоб швидше досягти найкращого результату. Коли кроки навчання дуже великі, глобального оптимуму не завжди можна досягти. Ці великі кроки можуть мати прямий вплив на час, необхідний для досягнення глобального оптимуму. Для вирішення цих проблем в роботі [51] було запропоновано метод градієнтного спуску за імпульсом. Він обмежує швидкість наступного кроку навчання, використовуючи середню швидкість попередніх кроків навчання. У цьому методі динамічне середнє минулих градієнтів (m_{t-1}) експоненціально зменшується і зберігається. Напрямок руху визначається з урахуванням цих динамічних усереднень. Таким чином, кроки процесу навчання рухаються швидше до найкращого результату з меншим відхиленням [52]. Правило оновлення може бути виражене у вигляді

$$m_t = \gamma m_{t-1} + \eta \nabla_{\theta} J(\theta_t),$$

$$\theta_{t+1} = \theta_t - m_t,$$

де γ – параметр імпульсу, який зазвичай має значення 0.9 або близьке до нього.

Ще одним варіантом навчання є алгоритм адаптивного градієнта (AdaGrad), який ділить компонент швидкості навчання на квадратний корінь з v_t , який є сумою поточного і попереднього квадратів градієнта до моменту часу t . Компонент градієнта, як і в SGD, залишається незмінним. AdaGrad здійснює відповідні оновлення для кожного параметра, використовуючи різні швидкості навчання для кожного кроку. Найважливішою перевагою використання AdaGrad є те, що швидкість навчання не регулюється вручну, як в інших системах адаптивного навчання [51]. Рівняння оновлення AdaGrad можуть бути виражені як

$$g_t = \nabla_{\theta} J(\theta_t),$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t + \epsilon}} g_t,$$

де ϵ – згладжуючий коефіцієнт, який дозволяє уникнути ділення на нуль (зазвичай встановлюється рівним 10^{-8}), а v_t – експоненціальна змінна середнього градієнта.

На рис. 6 зображено загальний вигляд системи, на якій видно, що до блоку отриманих результатів («test and score») від даних направлено два набори (тестовий та тренувальні). Окрім цього, навчання відбувається за допомогою декількох алгоритмів (Random Forest, Neural Network, Logistic Regression). Після цього результати потрапляють на блок «predictions», який відповідає за прогнозування системи для обробки тестових даних.




Рис. 6 – Загальний вигляд побудованої системи

Основними алгоритмами при побудові прогностичної моделі є: логістичної регресія, нейронна мережа та випадковий ліс. Для логістичної регресії було обрано тип регуляризації «Ridge (L2)», що використовується для запобігання надмірному узгодженню за рахунок виключення великих коефіцієнтів. Ступінь регуляризації в даній роботі налаштований за допомогою параметра «C» (встановлено на 1, що вказує на помірний рівень регуляризації) та встановлюється за допомогою бігунка, що забезпечує певний баланс між рівнем складності моделі та якістю навчання. Параметри нейронної мережі містять 200 нейронів у прихованому шарі та нелінійною функцією активації «tanh». Регулятор для оптимізації задано як «Adam», а регуляризацію визначено зі значенням $\alpha = 0.0001$. Процес навчання передбачає максимум 500 ітерацій, а опція «Повторюване навчання» гарантує отримання однакових результатів у всіх ітераціях та забезпечує отримання визначених результатів шляхом фіксації випадкових вхідних параметрів. В моделі випадкового лісу використано 10 дерев рішень, обсяг підмножини для виділення атрибутів під час розбиття встановлено на позначку в 5, що враховуються при кожному розбитті. Також включено збалансований класовий розподіл, а навчання є повторювальним. Контроль росту передбачає

обмеження глибини дерева до 3 і запобігання розбиттю на підмножини, розмір яких менший за 5 екземплярів.

Після вибору параметрів роботи отримуємо записані в блоки результати по тренувальним даним та тестовим даним (рис. 7).

Model	AUC	CA	F1	Prec	Recall	MCC
Neural Network	0.643	0.684	0.644	0.680	0.684	0.268
Random Forest	0.643	0.737	0.732	0.731	0.737	0.420
Logistic Regression	0.702	0.684	0.644	0.680	0.684	0.268

а)

Model	AUC	CA	F1	Prec	Recall	MCC
Neural Network	0.643	0.684	0.644	0.680	0.684	0.268
Random Forest	0.643	0.737	0.732	0.731	0.737	0.420
Logistic Regression	0.702	0.684	0.644	0.680	0.684	0.268

б)

Рис. 7 – Блок отриманих результатів роботи нейронних мереж: а) для тренувальних даних; б) для тестових даних

При роботі з програмним середовищем Orange можливо індивідуально налаштувати всі параметри системи, які знадобляться в роботі. Основою в роботі є датасет з параметрами ТЗ. Цільовий показник, який потрібно отримати, – необхідність в ремонті або ні зі значеннями «need gear» та «no gear». До набору даних можуть входити різні ознаки та параметри, пов'язані з роботою двигуна транспортного засобу, такі як оберти двигуна, температура, тиск та інші дані з датчиків. Він також може включати метадані про транспортний засіб, такі як марка, модель, рік випуску і пробіг. Так як таких різномірних даних з ТЗ отримується багато, потрібно виявити, які будуть використовуватись при побудові нейронної мережі, а саме, які впливають на результат. В роботі було виділено 6 ключових параметрів з датасету.

Вибрані екземпляри даних передаються на блок Data Sampler, в якому реалізується вибірка даних, а саме дані поділяються на тестовий набір та тренувальний за пропорціями 80/20 (де 80 показників зі 100 – для тренувального набору). Набір даних для тестування було вилучено з ШНМ на етапі навчання, щоб переконатися, що ШНМ зможе передбачити стан несправності, спираючись лише на свій власний досвід навчання.

Разом з цим, окремими блоками є три варіанти алгоритмів, які, як і дані з блоку Data Sampler, під'єднуються до блоку «Test and Score», в якому тестуються та навчаються алгоритми навчання даних. В цьому блоці візуалізуються результати алгоритмів нейронної мережі по певним коефіцієнтам (Area under ROC, Classification accuracy, F-1, Precision, Recall, Matthews correlation coefficient).

За алгоритми відповідають блоки логістичної регресії, випадкового лісу та нейронної мережі. Першим є алгоритм класифікації логістичної регресії з регуляризациєю LASSO (L1) або ridge (L2). Далі – випадковий ліс, який створює множину дерев рішень. Для побудови кожного дерева береться початкова вибірка з тренувальних даних. При побудові кожного окремого дерева формується довільна підмножина ознак, з якої вибирається найкраща для розбиття. Другим варіантом алгоритму є алгоритм багаторівневого перцептрона (MLP) із зворотним поширенням (на рис. 6 блок Neural Network). При побудові даного алгоритму потрібно визначити в меню певні параметри:

- кількість нейронів на прихований шар;
- функція активації для прихованого шару, яка може бути як логістична сигмоїдна функція, гіперболічна функція тангенса кута, випрямлена лінійна одинична функція або активація без операцій;
- регулятор для оптимізації ваг (L-BFGS-B, SGD, Adam, Alpha).

Після отримання даних від даних алгоритмів інформація з блоку «Test and Score» йде на блок «Confusion Matrix», в якому дана матриця плутанини показує кількість/співвідношення між прогнозованим і фактичним значеннями класів. Виділення елементів у цій матриці дає відповідні екземпляри у вихідному сигналі. Таким чином, можна бачити, які конкретні приклади були неправильно класифіковані і як саме за певним розподілом:

- Істинно позитивні (TP): кількість позитивних прикладів, які належать до позитивного класу і прогножуються як позитивні;
- Істинно негативні (TN): кількість прикладів, які належать до негативного класу і прогножуються як негативні;
- Хибно-позитивний (FP): кількість прикладів, які належать до негативного класу, але передбачені моделлю як позитивні;
- Хибно-негативні (FN): кількість прикладів, які належать до позитивного класу, але прогножуються моделлю як негативні [53].

Відповідно до результатів, зображених на рис. 8, побудуємо окрему матрицю плутанини для цих алгоритмів і проаналізуємо результати. Аналогічно будемо те ж саме, але вже для тестової вибірки.

Engine Condition	Neural Network	Random Forest	Logistic Regression	1 Network (need r	al Network (no re	om Forest (need r	om Forest (no re	Regression (neec	c Regression (no	Fold	Engine rpm	Lub oil pressure	Fuel pressure	Coolant pressure	lub oil temp	Coolant temp
need repair	need repair	need repair	need repair	0.991808	0.00819218	0.856212	0.143788	0.942886	0.0571142	1	666	2.51794	8.94487	2.78163	74.3556	68.1369
need repair	need repair	need repair	need repair	0.999184	0.000816287	0.756212	0.243788	0.946521	0.0534795	1	805	2.91303	17.569	1.74664	74.718	75.2551
need repair	need repair	need repair	need repair	0.574741	0.425259	0.935	0.065	0.627178	0.372822	1	538	4.26	7.69421	2.08363	80.1835	81.1808
need repair	need repair	need repair	need repair	0.835351	0.164649	0.8	0.2	0.834161	0.165839	1	704	2.26787	10.0127	2.14751	76.2482	88.9332
need repair	need repair	need repair	need repair	0.991102	0.00889755	0.756212	0.243788	0.908388	0.0916117	1	691	2.38106	8.00188	1.47438	75.0928	71.6119
need repair	need repair	need repair	need repair	0.831376	0.168624	0.735	0.265	0.77994	0.22006	1	790	2.49359	11.7909	3.17988	84.1442	81.6322
no repair	no repair	no repair	no repair	0.431536	0.568464	0.408960	0.591032	0.361281	0.638719	1	697	3.81376	1.83378	0.794514	78.634	86.7292
no repair	no repair	no repair	no repair	0.978887	0.0211126	0.911864	0.088136	0.949499	0.0515005	1	382	2.16255	7.77402	2.72735	77.0009	71.6238
no repair	no repair	no repair	no repair	0.158536	0.841464	0.463003	0.536997	0.416727	0.583273	1	596	4.21049	4.60145	1.31346	84.4637	76.6308
no repair	no repair	no repair	no repair	0.979806	0.0201938	0.941791	0.058209	0.926686	0.073314	1	657	4.2805	2.952	3.97609	75.7486	87.192
no repair	no repair	no repair	no repair	0.981856	0.0181442	1	0	0.868015	0.131985	1	495	3.37822	7.37628	3.09076	77.264	73.807
no repair	no repair	no repair	no repair	0.933911	0.0660891	0.409722	0.590278	0.868328	0.131672	1	876	2.94161	16.1939	2.4645	77.6409	82.4457
no repair	no repair	no repair	no repair	0.96116	0.0388396	0.835	0.165	0.841922	0.158078	1	583	3.39794	6.14666	1.62738	76.2243	70.6144
no repair	no repair	no repair	no repair	0.987062	0.0129384	0.035	0.965	0.885875	0.114125	1	779	2.02241	13.7866	1.02677	77.1272	84.8581
no repair	no repair	no repair	no repair	0.96631	0.0336896	0.7	0.3	0.727081	0.272919	1	664	3.97849	7.5371	4.85397	76.4129	84.5655
no repair	no repair	no repair	no repair	0.645784	0.354216	0.8	0.2	0.73639	0.26361	1	1053	2.53385	4.21219	4.70547	75.8421	75.9816
no repair	no repair	no repair	no repair	0.614352	0.385648	0.835	0.165	0.637988	0.362012	1	590	2.45449	6.65057	2.45012	83.6614	75.2497
no repair	no repair	no repair	no repair	0.510173	0.489827	0.239435	0.760565	0.554489	0.445511	1	1007	2.9857	4.77586	2.04503	76.9034	82.0885
no repair	no repair	no repair	no repair	0.41114	0.58886	0.467069	0.532931	0.475841	0.524159	1	1221	3.98923	6.67923	2.21425	76.4012	75.6698

Рис. 8 – Блок «predictions» для розробленого алгоритму при тестовому наборі даних

Як бачимо на рис. 9, нейронна мережа та випадковий ліс є більш точними в хибно-негативних та хибно-позитивних показниках, ніж логістична регресія, яка має похибку відносно цих двох алгоритмів. З рис. 10 вже можемо побачити, що для тестових даних всі алгоритми справились з приблизно однаковими результатами.

		Predicted		Σ
		need repair	no repair	
Actual	need repair	52	0	52
	no repair	5	23	28
Σ		57	23	80

а)

		Predicted		Σ
		need repair	no repair	
Actual	need repair	50	2	52
	no repair	2	26	28
Σ		52	28	80

б)

		Predicted		Σ
		need repair	no repair	
Actual	need repair	43	9	52
	no repair	19	9	28
Σ		62	18	80

в)

Рис. 9 – Матриці плутанини для тренувальних даних: а) нейронної мережі, б) випадкового лісу, в) логістичної регресії

Використовуючи матрицю плутанини, ми змогли виміряти ефективність моделі. Значення ТР представляє ситуацію, коли фактична помилка виникає, як і передбачалося моделлю, в межах часового інтервалу вікна прогнозування. І навпаки, FR показує передбачення помилки моделювання, коли фактично помилки не було.

		Predicted		Σ
		need repair	no repair	
Actual	need repair	11	1	12
	no repair	5	2	7
Σ		16	3	19

а)

		Predicted		Σ
		need repair	no repair	
Actual	need repair	10	2	12
	no repair	3	4	7
Σ		13	6	19

б)

		Predicted		Σ
		need repair	no repair	
Actual	need repair	11	1	12
	no repair	5	2	7
Σ		16	3	19

в)

Рис. 10 – Матриці плутанини для тестових даних: а) нейронної мережі, б) випадкового лісу, в) логістичної регресії

Висновки

В ході дослідження було розроблено алгоритм для проведення прогнозування необхідності технічного обслуговування транспортних засобів за допомогою програмних продуктів на базі Orange Data Mining. Отримані результати дають можливість використовувати даний програмний продукт для більш глибокого аналізу та дають можливість використовувати різні дані для побудови нейронних мереж при розробці прогностичної моделі технічного обслуговування.

Перелік використаних джерел:

1. Грицук В. Ю., Грицук Ю. В. Прогностичне обслуговування в автомобільному сервісі: використання IOT та BIG DATA. *Енергетичні установки та альтернативні джерела енергії*: зб. тез та доповідей міжнародної конференції, м. Харків, 11-12 березня 2024 р. Харків: ФОП Бровін О.В., 2024. С. 264-266.
2. Грицук В. Ю., Пронін С. В. Перспективи впровадження прогностичного обслуговування транспортних засобів на основі машинного навчання. *Сучасний стан досліджень в сфері IT*: матеріали Всеукр. наук.-практ. конф. здобувачів вищої освіти та молодих учених, м. Харків, 19 квітня 2024 р. Харків: ХНАДУ, 2024. С. 77-81.
3. Особливості моніторингу стану транспортних засобів з використанням бортових діагностичних комплексів / В. П. Матейчик та ін. *Управління проектами, системний аналіз і логістика*. 2014. Вип. 13. С. 126-138.
4. The peculiarities of monitoring road vehicle performance and environmental impact / I. Kuric et al. *MATEC Web of Conferences*. 2018. Vol. 244. Pp. 1-7. DOI: <https://doi.org/10.1051/matec-conf/201824403003>.
5. Survey of smartphone-based sensing in vehicles for intelligent transportation system applications / Engelbrecht J., Booysen M. J., Bruwer F. J., van Rooyen G.-J. *IET Intelligent Transport Systems*. 2015. Vol. 9. № 10. Pp. 924-935. DOI: <https://doi.org/10.1049/iet-its.2014.0248>.
6. Baek S. H., Jang J. W. Implementation of integrated OBD-II connector with external network. *Information Systems*. 2015. Vol. 50. Pp. 69-75. DOI: <https://doi.org/10.1016/j.is.2014.06.011>.
7. Design and Implementation of a Wireless OBD II Fleet Management System / R. Malekian et al. *IEEE Sensors Journal*. 2017. Vol. 17. № 4. Pp. 1154-1164. DOI: <https://doi.org/10.1109/JSEN.2016.2631542>.

8. Türker G. F., Kutlu A. Survey of Smartphone applications based on OBD-II for Intelligent Transportation Systems. *International journal of engineering research and applications*. 2016. Vol. 6. Iss. 1. Pp. 69-73.
9. Big IoT Data Analytics: Architecture, Opportunities, and Open Research Challenges / M. Marjani et al. *IEEE Access*. 2017. Vol. 5. Pp. 5247-5261. DOI: <https://doi.org/10.1109/ACCESS.2017.2689040>.
10. Machine learning predictive model for Industry 4.0 / I.S. Candanedo et al. *Knowledge Management in Organizations : Proceedings of the 13th International Conference, Žilina, Slovakia, 6-10 August 2018*. Pp. 501-510. DOI: https://doi.org/10.1007/978-3-319-95204-8_42.
11. Deep Learning in Industry 4.0 – Brief Overview / J. Hernavts et al. *Journal of Production Engineering*. 2018. Vol. 21. Pp. 1-5. DOI: <https://doi.org/10.24867/JPE-2018-02-001>.
12. Kazi K. Reverse Engineering's Neural Network Approach to human brain. *Journal of Communication Engineering & Systems*. 2022. Vol. 12. Iss. 2. Pp. 17-24. DOI: <https://doi.org/10.37591/joces.v12i2.951>.
13. Kazi K. Model for Agricultural Information system to improve crop yield using IoT. *Journal of Open Source Developments*. 2022. Vol. 9. Iss. 2. Pp. 16-24.
14. Announcement system in Bus / N. Salunke et al. *Journal of Image Processing and Intelligent Remote Sensing*. 2022. Vol. 2. Iss. 6. Pp. 1-10. DOI: <https://doi.org/10.55529/jipirs.26.1.10>.
15. Sending notification to someone missing you through smart watch / D. Vishwanath Swami et al. *International Journal Of Information Technology & Computer Engineering (IJITC)*. 2022. Vol 2. Iss. 8. Pp. 19-24. DOI: <https://doi.org/10.55529/ijitc.25.19.24>.
16. Reliability analysis for automobile engines: Conditional inference trees / S. Wang et al. *Procedia CIRP*. 2018. Vol. 72. Pp. 1392-1397. DOI: <https://doi.org/10.1016/j.procir.2018.03.065>.
17. Gayathri T. A Survey on Vehicle Health Monitoring and Prediction System. *International Journal of Computer Science Trends and Technology (IJCTST)*. 2017. Vol. 5. Iss. 3. Pp. 191-193.
18. Інформаційні системи моніторингу технічного стану автомобілів / В.П. Волков та ін. Харків : ФЛП Панов А.М., 2018. 299 с.
19. The Complex Application of Monitoring and Express Diagnosing for Searching Failures on Common Rail System Units / I. Gritsuk et al. *SAE Technical Paper*. 2018. DOI: <https://doi.org/10.4271/2018-01-1773>.
20. Information Security Risk Management of Vehicles / D. Klets et al. *SAE Technical Paper*. 2018. DOI: <https://doi.org/10.4271/2018-01-0015>.
21. Пути улучшения современной системы диагностирования автомобилей / В.В. Аулин та ін. *Підвищення надійності машин і обладнання : матеріали міжнар. наук.-практ. конф., м. Кропивницький, 17-19 квіт. 2019 р. Кропивницький : ЦНТУ, 2019. С. 218-223*.
22. Павленко В. М., Кужель В. П., Хорін М. Є. Сутність автомобільної діагностики при впровадженні експертних систем. *Вісник машинобудування*. 2020. № 2(12). С. 85-92. DOI: <https://doi.org/10.31649/2413-4503-2020-12-2-85-92>.
23. Шокарев О. М., Болтянська Н. І. Засоби діагностики сучасних автотранспортних засобів. *Технічне забезпечення інноваційних технологій в агропромисловому комплексі : II Міжнародна науково-практична конференція, м. Кропивницький, 27 листопада 2020 р. ТДАУ ім. Д. Моторного. С. 450-454*.
24. Nalina V., Jayarekha P. Real Time Automated Vehicle Monitoring and Control System Using Internet of Vehicles. *International Journal of Computer Sciences and Engineering*. 2018. Vol. 6. Pp. 491-494. DOI: <https://doi.org/10.26438/ijcse/v6i3.491494>.
25. Kusumaningrum D., Kurniati N., Santosa B. Machine Learning for Predictive Maintenance. *Proceedings of the International Conference on Industrial Engineering and Operations Management, Sao Paulo, Brazil, 5-8 April 2021*. Pp. 2348-2356.
26. Vehicle Maintenance Data. URL: <https://www.kaggle.com/datasets/chavindudulaj/vehicle-maintenance-data> (дата звернення 31.08.2024).
27. Multi-agent deep reinforcement learning-based maintenance optimization for multi-dependent component systems / P. Do et al. *Expert Systems with Applications*. 2024. Vol. 245. Article 123144. DOI: <https://doi.org/10.1016/j.eswa.2024.123144>.
28. Ali Y. H. Artificial Intelligence Application in Machine Condition Monitoring and Fault Diagnosis. *Artificial Intelligence*. Ch. 14. 2018. DOI: <https://doi.org/10.5772/intechopen.74932>.

29. Singh S. K., Singh A. K. A study: OBD III standard and its predecessors OBD I and OBD II. *Design Engineering*. 2021. Pp. 1-11.
30. Data Control in the Diagnostics and Forecasting the State of Complex Technical Systems / D. S. Shibaev et al. *Herald of advanced information technology*. 2019. Vol. 2. Iss. 3. Pp. 183-196. DOI: <https://doi.org/10.15276/hait.03.2019.2>.
31. Analysis and structuring diagnostic large volume data of technical condition of complex equipment in transport / V.V. Vyuzhuzhanin et al. *IOP Conf. Series: Materials Science and Engineering*. 2020. Vol. 776. Pp. 1-12. doi: <https://doi.org/10.1088/1757-899X/776/1/012049>.
32. Cognitive Model of the Internal Combustion Engine / V. Vychuzhanin et al. *SAE Technical Paper*. 2018. DOI: <https://doi.org/10.4271/2018-01-1738>.
33. Ghosh A. Possibilities and Challenges for the Inclusion of the Electric Vehicle (EV) to Reduce the Carbon Footprint in the Transport Sector: A Review. *Energies*. 2020. Vol. 13. Article 2602. DOI: <https://doi.org/10.3390/en13102602>.
34. Higher Layer Protocols. URL: <https://kvaser.com/about-can/higher-layer-protocols/> (дата звернення 10.09.2024).
35. Items included in the J1939 Standards Collection. URL: <https://www.sae.org/standards/development/ground-vehicle/sae-j1939-standards-collection-on-the-web> (дата звернення 31.08.2024).
36. Vehicle Remote Health Monitoring and Prognostic Maintenance System / U. Shafi et al. *Journal of Advanced Transportation*. 2018. Vol. 2018. Pp. 1-10. DOI: <https://doi.org/10.1155/2018/8061514>.
37. Impact of Driver Behaviour on Fuel Consumption: Classification, Evaluation and Prediction Using Machine Learning / P. Ping et al. *IEEE Access*. 2019. Vol. 7. Pp. 78515-78532. DOI: <https://doi.org/10.1109/ACCESS.2019.2920489>.
38. Basak S., Sengupta S., Dubey A. Mechanisms for Integrated Feature Normalization and Remaining Useful Life Estimation Using LSTMs Applied to Hard-Disks. *2019 IEEE International Conference on Smart Computing (SMARTCOMP)*, Washington, DC, USA, 12-15 June 2019. Pp. 208-216. DOI: <https://doi.org/10.1109/SMARTCOMP.2019.00055>.
39. In-Vehicle Communication Cyber Security: Challenges and Solutions / Rathore R. S., Hewage C., Kaiwartya O., Lloret J. *Sensors*. 2022. Vol. 22. Article 6679. DOI: <https://doi.org/10.3390/s22176679>.
40. Development of a sensor-based learning approach to prognostics in intelligent vehicle health monitoring / I. S. Cole et al. *PHM-2008 : Proceedings of the 2008 International Conference on Prognostics and Health Management*, Denver, USA, 06-09 October 2008. Pp. 1-7. DOI: <https://doi.org/10.1109/PHM.2008.4711441>.
41. Predicting the need for vehicle compressor repairs using maintenance records and logged vehicle data / Prytz R., Nowaczyk S., Rognvaldsson T., Byttner S. *Engineering Applications of Artificial Intelligence*. 2015. Vol. 41. Pp. 139-150. DOI: <https://doi.org/10.1016/j.engappai.2015.02.009>.
42. Remote vehicle state of health monitoring and its application to vehicle no-start prediction / Y. Zhang et al. *AUTOTESTCON : Proceedings of the International Automatic Testing Conference*, Anaheim, CA, USA, 14-17 September 2009. Pp. 88-93. DOI: <https://doi.org/10.1109/AUTEST.2009.5314011>.
43. Naryal E., Kasliwal P. Real time vehicle health monitoring and driver information display system based on CAN and Android. *International Journal of Advance Foundation and Research in Computer*. 2014. Vol. 1. Iss. 11. Pp. 76-84.
44. A fuzzy diagnosis of multi-fault state based on information fusion from multiple sensors / H. Xue et al. *Journal of Vibroengineering*. 2016. Vol. 18. Iss. 4. Pp. 2135-2148. DOI: <https://doi.org/10.21595/jve.2016.16712>.
45. Dubois D., Prade H. Possibility Theory: An Approach to Computerized Processing of Uncertainty. Plenum Press, New York, USA, 1988. 280 p.
46. Data Mining Fruitful and Fun. URL: <https://orangedatamining.com/> (дата звернення 31.08.2024)
47. Automotive Vehicles Engine Health Dataset. URL: <https://www.kaggle.com/datasets/parvmodi/automotive-vehicles-engine-health-dataset/data> (дата звернення 31.08.2024).
48. The Application of Random Forest to Predictive Maintenance / R. Kizito et al. *Proceedings of the 2018 IISE Annual Conference*, Orlando, Florida, USA, 19-22 May 2018. Pp. 354-359.

49. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*. 2012. Vol. 25(2). Pp. 1097-1105. DOI: <https://doi.org/10.1145/3065386>.
50. Ruder S., Park S.M., Sim K.B. An overview of gradient descent optimization algorithms. 2017. DOI: <https://doi.org/10.48550/arXiv.1609.04747>.
51. Reyad M., Sarhan A. M., Arafa M. A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*. 2023. Vol. 35(23). Pp. 17095-17112. DOI: <https://doi.org/10.1007/s00521-023-08568-z>.
52. Reddi S. J., Kale S., Kumar S. On the Convergence of Adam and beyond. *ICLR 2018 : the Sixth International Conference on Learning Representations*, Vancouver, Canada, Mon Apr 30 April - 3 May 2018. Pp. 1-23. DOI: <https://doi.org/10.48550/arXiv.1904.09237>.
53. Chicco D., Jurman G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*. 2020. Vol. 21. Article 6. DOI: <https://doi.org/10.1186/s12864-019-6413-7>.

References:

1. V.Yu. Hritsuk, and Yu.V. Hritsuk, «Prohnostychnе obsluhovuvannia v avtomobilnomu servisi: vykorystannia IOT ta BIG DATA» [«Predictive maintenance in automotive service: using IOT and BIG DATA»], in Proc. Int. Conf. «Power plants and alternative energy sources», Kharkiv, Ukraine, 2024, pp. 264-266. (Ukr.)
2. V.Yu. Hrytsuk, and S.V. Pronin, «Perspektyvy vprovadzhennia prohnostychnoho obsluhovuvannia transportnykh zasobiv na osnovi mashynnoho navchannia» [«Prospects for the implementation of predictive vehicle maintenance based on machine learning»], in Proc. All-Ukrainian Conf. of higher education students and young scientists «Current state of research in the field of IT», Kharkiv, Ukraine, 2024, pp. 77-81. (Ukr.)
3. V.P. Mateichyk, V.P. Volkov, P.B. Komov, I.V. Gritsuk, A.P. Komov, and Ju.V. Volkov, «Osoblyvosti monitorynhu stanu transportnykh zasobiv z vykorystanniam bortovykh diahnostychnykh kompleksiv» [«Features of monitoring of vehicles state with using of board diagnostic complexes»], *Upravlinnia proektamy, systemnyi analiz i lohistyka – Project Management, Systems Analysis and Logistics*, vol. 13, pp. 126-138, 2014. (Ukr.)
4. I. Kuric, V. Mateichyk, M. Smieszek, M. Tsiuman, N. Goridko, and I. Gritsuk, «The peculiarities of monitoring road vehicle performance and environmental impact», *MATEC Web of Conferences*, vol. 244, pp. 1-7, 2018. doi: **10.1051/mateconf/201824403003**.
5. J. Engelbrecht, M.J. Booysen, F.J. Bruwer, and G.-J. van Rooyen, «Survey of smartphone-based sensing in vehicles for intelligent transportation system applications», *IET Intelligent Transport Systems*, vol. 9, № 10, pp. 924-935, 2015. doi: **10.1049/iet-its.2014.0248**.
6. S.H. Baek, and J.W. Jang, «Implementation of integrated OBD-II connector with external network», *Information Systems*, vol. 50, pp. 69-75, 2015. doi: **10.1016/j.is.2014.06.011**.
7. R. Malekian, N.R. Moloisane, L. Nair, B.T. Maharaj, and U.A.K. Chude-Okonkwo, «Design and Implementation of a Wireless OBD II Fleet Management System», *IEEE Sensors Journal*, vol. 17, № 4, pp. 1154-1164, 2017. doi: **10.1109/JSEN.2016.2631542**.
8. G.F. Türker, and A. Kutlu, «Survey of Smartphone applications based on OBD-II for Intelligent Transportation Systems», *International journal of engineering research and applications*, vol. 6, iss. 1, pp. 69-73, 2016.
9. M. Marjani et al., «Big IoT Data Analytics: Architecture, Opportunities, and Open Research Challenges», *IEEE Access*, vol. 5, pp. 5247-5261, 2017. doi: **10.1109/ACCESS.2017.2689040**.
10. I. Sittón Candanedo, E. Hernández Nieves, S. Rodríguez González, M.T. Santos Martín, and A. González Briones, «Machine learning predictive model for Industry 4.0», in Proc. 13th International Conference «Knowledge Management in Organizations», Žilina, Slovakia, 2018, pp. 501-510. doi: **10.1007/978-3-319-95204-8_42**.
11. J. Hernavs, M. Ficko, L. Berus, R. Rudolf, and S. Klancnik, «Deep Learning in Industry 4.0 – Brief Overview», *Journal of Production Engineering*, vol. 21, pp. 1-5, 2018. doi: **10.24867/JPE-2018-02-001**.
12. K. Kazi, «Reverse Engineering's Neural Network Approach to human brain», *Journal of Communication Engineering & Systems*, vol. 12, iss. 2, pp. 17-24, 2022. doi: **10.37591/joces.v12i2.951**.

13. K. Kazi, «Model for Agricultural Information system to improve crop yield using IoT», *Journal of Open Source Developments*, vol. 9, iss. 2, pp. 16-24, 2022.
14. N. Salunke, S. Chavan, N. Karanje, S. Kalbhor, and K.S. Kazi, «Announcement system in Bus», *Journal of Image Processing and Intelligent Remote Sensing*, vol. 2, iss. 6, pp. 1-10, 2022. **doi: 10.55529/jipirs.26.1.10.**
15. D.V. Swami, S.S. Thamake, N.S. Ubale, P.V. Lokhande, and K.K.S. Liyakat, «Sending notification to someone missing you through smart watch», *International Journal of Information Technology & Computer Engineering (IJITC)*, vol 2, iss. 8, pp. 19-24, 2022. **doi: 10.55529/ijitc.25.19.24.**
16. S. Wang, Y. Liu, C. Di Cairano-Gilfedder, S. Titmus, M.M. Naim, and A.A. Syntetos, «Reliability analysis for automobile engines: Conditional inference trees», *Procedia CIRP*, vol. 72, pp. 1392-1397, 2018. **doi: 10.1016/j.procir.2018.03.065.**
17. T. Gayathri, «A Survey on Vehicle Health Monitoring and Prediction System», *International Journal of Computer Science Trends and Technology (IJCTST)*, vol. 5, iss. 3, pp. 191-193, 2017.
18. V.P. Volkov, I.V. Gritsuk, Yu.V. Hrytsuk, Yu.V. Volkov, and M.V. Volodarets, *Informatsiini systemy monitorynhu tekhnichnoho stanu avtomobiliv* [Information systems for monitoring the technical condition of vehicles]. Kharkiv, Ukraine: FLP Panov A.M. Publ., 2018. (Ukr.)
19. I. Gritsuk et al., «The Complex Application of Monitoring and Express Diagnosing for Searching Failures on Common Rail System Units», *SAE Technical Paper*. 2018. **doi: 10.4271/2018-01-1773.**
20. D. Klets et al., «Information Security Risk Management of Vehicles», *SAE Technical Paper*, 2018. **doi: 10.4271/2018-01-0015.**
21. V.V. Aulyn, T.N. Zamota, A.V. Hrynkyv, A.A. Karaychev, and E.O. Kyrychenko, «Puty uluchsheniya sovremennoi systemi dyagnostirovaniya avtomobylei» [«Ways to improve modern car diagnostics system»], in Proc. Int. Sci.-Pract. Conf. «Increasing the reliability of machines and equipment», Kropyvnytskyi, 2019, pp. 218-223. (Rus.)
22. V. Pavlenko, V. Kuzhel, M. Khorin, «Sutnist avtomobilnoi diahnostryky pry vprovadzhenni ekspertnykh system» [«The essence of automobile diagnostics in the implementation of expert systems»], *Visnyk mashynobuduvannia – Bulletin of Mechanical Engineering and Transport*, № 2(12), pp. 85-92, 2020. **doi: 10.31649/2413-4503-2020-12-2-85-92.**
23. O.M. Shokarev, and N.I. Boltianska, «Zasoby diahnostryky suchasnykh avtotransportnykh zasobiv» [«Diagnostic tools for modern vehicles»], in Proc. II Int. Sci.-Pract. Conf. «Technical support for innovative technologies in the agro-industrial complex», Kropyvnytskyi, 2020, pp. 450-454. (Ukr.)
24. V. Nalina, and P. Jayarekha, «Real Time Automated Vehicle Monitoring and Control System Using Internet of Vehicles», *International Journal of Computer Sciences and Engineering*, vol. 6, pp. 491-494, 2018. **doi: 10.26438/ijcse/v6i3.491494.**
25. D. Kusumaningrum, N. Kurniati, and B. Santosa, «Machine Learning for Predictive Maintenance», in Proc. Int. Conf. on Industrial Engineering and Operations Management, Sao Paulo, Brazil, 2021, pp. 2348-2356.
26. Vehicle Maintenance Data. [Online]. Available: <https://www.kaggle.com/datasets/chavindudulaj/vehicle-maintenance-data>. Accessed on: August 31, 2024.
27. P. Do, V.-T. Nguyen, A. Voisin, B. Iung, and W.A. Ferreira Neto, «Multi-agent deep reinforcement learning-based maintenance optimization for multi-dependent component systems», *Expert Systems with Applications*, vol. 245, article 123144, 2024. **doi: 10.1016/j.eswa.2024.123144.**
28. Y.H. Ali, «Artificial Intelligence Application in Machine Condition Monitoring and Fault Diagnosis», in *Artificial Intelligence*, chapter 14, 2018. **doi: 10.5772/intechopen.74932.**
29. S.K. Singh, and A.K. Singh, «A study: OBD III standard and its predecessors OBD I and OBD II», *Design Engineering*, pp. 1-11, 2021.
30. D.S. Shibaev, V.V. Vyuzhuzhanin, N.D. Rudnichenko, N.O. Shibaeva, and T.V. Otradskaia, «Data Control in the Diagnostics and Forecasting the State of Complex Technical Systems», *Herald of advanced information technology*, vol. 2, iss. 3, pp. 183-196, 2019. **doi: 10.15276/haict.03.2019.2.**
31. V.V. Vyuzhuzhanin et al., «Analysis and structuring diagnostic large volume data of technical condition of complex equipment in transport», *IOP Conf. Series: Materials Science and Engineering*, vol. 776, pp. 1-12, 2020. **doi: 10.1088/1757-899X/776/1/012049.**
32. V. Vychuzhanin et al., «Cognitive Model of the Internal Combustion Engine», *SAE Technical Paper*, 2018. **doi: 10.4271/2018-01-1738.**

33. A. Ghosh, «Possibilities and Challenges for the Inclusion of the Electric Vehicle (EV) to Reduce the Carbon Footprint in the Transport Sector: A Review», *Energies*, vol. 13, article 2602, 2020. **doi: 10.3390/en13102602**.
34. Higher Layer Protocols. [Online]. Available: <https://kvaser.com/about-can/higher-layer-protocols/>. Accessed on: September 10, 2024.
35. Items included in the J1939 Standards Collection. [Online]. Available: <https://www.sae.org/standards/development/ground-vehicle/sae-j1939-standards-collection-on-the-web>. Accessed on: August 31, 2024.
36. U. Shafi, A. Safi, A.R. Shahid, S. Ziauddin, and M.Q. Saleem, «Vehicle Remote Health Monitoring and Prognostic Maintenance System», *Journal of Advanced Transportation*, vol. 2018, pp. 1-10, 2018. **doi: 10.1155/2018/8061514**.
37. P. Ping, W. Qin, Y. Xu, C. Miyajima, and K. Takeda, «Impact of Driver Behaviour on Fuel Consumption: Classification, Evaluation and Prediction Using Machine Learning», *IEEE Access*, vol. 7, pp. 78515-78532, 2019. **doi: 10.1109/ACCESS.2019.2920489**.
38. S. Basak, S. Sengupta, and A. Dubey, «Mechanisms for Integrated Feature Normalization and Remaining Useful Life Estimation Using LSTMs Applied to Hard-Disks», in Proc. IEEE Int. Conf. on Smart Computing (SMARTCOMP), Washington, DC, USA, 2019, pp. 208-216. **doi: 10.1109/SMARTCOMP.2019.00055**.
39. R.S. Rathore, C. Hewage, O. Kaiwartya, and J. Lloret, «In-Vehicle Communication Cyber Security: Challenges and Solutions», *Sensors*, vol. 22, article 6679, 2022. **doi: 10.3390/s22176679**.
40. I.S. Cole et al. «Development of a sensor-based learning approach to prognostics in intelligent vehicle health monitoring», in Proc. 2008 Int. Conf. on Prognostics and Health Management, Denver, USA, 2008, pp. 1-7. **doi: 10.1109/PHM.2008.4711441**.
41. R. Prytz, S. Nowaczyk, T. Rognvaldsson, and S. Byttner, «Predicting the need for vehicle compressor repairs using maintenance records and logged vehicle data», *Engineering Applications of Artificial Intelligence*, vol. 41, pp. 139-150, 2015. **doi: 10.1016/j.engappai.2015.02.009**.
42. Y. Zhang et al., «Remote vehicle state of health monitoring and its application to vehicle no-start prediction», in Proc. Int. Automatic Testing Conf. AUTOTESTCON, Anaheim, CA, USA, 2009, pp. 88-93. **doi: 10.1109/AUTEST.2009.5314011**.
43. E. Naryal, and P. Kasliwal, «Real time vehicle health monitoring and driver information display system based on CAN and Android», *International Journal of Advance Foundation and Research in Computer*, vol. 1, iss. 11, pp. 76-84, 2014.
44. H. Xue, Z. Li, Y. Li, H. Jiang, and P. Chen, «A fuzzy diagnosis of multi-fault state based on information fusion from multiple sensors», *Journal of Vibroengineering*, vol. 18, iss. 4, pp. 2135-2148, 2016. **doi: 10.21595/jve.2016.16712**.
45. D. Dubois, and H. Prade, *Possibility Theory: An Approach to Computerized Processing of Uncertainty*. New York, USA: Plenum Press Publ., 1988.
46. Data Mining Fruitful and Fun. [Online]. Available: <https://orangedatamining.com/>. Accessed on: August 31, 2024.
47. Automotive Vehicles Engine Health Dataset. [Online]. Available: <https://www.kaggle.com/datasets/parvmodi/automotive-vehicles-engine-health-dataset/data>. Accessed on: August 31, 2024.
48. R. Kizito, P. Scruggs, X. Li, R. Kress, M. Devinney, and T. Berg, «The Application of Random Forest to Predictive Maintenance», in Proc. 2018 IISE Annual Conference, Orlando, Florida, USA, 2018, pp. 354-359.
49. A. Krizhevsky, I. Sutskever, and G.E. Hinton, «ImageNet classification with deep convolutional neural networks», *Advances in Neural Information Processing Systems*, vol. 25(2), pp. 1097-1105, 2012. **doi: 10.1145/3065386**.
50. S. Ruder, S.M. Park, and K.B. Sim, «An overview of gradient descent optimization algorithms», 2017. **doi: 10.48550/arXiv.1609.04747**.
51. M. Reyad, A.M. Sarhan, and M. Arafa, «A modified Adam algorithm for deep neural network optimization», *Neural Computing and Applications*, vol. 35(23), pp. 17095-17112, 2023. **doi: 10.1007/s00521-023-08568-z**.
52. S.J. Reddi, S. Kale, and S. Kumar, «On the Convergence of Adam and beyond», in Proc. 6-th Int. Conf. on Learning Representations ICLR 2018, Vancouver, Canada, 2018, pp. 1-23. **doi: 10.48550/arXiv.1904.09237**.

53. D. Chicco, and G. Jurman, «The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation», *BMC Genomics*, vol. 21, article 6, 2020. doi: 10.1186/s12864-019-6413-7.

Стаття надійшла 05.10.2024

Стаття прийнята 26.10.2024

УДК 004.94:378.091

doi: 10.31498/2225-6733.49.1.2024.321210

© Мальцева О.В.¹, Кривенко О.В.²

МОДЕЛЮВАННЯ БІЗНЕС-ПРОЦЕСІВ ЩОДО СУПРОВОДУ ВСТУПНОЇ КАМΠΑНІЇ У ДВНЗ «ПРИАЗОВСЬКИЙ ДЕРЖАВНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ»

У статті розглянуто застосування структурно-функціонального моделювання в освітній сфері з метою оптимізації основних бізнес-процесів. Враховуючи тенденцію на зменшення кількості вступників до ДВНЗ «Приазовський державний технічний університет», що намітилася за підсумками вступної кампанії 2024 року, проведено докладний аналіз чинної моделі керування внутрішньою системою забезпечення якості освіти. Виявлено місце вступної кампанії у цій системі, проаналізовано взаємодію з іншими бізнес-процесами задля переосмислення цього досвіду та пошуку нової бізнес-моделі набору студентів на навчання. Розроблено структурно-функціональну модель бізнес-процесу вступної кампанії у ДВНЗ «ПДТУ» «AS-IS» («ЯК Є») з позицій приймальної комісії та з огляду на її подальший аналіз та впровадження заходів реінжинірингу. Для побудови моделі бізнес-процесу вступної кампанії було залучено методологію SADT, а саме: стандарт функціонального моделювання і опису бізнес-процесів – IDEF0. Проєктування в нотації IDEF0 контекстної моделі «Набір студентів (вступна кампанія)» відбило загальну картину бізнес-процесу, визначило його зовнішні та внутрішні зв'язки, способи взаємодії з підсистемами та функціями, що супроводжують кожен етап вступної кампанії. У результаті виокремлення компонентів моделі першої декомпозиції проведено ідентифікацію та опис підпроцесів бізнес-процесу «Набір студентів (вступна кампанія)». Графічно представлено функціональні блоки, що відображають життєві цикли процесу вступної кампанії («Планування вступної кампанії»; «Організація вступної кампанії»; «Виконання вступної кампанії»; «Контроль і корекція вступної кампанії»), охарактеризовано кожний із них. На другому рівні декомпозиції розбудовано дерево вузлів бізнес-процесів та визначено субпроцеси, що є складниками підпроцесів. Створена модель «AS-IS» («ЯК Є») базується на реальному стані справ та передбачає її подальшу оптимізацію, тобто побудову моделі «TO-BE» («ЯК БУДЕ»).

Ключові слова: структурно-функціональне моделювання, нотація IDEF0, моделювання бізнес-процесів в освітній сфері, бізнес-процеси щодо супроводу вступної кампанії, приймальна комісія, заклад вищої освіти, ДВНЗ «ПДТУ».

O.V. Maltseva, O.V. Kryvenko. Modeling of business processes to support the admission campaign at the SHEI «Priazovsky State Technical University». The article considers the application of structural and functional modeling in the educational sphere in order to optimize the main business processes. Given the trend towards a decrease in the number

¹ магістрантка, ДВНЗ «Приазовський державний технічний університет», м. Дніпро, ORCID: 0000-0002-1497-4098, maltseva_o_v@pstu.edu

² канд. техн. наук, доцент, ДВНЗ «Приазовський державний технічний університет», м. Дніпро, ORCID: 0009-0006-2860-6575, krivenko_o_v@pstu.edu