DOI 10.34185/1562-9945-5-166-2026-21
УДК 004.8:37.018.43

К.О. Палагута, О.Є. Савон

ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ПІДТРИМКИ НАВЧАЛЬНИХ ТРАЄКТОРІЙ НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ І СИТУАЦІЙНО-СЦЕНАРНОГО ПІДХОДУ

Анотація. Актуальність дослідження зумовлена необхідністю підвищення ефективності підтримки навчальних траєкторій студентів у системах дистанційного навчання на основі інтелектуального аналізу накопичених освітніх даних. Сучасні освітні платформи забезпечують значні обсяги інформації про результати та активність студентів, однак прогнозування успішності саме по собі не визначає подальших педагогічних дій. Проблема дослідження полягає у необхідності переходу від отримання прогнозних показників до їх ситуаційної інтерпретації та формування адаптивних сценаріїв підтримки. Метою роботи є розроблення інформаційної технології підтримки навчальних траєкторій на основі поєднання рекурентних нейронних мереж і ситуаційно-сценарного підходу. Використано методи нейромережевого прогнозування часових послідовностей, ситуаційного аналізу, продукційні правила, порогові механізми прийняття рішень та експериментальне моделювання. Запропоновано багаторівневу архітектуру технології, що охоплює збір і підготовку даних, прогнозування, ситуаційну інтерпретацію, формування сценаріїв, звітність і візуалізацію. RNN-модель забезпечує прогнозування підсумкової оцінки та ймовірності успішного завершення курсу, а ситуаційно-сценарний модуль визначає стан навчальної траєкторії та формує відповідний набір педагогічних дій. Розроблено програмний прототип, інтегрований з LMS Moodle, та проведено його апробацію на модельних даних дисципліни «Основи програмування». Результати підтвердили працездатність повного технологічного циклу та можливість формування диференційованих сценаріїв підтримки з урахуванням прогнозованих результатів і показників навчальної активності студентів. Запропонована технологія створює передумови для своєчасного виявлення ризиків, адаптивного супроводу навчальних траєкторій та підтримки прийняття обґрунтованих педагогічних рішень у дистанційному навчанні.

Ключові слова: дистанційне навчання, освітня платформа, навчальна траєкторія, рекурентна нейронна мережа, RNN, GRU, прогнозування успішності, ситуаційно-сценарний підхід, адаптивна підтримка, LMS Moodle.

Постановка проблеми. Стрімкий розвиток технологій дистанційного навчання та поширення освітніх платформ зумовлюють накопичення значних обсягів даних про навчальну діяльність студентів, зокрема результати оцінювання, інтенсивність взаємодії з навчальними матеріалами, виконання тестових і практичних завдань, дотримання тер-

© Палагута К.О., Савон О.Є., 2026
Copyright for this paper by its authors. Use permitted under License CC BY 4.0.
ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

мінів та інші поведінкові характеристики. Використання цих даних створює передумови для переходу від традиційного ретроспективного оцінювання результатів навчання до прогнозування подальшої успішності та своєчасного виявлення ризиків відставання. Особливий потенціал у цьому контексті мають рекурентні нейронні мережі, здатні враховувати часову послідовність навчальних подій та динаміку поведінки студента.

Водночас отримання прогнозу саме по собі не забезпечує ефективної підтримки навчальної траєкторії. Прогнозована підсумкова оцінка або ймовірність успішного завершення курсу потребують подальшої інтерпретації з урахуванням фактичної активності студента та перетворення на конкретні педагогічні рекомендації й керуючі дії. Тому актуальною є задача інтеграції засобів нейромережевого прогнозування із ситуаційно-сценарним підходом, який дозволяє ідентифікувати поточну навчальну ситуацію та сформувати відповідний сценарій підтримки.

Отже, виникає необхідність розроблення інформаційної технології, яка забезпечувала б цілісний цикл опрацювання освітніх даних: від аналізу послідовності навчальних подій і прогнозування результатів засобами RNN до ситуаційної інтерпретації прогнозу, вибору сценарію та формування адаптивних рекомендацій у середовищі дистанційного навчання. Розв’язання цієї задачі створює підґрунтя для своєчасного виявлення несприятливих змін у навчальній траєкторії та підтримки прийняття обґрунтованих педагогічних рішень.

Аналіз останніх досліджень і публікацій. Цифрова трансформація освіти сприяла активному розвитку інтелектуальних освітніх платформ, здатних не лише накопичувати дані про навчальну діяльність здобувачів освіти, а й адаптувати освітній контент відповідно до індивідуальних потреб користувачів. Одним із найбільш перспективних напрямів розвитку таких платформ є використання рекурентних нейронних мереж (Recurrent Neural Networks, RNN) та сценарно-орієнтованого навчання (Scenario-Based Learning, SBL). Останні дослідження демонструють можливість поєднання цих підходів для створення адаптивних освітніх середовищ нового покоління.

Однією із фундаментальних праць у сфері застосування RNN в освіті є дослідження Deep Knowledge Tracing [1], у якому було запропоновано використовувати рекурентні нейронні мережі для моделювання динаміки навчання студентів. Автори довели, що RNN здатні ефективно відстежувати зміни рівня знань здобувача освіти на основі послідовності виконаних завдань та прогнозувати результати майбутньої діяльності. Запропонований підхід став основою для розвитку сучасних адаптивних систем навчання та технологій learning analytics.

Подальшого розвитку цей напрям набув у роботі [2], де було розроблено систему раннього попередження про академічні ризики студентів у STEM-курсах. Автори використали дані навчальної платформи, зокрема частоту входів до системи, активність на форумах та виконання домашніх завдань. Результати продемонстрували, що модель RNN забезпечує більш високу точність виявлення студентів групи ризику порівняно з традиційними алгоритмами машинного навчання. Особливою перевагою запропонова-

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

ного підходу є можливість використання обмеженого набору характеристик, доступних практично в будь-якій LMS.

Значна увага в сучасних дослідженнях приділяється також аналізу поведінкових характеристик студентів. Так, у роботі Jeong і Cho [3] досліджувалася можливість визначення рівня концентрації студентів під час дистанційного навчання за допомогою моделей RNN, LSTM та GRU. Для аналізу використовувалися дані відеоспостереження, включаючи напрямок погляду та міміку користувачів. Автори встановили, що модель GRU забезпечує найвищу точність прогнозування концентрації, що відкриває перспективи для створення адаптивних систем підтримки навчання в реальному часі.

Важливий напрям сучасних досліджень пов'язаний із персоналізацією освітнього контенту. У роботі [4] запропонована рекомендаційна система, яка аналізує навчальну активність користувачів віртуального освітнього середовища та формує персоналізовані рекомендації щодо подальшого проходження навчального матеріалу. Автори показали, що використання модифікованої архітектури LSTM дозволяє суттєво підвищити точність рекомендацій та забезпечити ефективніше індивідуалізоване навчання.

Окремий напрям формується навколо прогнозування академічної успішності студентів. У роботі Fazil, Rísquez та Halpin [5] представлено модель ASIST, яка поєднує механізм уваги (Attention Mechanism) із багатошаровими двонапрямними мережами BiLSTM для аналізу даних віртуального навчального середовища. Отримані результати показали високі значення AUC (0,86–0,90) та можливість виявлення студентів групи ризику на ранніх етапах навчання.

Схожі результати отримано в дослідженні Kalita та співавторів [6], де для прогнозування середнього балу студентів було використано двонапрямну мережу Bi-LSTM. Особливістю роботи стало застосування SHAP-аналізу для інтерпретації результатів моделі. Автори довели, що пояснюване машинне навчання дозволяє не лише здійснювати точні прогнози, але й виявляти фактори, які найбільше впливають на успішність студентів.

Паралельно з розвитком технологій штучного інтелекту активно розвивається сценарний підхід до організації навчання. Дослідження Morgan [7] демонструє ефективність інтеграції Scenario-Based Learning та Universal Design for Learning в асинхронних онлайн-курсах. Автор показує, що навчальні сценарії, побудовані на реальних професійних ситуаціях, сприяють підвищенню залученості студентів та розвитку практичних компетентностей.

Подальший розвиток сценарного підходу представлений у праці Younas та співавторів [8], де досліджується поєднання цифрового сценарного навчання та генеративного штучного інтелекту. Результати експерименту підтвердили покращення комунікативних навичок студентів, підвищення їх мотивації та адаптивності освітнього процесу. Особливого значення набуває можливість автоматичного генерування індивідуальних навчальних сценаріїв залежно від потреб конкретного студента.

Аналіз сучасних досліджень дозволяє зробити висновок, що розвиток інтелектуальних освітніх платформ відбувається у напрямі інтеграції двох взаємодоповнювальних підходів. RNN та їх похідні (LSTM, GRU, Bi-LSTM) забезпечують аналіз часових пос-

лідовностей навчальної активності, прогнозування результатів і побудову адаптивних рекомендацій. Сценарний підхід, своєю чергою, створює умови для практико-орієнтованого навчання, розвитку критичного мислення та формування професійних компетентностей. Перспективним напрямом подальших досліджень є створення освітніх платформ, у яких нейронні мережі автоматично формуватимуть та адаптуватимуть сценарії навчання відповідно до індивідуальної траєкторії здобувача освіти.

Мета дослідження. Метою дослідження є розроблення інформаційної технології підтримки навчальних траєкторій у системах дистанційного навчання на основі поєднання рекурентних нейронних мереж і ситуаційно-сценарного підходу, що забезпечує прогнозування результатів навчальної діяльності, інтерпретацію прогнозних і поведінкових показників, визначення поточної навчальної ситуації та формування адаптивних сценаріїв педагогічної підтримки.

Виклад основного матеріалу. У межах розробки освітньої платформи дистанційного навчання однією з ключових задач є побудова нейромережної моделі, яка дозволяє здійснювати інтелектуальний аналіз навчального процесу, прогнозування й адаптацію контенту до потреб студента. Нехай для кожного користувача задана послідовність дій у часі:

$$X = \{x_1, x_2, ..., x_T\}, \quad (1)$$

де $x_t \in R^n$ — вектор параметрів користувача на кроці t. Кожен вектор включає: оцінки (g_t), час активності (a_t), перегляд матеріалів ($_{mt)}$, виконання тестів (t_t), тему заняття (s_t).

Побудована модель f реалізує:

- регресійне прогнозування оцінки: $\hat{y}_T = f(X)$;
- класифікацію ймовірності успішного завершення курсу: $\hat{y}_T = P$(успіх | X).

У рамках проєктування інтелектуального модуля для платформи дистанційного навчання обрано архітектуру нейромережі, яка: здатна обробляти послідовності подій у часі; ефективно враховує контекст навчального процесу; забезпечує точне прогнозування навчальних результатів; дозволяє генерувати рекомендації та підтримує адаптивну поведінку системи. Доцільним є використання рекурентної нейронної мережі (RNN), яка забезпечує внутрішню пам'ять системи завдяки механізму зворотного зв’язку. Кожен крок у послідовності впливає на наступний за допомогою прихованого стану, що дозволяє враховувати динаміку поведінки студента в часі. Розглянемо математичний опис RNN.

Умовні позначення:

$x_t \in R^n$ — вектор вхідних даних на кроці часу t;

$h_t \in R^m$ — прихований стан мережі на кроці t;

$y_t \in R^k$ — вихід мережі на кроці t;

$W_{xh} \in R^{mxn}$ — матриця ваг від входу до прихованого шару;

$W_{hh} \in R^{mxm}$ — матриця ваг між прихованими станами;

$W_{hy} \in R^{mxk}$ — матриця ваг від прихованого стану до виходу;

$b_h \in R^m$, $b_y \in R^k$ — вектори зміщення (bias terms);

σ_h — функція активації прихованого шару (наприклад, tanh);

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

σ_y — функція активації виходу (наприклад, softmax).

Оновлення стану здійснюється в такий спосіб - на кожному кроці часу t прихований стан h_t оновлюється за допомогою вхідного вектору x_t та попереднього стану h_{t-1}:

$$h_t = \sigma_h(W_{xh} * x_t + W_{hh} * h_{t-1} + b_h), \quad (2)$$

де σ_h – нелінійна активаційна функція.

Вихід мережі y_t обчислюється як:

$$y_t = \sigma_y(W_{hy} * h_t + b_y), \quad (3)$$

де σ_y – функція активації.

При навчанні на послідовності довжини T загальна функція втрат має вигляд:

$$\mathcal{L} = \sum_{t=1}^{T} \mathcal{L}_t(\hat{y}_t, y_t) \quad (4)$$

де $\hat{y}_t$ — справжнє (еталонне) значення виходу на кроці t.

Навчання RNN проводиться за допомогою алгоритму зворотного поширення помилки у часі (Backpropagation Through Time, BPTT), який враховує залежності між усіма кроками часу:

$$\frac{\partial \mathcal{L}}{\partial W} = \sum_{t=1}^{T} \frac{\partial \mathcal{L}_t}{\partial \hat{y}_t} \cdot \frac{\partial \hat{y}_t}{\partial h_t} \cdot \frac{\partial h_t}{\partial W} \quad (5)$$

У системі дистанційного навчання, що спроєктована, рекурентна нейронна мережа (RNN) використовується для аналізу послідовності дій студента з метою прогнозування його успішності, адаптації контенту, виявлення ризиків відставання тощо.

Кожен студент формує послідовність подій $\{x_1, x_2, ..., x_T\}$, де кожен x_t — це вектор ознак, наприклад:

- g_t — оцінка за практичну роботу
- a_t — час активності в системі
- v_t — час роботи з теоретичним матеріалом
- t_t — виконання тесту (0 або 1)
- s_t — тема заняття (у вигляді one-hot encoding)

Мережа обробляє послідовність $\{x_1, x_2, ..., x_T\}$, оновлюючи прихований стан h_t і формуючи прогноз y_t — наприклад, ймовірність успішного завершення модуля або очікувана підсумкова оцінка.

Стан прихованого шару оновлюється на кожному кроці часу:

$$h_t = \tanh(W_{xh} * x_t + W_{hh} * h_{t-1} + b_h) \quad (6)$$

Прогнозований вихід:

$$\hat{y}_t = \sigma(W_{hy} * h_t + b_y), \quad (7)$$

де W_{xh} — ваги входу;

W_{hh} — рекурентні ваги;

W_{hy} — ваги виходу;

σ — сигмоїда.

Задачі прогнозування:

- Прогноз оцінки:

$$\hat{y}_T = \text{expected grade} \in [0,100] \quad (8)$$

- Ймовірність завершити курс:

$$\hat{y}_T = P(\text{успішне завершення курсу} \mid x_1, x_2, \ldots, x_T) \quad (9)$$

Функція втрат на всій послідовності має вигляд:

$$\mathcal{L} = \sum_{t=1}^{T} \mathcal{L}_t(\hat{y}_t, y_t) \quad (10)$$

Зворотне поширення помилки у часі (BPTT) дозволяє оновлювати ваги W_{xh}, W_{hh}, W_{hy}.

Модель оцінюється за метриками: MAE, RMSE — для оцінок, Accuracy, F1-score — для класифікації успішності, AUC-ROC — для ймовірнісних прогнозів.

Сценарний модуль освітньої платформи, що пропонується, не виконує прогнозування, а інтерпретує прогноз разом із фактичними показниками активності та визначає ситуацію і набір керуючих дій.

Тобто вхідний вектор ситуаційно-сценарного модуля доцільно визначити як

$$\mathbf{x}_i(t) = \left[\hat{G}_i, \hat{P}_i, R_i, A_i(t), T_i(t), D_i(t), L_i(t), \Delta A_i(t), \ldots\right], \quad (11)$$

де $\hat{G}_i$— прогнозована підсумкова оцінка; $\hat{P}_i$ — прогнозована ймовірність успішного завершення курсу; R_i — рівень ризику; $A_i(t)$ — показник навчальної активності; $T_i(t)$ — результати тестування; $D_i(t)$ — показник дотримання термінів; $L_i(t)$ — показник роботи з навчальними матеріалами; $\Delta A_i(t)$ — зміна активності порівняно з попереднім періодом.

Далі працює rule engine, тобто ситуація визначається не нейронною мережею, а системою впорядкованих правил:

$$r_j : C_j(\mathbf{x}_i(t), \theta) \rightarrow S_j, \quad (12)$$

де C_j — логічна умова правила; θ — множина порогових значень із thresholds; S_j — відповідна навчальна ситуація.

Оскільки правила мають пріоритети, механізм вибору ситуації можна записати як

$$S_i(t) = S_{j^*}, \qquad j^* = arg \max_{j : C_j(\mathbf{x}_i(t))=1} p_j, \quad (13)$$

де p_j — пріоритет правила. Таким чином, якщо одночасно виконуються умови кількох правил, обирається ситуація, пов'язана з правилом найвищого пріоритету.

Наприклад, для критичного ризику правило може мати вигляд:

$$(\hat{P}_i < \theta_P) \wedge (\hat{G}_i < \theta_G) \wedge (A_i < \theta_A) \rightarrow S3_{\text{RISK_CRITICAL}}$$

Для зниження активності:

$$\Delta A_i < -\theta_{\Delta A} \wedge \hat{P}_i \geq \theta_P \rightarrow S2_{\text{ACTIVITY_DECLINE}}$$

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

А для ситуації відновлення особливо важливо використовувати динаміку, а не лише поточне значення:

$$A_i(t) > A_i(t-1) \wedge T_i(t) > T_i(t-1) \wedge R_i(t) > R_i(t-1) \rightarrow S4_{\text{RECOVERY}}$$

Після визначення ситуації застосовується відображення

$$\Phi: S_j \rightarrow \mathcal{A}_j,$$

де $\mathcal{A}_i = \{a_1, a_2, \dots, a_m\}$ — набір сценарних дій. Наприклад,

$$S3_{\text{RISK_CRITICAL}} \rightarrow \{a_{\text{student-message}}, a_{\text{teacher-notify}}, a_{\text{resource}}, a_{\text{consultation}}\}$$

На цьому етапі scenarios.json фактично виконує роль формалізованої бази знань сценарного модуля: thresholds → параметри прийняття рішень; rules → продукційні правила виду «умова → ситуація»; situations → семантичний опис станів навчальної траєкторії; scenarios → відображення «ситуація → набір дій»; moodle_action_mapping → відображення «сценарна дія → механізм реалізації в Moodle».

Всю модель сценарного підходу можна компактно формалізував як:

$$\mathbf{x}_i(t) \xrightarrow[\theta]{\mathcal{R}} S_i(t) \xrightarrow{\Phi} \mathcal{A}_j(t) \xrightarrow{\psi} \mathcal{M}_j(t), \qquad (14)$$

де $\mathcal{R}$ — множина правил; $S_i(t)$ — визначена ситуація; Φ — функція вибору сценарних дій; ψ — функція відображення сценарних дій; $\mathcal{M}_j(t)$ — множина фактично виконуваних дій у середовищі дистанційного навчання.

Отже, у роботі запропоновано механізм формалізованого перетворення прогнозно-поведінкового стану студента на педагогічну ситуацію, а ситуації — на адаптивний сценарій підтримки.

Архітектурно запропонована технологія реалізується як багатомодульний програмний комплекс, інтегрований із LMS (наприклад, Moodle) через механізми обміну даними (REST API, журнали подій, результати оцінювання).

Структурно виділено такі функціональні рівні:

1. Рівень збору та підготовки даних — забезпечує отримання журналів активності та результатів навчання, їх очищення, агрегування та перетворення у формат, придатний для аналітичної обробки.
2. Аналітичний рівень (прогнозування) — реалізує обчислення прогнозних показників успішності та ризику на основі рекурентної нейромережевої моделі.
3. Логічний рівень (ситуаційна інтерпретація) — здійснює класифікацію поточного стану навчальної траєкторії відповідно до визначених правил та порогових значень.
4. Сценарний рівень — формує набір педагогічних рекомендацій та управлінських дій залежно від встановленої ситуації.
5. Рівень звітності та візуалізації — забезпечує генерацію аналітичних звітів та графічних матеріалів для підтримки прийняття рішень викладачем.

Така багаторівнева структура дозволяє чітко розмежувати функціональні ролі компонентів і забезпечити масштабованість системи.

Функціонування технології організовано у вигляді замкненого адаптивного циклу, що включає: накопичення даних про навчальну діяльність; аналітичну обробку та прогнозування; інтерпретацію результатів; формування рекомендацій; реалізацію педагогічного впливу через LMS; подальше накопичення нових даних. Таким чином, створюється контур зворотного зв'язку, в якому результати прогнозування впливають на освітню поведінку, що, у свою чергу, змінює подальші аналітичні оцінки (рис.1).

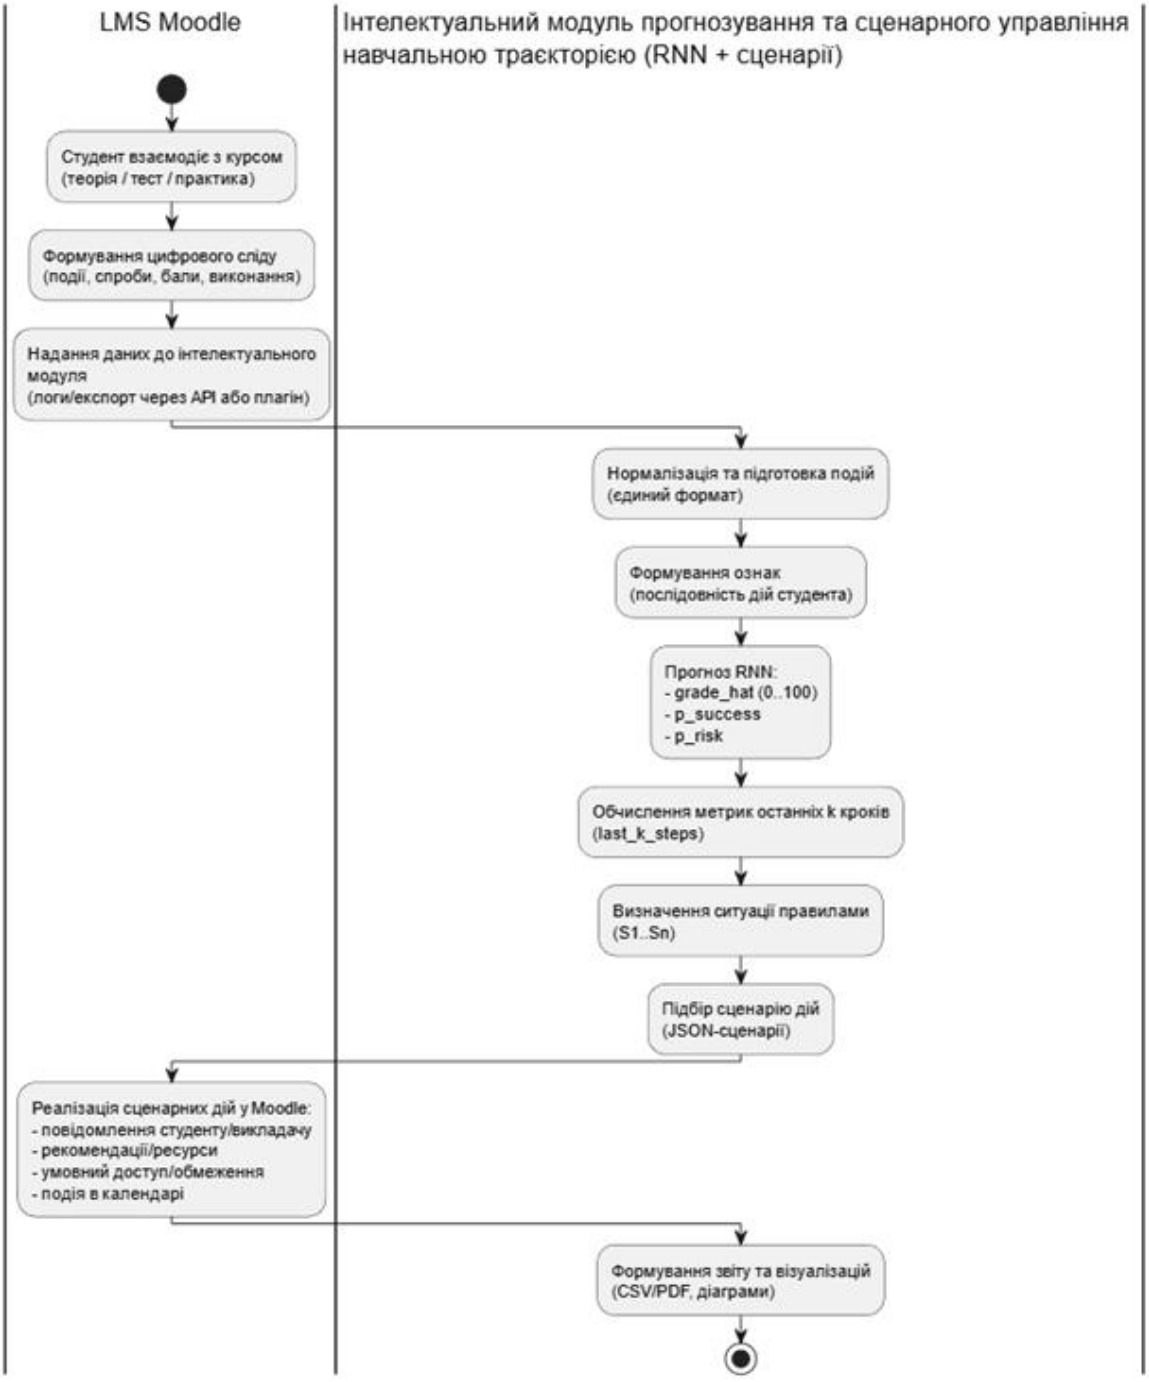


Рисунок 1 – Узагальнений цикл функціонування технології ситуаційно-сценарного управління навчальною траєкторією з використанням RNN

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

Реалізація інформаційної технології освітньої платформи дистанційного навчання здійснена у вигляді програмного прототипу, який інтегрується з LMS Moodle та забезпечує повний цикл аналітичної обробки навчальної активності студентів: від збору подій до формування управлінських сценаріїв і звітів. Архітектурно система реалізована як багатомодульний програмний комплекс, що включає модуль підготовки даних, модуль прогнозування на основі RNN, модуль ситуаційно-сценарного аналізу та модуль формування аналітичних звітів (CSV/PDF та графічні діаграми). Розроблено програмне забезпечення, яке виконує побудову датасету та навчання RNN-моделі у прототипі (рис.2).

```python
from __future__ import annotations
import argparse, csv
from collections import defaultdict
from dataclasses import dataclass
from typing import Dict, List, Tuple, Optional

import torch
import torch.nn as nn
from torch.utils.data import Dataset, DataLoader
from torch.nn.utils.rnn import pack_padded_sequence


# ----------------------------
# Конфіг
# ----------------------------
@dataclass
class ModelConfig:
    num_features: int
    cat_features: Dict[str, Tuple[int, int]]
    rnn_type: str = "gru"
    hidden_size: int = 128
    num_layers: int = 1
    dropout: float = 0.2
    bidirectional: bool = False
    predict_risk: bool = True
    grade_min: float = 0.0
    grade_max: float = 100.0


# ----------------------------
# Dataset + collate
# ----------------------------
class MoodleseqDataset(Dataset):
    def __init__(self, samples: List[Dict], cat_feature_names: List[str], include_risk: bool = True):
        self.samples = samples
        self.cat_feature_names = cat_feature_names
        self.include_risk = include_risk

    def __len__(self) -> int:
        return len(self.samples)
```

Рисунок 2 – Фрагмент коду модуля підготовки датасету і навчання RNN-моделі

Після завершення навчання здійснюється оцінювання якості моделі на валідаційній вибірці. За результатами оцінювання обирається найкраща версія моделі, яка зберігається у вигляді файлу ваг. Ця версія моделі передається в режим експлуатації та використовується для прогнозування навчальних результатів у реальному часі. Надалі, у міру накопичення нових даних, може здійснюватися періодичне донавчання або повне

перенавчання моделі, що дозволяє адаптувати її до змін у навчальних траєкторіях студентів, структурі курсу або педагогічних підходах.

Режим експлуатації є основним режимом функціонування інтелектуального модуля у складі освітньої платформи. У цьому режимі модель не навчається, а використовується для прогнозування та підтримки прийняття педагогічних рішень. Джерелом даних виступають поточні події навчальної діяльності студентів у LMS Moodle. Ці події передаються до модуля підготовки даних, де здійснюється їх нормалізація, агрегування та формування послідовностей ознак, що відповідають поточній навчальній траєкторії студента. Підготовлені дані подаються на вхід навченої рекурентної моделі, яка формує прогнозні показники: очікувану підсумкову оцінку, ймовірність успішного завершення курсу та ймовірність ризику неуспішності. Отримані значення передаються до модуля ситуаційно-сценарного аналізу, де на основі заданих правил і порогових значень визначається поточна навчальна ситуація студента. Відповідно до визначеної ситуації формується сценарій дій, який може включати рекомендації щодо повторення матеріалу, нагадування про необхідність виконання завдань, пропозицію консультації або інші підтримувальні заходи.

Для експерименту використано дисципліну **«**Основи програмування», що структурована на 10 тем, кожна з яких містить три компоненти: теоретичний матеріал (умовно — читання/перегляд); тестування (quiz); практичне завдання (assignment/practice). Для відтворення логіки Moodle сформовано події типу theory / quiz / practice. Кожна подія характеризується часовими, поведінковими та результативними ознаками. Важливим елементом експерименту стала формалізація системи оцінювання, яка прив’язує дії студента до балів, максимально наближених до реальної практики викладання: опрацювання теоретичного матеріалу не менше 30 хв → 2 бали; тест → максимум 4 бали, при цьому кожна додаткова спроба зменшує результат на 10%; практичне завдання → максимум 4 бали, при запізненні мінус 10%; сумарна оцінка за дисципліну — 100 балів. Параметри вибірки: кількість студентів: 50; кількість тем дисципліни: 10; кількість активностей на тему: 3 (теорія, тест, практика); максимальна підсумкова оцінка: 100 балів; частка студентів, що завершують курс: ≈70 %.

Для кожного студента формувалася часово впорядкована послідовність подій довжиною до 30 кроків. Було проведено навчання RNN, побудовані графіки навчання: **к**рива навчальної втрати (рис.3), крива валідаційної втрати (рис.4). Також досліджено інференс системи на даних про вивчення перших 6-ти тем дисципліни, отримані результати ситуаційно-сценарного аналізу (рис.5), сформовані звіти (рис.6).

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

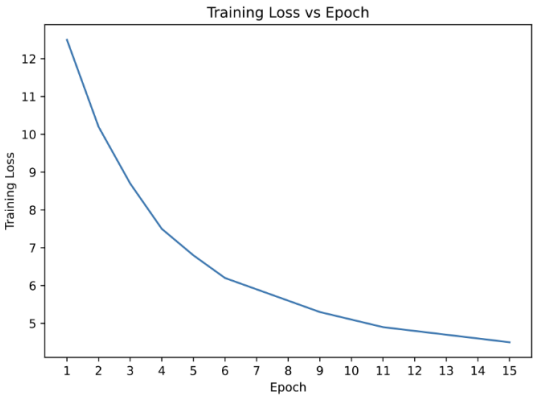


Рисунок 3 – Крива навчальної втрати

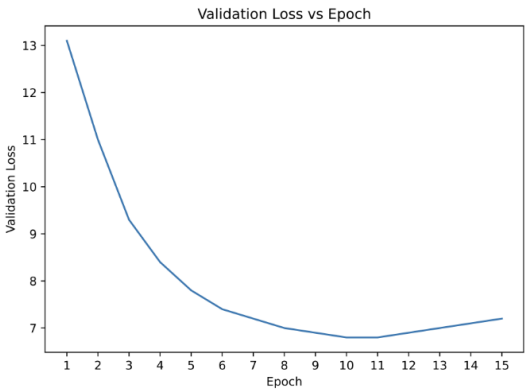


Рисунок 4 – Крива валідаційної втрати

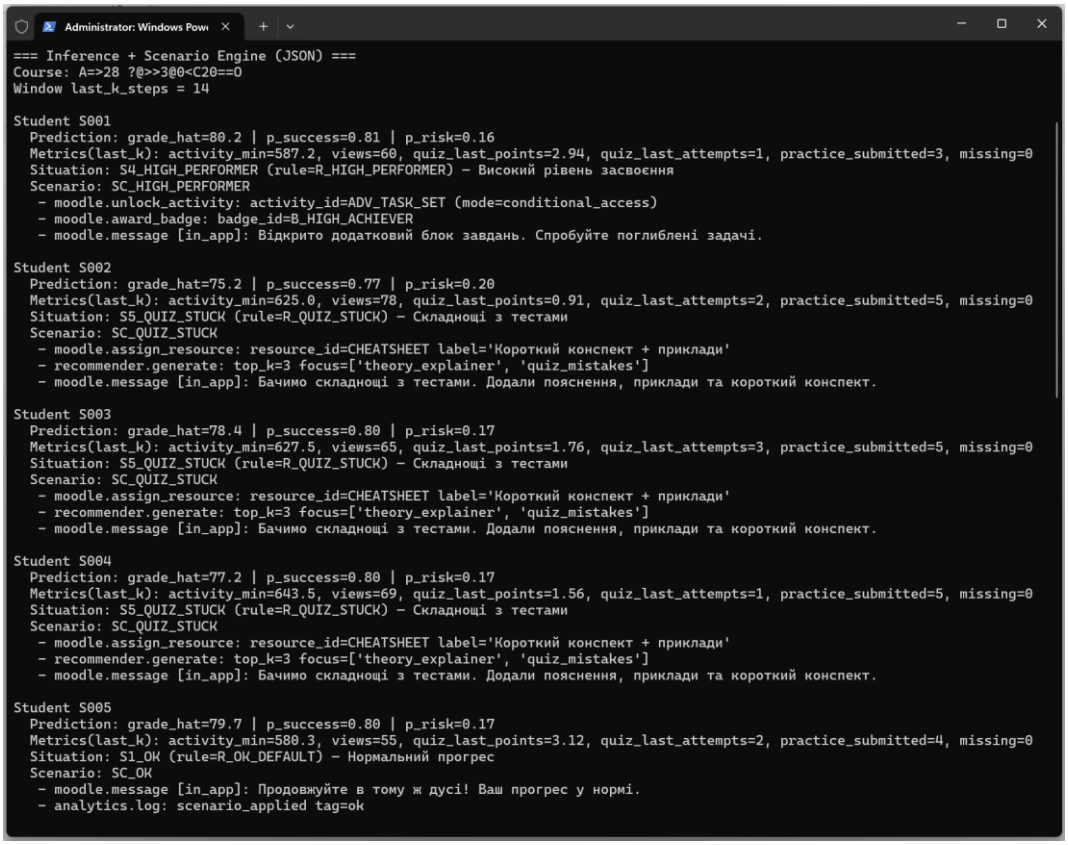
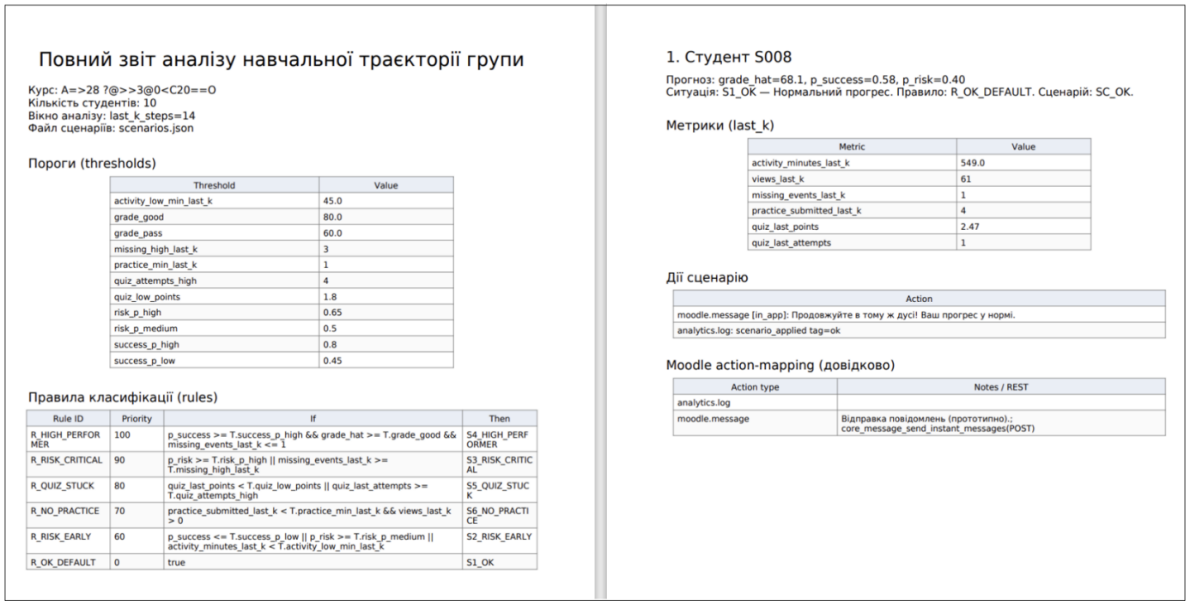


Рисунок 5 – Результати ситуаційно-сценарного аналізу



Повний звіт аналізу навчальної траєкторії групи

Курс: A=>28 ?@>>3@0<C20==O
Кількість студентів: 10
Вікно аналізу: last_k_steps=14
Файл сценаріїв: scenarios.json

Пороги (thresholds)

Threshold	Value
activity_low_min_last_k	45.0
grade_good	80.0
grade_pass	60.0
missing_high_last_k	3
practice_min_last_k	1
quiz_attempts_high	4
quiz_low_points	1.8
risk_p_high	0.65
risk_p_medium	0.5
success_p_high	0.8
success_p_low	0.45

Правила класифікації (rules)

Rule ID	Priority	If	Then
R_HIGH_PERFORMER	100	p_success >= T.success_p_high && grade_hat >= T.grade_good && missing_events_last_k <= 1	S4_HIGH_PERFORMER
R_RISK_CRITICAL	90	p_risk >= T.risk_p_high || missing_events_last_k >= T.missing_high_last_k	S3_RISK_CRITICAL
R_QUIZ_STUCK	80	quiz_last_points < T.quiz_low_points || quiz_last_attempts >= T.quiz_attempts_high	S5_QUIZ_STUCK
R_NO_PRACTICE	70	practice_submitted_last_k < T.practice_min_last_k && views_last_k > 0	S6_NO_PRACTICE
R_RISK_EARLY	60	p_success <= T.success_p_low || p_risk >= T.risk_p_medium || activity_minutes_last_k < T.activity_low_min_last_k	S2_RISK_EARLY
R_OK_DEFAULT	0	true	S1_OK

1. Студент S008

Прогноз: grade_hat=68.1, p_success=0.58, p_risk=0.40
Ситуація: S1_OK — Нормальний прогрес. Правило: R_OK_DEFAULT. Сценарій: SC_OK.

Метрики (last_k)

Metric	Value
activity_minutes_last_k	549.0
views_last_k	61
missing_events_last_k	1
practice_submitted_last_k	4
quiz_last_points	2.47
quiz_last_attempts	1

Дії сценарію

Action
moodle.message [in_app]: Продовжуйте в тому ж дусі! Ваш прогрес у нормі.
analytics.log: scenario_applied tag=ok

Moodle action-mapping (довідково)

Action type	Notes / REST
analytics.log	
moodle.message	Відправка повідомлень (прототипно).: core_message_send_instant_messages(POST)

Рисунок 6 – Фрагмент звіту з результатами ситуаційно-сценарного аналізу

Висновки. У роботі запропоновано інформаційну технологію підтримки навчального процесу в освітніх платформах дистанційного навчання, що поєднує прогнозування на основі рекурентних нейронних мереж із ситуаційно-сценарним механізмом інтерпретації результатів та формування педагогічних рекомендацій. RNN-модель забезпечує прогнозування підсумкової оцінки та ймовірності успішного завершення курсу, тоді як ситуаційно-сценарний модуль на основі прогнозних і фактичних показників, системи правил, порогових значень та пріоритетів визначає поточну навчальну ситуацію і формує відповідний сценарій підтримки.

Запропоновано багаторівневу архітектуру технології, що охоплює збір і підготовку даних, прогнозування, ситуаційну інтерпретацію, формування сценаріїв, звітність та візуалізацію. Її практичну реалізацію здійснено у вигляді програмного прототипу, інтегрованого з LMS Moodle та організованого у двох взаємопов’язаних режимах — навчання моделі та експлуатації.

Експериментальна апробація на модельних даних дисципліни «Основи програмування» підтвердила працездатність повного технологічного циклу — від обробки навчальних подій і прогнозування результатів до визначення ситуацій, формування диференційованих рекомендацій та аналітичної звітності. Отримані результати підтверджують можливість використання запропонованої технології для підтримки прийняття педагогічних рішень та індивідуалізації навчальних траєкторій. Подальші дослідження доцільно спрямувати на апробацію технології на реальних даних LMS, удосконалення механізмів налаштування сценарних правил та оцінювання впливу сформованих рекомендацій на результати навчання.

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)

ЛІТЕРАТУРА / REFERENCES

1. Piech C., Spencer J., Huang J., Ganguli S., Sahami M., Guibas L., Sohl-Dickstein J. Deep Knowledge Tracing. Advances in Neural Information Processing Systems. 2015. Vol. 28. DOI: https://doi.org/10.48550/arXiv.1506.05908.
2. Yu C.-C., Wu Y. Early Warning System for Online STEM Learning—A Slimmer Approach Using Recurrent Neural Networks. Sustainability. 2021. Vol. 13, No. 22. Article 12461. DOI: https://doi.org/10.3390/su132212461.
3. Jeong Y.-S., Cho N.-W. Evaluation of e-learners' concentration using recurrent neural networks. Journal of Supercomputing. 2023. Vol. 79. P. 4146–4163.
DOI: https://doi.org/10.1007/s11227-022-04804-w.
4. Dynamic Educational Recommender System Based on Improved LSTM Neural Network. Scientific Reports. 2024. Vol. 14. DOI: https://doi.org/10.1038/s41598-024-54729-y.
5. Fazil M., Rísquez A., Halpin C. A Novel Deep Learning Model for Student Performance Prediction Using Engagement Data. Journal of Learning Analytics. 2024. Vol. 11, No. 2. P. 23–41. DOI: https://doi.org/10.18608/jla.2024.7985.
6. Kalita E., Alfarwan A. M., El Aouifi H., Kukkar A., Hussain S., Ali T., Gaftandzhieva S. Predicting Student Academic Performance Using Bi-LSTM: A Deep Learning Framework with SHAP-Based Interpretability and Statistical Validation. Frontiers in Education. 2025. Vol. 10. DOI: https://doi.org/10.3389/feduc.2025.1581247.
7. Morgan A. Enhancing Access in an Online Course Using Universal Design for Learning (UDL) and Scenario-Based Learning (SBL). TechTrends. 2024.
DOI: https://doi.org/10.1007/s11528-024-00981-y.
8. Younas M., Ismayil I., El-Dakhs D. A. S., Anwar B., Noor U. Evaluating the Effectiveness of Digital Scenario-Based English Teaching at the University Level Using Artificial Intelligence Generated Content. Frontiers in Education. 2025. Vol. 10.
DOI: https://doi.org/10.3389/feduc.2025.1670892.
9. Brown M. Scenario-based Learning. In: How to Use Digital Learning with Confidence and Creativity. Cheltenham : Edward Elgar Publishing, 2024. P. 260–268.
DOI: https://doi.org/10.4337/9781035311293.00047.
10. Ören F. Ş., Karapınar A., Sarı K., Demirer T. The Effect of Scenario-Based Learning on Eighth-Grade Students' Perceptions of Scientists. Journal of Educational Research and Practice. 2023. Vol. 13, No. 1. P. 99–122. DOI: https://doi.org/10.5590/JERAP.2023.13.1.09.

Received 24.06.2026.
Accepted 25.08.2026.
Published 30.10.2026

Information technology for supporting learning trajectories based on recurrent neural networks and a situation-scenario approach

Abstract. The relevance of this study is determined by the need to improve the effectiveness of supporting students' learning trajectories in distance learning systems through intelligent analysis of accumulated educational data. Modern educational platforms provide substantial amounts of information on student performance and activity; however, academic performance prediction alone does not determine subsequent pedagogical actions. The research problem lies in the need to move from obtaining predictive indicators to their situational in-

terpretation and the formation of adaptive support scenarios. The aim of the study is to develop an information technology for supporting learning trajectories based on the integration of recurrent neural networks and a situation-scenario approach. The research employs methods of neural network forecasting of time series, situational analysis, production rules, threshold-based decision-making mechanisms, and experimental modeling. A multi-level architecture of the proposed technology is developed, encompassing data collection and preparation, forecasting, situational interpretation, scenario generation, reporting, and visualization. The RNN model provides predictions of the final grade and the probability of successful course completion, while the situation-scenario module determines the state of a learning trajectory and generates an appropriate set of pedagogical actions. A software prototype integrated with LMS Moodle was developed and tested using model data from the course Fundamentals of Programming. The results confirmed the operability of the complete technological cycle and demonstrated the possibility of generating differentiated support scenarios based on predicted outcomes and indicators of students' learning activity. The proposed technology creates prerequisites for the timely detection of risks, adaptive support of learning trajectories, and informed pedagogical decision-making in distance education.

Keywords: distance learning, educational platform, learning trajectory, recurrent neural network, RNN, GRU, academic performance prediction, situation-scenario approach, adaptive support, LMS Moodle.

Палагута Катерина Олексіївна - кандидат економічних наук, доцент, доцент кафедри інженерії програмного забезпечення та кібербезпеки, Державний торговельно-економічний університет, м. Київ, Україна.
ORCID: https://orcid.org/0000-0003-1167-9509
Савон Олексій Євгенійович – аспірант кафедри інженерії програмного забезпечення та кібербезпеки, Державний торговельно-економічний університет, м. Київ, Україна.
ORCID: https://orcid.org/0009-0006-4905-8969

Palaguta Kateryna Oleksiivna – PhD in Economics, Associate Professor, Associate Professor of the Department of Software Engineering and Cybersecurity, State University of Trade and Economics, Kyiv, Ukraine.
ORCID: https://orcid.org/0000-0003-1167-9509
Savon Oleksii Yevheniiovych – Postgraduate Student (PhD Student) of the Department of Software Engineering and Cybersecurity, State University of Trade and Economics, Kyiv, Ukraine.
ORCID: https://orcid.org/0009-0006-4905-8969

ISSN 1562-9945 (Print)
ISSN 2707-7977 (Online)