

DOI <https://doi.org/10.32782/2220-8674-2026-16-1-29>

УДК 004.85:37.013.2

А. С. Янко, канд. техн. наук, доцент

ORCID: 0000-0003-2876-9316

М. С. Мизюра, аспірант

ORCID: 0009-0009-9301-2054

Національний університет «Полтавська політехніка імені Юрія Кондратюка»

e-mail: al9_yanko@ukr.net

МОДЕЛЬ ПЕРСОНАЛІЗАЦІЇ НАВЧАЛЬНОГО ПРОЦЕСУ ЧЕРЕЗ ІНТЕГРАЦІЮ LLM У ВЕБЗАСТОСУНОК ІЗ ДИНАМІЧНОЮ ГЕНЕРАЦІЄЮ ПОЯСНЕНЬ

Анотація. Об'єктом дослідження є персоналізація навчальної взаємодії у вебзастосунках на основі великих мовних моделей (LLM) як адаптивного пояснювального ядра. Предметом – модель динамічної генерації роз'яснень, що адаптує складність та стиль викладу до когнітивного профілю та історії помилок студента. Метою роботи є теоретичне обґрунтування та розвиток моделі персоналізації навчального процесу через інтеграцію LLM у структуру вебзастосунку для створення динамічного циклу генерації індивідуальних пояснень із забезпеченням безперервного зворотного зв'язку. Наукова новизна полягає у поєднанні когнітивного профілювання та оркестрування промптів, що враховує структуру помилок, темп діяльності та ознаки рефлексії. Практична значущість підтверджується можливістю вбудовування запропонованої моделі у наявні LMS/EdTech-платформи, скороченням часу на формування пояснення та підвищенням приросту навчальних результатів у контрольованому експерименті.

Ключові слова: персоналізація навчання, великі мовні моделі, вебзастосунок, адаптивне пояснення, когнітивний профіль, контекстне вікно, інтелектуальні системи навчання, генеративний ШІ.

Постановка проблеми. Сучасний етап розвитку світової цифрової освіти характеризується зміною фундаментальної парадигми взаємодії у тріаді «викладач – навчальний матеріал – студент» під впливом генеративного штучного інтелекту. Швидке проникнення великих мовних моделей (LLM) у навчальний процес створює передумови для вирішення «проблеми 2-х сигм» [1, с. 5], що полягає у пошуку методів групового навчання, які за ефективністю не поступалися б індивідуальному репетиторству. На світовому рівні актуальність дослідження зумовлена необхідністю подолання неоднорідності студентських груп у дистанційних курсах. Здобувачі зазвичай мають різний когнітивний багаж, працюють з абстракціями у власному темпі та обирають несхожі навчальні стратегії [2, с. 207].

Статичні сценарії сучасних вебкурсів часто ігнорують ці відмінності, що призводить до когнітивного перевантаження одних студентів та недостатньої мотивації інших [3, с. 845; 4, с. 4]. Наукова новизна роботи полягає у розробці моделі динамічної генерації пояснень, яка, на відміну від існуючих чат-ботів, інтегрує LLM як кероване ядро, що адаптується до структури помилок та ознак метакогнітивної рефлексії студента [5, с. 1; 6, с. 151]. Актуальність роботи також підкріплюється державними пріоритетами України щодо цифровізації освіти та розвитку цифрових компетентностей [4, с. 5; 7, с. 1].

Аналіз останніх досліджень. Розвиток інтелектуальних систем навчання за останні десять років демонструє поступову трансформацію від жорстко детермінованих алгоритмів [8, с. 185] до гнучких архітектур на основі глибокого навчання [9, с. 603]. Аналіз актуальних публікацій у провідних наукових виданнях дозволяє констатувати зміну парадигми: від використання



статичних тьюторів до впровадження динамічних екосистем, побудованих навколо великих мовних моделей (LLM).

У роботі [5, с. 6] обґрунтовано, що застосування LLM-орієнтованих фреймворків у поєднанні з рефлексивним контуром пам'яті дозволяє досягти високого рівня персоналізації, особливо у складних технічних доменах, як-от навчання програмуванню. Дослідження [10, с. 2] розширює цей підхід, доводячи, що інтеграція архітектури RAG (Retrieval-Augmented Generation) та знанневих графів критично підвищує фактологічну точність генеративних відповідей, мінімізуючи ризики «галюцинацій» ШІ у вузькоспеціалізованих дисциплінах.

Ефективність використання сучасних моделей (зокрема GPT-4) як бази для інтелектуальних тьюторських систем нового покоління підтверджується у дослідженні [11, с. 4], де акцентовано на важливості модульної інженерії для забезпечення педагогічної адаптивності. Водночас у публікаціях [12, с. 1; 13, с. 4] зазначається, що ключовою невирішеною частиною загальної проблеми залишається відсутність прозорих механізмів профілювання, що без належної системи пояснень може спровокувати когнітивну пасивність здобувачів.

Незважаючи на значну кількість розробок, поза увагою дослідників часто залишається питання безперервного динамічного коригування складності пояснень на основі аналізу структури помилок у реальному часі. Саме вирішенню цієї наукової задачі, що базується на синтезі когнітивного профілювання та адаптивного оркестрування промптів, присвячується дана стаття.

Формулювання мети статті (постановка завдання). Метою статті є теоретичне обґрунтування та розробка моделі персоналізації навчального процесу через інтеграцію великих мовних моделей у структуру вебзастосунку для створення динамічного циклу генерації індивідуальних пояснень.

Необхідність розробки зумовлена тим, що у прикладних освітніх вебсистемах часто використовують або шаблонні підказки, або універсальні чат-боти з фіксованим стилем відповіді. Такий підхід має чотири критичні вади:

1. Відсутня безперервна підстройка складності під поточний когнітивний стан.
2. Недостатньо враховується тип помилки (концептуальна, процедурна, термінологічна, рефлексивна).
3. Контекстне вікно використовується фрагментарно, тож історія взаємодії слабо впливає на нове пояснення.
4. Масштабування ускладнюється через залежність від викладача як єдиного джерела індивідуальних пояснень [14, с. 3].

Для подолання цих недоліків та досягнення поставленої мети сформовано такі завдання:

1. Формалізувати опис стану здобувача через когнітивний вектор $v(t)$.
2. Розробити 7-кроковий алгоритм динамічного пояснювального циклу.
3. Описати структуру та педагогічні функції модулів персоналізації (див. табл. 1).
4. Експериментально перевірити ефективність запропонованого підходу.

Основний матеріал і результати досліджень. Запропонована модель докорінно змінює логіку взаємодії: пояснення будується як керований цикл з кількох кроків: оцінювання профілю → оркестрування контексту → генерація → перевірка педагогічних обмежень → оновлення профілю. Це переводить систему зі стану «статичний асистент» у стан «динамічний пояснювальний цикл».

Взаємодія компонентів системи та їхнє функціональне навантаження представлені у Таблиці 1.

Загальна структурно-функціональна схема взаємодії зазначених модулів у межах розробленої архітектури представлена на рис. 1.

Модель описує здобувача через когнітивний вектор $v(t) = \{k_t, p_t, r_t, m_t, e_t\}$, де k_t – предметні знання, p_t – процедурна компетентність, r_t – рефлексивність, m_t – мотиваційна стійкість, e_t –

Таблиця 1

Порівняльна характеристика модулів персоналізації навчального вебзастосунку

Модуль	Вхідні дані	Вихідні дані	Педагогічна функція
Профілювання здобувача	логи взаємодії, результати тестів, темп виконання	когнітивний вектор $v(t)$	визначення рівня складності та каналу пояснення
Контекстний оркестратор	$v(t)$, історія діалогу, освітній сценарій	структурований промпт $P(t)$	підготовка даних для LLM без втрати дидактичної мети
Генератор пояснень	$P(t)$, база прикладів, правила оцінювання	індивідуалізований фрагмент пояснення $E(t)$	адаптація стилю, глибини та прикладів до профілю
Петля зворотного зв'язку	реакції студента, уточнення, нові помилки	оновлений $v(t + 1)$, корекція стратегії	безперервне покращення якості підтримки



Рис. 1. Архітектура моделі персоналізації з динамічною генерацією пояснень

індикатор когнітивного навантаження. Оцінювання компонентів відбувається за гібридною схемою: мікротести, поведінкові логи та аналіз мовленнєвих актів у діалозі.

Оновлення когнітивного профілю задається рекурентним правилом:

$$v(t + 1) = \alpha \cdot v(t) + (1 - \alpha) \cdot \Phi(x_t, y_t, h_t), \tag{1}$$

- де x_t – набір навчальних дій на кроці t ;
- y_t – якість відповіді;
- h_t – часові та метаповедінкові ознаки;
- $\Phi(\cdot)$ – агрегувальний оператор профілювання;
- α – коефіцієнт інерційності стану.

Динамічну складність пояснення визначає функція:

$$c_t = \sigma(w_1 \cdot (1 - k_t) + w_2 \cdot e_t + w_3 \cdot \delta_t + w_4 \cdot u_t), \tag{2}$$

де w_1 – вагові коефіцієнти, які визначають пріоритетність (вплив) кожного фактора на фінальний рівень складності пояснення c_t ;

- δ_t – параметр, що описує тип і глибину помилки;
- u_t – параметр, що описує невизначеність моделі щодо наміру студента.

Значення інтегрального показника складності c_t , розраховане згідно з формулою (2), визначає стратегію формування відповіді. Зокрема, при низьких значеннях c_t система генерує лаконічні евристичні підказки (натяжки), стимулюючи самостійну рефлексію. При зростанні показника c_t , модель автоматично переходить до детальшого покрокового розбору матеріалу, додаючи аналогії та контрприкладів для подолання зафіксованих когнітивних бар'єрів.

Оптимізаційний критерій генерації пояснень має форму:

$$L = \lambda_1 \cdot Err + \lambda_2 \cdot Load + \lambda_3 \cdot Time - \lambda_4 \cdot Gain, \tag{3}$$



де λ_i – коефіцієнтами штрафу та заохочення (вагами регуляризації), які визначають «ціну» кожної складової при виборі найкращого варіанта пояснення;

Err – частота повторної помилки після пояснення;

Load – індекс когнітивного перевантаження;

Time – затримка відповіді;

Gain – приріст засвоєння знань у мікроциклі.

Мінімізацію L за формулою (3) забезпечує налаштування промпт-стратегії, довжини контексту та типу прикладів.

Окремий акцент зроблено на роботі контекстного вікна LLM. Замість механічного накопичення історії використано селективне наповнення: до контексту потрапляють лише фрагменти, релевантні поточному наміру навчання (типові помилки, останні успіхи, персональні «зони ризику»). Це зменшує шум, стабілізує відповіді і допомагає ефективно працювати навіть за обмеженого вікна у довгих сесіях [15, с. 1].

Ще один важливий компонент – педагогічний фільтр. Після генерації відповідь LLM проходить перевірку дидактичних обмежень: відповідність цілі заняття, коректність термінів, допустимий рівень абстракції та наявність мотиваційного елемента. Це знижує ризик ситуацій, коли технічно правильний текст не працює як навчальне пояснення.

На основі аналізу [10]–[13] у роботі застосовано підхід «керованої цитованості». Наприклад, висновок із [11, с. 5] про те, що «generative ITSs represent a transformative approach to personalized education through real-time adaptability», інтерпретується як потреба вбудувати адаптацію всередину самого алгоритму генерації, а не залишати її на рівні зовнішніх правил. Інше положення з [10, с. 3] щодо «critical need for domain-specific knowledge support» реалізовано через підмодуль тематичних мікроконтекстів, які додаються до промпту лише тоді, коли зафіксовано семантичний дефіцит.

Експериментальну перевірку проведено в навчальному вебзастосунку з дисципліни «Основи аналізу даних». Сформовано дві групи (контрольна та експериментальна), які проходили однакові тематичні модулі. Відмінність була лише у механізмі пояснень: у контролі працював статичний чат-бот, у експерименті – алгоритм динамічної генерації. Період спостереження становив 12 тижнів. Початкові значення в обох групах були статистично близькими. Після впровадження динамічної персоналізації зафіксовано стабільно вищий темп приросту засвоєння. Візуалізація порівняльної динаміки середнього показника засвоєння впродовж 12-тижневого навчального циклу наведена на рис. 2. Додатково оцінювалися: частота повторних запитів, час до розуміння нового поняття, частка коректних самопояснень і кількість звернень до викладача. Узагальнені результати проведеного педагогічного експерименту та їх порівняльна характеристика наведені в табл. 2.

Окремо оцінено відповідність рівня пояснення профілю здобувача. Дані показали, що найбільший приріст отримується тоді, коли адаптація враховує не лише рівень знань, а й компоненти рефлексії та когнітивного навантаження. Ця закономірність підтверджується побудованою матрицею релевантності рівня пояснення до параметрів когнітивного профілю (див. рис. 3).

Методика обчислювального експерименту. Для відтворюваності застосовано тривірневий протокол: рівень мікрвзаємодій – якість окремого пояснення; рівень сесії – інтегральний прогрес за 60–90 хв; рівень навчального циклу – підсумковий приріст компетентності за 12 тижнів. На першому рівні фіксували латентність відповіді LLM, кількість уточнень до коректного розуміння, частоту повтору помилки та індекс самопояснення. На другому рівні додавали індикатори стійкості уваги, динаміку складності задач і частку завершення блоку без зовнішньої допомоги. На третьому рівні узагальнювали передтест/післятест, утримання знань за відкладеним тестом і перенос навичок на нові типи завдань.

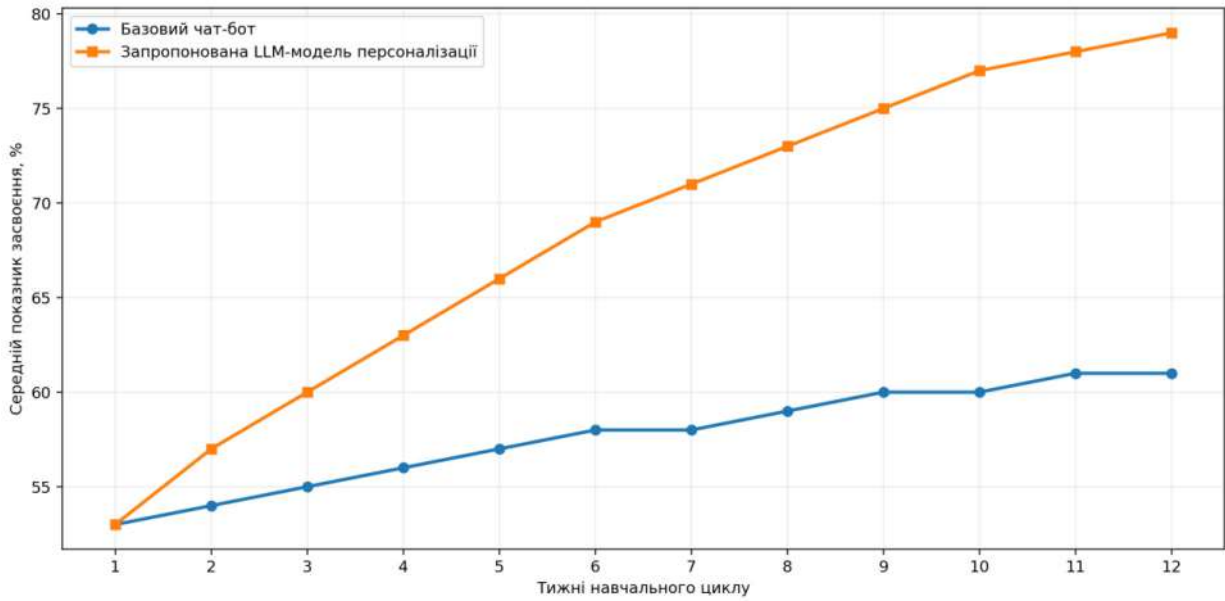


Рис. 2. Динаміка середнього показника засвоєння впродовж навчального циклу

Таблиця 2

Результати педагогічного експерименту ($n = 86$)

Група	Передтест, %	Післятест, %	Приріст, %	Час на пояснення (с)
Контрольна (чат-бот без адаптації)	54,2	63,1	8,9	12,7
Експериментальна (динамічна генерація)	54,0	77,8	23,8	7,4

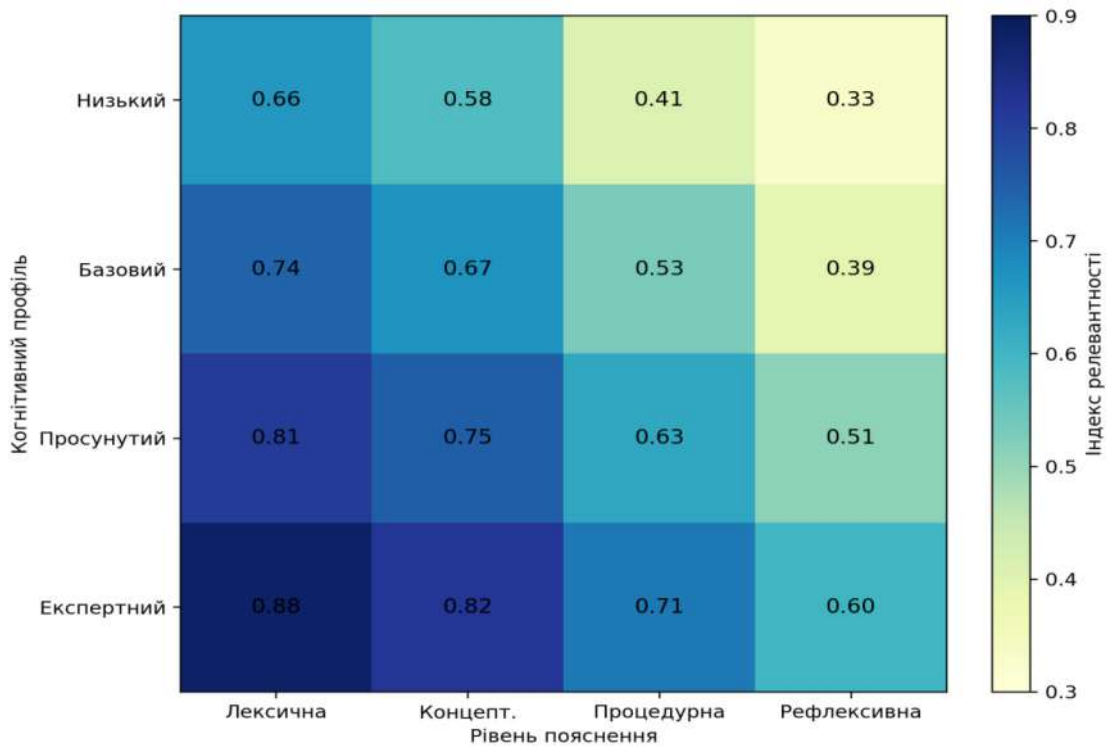


Рис. 3. Матриця релевантності рівня пояснення до когнітивного профілю



Щоб зменшити ефект «новизни інструмента», передбачили двотижневий адаптаційний період. Показники цього етапу не включалися до фінальної статистики і використовувалися лише для калібрування ваг у формулах (1)–(3). Вплив викладача контролювався: матеріали, дедлайни та критерії оцінювання для обох груп були однаковими. Розподіл студентів будували так, щоб вирівняти стартовий бал, попередній досвід роботи з чат-ботами та інтенсивність відвідувань. Аналіз чутливості до параметра α показав найстабільнішу роботу в інтервалі 0,62–0,74: модель зберігає пам'ять про динаміку профілю, але не «залипає» на застарілих оцінках.

Алгоритм динамічної генерації реалізовано як 7-крокову послідовність: 1) збір поточних ознак взаємодії; 2) оновлення вектора $v(t+1)$; 3) оцінка цільового рівня c_i ; 4) формування контекстного пакета k_t з відбором релевантних фрагментів; 5) генерація кандидатів $e_1...e_n$ різної довжини й стилю; 6) ранжування за критерієм L та педагогічними обмеженнями; 7) подання найкращого кандидата і донавчання профілю за реакцією користувача. На відміну від одно-разових промптів, у контур вбудовано «самоперевірку»: модель генерує коротку валідаційну репліку (контрольне питання або мікрозавдання), щоб відрізнити реальне розуміння від формальної згоди.

Для педагогічної ефективності критичним виявився контроль стилю пояснення. У моделі використовуються чотири базові стилі: інструктивний (чіткі кроки), евристичний (натяки та запитання), аналогічний (побутові або професійні аналогії) і рефлексивний (самоперевірка). Перехід між стилями відбувається автоматично на основі історії успішності. Наприклад, якщо студент швидко проходить процедури, але плутає базові поняття, система зменшує процедурну деталізацію і посилює концептуальні аналогії. Якщо ж з'являється довга серія повторних помилок одного класу, активується рефлексивний режим із короткими контрольними запитаннями після кожного блоку.

Додатково проаналізовано вплив довжини контекстного вікна на якість пояснень. Тестувалися три режими: короткий (до 2 тис. токенів), середній (4–8 тис.) і розширений (понад 8 тис.). Виявлено, що збільшення вікна не дає автоматичного зростання якості: у частині сценаріїв надмірний контекст, навпаки, погіршував педагогічну чіткість через домішки нерелевантних фрагментів. Тому в архітектурі закладено принцип «керованої компактності»: вікно розширюється лише за індикаторів складної помилки або низької впевненості моделі. Це узгоджується з висновками [10, с. 3] про критичність контекстно-специфічної підтримки знаннями.

Порівняння типових сценаріїв використання показало, що найпомітніший ефект спостерігається у трьох випадках: (1) первинне опанування нової теми, коли важливо швидко сформулювати базову інтуїцію; (2) корекція стійких помилок після контрольних завдань; (3) передекзаменаційне повторення, де критично важливі короткі адаптивні мікропояснення. У рутинному тренуванні простих задач відрив від базового чат-бота менший, бо там домінує ефект повторення, а не складна інтерпретація матеріалу. Отже, модель найдоцільніше застосовувати у «вузьких місцях» навчального процесу, де стандартні пояснення працюють слабо.

Педагогічне трактування результатів спирається на теорію когнітивного навантаження [2, с. 203] і механізм самопояснення [6, с. 153]. Коли пояснення синхронізується з поточним рівнем підготовки, зменшується частка зовнішнього (непродуктивного) навантаження і зростає змістове опрацювання. У цьому сенсі LLM працює не просто як «джерело відповіді», а як інструмент дозування складності. Це пояснює, чому експериментальна група показала не лише кращий тестовий бал, а й вищий трансфер знань на нові задачі.

Аналіз ризиків і загроз валідності. Внутрішню валідність потенційно знижував мотиваційний фактор: частина студентів експериментальної групи могла бути активнішою через новизну технології. Для компенсації використано адаптаційний період і нормалізацію за інтенсивністю взаємодії. Зовнішня валідність обмежена дисципліною, рівнем підготовки та мовою контенту,



тож пряме перенесення числових коефіцієнтів на інші галузі потребує окремої перевірки. Конструктивна валідність пов'язана з тим, що когнітивний профіль є латентною величиною: його оцінка залежить від якості проксі-ознак (час, патерни помилок, мовні маркери). Надійність підвищували багатоканальним оцінюванням і перехресною перевіркою на відкладеній підвибірці.

Етичні й організаційні аспекти впровадження. Інтеграція LLM у навчання має тримати баланс між персоналізацією та автономією мислення. Якщо система занадто швидко дає «готові» відповіді, зростає ризик зниження самостійної інтелектуальної активності, що також фіксують сучасні огляди [13, с. 2; 16, с. 110]. Тому модель реалізує режим «ступового розкриття»: спочатку натяк або напрям думки, а повніше пояснення, після спроби самостійного кроку. Додатково ведеться журнал прозорості, де фіксуються версія моделі, параметри промпту, тип профілю та педагогічний шаблон відповіді. Це створює основу для аудиту якості в межах інституційного контролю академічної доброчесності.

Практичні рекомендації для закладів освіти. Доцільна поетапна стратегія впровадження: пілот на одній дисципліні → методичне налаштування профілів → масштабування на курс або програму. На першому етапі важливо зібрати локальний корпус типових помилок і прикладів «якісного пояснення» від викладачів. На другому зафіксувати правила ескалації складних випадків до людини-експерта. На третьому впровадити аналітичну панель із ключовими метриками (приріст балів, частка повторних помилок, середня латентність, індекс задоволеності). Такий підхід запобігає техноцентричному впровадженню і прив'язує LLM-модель до реальних освітніх цілей.

Обговорення результатів. Отримані дані узгоджуються з класичними педагогічними спостереженнями про переваги індивідуалізованого супроводу (ефект у [1, с. 11]), але на відміну від традиційного репетиторства модель забезпечує масштабованість у вебсередовищі. Ключовий внесок у приріст ефективності дають три чинники: (1) адаптивний добір складності; (2) кероване використання контекстного вікна LLM; (3) замкнений цикл зворотного зв'язку з оновленням профілю після кожної мікрвзаємодії.

Порівняння з іншими роботами показує, що модель концептуально близька до модульних підходів [11, с. 2], але розширює їх завдяки явно заданому критерію оптимізації пояснення та глибшій персоналізації стилю. На відміну від суто рекомендаційних систем [12, с. 3], рішення сфокусоване на інтерпретації матеріалу і подоланні конкретної навчальної помилки. Порівняно з підходами когнітивного профілювання [13, с. 2], акцент зроблено на оперативній динаміці профілю всередині однієї сесії, а не лише на міжсеместровій аналітиці.

Практично важливий наслідок – зниження навантаження на викладача. У масовому змішаному навчанні викладач часто фізично не встигає дати індивідуальне пояснення саме в момент появи труднощів. Автоматизований механізм персоналізованих роз'яснень частково закриває цей розрив і вивільняє час для складніших завдань: проєктування активностей, верифікація змісту, етичне модераторство.

Разом із перевагами виявлено і обмеження. По-перше, якість генерації залежить від повноти бази прикладів і якості первинної розмітки помилок. По-друге, у спеціалізованих темах потрібне додаткове доменне налаштування, інакше зростає ризик неточних узагальнень. По-третє, необхідне постійне дотримання принципів академічної доброчесності й прозорості, що узгоджується з рекомендаціями UNESCO [7, с. 3].

Висновки. У статті вирішено актуальну наукову задачу вдосконалення моделі персоналізації навчального процесу шляхом інтеграції великих мовних моделей у функціональну структуру вебзастосунку.

1. Теоретично обґрунтовано та впроваджено модель динамічної генерації пояснень, ключовою особливістю якої є перехід від статичних підказок до керованого адаптивного циклу.



Це забезпечується використанням когнітивного вектора здобувача $v(t)$, що динамічно оновлюється за рекурентним правилом, дозволяючи системі миттєво реагувати на зміну стану знань, темп діяльності та рівень рефлексії студента.

2. Розроблено алгоритм селективного керування контекстом, який на відміну від механічного накопичення історії взаємодії, фокусується на релевантних «зонах ризику» та типових помилках. Впровадження оптимізаційного критерію L та педагогічного фільтра дозволило стабілізувати відповіді LLM, гарантуючи їхню дидактичну коректність та відповідність цілям навчання.

3. Експериментально підтверджено переваги запропонованого підходу. Результати 12-тижневого педагогічного експерименту ($n = 86$) показали статистично значущий приріст навчальних результатів в експериментальній групі на рівні 23,8 % порівняно з 8,9 % у контрольній групі. Зафіксовано скорочення часу на розуміння складних понять (з 12,7 с до 7,4 с на цикл пояснення) та підвищення здатності студентів до трансферу знань на нові типи завдань.

4. Визначено практичну значущість моделі для сучасних EdTech-платформ. Встановлено, що найбільша ефективність персоналізації досягається у фазах первинного опанування складних тем та корекції стійких когнітивних упереджень. Модель дозволяє масштабувати ефект індивідуального репетиторства («проблема 2-х сигм») у масовому вебсередовищі, суттєво знижуючи рутинне навантаження на викладача.

Перспективи подальших досліджень полягають у розробці мультимодальних профілів (інтеграція аналізу голосу та поведінкових патернів) та створенні інструментів прозорої аналітики для викладачів, що дозволить здійснювати глибший аудит академічної доброчесності в умовах використання генеративного штучного інтелекту.

Список використаних джерел

1. Bloom B. S. The 2 Sigma Problem: The Search for Methods of Group Instruction as Effective as One-to-One Tutoring. *Educational Researcher*. 1984. Vol. 13 (6). P. 4–16. DOI: <https://doi.org/10.3102/0013189X013006004>
2. Mayer R. E. *Multimedia Learning*. 3rd ed. Cambridge: Cambridge University Press, 2021. 427 p.
3. Russell S., Norvig P. *Artificial Intelligence: A Modern Approach*. 4th ed. Pearson, 2020. 1136 p.
4. Про схвалення Концепції розвитку штучного інтелекту в Україні: розпорядження Кабінету Міністрів України від 02.12.2020 № 1556-р. URL: <https://zakon.rada.gov.ua/laws/show/1556-2020-%D1%80>
5. Huang S., Sun Y., Yu X. SP-TeachLLM: An LLM-Driven Framework for Personalized and Adaptive Programming Education. *Information*. 2025. Vol. 16 (12). Art. 1045. DOI: <https://doi.org/10.3390/info16121045>
6. Chi M. T. H., Bassok M., Lewis M. W., Reimann P., Glaser R. Self-Explanations: How Students Study and Use Examples in Learning to Solve Problems. *Cognitive Science*. 1989. Vol. 13 (2). P. 145–182. DOI: https://doi.org/10.1207/s15516709cog1302_1
7. Про схвалення Концепції розвитку цифрових компетентностей: розпорядження Кабінету Міністрів України від 03.03.2021 № 167-р. URL: <https://zakon.rada.gov.ua/laws/show/167-2021-%D1%80>
8. Woolf B. *Building Intelligent Interactive Tutors: Student-Centered Strategies for Revolutionizing E-Learning*. Morgan Kaufmann, 2010. 466 p.
9. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016. 800 p.
10. Yao Y., González-Vélez H. AI-Powered System to Facilitate Personalized Adaptive Learning in Digital Transformation. *Applied Sciences*. 2025. Vol. 15 (9). Art. 4989. DOI: <https://doi.org/10.3390/app15094989>
11. Liu S., Guo X., Hu X., Zhao X. Advancing Generative Intelligent Tutoring Systems with GPT-4: Design, Evaluation, and a Modular Framework for Future Learning Platforms. *Electronics*. 2024. Vol. 13 (24). Art. 4876. DOI: <https://doi.org/10.3390/electronics13244876>
12. Yang Q., Liang C. A Second-Classroom Personalized Learning Path Recommendation System Based on Large Language Model Technology. *Applied Sciences*. 2025. Vol. 15 (14). Art. 7655. DOI: <https://doi.org/10.3390/app15147655>
13. Marín Díaz G. Supporting Reflective AI Use in Education: A Fuzzy-Explainable Model for Identifying Cognitive Risk Profiles. *Education Sciences*. 2025. Vol. 15 (7). Art. 923. DOI: <https://doi.org/10.3390/educsci15070923>



14. Про освіту: Закон України від 05.09.2017 № 2145-VIII (зі змінами). URL: <https://zakon.rada.gov.ua/laws/show/2145-19>
15. Міністерство освіти і науки України. Стратегія розвитку вищої освіти в Україні на 2022-2032 роки. Київ: МОН України, 2022. URL: <https://mon.gov.ua/storage/app/media/rizne/2022/02/23/Stratehiya.rozv.vyshchoyi.osvity-23.02.22.pdf>
16. Luckin R. Machine Learning and Human Intelligence: The Future of Education for the 21st Century. UCL Institute of Education Press, 2018. 232 p.

Дата першого надходження статті до видання: 19.02.2026

Дата прийняття статті до друку після рецензування: 15.03.2026

Дата публікації (оприлюднення) статті: 18.05.2026

Стаття поширюється на умовах ліцензії відкритого доступу (CC BY 4.0)



A. Yanko, M. Myziura
National University “Yuri Kondratyuk Poltava Polytechnic”

MODEL OF EDUCATIONAL PROCESS PERSONALIZATION VIA LLM INTEGRATION INTO A WEB APPLICATION WITH DYNAMIC EXPLANATION GENERATION

Summary

The rapid integration of generative artificial intelligence into the educational process fundamentally changes the interaction within the “teacher – learning material – student” triad. In digital courses, the most prominent problem remains the heterogeneity of student groups, where learners start with different knowledge backgrounds, master new material at different paces, and utilize various cognitive strategies. This study aims to theoretically substantiate and develop a personalization model for the educational process through the integration of Large Language Models (LLMs) into the structure of a web application to create a dynamic cycle for generating individualized explanations. The focus is on overcoming the “2 Sigma Problem” by providing automated tutoring support that matches the effectiveness of one-to-one human instruction. *Methodology.* The proposed model describes the learner through a multidimensional cognitive vector $v(t)$, which includes domain knowledge, procedural competence, reflectiveness, motivational stability, and a cognitive load indicator. A recurrent rule for updating the cognitive profile is established, using a hybrid evaluation scheme: micro-tests, behavioral logs, and dialogue analysis. The dynamic complexity of explanations is determined by an optimization criterion L , which balances penalty coefficients for repeated errors, cognitive overload, and response latency against the rewards of knowledge gain. A 7-step algorithm for dynamic generation was implemented, featuring selective context window management and a multi-level pedagogical filter to ensure didactic correctness and term consistency. *Results.* Experimental verification was conducted within a web application for the “Data Analysis Basics” course over a 12-week period with 86 participants. The results demonstrated a statistically significant increase in learning outcomes. The experimental group, utilizing the dynamic generation algorithm, showed a knowledge gain of 23.8 %, compared to 8.9 % in the control group using a static chatbot. Furthermore, the average time required for a student to understand a complex concept was reduced from 12.7 to 7.4 seconds. The relevance matrix confirmed a high correlation between the calculated complexity level c_i and the actual cognitive needs of the students. *Scientific Novelty and Practical Significance.* The scientific novelty lies in the synthesis of cognitive profiling, prompt orchestration, and a feedback loop that accounts for error structures and metacognitive reflection. The practical value is confirmed by the possibility of embedding the model into existing LMS/EdTech platforms, reducing the instructor’s routine workload, and enhancing the transfer of knowledge to new types of tasks. The study concludes that LLMs function not merely as information sources but as adaptive scaffolding tools for managing cognitive load in real-time.

Keywords: personalization of learning, large language models, web application, adaptive explanation, cognitive profile, context window, intelligent tutoring systems, generative AI.