

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 багатоетапного 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, проєктування, 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, проєктування, 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 ($M_{\text{поч.}}^{\text{рез.}}$); остаточний рівень знань і вмінь суб'єкта навчання (π); 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 ($M_{\text{поч.}}^{\text{рез.}}$, $M_{\text{ост.}}^{\text{рез.}}$) 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 $[0,1]$.

$$R_j = \frac{\sum_{i \in \tilde{Q}} R_i \cdot C_i}{\sum_{i \in \tilde{Q}} C_i}, \quad (10)$$

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

$$B_i \Rightarrow \Phi_i \Rightarrow O_i \Rightarrow K_i \Rightarrow B_2 \Rightarrow \Phi_2 \Rightarrow O_2 \Rightarrow K_2 \Rightarrow \dots B_i \Rightarrow \Phi_i \Rightarrow O_i \Rightarrow K_i \Rightarrow \dots B_n \Rightarrow \Phi_n \Rightarrow O_n \Rightarrow K_n, (i = 1, \dots, n) \quad (12)$$

де n – кількість кроків набуття знань; B_i – сприйняття еталона знань (ЕТЗ) на кроці i ; Φ_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; $S = \{S_1, \dots, S_n\}$ – 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. Φ_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; φ – 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

$$\frac{U(t)}{U_0} = \frac{\varphi}{U_0} + \left(1 - \frac{\varphi}{U_0}\right)e^{-t/T}. \quad (15)$$

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 $M_{зз}$ і еталона знань M_e . Експериментальні результати показують, що $\bar{\varphi} \approx 0,1$ [16]. Це означає, що обсяг залишкових знань $M_{зз}$ становить близько 10 % від первісно набутих знань за умови $t \rightarrow \infty$. Якщо за деякий проміжок часу Δt знання будуть відтворені, зіставлені з еталоном M_e і сприйняті повторно, тоді їх ступінь толерантності знову набуде значення, близького до 1. Очевидно, що менший проміжок часу Δt , то більш згладженою буде крива залежності ступеня толерантності від часу. За умови досить малого інтервалу Δt значення ступеня толерантності незначно відрізнятиметься від 1 (рис. 5).




Рис. 5. Графік залежності ступеня толерантності від часу за умови періодичного відтворення залишкових знань

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 $E(M_{li}; M_{ei})$, і тільки після цього повторно здійснити сприйняття еталона M_e , якщо $E(M_{li}; M_{ei}) \neq 1$. У цьому разі активується шлях до образу M_{li} еталона знань і за умови повторного сприйняття еталона

знань M_{ei} 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_{ei} .

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_{ei} (предикат $E(M_{li}; M_{ei})$) – перехід у кінець алгоритму оновлення знань, інакше – перехід до наступного пункту алгоритму.
4. B_i – сприйняття еталона знань M_{ei} на кроці i .
5. ϕ_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 $M_i = \varphi(M_{li})$ і реалізацію предиката $E(M_{li}; M_e)$, є найнефективнішими, 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); $I_n = \{I_0, i_n\}$ – ступінь інтегральності впливу (сфера застосовності впливу), де I_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
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
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., Kozyriyev, 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
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>

Надійшла (Received) 01.02.2025

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; 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; 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>