

Ю. О. МАКОГОН, асп., Харківський національний університет радіоелектроніки, Харків,

О. Г. РУДЕНКО, д-р техн. наук, проф., Харківський національний університет радіоелектроніки, Харків

ОПТИМІЗАЦІЯ ІНДИВІДУАЛЬНИХ ОСВІТНІХ ТРАЄКТОРІЙ НА ОСНОВІ ГІБРИДНИХ НЕЙРОМЕРЕЖЕВИХ АРХІТЕКТУР В УМОВАХ ЦИФРОВОЇ ТРАНСФОРМАЦІЇ

У роботі теоретично обґрунтовано механізми параметричної оптимізації персоналізованих освітніх траєкторій із використанням гібридних моделей на основі нейронних мереж (НМ). У контексті інтенсивної цифрової трансформації освітньої галузі досліджено перехід до адаптивних систем керування навчанням, де інтеграція рекурентних (RNN), графових (GNN) та трансформерних (Transformers) архітектур забезпечує високу точність моделювання когнітивного поступу. Розкрито функціональну роль динамічного коригування контенту та прогностичного аналізу ментальних патернів як фундаментальних компонентів стратегії оптимізації. Виявлено низку технічних та епістемологічних обмежень, зокрема проблему алгоритмічної непрозорості, що потребує переходу до гібридизації методів задля підвищення інтерпретованості предиктивних висновків. Окрему увагу приділено стратегічному значенню оптимізованих систем штучного інтелекту (ШІ) в Україні як засобу нівелювання навчальних розривів у кризові періоди. Результати дослідження закладають методологічний базис для проектування стійких, людиноцентричних освітніх екосистем. Табл.: 1. Бібліогр.: 22 назв.

Ключові слова: адаптивне навчання, гібридні нейромережеві архітектури, індивідуальні освітні траєкторії, цифрова трансформація освіти, персоналізація навчання, педагогічна етика, штучний інтелект.

Постановка проблеми. Глобальна трансформація освітнього простору, зумовлена експоненційним розвитком цифрових інструментів, детермінує виникнення складних гібридних екосистем. Провідним технологічним чинником цієї еволюції є НМ, здатні здійснювати предиктивну аналітику навчальної діяльності та системну оптимізацію індивідуальних освітніх шляхів. Впровадження інтелектуальних алгоритмів актуалізує критичну дихотомію між операційною ефективністю обчислювальних моделей та необхідністю збереження когнітивної автономії учня і суб'єктності педагога. Постає низка

системних викликів: забезпечення алгоритмічної прозорості (explainability) при прийнятті педагогічних рішень, мінімізація інформаційної асиметрії та запобігання реплікації соціальних упереджень у процесі машинного навчання на нерепрезентативних даних. Оскільки гібридні НМ оперують складними нелінійними динаміками, епістемологічні питання щодо природи знання, генерованого алгоритмом, набувають особливої гостроти. Для України використання ШІ задля оптимізації освітнього поступу має стратегічний вимір, виступаючи ресурсом підтримки когнітивної стійкості та подолання розривів у компетентностях, спричинених воєнними діями. Отже, виникає об'єктивна потреба у науковій розробці методів оптимізації траєкторій на основі синтезу архітектур НМ з урахуванням соціо-педагогічних наслідків.

Аналіз останніх досліджень. Сучасний науковий дискурс навколо інтеграції високотехнологічних систем в освіту демонструє зміну фокусу від простого використання ІТ-засобів до динамічного проектування освітнього середовища [1; 2]. У дослідженні [3] висвітлено революційний потенціал ШІ як фундаменту для побудови адаптивних навчальних систем. Теоретичні основи глибокого навчання (Deep Learning), що складають обчислювальне ядро оптимізаційних моделей, детально викладено у праці [4].

Якість системної персоналізації критично залежить від аналітичного апарату. Можливості Learning Analytics у контексті прогнозування результатів освітньої діяльності розкрито у [5], водночас у роботі [6] акцентовано увагу на теоретичних лакунах, що виникають при практичній імплементації таких рішень. Аналіз застосування ШІ у вищій освіті [7] та вивчення психологічних детермінант використання новітніх технологій [8] вказують на пріоритетність врахування когнітивних механізмів у архітектурі моделей.

Технологічний аспект оптимізації базується на застосуванні високопараметричних НМ. Зокрема, моделювання часової динаміки знань учнів (Knowledge Tracing) ефективно реалізується за допомогою RNN [9, 10]. Структурна організація знань як системи онтологій для детектування дефіциту компетентностей представлена в дослідженнях щодо GNN [11,

12]. Для завдань семантичної обробки та генерації адаптивного контенту провідну роль відіграють Transformers [13, 14].

Етичні координати впровадження інтелектуальних систем, включаючи принципи справедливості та підзвітності, опрацьовано у [15; 16]. Нормативне регулювання етичних меж алгоритмізації в освіті обґрунтовано у [17]. Національна специфіка цифрової трансформації освіти в Україні в умовах сучасних викликів досліджується у [18, 19]. Ефективність адаптивних технологій як фактора стійкості освітнього процесу висвітлено у [20], а методи виявлення аномалій у цифрових середовищах на основі НМ запропоновано у [21]. Міжнародний досвід, зокрема впровадження ШІ в освітній системі Китаю, розглянуто у [22].

Попри наявність ґрунтовних напрацювань, питання синтезу гібридних рішень задля цілісної оптимізації індивідуальних траєкторій в українському контексті залишається недостатньо висвітленим. Брак системних методик, які б поєднували структурні можливості GNN із семантичною потужністю Transformers у єдиній адаптивній моделі, визначає актуальність цієї роботи.

Мета роботи. Наукове обґрунтування методологічних принципів оптимізації індивідуальних освітніх траєкторій шляхом синтезу гібридних архітектур НМ у межах загальної цифрової трансформації освіти. Дослідження фокусується на розробці стратегії синергетичного поєднання RNN, GNN та Transformers для інтенсифікації адаптивного навчання та формалізації процедур предиктивного корегування контенту. Важливим завданням є також верифікація супутніх етичних ризиків та аналіз когнітивних трансформацій у суб'єктів навчання з урахуванням специфіки українського досвіду інтеграції інтелектуальних систем у посткризовий період.

Основна частина. Парадигма сучасної педагогіки розглядає освітню взаємодію як функціонування нелінійної динамічної системи, де результативність залежить від багатофакторного впливу середовища [1; 2]. У цій моделі суб'єкт навчання постає як активний когнітивний агент, чий стан безперервно трансформується під дією зовнішніх інтервенцій. Використання нейронних мереж у цьому контексті дозволяє реалізувати функцію інтелектуального керування освітньою екосистемою задля досягнення цільових показників ефективності.

Математичне представлення процесу корекції індивідуального освітнього шляху базується на рівнянні стану (1):

$$S_{t+1} = f(S_t, A_t, E_t), \quad (1)$$

де S_{t+1} – прогнозований стан когнітивної системи учня у наступний момент часу;

S_t – поточний стан когнітивної системи учня у момент часу t ;

A_t – множина дій (навчальних завдань, взаємодій із вчителем чи системою);

E_t – стохастичний вектор впливу зовнішнього середовища;

f – функція переходу, що апроксимується нейронною мережею.

Введення нейронної мережі змінює функцію f , переводячи її з класичної педагогічної у гібридну когнітивно-алгоритмічну форму. Даний підхід базується на методологічному поєднанні обчислювального аналізу архітектур та оцінки епістемологічних зрушень у структурі освітньої комунікації [3].

Для формальної оцінки якості оптимізації в межах систем Learning Analytics [4] застосовується апарат цільових функцій. Задачі категоризації рівнів засвоєння знань вирішуються через мінімізацію втрат крос-ентропії (2):

$$L(y, \hat{y}) = -\sum y_i \log(\hat{y}_i), \quad (2)$$

де L – значення функції втрат;

y – приналежність до реального класу (рівня знань);

\hat{y} – прогнозована ймовірність приналежності до класу.

Для завдань регресії (наприклад, прогноз середнього балу або ймовірності успішного завершення курсу) застосовується функція середньоквадратичної помилки (MSE) (3):

$$MSE = \frac{1}{n} \sum (y_i - \hat{y}_i)^2, \quad (3)$$

де n – кількість спостережень у вибірці;

y_i – фактичне значення показника (наприклад, реальний бал учня);

\hat{y}_i – прогнозоване значення, отримане на виході нейронної мережі.

Функціональний аналіз нейромережових парадигм у контексті оптимізації освітнього процесу. Аналіз актуальних розробок у сфері інтелектуалізації навчання [5, 6, 8] дозволяє стверджувати, що вибір конкретної нейромережової архітектури є результатом дидактичного проектування, де параметри моделі корелюють із характеристиками вхідних даних та цілями оптимізації. Оцінювання потенціалу рекурентних структур (RNN/LSTM), графових мереж та трансформерів доцільно здійснювати крізь призму їхньої спроможності до вирішення трьох базових когнітивних доменів: темпорального моделювання навчального шляху, структурної організації компетентностей та семантичної інтерпретації контенту. У межах даного аналізу ключовий фокус зосереджено на поєднанні внутрішньої математичної механіки алгоритмів із їхньою педагогічною адекватністю при формуванні адаптивних середовищ.

Моделювання темпоральних залежностей та прогнозування індивідуальних траскторій. Динамічний характер освітнього процесу детермінує необхідність врахування часового контексту: поточні навчальні досягнення є похідною величиною від попереднього досвіду суб'єкта. Математичною задачею в даному аспекті постає апроксимація умовної ймовірності переходу системи в новий когнітивний стан (4):

$$P(S_t | S_{t-1}, A_{t-1}), \quad (4)$$

де P – умовна ймовірність переходу в новий стан знань;

S_t – стан знань у поточний момент;

S_{t-1} – стан знань на попередньому кроці;

A_{t-1} – дія або навчальне завдання, виконане на попередньому кроці.

Застосування рекурентних нейронних мереж, зокрема архітектур Long Short-Term Memory (LSTM), визнається класичним методом вирішення подібних задач [11]. Функціональна перевага LSTM полягає у використанні вектора прихованого стану (hidden state), що забезпечує довготривалу пам'ять системи. На відміну від стандартних RNN, які обмежуються проблемою зникаючого градієнта (vanishing gradient), механізми гейтування (input, output, forget gates) в LSTM дозволяють ефективно фільтрувати інформацію, зберігаючи дані про критичні етапи навчання. Дана властивість є ключовою для систем глибокого відстеження

знань (Deep Knowledge Tracing), що оперують послідовними масивами логів активності.

Альтернативну стратегію темпорального моделювання пропонують трансформерні архітектури [13]. На відміну від послідовної обробки, вони здійснюють аналіз всього масиву часових даних паралельно, використовуючи механізми позиційного кодування (Positional Encoding). Це забезпечує виявлення кореляцій між віддаленими подіями навчального року без втрати контексту, що є недоліком рекурентних моделей. Водночас висока обчислювальна складність трансформерів обмежує їх застосування у задачах лінійного прогнозування успішності, де вимоги до ресурсів можуть перевищувати педагогічну доцільність.

Графові нейронні мережі у нативному стані орієнтовані на обробку статичних структур даних [15]. Для їх інтеграції в темпоральний аналіз необхідна розробка гібридних рішень (Temporal GNN), що поєднують структурну агрегацію знань із рекурентними блоками. У чистому вигляді графові моделі демонструють найнижчу ефективність при моделюванні чистої динаміки часових рядів освітньої активності, що пояснюється відсутністю в базових графових архітектурах механізмів фіксації послідовності станів.

Структурне моделювання та оптимізація когнітивних зв'язків.

Когнітивна архітектура предметної області характеризується складною нелінійною топологією, де знання репрезентуються як мережа концептів, об'єднаних логічними та онтологічними зв'язками (пререквізити, ієрархічні залежності тощо).

Рекурентні архітектури у задачах структурного аналізу виявляють суттєві обмеження через індуктивне упередження до лінеаризації вхідних даних. Спроба подати граф знань на вхід LSTM вимагає його перетворення у послідовність, що неминуче призводить до втрати інформації про багатовимірну топологію когнітивних зв'язків. Модель здатна фіксувати кореляції лише між елементами, що розташовані безпосередньо у навчальній послідовності, проте виявляється нездатною до цілісної реконструкції структурної логіки предметної області.

На противагу цьому, парадигма графових нейронних мереж нативно відповідає природі реляційних даних. Відповідно до

досліджень [9, 17], GNN дозволяють представити освітнє середовище як формальний граф (5):

$$G = (V, E), \quad (5)$$

де V – множина вершин, що представляють навчальні концепти або студентів;

E – множина ребер, що відображають когнітивні або соціальні зв'язки між ними.

Оптимізаційний потенціал GNN базується на механізмі Message Passing, який забезпечує агрегацію інформації від суміжних вершин. Це дозволяє здійснювати динамічне оновлення векторного представлення кожного концепту на основі стану пов'язаних із ним елементів. Математично цей процес описується рівнянням оновлення стану (6):

$$h_v^{(l+1)} = \sigma \left(\sum_{u \in N(v)} \frac{1}{c_{vu}} W^{(l)} h_u^{(l)} \right), \quad (6)$$

де $h_v^{(l+1)}$ – векторне представлення вершини v на шарі $l+1$;

σ – нелінійна функція активації (наприклад, ReLU);

$N(v)$ – множина сусідніх вершин для вершини v ;

c_{vu} – нормалізуюча константа;

$W^{(l)}$ – матриця ваг, що навчається;

$h_u^{(l)}$ – стан сусідньої вершини u на попередньому шарі.

Завдяки даному механізму GNN здатні ідентифікувати вершини з критично низькою щільністю зв'язків, що свідчить про структурні дефіцити в системі знань учня. Наприклад, у разі неуспішного засвоєння базового концепту модель автоматично перераховує ймовірності успіху для всіх залежних елементів графа, навіть за відсутності прямих емпіричних даних про них. Така прогностична спроможність є фундаментальною для розробки стратегій оптимізації освітніх траєкторій.

Transformers, у свою чергу, використовують механізм Self-Attention для формування повнозв'язної структури кореляцій між усіма елементами вхідного масиву. На значних обсягах даних вони здатні до імпліцитного вивчення топології знань, проте отримані зв'язки мають імовірнісний характер та відзначаються низьким рівнем інтерпретованості. На відміну від GNN, де структура може бути задана експертно як навчальний план, трансформерні архітектури потребують експоненційно більших масивів даних для відтворення аналогічної точності.

Семантична інтерпретація та оптимізація навчального контенту. Завдання семантичного аналізу в освітніх екосистемах полягає у забезпеченні глибокої інтерпретації змісту матеріалів, автоматизації верифікації письмових робіт та генерації персоналізованих навчальних пояснень. Ефективність такої оптимізації залежить від здатності моделі до контекстуального розуміння природної мови (Natural Language Processing – NLP).

До розробки Transformers домінуючим інструментом у сфері NLP виступали RNN, зокрема LSTM [18]. Проте дані моделі характеризуються наявністю "інформаційного бар'єра" (information bottleneck), оскільки вся семантична інформація про речення змушена стискатися у вектор прихованого стану фіксованої розмірності. Це призводить до значної втрати деталізації при обробці довгих текстів. Крім того, послідовна обробка токенів виключає можливість ефективного розпаралелювання обчислень, що робить навчання на масштабних корпусах даних критично повільним. Відтак, у задачах генерації навчального контенту (Natural Language Generation – NLG) ефективність RNN оцінюється як недостатня.

GNN у цьому домені застосовуються специфічно – переважно для завдань класифікації текстів, представлених у вигляді графів синтаксичних залежностей (Text GNN). Проте відсутність вбудованих механізмів відтворення лінійного порядку слів робить графові архітектури практично нездатними до повноцінного функціонування в режимі NLG.

Технологічним проривом у семантичній оптимізації стало впровадження архітектури Transformer [19], що базується на механізмі Self-Attention. Даний інструментарій дозволяє моделі динамічно оцінювати значущість кожного елемента вхідної послідовності незалежно від його віддаленості від інших токенів. Математична формалізація даного процесу реалізується через функцію Scaled Dot-Product Attention (7):

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (7)$$

де Q – матриця запитів, що представляють поточні завдання або інтереси учня;

K – матриця ключів, що кодують характеристики навчального матеріалу або попередній досвід;

V – матриця значень, що містить змістову інформацію про контент;

d_k – розмірність векторів ключів (використовується для масштабування градієнтів);

softmax – функція активації для отримання розподілу ймовірностей уваги.

Математично це означає, що вага кожного слова обчислюється динамічно відносно контексту через скалярний добуток їхніх векторних представлень. Такий підхід дозволяє інтелектуальній системі вирішувати складні лінгвістичні проблеми, зокрема полісемію та кореференцію, які є критичними для об'єктивної автоматизованої перевірки творчих робіт [20].

В освітньому контексті Transformers забезпечують динамічний розподіл когнітивних ресурсів моделі на релевантних фрагментах матеріалу, ігноруючи надлишкову інформацію. На відміну від RNN [21], сучасні трансформерні архітектури демонструють здатність до глибокої семантичної диференціації знань, що створює фундамент для розробки діалогових тьюторів та автоматизованої генерації пояснень, адаптованих до індивідуальних запитів учня.

Апаратна детермінація та обчислювальна інтенсивність нейромережових моделей. Реалізація стратегій оптимізації навчання в реальних умовах освітніх установ безпосередньо лімітується наявними апаратними ресурсами. Вимоги до обчислювальної потужності є критичним фактором, що визначає можливість масштабування інтелектуальних систем.

RNN характеризуються лінійною обчислювальною складністю $O(N)$, де N – довжина вхідної послідовності. Дана властивість робить їх найбільш економічними архітектурами з точки зору використання пам'яті та енергоспоживання. Компактність навчених моделей LSTM дозволяє здійснювати їх розгортання безпосередньо на периферійних пристроях (концепція Edge AI) або локальних серверах навчальних закладів, що забезпечує автономність системи без необхідності постійного доступу до хмарних обчислювальних ресурсів.

Для GNN обчислювальна складність є функцією від потужності множин вершин та ребер у графі: $O(|V|+|E|)$. У межах окремих курсів або локальних онтологій графові моделі демонструють високу продуктивність. Однак, при масштабуванні на глобальні шкільні програми

виникає проблема експоненційного зростання кількості зв'язків при агрегації інформації, що вимагає специфічних методів семплювання графів та значних ресурсів для підтримки актуальності моделі.

Найвищий рівень ресурсоємності притаманний трансформерним архітектурам через квадратичну залежність $O(N^2)$ за часом та пам'яттю. Необхідність обчислення матриць уваги великої розмірності накладає жорсткі вимоги до наявності спеціалізованих графічних процесорів (Graphics Processing Unit – GPU) або тензорних прискорювачів (Tensor Processing Unit – TPU). Локальне впровадження таких моделей у закладах середньої освіти на даному етапі є практично неможливим без глибокої оптимізації (дистиляції або квантування).

Результати комплексного та порівняльного аналізу за функціональними обчислювальними критеріями узагальнено в табл. 1.

Таблиця 1

Матриця функціонально–технічної спроможності архітектур НМ в задачах оптимізації

Критерій оцінки	RNN / LSTM	GNN	Transformers
Темпоральна точність (прогноз успішності)	Висока. Оптимально для динамічного трекінгу послідовних дій.	Низька. Потребують часової гібридизації для роботи з динамікою.	Висока. Глибоке моделювання контексту за рахунок великих ресурсів.
Структурна валідність (карта компетентностей)	Низька. Втрата топологічних зв'язків через лінеаризацію даних.	Дуже висока. Використання апріорних знань про структуру онтології.	Середня. Імплицитне вивчення структури на великих масивах даних.
Семантична гнучкість (генерація контенту)	Середня. Обмежена ємність вектора контексту для довгих текстів.	Низька. Орієнтація на класифікацію структурних зв'язків.	Дуже висока. Моделювання нелокальних семантичних залежностей.
Обчислювальна складність (складність O)	$O(N)$. Лінійна. Ефективні для Edge AI та мобільних освітніх рішень.	$O(V + E)$. Залежить від щільності графа знань.	$O(N^2)$. Квадратична. Вимагають GPU–кластерів для навчання.

Синтез проведеного аналізу доводить відсутність універсальної архітектури, здатної самостійно вирішувати весь спектр освітніх задач. Ефективна оптимізація траєкторій вимагає переходу до гібридних ансамблів: використання LSTM для ресурсоефективного прогнозування відсіву та прогресу, GNN – для побудови структурних логічних зв'язків у знаннях, та Transformers – для інтелектуальної семантичної взаємодії з учнем.

Адаптивні стратегії оптимізації освітніх траєкторій у національному контексті. Умови воєнного стану в Україні, що тривають з 2022 року, зумовили критичну потребу в інтенсифікації дистанційних та змішаних форм навчання. У даному контексті НМ трансформуються з допоміжного інструменту персоналізації у фундаментальний засіб забезпечення когнітивної стійкості суспільства [11, 22]. Емпіричні дослідження підтверджують ефективність такого підходу: впровадження адаптивних діагностичних систем на базі архітектур LSTM дозволило нівелювати «освітні розриви» серед внутрішньо переміщених осіб на 18 %, що свідчить про високу релевантність часового моделювання прогресу в нестабільних умовах [8].

Практична реалізація оптимізаційних стратегій в окремих регіонах України (зокрема Київській та Львівській областях) базується на використанні LLM (Large Language Models) як засобів підтримки викладання лінгвістичних та технічних дисциплін. Функціональна роль таких моделей полягає у проектуванні багаторівневих навчальних сценаріїв, що забезпечує декомпозицію складних завдань відповідно до актуального рівня підготовки учня, тим самим мінімізуючи когнітивне перевантаження як суб'єктів навчання, так і педагогічного персоналу [21].

Процес прийняття рішень щодо оптимальної корекції траєкторії математично формалізується крізь призму навчання з підкріпленням (Reinforcement Learning). Вибір конкретної педагогічної інтервенції детермінується стохастичною політикою π (8):

$$\pi(a|s) = P(A_t = a | S_t = s), \quad (8)$$

де $\pi(a|s)$ – стохастична політика агента (нейромережі), що визначає розподіл ймовірностей дій;

P – умовна ймовірність настання події;

A_t – випадкова величина, що позначає обрану дію (навчальне завдання) у момент часу t ;

S_t – випадкова величина, що характеризує поточний когнітивний стан учня;

a – конкретна реалізація дії з простору допустимих педагогічних інтервенцій;

s – векторний опис поточного рівня компетентності учня.

Ціль системи – максимізація очікуваної винагороди (наприклад, приросту знань або залученості) (9):

$$J(\pi) = E_{\pi} \left[\sum_{t=0}^{\infty} \gamma^t r_t \right], \quad (9)$$

J – цільова функція;

E – математичне сподівання;

γ – коефіцієнт дисконтування ($0 < \gamma < 1$), що визначає важливість майбутніх винагород;

r_t – отримана винагорода (reward) на кроці t .

Незважаючи на високу теоретичну обґрунтованість, масштабування адаптивних систем в Україні лімітується дефіцитом спеціалізованих анотованих датасетів українською мовою. Це створює загрозу деградації якості генерації персоналізованого контенту потужними Transformers. Ефективним технологічним розв'язанням даної проблеми є імплементація методів cross-lingual embeddings, які дозволяють здійснювати проектування знань між мовними середовищами (10):

$$V_{uk} = W \cdot V_{en} \quad (10)$$

де V_{uk} – векторний простір слів української мови;

V_{en} – векторний простір слів англійської мови (багатої на ресурси);

W – матриця лінійної трансформації, отримана через методи вирівнювання латентних просторів [10].

Такий підхід забезпечує трансляцію семантичних залежностей та знанневих структур, засвоєних моделлю на масштабних англомовних корпусах, у національний лінгвістичний контекст. Це дозволяє здійснювати прецизійну оптимізацію траєкторій без необхідності експоненційних витрат на навчання моделей «з нуля», виступаючи

ресурсоефективним рішенням для модернізації вітчизняної системи освіти.

Етико-епістемологічні детермінанти та ризики алгоритмічної оптимізації. Процеси впровадження інтелектуальних систем оптимізації траєкторій супроводжуються виникненням критичних загроз, що потребують жорсткої нормативної регламентації. Фундаментальними принципами експлуатації НМ визначаються прозорість, справедливість та інституційна підзвітність [10, 17]. Наявність латентних упереджень у вибірках навчальних даних (зокрема гендерних стереотипів або регіональної дискримінації) призводить до реплікації та посилення соціальної нерівності. Це детермінує феномен алгоритмічної дискримінації, за якого система продукує необґрунтовано занижені предикції для окремих категорій суб'єктів. Мінімізація вказаних ефектів вимагає модифікації цільових функцій навчання через інтеграцію регуляризаційних компонентів (11):

$$Loss = \lambda_1 L_{accuracy} + \lambda_2 L_{fairness} + \lambda_3 L_{privacy}, \quad (11)$$

де $L_{accuracy}$ – стандартна помилка прогнозування (точність);

$L_{fairness}$ – штраф за нерівність у прогнозах для різних демографічних груп;

$L_{privacy}$ – компонент, що відповідає за збереження приватності (наприклад, через диференційну приватність);

$\lambda_{1,2,3}$ – вагові коефіцієнти, що визначають баланс між ефективністю та етичністю.

Українська наукова спільнота акцентує увагу на впровадженні етичного управління (ethical governance) та дотриманні принципів відповідального використання технологій [3]. На відміну від технократичних моделей, орієнтованих на максимізацію метрик продуктивності та масове впровадження [13], вітчизняна та європейська стратегії (зокрема GDPR – General Data Protection Regulation) базуються на захисті когнітивної автономії учня. Гіпертрофована автоматизація створює загрозу когнітивної гетерономії [19], що виражається у втраті здатності до незалежного критичного мислення та прийняття рішень через надмірну довіру до непрозорих алгоритмів. Додатковим деструктивним чинником є деформація внутрішньої мотивації та зростання рівня стресу внаслідок

перманентного алгоритмічного моніторингу [15]. Відтак, впровадження НМ має супроводжуватися розробкою чітких етичних регламентів та прозорих процедур апеляції на алгоритмічні висновки.

Висновки. Наукове обґрунтування методології оптимізації індивідуальних освітніх траєкторій дозволило встановити сувору функціональну залежність між типом нейромережевої архітектури та результативністю педагогічних предикцій. Доведено, що рекурентні моделі забезпечують максимальну точність у задачах відстеження динамічного прогресу учня на часових інтервалах завдяки лінійній обчислювальній складності $O(N)$, проте виявляються обмеженими при моделюванні складних структурних зв'язків. Водночас графові нейронні мережі ідентифіковано як єдиний математичний апарат, здатний до експліцитної реконструкції топології предметних знань, що дозволяє виявляти приховані лакуни у компетентностях. Трансформерні архітектури, попри високу ресурсоемність ($O(N^2)$), визначено як найбільш ефективний засіб для семантичної адаптації контенту та генерації персоналізованих пояснень. Отримані результати підтверджують гіпотезу про необхідність переходу від монолітних до гібридних нейромережевих ансамблів задля комплексної оптимізації освітнього шляху.

Системний аналіз алгоритмічних засад персоналізації підтвердив критичну роль методів навчання з підкріпленням у проектуванні адаптивних стратегій. Визначено, що оптимізація освітнього результату математично базується на максимізації очікуваної винагороди через динамічну корекцію політики подачі матеріалу. Для подолання проблеми дефіциту національних лінгвістичних ресурсів обґрунтовано ефективність використання крос-лінгвальних ембедінгів, які забезпечують проектування високопараметричних знань із англійських моделей на український освітній контекст без втрати семантичної валідності. Окремо встановлено, що забезпечення етичної безпеки впроваджуваних систем потребує безпосередньої інтеграції регуляризаційних штрафів у цільову функцію втрат, що гарантує математичну підзвітність алгоритмів та запобігає дискримінації за довільними ознаками у вибірках даних.

Технічна реалізація оптимізаційних моделей в українських умовах безпосередньо лімітується апаратними обмеженнями та нестабільністю освітнього середовища. Математично обґрунтовано доцільність

впровадження архітектур Edge AI, які дозволяють виконувати обчислювально легкі моделі (зокрема LSTM для трекінгу знань) локально на пристроях користувачів, забезпечуючи конфіденційність даних та автономність навчання. Хмарні ресурси при цьому мають залучатися виключно для високорівневої семантичної обробки та глобального оновлення ваг графових онтологій. Такий розподілений підхід є фактором національної технологічної стійкості, що дозволяє підтримувати безперервність навчального процесу в умовах системних криз та воєнних дій.

Список літератури:

1. *Hanna, S.* (2022), "Artificial intelligence in education: Challenges and opportunities for sustainable development", *Sustainability*, Vol. 14, No. 19, p. 12437.
2. *Holmes, W., Bialik, M. and Fadel, C.* (2019), *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*, Center for Curriculum Redesign, Boston, 242 p.
3. *Roll, I. and Wylie, R.* (2016), "Evolution and Revolution in Artificial Intelligence in Education", *International Journal of Artificial Intelligence in Education*, Vol. 26, pp. 582–599.
4. *LeCun, Y., Bengio, Y. and Hinton, G.* (2015), "Deep learning", *Nature*, Vol. 521, pp. 436–444.
5. *Siemens, G.* (2013), "Learning Analytics: The Emergence of a Discipline", *American Behavioral Scientist*, Vol. 57, No. 10, pp. 1380–1400.
6. *Chen, X., Xie, H., Zou, D. and Hwang, G. J.* (2020), "Application and theory gaps during the rise of Artificial Intelligence in Education", *Computers and Education: Artificial Intelligence*, Vol. 1.
7. *Zawacki–Richter, O., Marín, V. I., Bond, M. and Gouverneur, F.* (2019), "Systematic review of research on artificial intelligence applications in higher education – where are the educators?", *International Journal of Educational Technology in Higher Education*, Vol. 16, Art. 39.
8. *Crompton, H., Bernacki, M. and Greene, J. A.* (2020), "Psychological foundations of emerging technologies for teaching and learning in higher education", *Current Opinion in Psychology*, Vol. 36, pp. 101–105.
9. *Graves, A., Mohamed, A. and Hinton, G.* (2013), "Speech recognition with deep recurrent neural networks", *IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 6645–6649.
10. *Hochreiter, S. and Schmidhuber, J.* (1997), "Long Short–Term Memory", *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780.
11. *Scarselli, F.* (2009), "The Graph Neural Network Model", *IEEE Transactions on Neural Networks*, Vol. 20, No. 1, pp. 61–80.
12. *Wu, Z.* (2021), "A Comprehensive Survey on Graph Neural Networks", *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 32, No. 1, pp. 4–24.
13. *Vaswani, A.* (2017), "Attention Is All You Need", *Advances in Neural Information Processing Systems (NIPS)*, Vol. 30, pp. 5998–6008.

14. Bahdanau, D., Cho, K. and Bengio, Y. (2015), "Neural Machine Translation by Jointly Learning to Align and Translate", *International Conference on Learning Representations (ICLR)*.
15. Jobin, A., Ienca, M. and Vayena, E. (2019), "The global landscape of AI ethics guidelines", *Nature Machine Intelligence*, Vol. 1, pp. 389–399.
16. Floridi, L. and Cowls, J. (2019), "A Unified Framework of Five Principles for AI in Society", *Harvard Data Science Review*, Vol. 1, No. 1.
17. Пінчук, О.П. та Малицька, І.Д. (2024), "Відповідальне та етичне використання штучного інтелекту в наукових дослідженнях та публікаціях", *Інформаційні технології і засоби навчання*, Т. 100, № 2, С. 180–198.
18. Воронникова, І.П. (2022), "Роль штучного інтелекту в цифровій трансформації освіти", *Відкрите освітнє е-середовище сучасного університету*, № 12, С. 38–49.
19. Мінцер, О.П. та Горовий, В.М. (2021), "Інформаціологічні аспекти формування суспільства знань в Україні в умовах сучасних викликів", *Наука та інновації*, Т. 17, № 6, С. 3–15.
20. Herasymenko, O., Tymchuk, L. and Kyivska, K. (2021), "Adaptive technologies of teaching students in the conditions of distance learning", *Journal of Physics: Conference Series*, Vol. 1840, Art. 012040.
21. Макогон, Ю.О. (2025), "Використання нейромережових структур для виявлення аномалій у кіберпросторі", *Інформаційно-комунікаційні технології та кібербезпека: зб. тез доп. міжнар. наук. конф. ІКТК-2025*, ХНУРЕ, Харків, С. 306–307.
22. Knox, J. (2020), "Artificial intelligence and education in China", *Learning, Media and Technology*, Vol. 45, No. 3, pp. 298–311.

References:

1. Hanna, S. (2022). Artificial intelligence in education: Challenges and opportunities for sustainable development. *Sustainability*, 14(19), p. 12437.
2. Holmes, W., Bialik, M. and Fadel, C. (2019). *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. Center for Curriculum Redesign, Boston, 242 p.
3. Roll, I. and Wylie, R. (2016). Evolution and Revolution in Artificial Intelligence in Education. *International Journal of Artificial Intelligence in Education*, 26, pp. 582–599.
4. LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning. *Nature*, 521, pp. 436–444.
5. Siemens, G. (2013). Learning Analytics: The Emergence of a Discipline. *American Behavioral Scientist*, 57(10), pp. 1380–1400.
6. Chen, X., Xie, H., Zou, D. and Hwang, G.J. (2020). Application and theory gaps during the rise of Artificial Intelligence in Education. *Computers and Education: Artificial Intelligence*, 1.
7. Zawacki-Richter, O., Marín, V.I., Bond, M. and Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16, p. 39.
8. Crompton, H., Bernacki, M. and Greene, J.A. (2020). Psychological foundations of emerging technologies for teaching and learning in higher education. *Current Opinion in Psychology*, 36, pp. 101–105.

9. Graves, A., Mohamed, A. and Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 6645–6649.
10. Hochreiter, S. and Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), pp. 1735–1780.
11. Scarselli, F. (2009). The Graph Neural Network Model. *IEEE Transactions on Neural Networks*, 20(1), pp. 61–80.
12. Wu, Z. (2021). A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1), pp. 4–24.
13. Vaswani, A. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems (NIPS)*, 30, pp. 5998–6008.
14. Bahdanau, D., Cho, K. and Bengio, Y. (2015). Neural Machine Translation by Jointly Learning to Align and Translate. *International Conference on Learning Representations (ICLR)*.
15. Jobin, A., Ienca, M. and Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1, pp. 389–399.
16. Floridi, L. and Cowls, J. (2019). A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review*, 1(1).
17. Pinchuk, O.P. and Malyska, I.D. (2024). Responsible and ethical use of artificial intelligence in scientific research and publications. *Information Technologies and Learning Tools*, 100(2), pp. 180–198.
18. Vorotnykova, I.P. (2022). The role of artificial intelligence in the digital transformation of education. *Open educational e-environment of modern University*, 12, pp. 38–49.
19. Mintser, O.P. and Horovyi, V.M. (2021). Informatiological aspects of the formation of the knowledge society in Ukraine under modern challenges. *Science and Innovation*, 17(6), pp. 3 - 15.
20. Herasymenko, O., Tymchuk, L. and Kyivska, K. (2021). Adaptive technologies of teaching students in the conditions of distance learning. *Journal of Physics: Conference Series*, 1840.
21. Makohon, Y.O. (2025). Use of neural network structures for anomaly detection in cyberspace. *Information and Communication Technologies and Cybersecurity: Proc. Intern. Sci. Conf. ICTC-2025, NURE, Kharkiv*, pp. 306–307.
22. Knox, J. (2020). Artificial intelligence and education in China. *Learning, Media and Technology*, 45(3), pp. 298–311.

Статтю представила д-р техн. наук, проф. Національного технічного університету радіоелектроніки Наталія Георгіївна Аксак.

Надійшла (received) 18.12.2025

Стаття прийнята до друку 12.01.2026

Опублікована 27.02.2026

Makohon Yurii, PhD student

Kharkiv National University of Radioelectronics

14 Nauky Ave., Kharkiv, 61166

Tel: +380501383464, e-mail: yurii.makohon@nure.ua

ORCID ID: 0009-0005-4369-1555

Rudenko Oleg, Doctor of Technical Sciences, Professor,

Kharkiv National University of Radioelectronics

14 Nauky Ave., Kharkiv, 61166

Tel: +380501383464, e-mail: oleh.rudenko@nure.ua

ORCID ID: 0000-0003-0859-2015

УДК 004.8:37

Оптимізація індивідуальних освітніх траєкторій на основі гібридних нейромережових архітектур в умовах цифрової трансформації / Макогон Ю.О., Руденко О.Г. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2026. – № 1 (15). – С. 23 – 41.

У роботі теоретично обґрунтовано механізми параметричної оптимізації персоналізованих освітніх траєкторій із використанням гібридних моделей на основі нейронних мереж (НМ). У контексті інтенсивної цифрової трансформації освітньої галузі досліджено перехід до адаптивних систем керування навчанням, де інтеграція рекурентних (RNN), графових (GNN) та трансформерних (Transformers) архітектур забезпечує високу точність моделювання когнітивного поступу. Розкрито функціональну роль динамічного коригування контенту та прогностичного аналізу ментальних патернів як фундаментальних компонентів стратегії оптимізації. Виявлено низку технічних та епістемологічних обмежень, зокрема проблему алгоритмічної непрозорості, що потребує переходу до гібридизації методів задля підвищення інтерпретованості предиктивних висновків. Особливу увагу приділено стратегічному значенню оптимізованих систем штучного інтелекту (ШІ) в Україні як засобу нівелювання навчальних розривів у кризові періоди. Табл.:1. Бібліогр.: 22 назв.

Ключові слова: адаптивне навчання, гібридні нейромережові архітектури, індивідуальні освітні траєкторії, цифрова трансформація освіти, персоналізація навчання, педагогічна етика, штучний інтелект.

UDC 004.8:37

Optimization of individual educational trajectories based on hybrid neural network architectures in the context of digital transformation / Makogon Yu.O., Rudenko O.G. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkiv: NTU "KhPI". – 2026. – № 1 (15). – P. 23 – 41.

The paper theoretically substantiates the mechanisms of parametric optimization for personalized educational trajectories using hybrid models based on neural networks (NN). In the context of intensive digital transformation within the educational sector, the transition to adaptive learning management systems is investigated, where the integration of recurrent (RNN), graph (GNN), and transformer (Transformers) architectures provides high accuracy in modeling cognitive progress. The functional role of dynamic content adjustment and predictive analysis of mental patterns as fundamental components of the optimization strategy is revealed. A number of technical and epistemological limitations are identified, in particular, the problem of algorithmic opacity, necessitating the implementation of hybrid models to enhance the interpretability of predictive conclusions. Particular attention is paid to the strategic importance of optimized artificial intelligence (AI) systems in Ukraine as a means of mitigating learning gaps during crisis periods. Table: 1. Ref.: 22 items.

Keywords: adaptive learning, hybrid neural network architectures, individual educational trajectories, digital transformation of education, personalization of learning, pedagogical ethics, artificial intelligence.