

**ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ
ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КАФЕДРА ІНЖЕНЕРІЇ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ**

КВАЛІФІКАЦІЙНА РОБОТА

на тему: «Методика рекомендації навчальних матеріалів у
корпоративному середовищі на основі колаборативної
фільтрації»

на здобуття освітнього ступеня магістра
зі спеціальності 121 Інженерія програмного забезпечення
освітньо-професійної програми «Інженерія програмного забезпечення»

Кваліфікаційна робота містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

_____ Олександр ГУДОВСЬКИХ
(підпис)

Виконав: здобувач вищої освіти групи ПДМ-63
Олександр ГУДОВСЬКИХ

Керівник: _____ Данило КОВАЛЕНКО
доктор філософії PhD

Рецензент: _____
науковий ступінь, _____
вчене звання _____
Ім'я, ПРІЗВИЩЕ

**ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ**
Навчально-науковий інститут інформаційних технологій

Кафедра Інженерії програмного забезпечення

Ступінь вищої освіти Магістр

Спеціальність 121 Інженерія програмного забезпечення

Освітньо-професійна програма «Інженерія програмного забезпечення»

ЗАТВЕРДЖУЮ

Завідувач кафедри

Інженерії програмного забезпечення

_____ Ірина ЗАМРІЙ

« _____ » _____ 2025 р.

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

Гудовських Олександрю Вадимовичу

1. Тема кваліфікаційної роботи: «Методика рекомендації навчальних матеріалів у корпоративному середовищі на основі колаборативної фільтрації»
керівник кваліфікаційної роботи Данило КОВАЛЕНКО, доктор філософії PhD,
затверджені наказом Державного університету інформаційно-комунікаційних
технологій від «30» жовтня 2025 р. № 467.
2. Строк подання кваліфікаційної роботи «19» грудня 2025 р.
3. Вихідні дані до кваліфікаційної роботи: дані про користувачів і навчальні
матеріали корпоративної системи, алгоритми колаборативної та контентної
фільтрації, бібліотека LightFM, метрики оцінювання точності (MAE,
Precision@K).
4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно
розробити)
 1. Аналіз предметної області та огляд сучасних підходів до корпоративного
навчання.
 2. Огляд існуючих моделей і методів рекомендаційних систем, заснованих на
колаборативній та контентній фільтрації.
 3. Розроблення гібридної методики рекомендації навчальних матеріалів у
корпоративному середовищі.
 4. Побудова математичної моделі та алгоритму роботи системи.

5. Реалізація програмного прототипу рекомендаційного модуля засобами Python та бібліотеки LightFM.
 6. Експериментальна перевірка ефективності моделі за допомогою метрик MAE, RMSE, Precision@K, Recall@K.
 7. Формулювання висновків і пропозицій щодо впровадження розробленої методики у корпоративні освітні системи.
5. Перелік ілюстративного матеріалу: презентація
1. Актуальність роботи.
 2. Математична модель гібридної рекомендаційної системи.
 3. Алгоритм роботи гібридної рекомендаційної системи.
 4. Модифікований метод колаборативної фільтрації.
 5. Ефективність запропонованого рішення.
 6. Практичне значення.
6. Дата видачі завдання «31» жовтня 2025 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1	Аналіз наявної науково-технічної літератури	31.10 – 05.11.2025	
2	Вивчення існуючих підходів до побудови колаборативних, контентних і гібридних моделей рекомендацій	06.11 – 11.11.2024	
3	Дослідження алгоритмів колаборативної фільтрації (User-based CF, Item-based CF)	12.11.- 17.11.2025	
4	Аналіз впливу контентних і контекстних факторів на точність рекомендацій	17.11 – 20.11.2025	
5	Розробка математичної моделі гібридної методики рекомендації навчальних матеріалів	21.11- 30.11.2025	
6	Реалізація моделі та проведення експериментального тестування в середовищі Python	01.12 – 06.12.2025	
7	Аналіз результатів експерименту, оцінювання ефективності за метриками (MAE, RMSE, Precision@5, Recall@5)	07.12 – 11.12.2025	
7	Оформлення роботи: вступ, висновки, реферат	12.12 - 16.12.2025	
8	Розробка демонстраційних матеріалів	17.12 - 19.12.2025	

Здобувач вищої освіти _____

(підпис)

Олександр ГУДОВСЬКИХ

Керівник
кваліфікаційної роботи _____

(підпис)

Данило КОВАЛЕНКО

РЕФЕРАТ

Текстова частина кваліфікаційної роботи на здобуття освітнього ступеня магістра: 68 стор., 5 табл., 3 рис., 37 джерел.

Мета роботи – удосконалення підбору навчальних матеріалів за допомогою на основі колаборативної фільтрації для підвищення ефективності та персоналізації процесу навчання.

Об'єкт дослідження – Процес рекомендації та персоналізації навчальних матеріалів у корпоративному середовищі з використанням цифрових освітніх систем.

Предмет дослідження – методика рекомендації навчальних матеріалів у корпоративному середовищі на основі колаборативної фільтрації.

У роботі використано різноманітні методи, такі як колаборативна та контентна фільтрація, факторизація матриць, а також гібридні підходи до персоналізації навчання.

Проведено аналіз сучасних алгоритмів рекомендаційних систем і визначено їхні переваги та обмеження у контексті корпоративного навчання.

Розроблено та оптимізовано гібридну модель, яка поєднує колаборативний, контентний та контекстний підходи для підвищення точності рекомендацій.

Проведено експерименти з оцінювання ефективності запропонованої моделі за метриками MAE, Precision@K та Recall@K.

КЛЮЧОВІ СЛОВА: КОЛАБОРАТИВНА ФІЛЬТРАЦІЯ, КОРПОРАТИВНЕ НАВЧАННЯ, ПЕРСОНАЛІЗАЦІЯ, ГІБРИДНА МОДЕЛЬ, КОНТЕНТНА ФІЛЬТРАЦІЯ, КОНТЕКСТНА АДАПТАЦІЯ, LIGHTFM, ОЦІНКА ТОЧНОСТІ, MAE, PRECISION@K.

ABSTRACT

The text part of the master's qualification thesis contains 72 pages, 5 tables, 3 figures, and 37 references.

Purpose of the work – Development of a methodology for recommending learning materials in a corporate environment based on collaborative filtering to improve the efficiency and personalization of the learning process.

Object of research – The process of recommending and personalizing learning materials in a corporate environment using digital educational systems.

Subject of research – The method of recommending learning materials in a corporate environment based on collaborative filtering.

Various methods were used in the work, such as collaborative and content-based filtering, matrix factorization, as well as hybrid approaches to learning personalization.

An analysis of modern recommendation system algorithms was conducted, and their advantages and limitations in the context of corporate learning were identified.

A hybrid model combining collaborative, content-based, and context-aware approaches was developed and optimized to improve recommendation accuracy.

Experiments were carried out to evaluate the effectiveness of the proposed model using metrics such as MAE, Precision@K, and Recall@K.

KEYWORDS: COLLABORATIVE FILTERING, CORPORATE LEARNING, PERSONALIZATION, HYBRID MODEL, CONTENT-BASED FILTERING, CONTEXT ADAPTATION, LIGHTFM, ACCURACY EVALUATION, MAE, PRECISION@K.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ.....	9
ВСТУП.....	11
1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ.....	16
1.1 Теоретичні основи корпоративного навчання та цифрових освітніх систем.....	16
1.2. Класифікація рекомендаційних систем у цифровій освіті	18
1.3. Колаборативна фільтрація: принципи та алгоритми.....	21
1.4 Висновки до розділу 1	25
2. МОДЕЛІ КОЛАБОРАТИВНОЇ ФІЛЬТРАЦІЇ ТА ЇХ ЗАСТОСУВАННЯ У СИСТЕМАХ РЕКОМЕНДАЦІЇ НАВЧАЛЬНИХ МАТЕРІАЛІВ.....	26
2.1. Концептуальні підходи до побудови рекомендаційних моделей	27
2.2. Алгоритми колаборативної фільтрації в освітніх системах	29
2.3. Архітектура запропонованої методики.....	31
2.4. Алгоритмічна модель рекомендацій	32
2.5. Метрики оцінювання якості рекомендаційних систем	33
2.6 Висновки до розділу 2	34
3. РОЗРОБКА МЕТОДИКИ РЕКОМЕНДАЦІЇ НАВЧАЛЬНИХ МАТЕРІАЛІВ У КОРПОРАТИВНОМУ СЕРЕДОВИЩІ.....	35
3.1. Загальні принципи побудови рекомендаційної системи в корпоративному навчанні	36
3.2. Архітектура запропонованої методики.....	37
3.3. Алгоритмічна модель методики	38
3.4. Оцінювання якості моделі.....	40
3.5. Практичне значення розробленої методики.....	41

3.7. Експериментальна перевірка ефективності запропонованої методики.....	42
3.8. Мета та завдання експерименту	43
3.9. Організація експерименту	43
3.10. Методика проведення експерименту	44
3.11. Результати експерименту	46
3.12. Аналіз результатів.....	47
3.13. Візуалізація результатів.....	48
3.14. Аналіз результатів.....	49
3.15. Рекомендації та перспективи подальших досліджень	50
3.16. Висновки до розділу 3	53
ВИСНОВКИ.....	55
ПЕРЕЛІК ПОСИЛАНЬ	58
ДОДАТОК А. ДЕМОНСТРАЦІЙНІ МАТЕРІАЛИ	61

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

AI (Artificial Intelligence) — штучний інтелект, галузь інформатики, що займається створенням систем, здатних виконувати завдання, які потребують інтелектуальної діяльності людини.

CF (Collaborative Filtering) — колаборативна фільтрація; метод рекомендацій, що ґрунтується на аналізі схожості користувачів або об'єктів.

CBF (Content-Based Filtering) — контентна фільтрація; підхід, що базується на порівнянні змістових характеристик навчальних матеріалів.

LMS (Learning Management System) — система управління навчанням; програмна платформа для організації, проведення та моніторингу навчального процесу.

LXP (Learning Experience Platform) — платформа навчального досвіду; інтегроване середовище для персоналізованого навчання з елементами аналітики й рекомендацій.

MAE (Mean Absolute Error) — середня абсолютна похибка; показник точності прогнозу в рекомендаційних системах.

RMSE (Root Mean Square Error) — корінь середньоквадратичної похибки; метрика стабільності прогнозу.

Precision@K — показник точності серед перших K рекомендацій, який визначає частку релевантних навчальних матеріалів.

Recall@K — показник повноти серед перших K рекомендацій, який відображає частку всіх релевантних матеріалів, знайдених системою.

F1-score — гармонійне середнє між показниками Precision і Recall, що характеризує загальну ефективність системи.

Big Data — великі дані; масиви структурованої та неструктурованої інформації, що обробляються з використанням спеціалізованих аналітичних методів.

ML (Machine Learning) — машинне навчання; підгалузь штучного інтелекту, яка забезпечує здатність систем автоматично вдосконалюватися на основі даних.

NLP (Natural Language Processing) — обробка природної мови; технології аналізу текстових даних у рекомендаційних системах.

CF User-based — колаборативна фільтрація, орієнтована на користувачів; метод пошуку схожих користувачів для прогнозування їхніх уподобань.

CF Item-based — колаборативна фільтрація, орієнтована на об'єкти; метод визначення схожих навчальних матеріалів для формування рекомендацій.

Matrix Factorization (MF) — матрична факторизація; модель розкладу матриці рейтингів на добуток матриць користувачів і курсів для виявлення латентних зв'язків.

Hybrid CF — гібридна колаборативна фільтрація; підхід, що поєднує декілька методів рекомендацій (колаборативний, контентний, контекстний).

Context-aware System — контекстно-залежна система; рекомендаційна система, що враховує додаткові фактори (посада, навички, відділ, цілі розвитку).

HRM (Human Resource Management) — управління людськими ресурсами; стратегічна діяльність компанії, спрямована на розвиток персоналу.

Python — мова програмування, що широко застосовується для побудови систем машинного навчання й аналітики даних.

LightFM — бібліотека Python для реалізації гібридних рекомендаційних моделей на основі колаборативної фільтрації та контентного аналізу.

MAE ↓ / RMSE ↓ — стрілка «вниз» позначає бажання зменшення показника (менше — краще).

Precision@K ↑ / Recall@K ↑ — стрілка «вгору» позначає бажання збільшення показника (більше — краще).

ВСТУП

У сучасних умовах глобальної цифрової трансформації та швидких технологічних змін питання підвищення ефективності корпоративного навчання набуває особливої актуальності. Знання, компетенції та навички працівників стають ключовим стратегічним ресурсом, який визначає конкурентоспроможність підприємств у динамічному ринковому середовищі. Однак стрімке зростання обсягів інформації та різноманіття навчальних матеріалів ускладнюють процес їх раціонального відбору та адаптації до потреб конкретного працівника.

Технологічні зміни, що відбуваються в глобальному масштабі, потребують від компаній нових підходів до управління компетенціями працівників. Корпоративне навчання, як складова стратегії розвитку персоналу, стає не лише інструментом підвищення кваліфікації, а й ключовим чинником підтримання конкурентоспроможності організації.

У цьому контексті традиційні методи підготовки кадрів поступаються місцем інтелектуальним цифровим системам, які здатні не лише фіксувати результати навчання, а й прогнозувати освітні потреби працівників. Особливу роль у цьому процесі відіграють рекомендаційні системи, що забезпечують персоналізований підхід до навчання, формуючи індивідуальні траєкторії розвитку з урахуванням рівня компетентності, посади та кар'єрних цілей користувача.

Одним із найефективніших підходів до побудови таких систем є колаборативна фільтрація (Collaborative Filtering), що ґрунтується на аналізі подібності між користувачами або навчальними матеріалами за історією їхніх взаємодій. Даний метод довів свою ефективність у комерційних і соціальних платформах (Amazon, Netflix, Spotify) та демонструє значний потенціал у сфері корпоративного e-learning. Водночас його застосування у корпоративному контексті супроводжується низкою викликів: розрідженістю даних, проблемою

“холодного старту”, необхідністю врахування контексту користувача та постійною динамікою освітнього контенту.

Отже, актуальність дослідження зумовлена потребою створення інтелектуальних рекомендаційних систем корпоративного навчання, що поєднують сучасні підходи машинного навчання з методами аналітики освітніх даних і враховують контекстні характеристики користувачів.

Метою роботи є розроблення методики рекомендації навчальних матеріалів у корпоративному середовищі, що базується на принципах колаборативної фільтрації та враховує професійні особливості працівників.

Для досягнення поставленої мети необхідно вирішити такі завдання:

1. Провести аналіз предметної області корпоративного навчання та сучасних підходів до побудови рекомендаційних систем.
2. Дослідити алгоритми колаборативної, контентної та гібридної фільтрації, їхні переваги та обмеження.
3. Розробити методику рекомендації навчальних матеріалів для корпоративного середовища.
4. Реалізувати прототип рекомендаційної системи засобами Python із використанням бібліотеки LightFM.
5. Провести експериментальну перевірку ефективності розробленої методики та оцінити її якість за метриками MAE, RMSE, Precision@K і Recall@K.

Об’єкт дослідження – процес персоналізованого корпоративного навчання.

Предмет дослідження – методи побудови рекомендаційних систем для індивідуалізації навчального процесу.

Методи дослідження включають аналіз наукових джерел, моделювання алгоритмів машинного навчання, використання бібліотек Python (LightFM, NumPy, Pandas, Matplotlib) та експериментальне тестування моделі на синтетичних і відкритих наборах даних.

Наукова новизна полягає в удосконаленні гібридного підходу до рекомендації навчальних матеріалів, який об'єднує колаборативну та контентну фільтрацію з урахуванням професійного контексту користувача.

Практичне значення роботи полягає у можливості впровадження розробленої методики в корпоративні системи управління навчанням (LMS/LXP), що дозволить підвищити ефективність навчання персоналу та скоротити час на пошук релевантних освітніх ресурсів.

Апробація результатів роботи. Міжнародна науково-практична конференція «Прикладні системи управління та робототехніка» - Київ, 13.11.2025: Інституту прикладних систем управління НАН України, 2025.

Структура роботи. Магістерська кваліфікаційна робота складається з п'яти розділів, висновків, списку використаних джерел і додатків.

У першому розділі виконано аналіз предметної області корпоративного навчання та цифрових освітніх систем.

Другий розділ присвячено дослідженню моделей колаборативної фільтрації та їх застосування в освітніх рекомендаційних системах.

У третьому розділі розроблено гібридну методику рекомендації навчальних матеріалів і представлено її архітектуру.

Четвертий розділ містить результати експериментальної перевірки ефективності моделі та аналіз її показників.

У п'ятому розділі наведено узагальнені висновки, практичні рекомендації та перспективи подальших досліджень.

У висновках узагальнено результати дослідження, визначено наукову новизну, практичну цінність і перспективи подальших розробок.

1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

1.1 Теоретичні основи корпоративного навчання та цифрових освітніх систем

За останнє десятиліття поняття «цифрове навчання» набуло нового змісту. Якщо раніше воно зводилося переважно до електронних курсів, то сьогодні цифрове середовище включає складні системи збору, обробки та аналізу даних про навчальну діяльність.

Корпоративне навчання трансформується з ізольованого процесу у багатовимірну екосистему, де працівники, навчальні матеріали, аналітика та управлінські рішення утворюють єдиний інформаційний простір.

У цьому контексті зростає роль систем, здатних не лише надавати контент, а й розуміти, що саме потрібно користувачу.

Історично ідея персоналізованих рекомендацій бере свій початок у сфері електронної комерції. У 1990-х роках з'явилися перші алгоритми рекомендацій товарів (Amazon, eBay), які швидко довели свою ефективність.

Надалі ці технології почали впроваджуватись у цифрову освіту. Зокрема, освітні платформи Coursera, EdX, Udemy застосовують принципи колаборативної фільтрації для формування індивідуальних рекомендацій курсів і треків навчання.

Одним із головних напрямів досліджень у сфері освітньої інформатики є пошук механізмів, які дозволяють поєднати дані про компетенції, результати навчання та професійний досвід у єдину модель користувача.

Це відкриває можливості для побудови адаптивних систем, що враховують попередній досвід працівника, його роль у компанії, поточні завдання та навіть кар'єрні цілі.

Сучасний етап розвитку економіки характеризується інтенсивною цифровізацією бізнес-процесів, що зумовлює необхідність безперервного оновлення знань і компетенцій працівників. У таких умовах корпоративне

навчання розглядається не лише як форма підвищення кваліфікації персоналу, а як стратегічна складова управління людським капіталом.

Згідно з дослідженням Barile, Ciasullo, Testa і La Sala (2023) [1], корпоративне навчання — це систематичний процес розвитку компетенцій працівників з урахуванням стратегічних цілей організації. Воно спрямоване на формування знань, навичок і цінностей, що забезпечують адаптацію до технологічних і організаційних змін.

З переходом бізнесу у цифрову площину формується новий формат — цифрове корпоративне навчання (Digital Corporate Learning), який поєднує можливості інформаційних технологій, аналітики даних і адаптивних освітніх платформ. Як зазначають Shurygin, Saenko та Klochko (2021) [2], ефективність сучасних навчальних систем визначається рівнем інтеграції технологій управління знаннями (Knowledge Management Systems) і навчанням у корпоративному середовищі.

Цифрові освітні системи у корпоративному секторі функціонують на базі Learning Management Systems (LMS), які забезпечують управління курсами, контролем успішності та комунікацією між працівниками. Утім, у 2020-х роках відбувається поступовий перехід до Learning Experience Platforms (LXP) — платформ, орієнтованих не лише на контент, а й на досвід користувача, його мотивацію та професійний розвиток (Alenezi, 2023) [3].

Психолого-педагогічні основи корпоративного навчання базуються на теоріях андрагогіки (Knowles, 1984) [4], конструктивізму (Piaget, 1970) [5] та конективізму (Siemens, 2005) [6]. Особливо важливою у цифрову добу є теорія конективізму, згідно з якою навчання відбувається шляхом створення і підтримки зв'язків між інформаційними вузлами — людьми, технологіями та спільнотами (Dziubaniuk & Ivanova-Gongne, 2023) [7].

Таким чином, корпоративне навчання у цифровому середовищі — це динамічна система формальної та неформальної освіти, у якій працівник є активним учасником процесу побудови знань. Цифрові платформи (Coursera for Business, LinkedIn Learning, Degreed, Udemy for Teams) виконують роль

посередників між індивідуальними потребами та корпоративними компетенціями.

Розвиток корпоративного навчання дедалі більше орієнтується на аналітику навчання (Learning Analytics), адаптивність контенту та персоналізацію траєкторій розвитку (Ivaldi, Scaratti & Fregnan, 2022) [8]. Ці принципи лежать в основі побудови рекомендаційних систем, що дозволяють узгоджувати навчальні потреби працівників із вимогами компанії.

1.2. Класифікація рекомендаційних систем у цифровій освіті

У сучасних цифрових освітніх середовищах рекомендаційні системи виступають ключовим інструментом персоналізації навчання, оскільки вони забезпечують індивідуальний добір навчальних матеріалів, курсів і завдань відповідно до потреб, інтересів і рівня підготовки користувача. Як зазначає Zhang та співавт. (2021) [9], рекомендаційна система — це інтелектуальна технологія, що прогнозує переваги користувача на основі аналізу даних про його поведінку, попередню активність, успішність і навчальні результати.

У контексті цифрової освіти такі системи виконують роль адаптивного посередника між користувачем і великими обсягами навчального контенту. Вони формують рекомендації, виходячи з цілей навчання, стилю засвоєння інформації, професійного профілю та контексту роботи користувача. На відміну від традиційних платформ, які пропонують однаковий набір курсів для всіх, рекомендаційні системи дозволяють створювати персоналізовані траєкторії навчання, що підвищують мотивацію, залученість і результативність.

Як зазначають Joy і Pillai (2022) [10] та Uddin і співавт. (2021) [11], у більшості сучасних освітніх рекомендаційних систем реалізовано методи машинного навчання, обробки природної мови (NLP), онтологічного моделювання, а також аналітики великих даних (Big Data Analytics). Це дозволяє системам навчатися на основі історичних даних, передбачати інтереси користувачів і пропонувати релевантні матеріали у реальному часі.

Для забезпечення повної індивідуалізації навчального процесу рекомендаційні системи мають враховувати не лише попередню поведінку користувача, але й контекст його діяльності, психологічні особливості та типи мислення.

Сучасні дослідження показують, що рівень сприйняття навчального контенту суттєво залежить від стилю навчання (візуальний, аудіальний, кінестетичний), що, у свою чергу, впливає на алгоритми персоналізації.

Таким чином, ефективна рекомендаційна система у сфері освіти повинна бути багатовимірною, тобто аналізувати не лише історію взаємодій, а й особистісні характеристики користувача.

Згідно з класифікацією, запропонованою Jena, Kumar і Sharma (2022) [12], а також Souabi, Serhani та El Ouahidi (2021) [13], усі рекомендаційні системи, що застосовуються в цифровій освіті, можна поділити на п'ять основних типів (див. табл. 1):

Таблиця 1

Класифікація рекомендаційних систем у цифровій освіті

Тип рекомендаційної системи	Коротка характеристика	Переваги	Недоліки
Контентно-орієнтована (Content-based Filtering)	Аналізує характеристики навчальних матеріалів і підбирає схожі за змістом	Проста реалізація, індивідуальний підхід	Обмежене різноманіття, залежність від якості опису контенту
Колаборативна фільтрація (Collaborative Filtering)	Ґрунтується на схожості користувачів або об'єктів за їх оцінками	Висока точність, врахування поведінки користувачів	Проблеми “cold start”, чутливість до розрідженості даних
Гібридна система (Hybrid Recommendation)	Поєднує контентну та колаборативну фільтрацію	Збалансована точність, адаптивність	Складність реалізації, потреба в налаштуванні ваг
Знання-орієнтована (Knowledge-based)	Використовує онтології та експертні правила для формування рекомендацій	Точність у спеціалізованих областях	Висока трудомісткість підтримки бази знань
Контекстно-орієнтована (Context-aware Recommendation)	Враховує контекст користувача — час, місце, роль, пристрій	Актуальність і персоналізація	Високі вимоги до збору контекстних даних

За рівнем інтеграції у навчальний процес освітні рекомендаційні системи можна класифікувати на три основні групи (Souabi, Serhani & El Ouahidi, 2021) [13]:

— Пасивні системи — забезпечують користувача переліком рекомендованих ресурсів без урахування його результатів, прогресу чи поведінкових характеристик. Такі системи здебільшого реалізують базову фільтрацію контенту та не здійснюють глибокого аналізу потреб користувача.

— Активні (адаптивні) системи — використовують алгоритми машинного навчання для автоматичного підбору контенту залежно від поточних результатів, темпу навчання, історії переглядів і вподобань користувача. Вони формують персоналізовані траєкторії розвитку та можуть динамічно змінювати навчальний план.

— Інтелектуальні або контекстно-орієнтовані системи (Context-aware Systems) — інтегрують дані про зовнішні фактори, такі як час, місце навчання, роль у компанії, рівень досвіду чи пристрій користувача. Завдяки цьому вони забезпечують максимальний рівень персоналізації та адаптації до умов реального корпоративного середовища.

Таким чином, класифікація рекомендаційних систем демонструє, що найперспективнішим підходом у цифровій освіті є гібридні моделі, які поєднують кілька методів — зокрема колаборативну, контентну та контекстну фільтрацію. Вони дозволяють подолати обмеження окремих алгоритмів і забезпечити вищу точність рекомендацій, що є критично важливим для корпоративного навчання.

У ході розвитку освітніх технологій сформувалися різні парадигми побудови рекомендаційних систем, кожна з яких має свої особливості й обмеження.

На початкових етапах застосовувалися так звані правиліві системи (rule-based systems), які функціонували за принципом фіксованих сценаріїв: якщо користувач завершив курс «Основи маркетингу», то система рекомендувала курс «Маркетингова аналітика».

Хоча такі рішення є простими, вони не враховують індивідуальних відмінностей користувачів і не здатні до самонавчання.

Подальший розвиток рекомендаційних технологій пов'язаний із появою контентно-орієнтованих методів, які використовують ключові слова, описи курсів, теги та метадані.

У цьому випадку система намагається знайти матеріали, схожі за змістом на ті, з якими користувач взаємодіяв раніше.

Наприклад, якщо співробітник переглядав курси з проєктного менеджменту, система може запропонувати матеріали з Agile або Scrum.

Незважаючи на простоту реалізації, контентна фільтрація має серйозне обмеження — вона не здатна виявляти приховані зв'язки між користувачами.

Саме тому на зміну цим підходам прийшла колаборативна фільтрація, яка стала основою сучасних рекомендаційних систем.

Вона базується на припущенні, що користувачі, які поведуться схожим чином, матимуть подібні інтереси у майбутньому.

1.3. Колаборативна фільтрація: принципи та алгоритми

Колаборативна фільтрація (Collaborative Filtering, CF) є одним із найефективніших і найпоширеніших підходів до побудови рекомендаційних систем. Її основна ідея полягає у тому, що користувачі, які в минулому мали схожі вподобання, з великою ймовірністю демонструватимуть подібну поведінку в майбутньому (Ricci, Rokach & Shapira, 2021) [14].

Мета колаборативної фільтрації полягає у прогнозуванні оцінки, яку користувач може поставити певному навчальному матеріалу або курсу, спираючись на історію взаємодій інших користувачів із подібними характеристиками.

Основним елементом методу є матриця взаємодій $R = [r_{ui}]$, де r_{ui} — оцінка, яку користувач u надав об'єкту i . Проте ця матриця зазвичай є розрідженою, оскільки користувачі взаємодіють лише з невеликою частиною

контенту, тому завдання CF полягає у заповненні пропусків — тобто передбаченні відсутніх оцінок.

Колаборативна фільтрація на основі користувачів (User-based Collaborative Filtering)

Метод орієнтований на пошук користувачів зі схожими моделями поведінки. Схожість між двома користувачами u і v обчислюється за коефіцієнтом кореляції Пірсона, який визначає ступінь лінійного зв'язку між їх оцінками (Resnick et al., 1994) [15]:

$$\text{sim}(u, v) = \frac{\sum_i (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)}{\sqrt{\sum_i (r_{ui} - \bar{r}_u)^2} \cdot \sqrt{\sum_i (r_{vi} - \bar{r}_v)^2}} \quad (1.1)$$

де

r_{ui} — оцінка користувача u для об'єкта i ;

\bar{r}_u — середня оцінка користувача u ;

$N(u)$ — множина користувачів, подібних до u .

Після цього прогнозована оцінка користувача u для навчального матеріалу i розраховується за формулою (Su & Khoshgoftaar, 2009) [16]:

$$\hat{r}_{ui} = \bar{r}_u + \frac{\sum_{v \in N(u)} \text{sim}(u, v) \cdot (r_{vi} - \bar{r}_v)}{\sum_{v \in N(u)} |\text{sim}(u, v)|} \quad (1.2)$$

Колаборативна фільтрація на основі об'єктів (Item-based Collaborative Filtering)

На відміну від попереднього підходу, Item-based CF орієнтований не на користувачів, а на самі об'єкти (курси чи матеріали). Якщо користувач позитивно оцінив певний курс, система шукає інші курси, подібні за характеристиками або рівнем популярності серед схожих користувачів. Прогнозована оцінка в цьому разі обчислюється як (Sarwar et al., 2001) [17]:

$$\hat{r}_{ui} = \frac{\sum_{j \in N(i)} \text{sim}(i, j) \cdot r_{uj}}{\sum_{j \in N(i)} |\text{sim}(i, j)|} \quad (1.3)$$

де

$N(i)$ — множина елементів, схожих на об'єкт i ,

$\text{sim}(i, j)$ — міра подібності між об'єктами i та j .

Перевага цього підходу полягає у вищій масштабованості — розрахунок подібності між об'єктами виконується один раз, що зменшує обчислювальні витрати при великій кількості користувачів.

Метод матричної факторизації

У більш сучасних системах колаборативна фільтрація реалізується через матричну факторизацію (Matrix Factorization), запропоновану Koren, Bell і Volinsky (2009) [18]. Ідея методу полягає у представленні матриці оцінок R як добутку двох матриць менших розмірностей: і

$$R \approx P \times Q^T \quad (1.4)$$

де

$P \in R^{m \times k}$ — матриця користувачів, що містить k латентних факторів;

$Q \in R^{n \times k}$ — матриця об'єктів у тому ж латентному просторі;

k — кількість прихованих характеристик (факторів).

Навчання виконується шляхом мінімізації функції втрат:

$$L = \sum_{(u,i) \in K} (r_{ui} - P_u Q_i^T)^2 + \lambda (||P_u||^2 + ||Q_i||^2) \quad (1.5)$$

де

K — множина відомих оцінок,

λ — коефіцієнт регуляризації для запобігання перенавчанню.

Такий підхід дозволяє виявити приховані закономірності між користувачами й навчальними матеріалами, що недоступні при класичних підходах.

Гібридні та контекстно-орієнтовані моделі

Останні дослідження свідчать про підвищення ефективності систем, які поєднують колаборативну фільтрацію з іншими підходами.

Зокрема, гібридні моделі (Hybrid CF) поєднують принципи колаборативного аналізу з контентним або онтологічним описом навчальних курсів (Joy, Pillai & George, 2021) [19].

Контекстно-орієнтовані моделі (Context-aware CF) враховують додаткові чинники — посаду працівника, компетенції, часові обмеження, кар'єрну траєкторію (Uddin et al., 2021) [11].

Крім того, Deep CF моделі (Salau, Owolabi & Abubakar, 2022) [20] застосовують глибинні нейронні мережі для виявлення складних латентних залежностей у великих навчальних даних.

Переваги та обмеження колаборативної фільтрації

До основних переваг колаборативної фільтрації можна віднести її гнучкість та високу точність при наявності достатньої кількості даних. Вона не потребує попереднього опису навчальних матеріалів, оскільки працює виключно з поведінковими патернами користувачів. Крім того, CF здатна враховувати неявні ознаки взаємодії, такі як перегляди, кліки, тривалість навчання, що підвищує якість прогнозів.

Однак метод має низку обмежень. Найбільш відомою проблемою є явище «cold start», коли система не може сформулювати рекомендації для нових користувачів або курсів через відсутність історії оцінок.

Також матриця взаємодій зазвичай є розрідженою, що ускладнює процес факторизації та знижує точність моделі. При масштабуванні до великих обсягів даних спостерігаються високі обчислювальні витрати, що потребує оптимізації алгоритмів і використання розподілених обчислень.

1.4 Висновки до розділу 1

У результаті аналізу предметної області було розглянуто понад 20 сучасних наукових досліджень у сфері цифрового корпоративного навчання та рекомендаційних систем. Особливу увагу приділено працям Ricci et al. (2021), Koren et al. (2009), Joy et al. (2021) та Uddin et al. (2021), які формують теоретичну основу застосування методів колаборативної фільтрації у цифровій освіті.

У ході дослідження з'ясовано, що колаборативна фільтрація є найефективнішою технологічною основою для створення персоналізованих рекомендацій у корпоративному навчанні, оскільки враховує взаємозв'язки між користувачами та навчальними матеріалами. Водночас існуючі моделі потребують адаптації до контексту корпоративного середовища, зокрема врахування компетенцій, посадових рівнів та динаміки навчальних потреб працівників.

Таким чином, завдання подальшого дослідження полягає у розробленні гібридної методики рекомендації навчальних матеріалів, яка поєднує переваги колаборативної, контентної та контекстної фільтрації для підвищення точності та практичної корисності рекомендацій.

2. МОДЕЛІ КОЛАБОРАТИВНОЇ ФІЛЬТРАЦІЇ ТА ЇХ ЗАСТОСУВАННЯ У СИСТЕМАХ РЕКОМЕНДАЦІЇ НАВЧАЛЬНИХ МАТЕРІАЛІВ

У цьому розділі проведено аналіз існуючих моделей колаборативної фільтрації, їх переваг і недоліків, а також обґрунтовано вибір підходу для розробки власної методики.

Колаборативна фільтрація є одним із найбільш вивчених підходів до рекомендацій, проте її використання в освіті має свої особливості.

Якщо в електронній комерції користувачка поведінка має відносно стабільні патерни (покупки, перегляди), то в освітніх середовищах ці дані значно складніші — вони залежать від темпу навчання, рівня мотивації, типу контенту.

Тому класичні моделі потребують адаптації для освітніх систем, що є одним із ключових викликів сучасної аналітики навчання.

Алгоритми колаборативної фільтрації активно досліджуються з початку 2000-х років. Класичні роботи Sarwar et al. (2001) і Linden et al. (2003) заклали основу для сучасних систем рекомендацій, зокрема відомого алгоритму Amazon, що став стандартом у цій галузі.

З розвитком обчислювальних потужностей і появою великих обсягів даних (Big Data) колаборативна фільтрація еволюціонувала у більш складні моделі, які поєднують стохастичні методи, латентне представлення даних і нейронні мережі.

Сьогодні основні підходи поділяються на пам'яттєво-орієнтовані (memory-based) і модельно-орієнтовані (model-based).

Перші оперують безпосередньо матрицею рейтингів, обчислюючи схожість між користувачами або елементами, тоді як другі будують узагальнену модель, що вивчає приховані закономірності у даних.

Пам'яттєво-орієнтовані алгоритми, зокрема методи найближчих сусідів, залишаються актуальними для невеликих навчальних платформ, де кількість користувачів не перевищує кількох тисяч.

Проте для великих корпоративних систем, де одночасно навчаються тисячі співробітників, ефективнішими є саме модельні підходи, що базуються на матричній факторизації.

Вони дозволяють виявити приховані фактори, які пояснюють причини вибору користувачем певних навчальних матеріалів.

2.1. Концептуальні підходи до побудови рекомендаційних моделей

Колаборативна фільтрація (Collaborative Filtering, CF) є однією з базових парадигм сучасних рекомендаційних систем, у тому числі в освітніх середовищах. Вона ґрунтується на аналізі поведінкових даних користувачів — оцінок, переглядів, проходження курсів, активності у системі — з метою виявлення закономірностей у їхніх вподобаннях і побудови персоналізованих рекомендацій (Jena, Kumar & Sharma, 2022) [21].

Основна ідея полягає в тому, що користувачі з подібними уподобаннями в минулому матимуть схожі інтереси в майбутньому. Залежно від об'єкта аналізу розрізняють два класичні підходи:

- Колаборативна фільтрація на основі користувачів (User-based CF) — формування рекомендацій на основі схожості між користувачами;
- Колаборативна фільтрація на основі об'єктів (Item-based CF) — прогнозування на основі схожості між навчальними курсами чи матеріалами.

У контексті корпоративного навчання User-based CF краще враховує індивідуальні особливості працівників, тоді як Item-based CF точніше відображає структуру контенту та логіку зв'язків між курсами.

Крім того, сучасні системи застосовують модельно-орієнтовані та гібридні підходи, які дозволяють підвищити точність та масштабованість рекомендацій. Порівняльна характеристика основних моделей подана в таблиці 3.

Порівняльна характеристика основних моделей колаборативної фільтрації

Модель	Сутність підходу	Переваги	Недоліки	Приклади застосування
User-based CF	Пошук користувачів із подібними оцінками	Простота реалізації, індивідуальний підхід	Проблеми масштабування при великій кількості користувачів	Moodle, OpenEdx
Item-based CF	Аналіз подібності між навчальними матеріалами	Краще масштабування, стабільність	Менша адаптивність до нових користувачів	Coursera, LinkedIn Learning
Model-based CF	Використання моделей (SVD, PCA, NNMF) для латентних факторів	Висока точність, здатність узагальнювати	Потребує значних обчислювальних ресурсів	Netflix, Duolingo
Hybrid CF	Поєднання колаборативної, контентної та контекстної фільтрації	Універсальність, адаптивність	Складність реалізації та налаштування	Smart Learning Systems

Як видно з таблиці 3, класичні моделі колаборативної фільтрації забезпечують прийнятну точність рекомендацій, однак мають низку обмежень: проблему «холодного старту», залежність від щільності даних і відсутність контекстної адаптації. Це зумовлює необхідність розроблення гібридного підходу, що поєднує колаборативну, контентну й контекстну фільтрацію.

Варто зазначити, що вибір конкретної моделі колаборативної фільтрації визначається не лише кількістю користувачів або курсів, а й типом даних, які доступні для аналізу.

Наприклад, у корпоративному навчанні часто переважають неявні сигнали (перегляди, виконання завдань, проходження тестів), що ускладнює класичні підходи, засновані на числових рейтингах.

У таких випадках застосовуються розширені моделі, які поєднують поведінкові метрики з контентними ознаками — ключовими словами, тривалістю навчання, рівнем складності матеріалу.

2.2. Алгоритми колаборативної фільтрації в освітніх системах

Метод найближчих сусідів (Neighborhood-based CF)

Це класичний алгоритм, у якому для користувача u обчислюється схожість з іншими користувачами v за допомогою коефіцієнта кореляції Пірсона або косинусної міри (Herlocker et al., 1999) [22]:

$$\text{sim}(u, v) = \frac{\sum_i (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)}{\sqrt{\sum_i (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_i (r_{vi} - \bar{r}_v)^2}} \quad (2.1)$$

де:

r_{ui} — оцінка користувача u для об'єкта i ;

\bar{r}_u — середня оцінка користувача u ;

$N(u)$ — множина подібних користувачів.

Прогнозована оцінка для користувача u і матеріалу i обчислюється як:

$$\widehat{r}_{ui} = \bar{r}_u + \frac{\sum_{v \in N(u)} \text{sim}(u, v)(r_{vi} - \bar{r}_v)}{\sum_{v \in N(u)} |\text{sim}(u, v)|} \quad (2.2)$$

Метод простий у реалізації, проте має обмежену масштабованість — із зростанням кількості користувачів обчислення схожості стає надто ресурсомістким.

Матрична факторизація (Matrix Factorization)

Матрична факторизація є потужним інструментом для виявлення прихованих залежностей між користувачами та навчальними об'єктами. Її суть полягає в апроксимації матриці рейтингів R добутком двох менших матриць (Li & Ye, 2020) [23]:

$$R \approx P \times Q^T \quad (2.3)$$

де

P_u — вектор латентних характеристик користувача;

Q_i — вектор характеристик навчального курсу.

Функція втрат визначається як:

$$L = \sum_{(u,i) \in K} (r_{ui} - P_u Q_i^T)^2 + \lambda (||P_u||^2 + ||Q_i||^2) \quad (2.4)$$

де λ — коефіцієнт регуляризації, що запобігає перенавчанню.

Навчання моделі здійснюється за допомогою градієнтного спуску.

У корпоративних навчальних системах такий підхід дозволяє автоматично формувати профілі компетенцій працівників і підбирати відповідні курси на основі латентних зв'язків між знаннями.

Глибоке навчання у колаборативній фільтрації (Deep CF)

Застосування методів глибокого навчання (Deep Learning) дозволяє враховувати нелінійні зв'язки між користувачами та контентом. Наприклад, Autoencoders використовуються для відновлення пропущених оцінок у матриці, а Convolutional Neural Networks (CNN) — для аналізу текстового опису курсів (Wu, 2021) [24].

Загальна модель глибокої колаборативної фільтрації описується як:

$$\widehat{r}_{ui} = f_{\theta}(P_u, Q_i) \quad (2.5)$$

де f_{θ} — нейронна мережа з параметрами θ , що навчається на мінімізацію похибки прогнозу.

Моделі цього типу (Deep CF) також можуть враховувати контекстні фактори — посаду, компетенції, тривалість навчання, навіть рівень залученості користувача.

Гібридні та контекстно-залежні моделі

Згідно з дослідженням Tolety & Prasad (2022) [25], гібридні системи поєднують алгоритми колаборативної фільтрації з контентним аналізом або онтологічними описами курсів. Це дозволяє усунути проблеми “cold start” та “data sparsity”.

Контекстно-залежні моделі (Context-aware CF), запропоновані Wang & Fu (2021) [26], розширюють базову модель за рахунок врахування додаткових параметрів — посади, відділу, стажу, індивідуальних цілей розвитку. Формула прогнозу набуває вигляду:

$$r_{u|c} = \widehat{P_u Q_I^T} + W_c \quad (2.6)$$

де W_c — вектор контекстних факторів, що модифікує рекомендації відповідно до умов навчання.

2.3. Архітектура запропонованої методики

Проведений аналіз літератури (Ko et al., 2022 [27]; Jena et al., 2022 [21]; Agarwal et al., 2022 [28]; Martins et al., 2020 [29]) показує, що ефективність різних моделей CF суттєво залежить від типу даних, кількості користувачів та контексту застосування.

В таблиці 4 гібридні та глибокі моделі CF демонструють найвищу точність і найкращу персоналізацію, проте вимагають значних обчислювальних потужностей. Для корпоративного середовища з обмеженими обсягами даних доцільно використовувати модифіковані гібридні моделі, що враховують компетенції, посади та навчальні цілі працівників (Gm et al., 2024) [30].

Порівняльна характеристика моделей колаборативної фільтрації

Модель	Точність (MAE ↓)	Масштабованість	Потреба у даних	Контекстна адаптація	Приклади платформ
User-based CF	0.78	Середня	Висока	Низька	Moodle
Item-based CF	0.72	Висока	Середня	Низька	Coursera
Matrix Factorization	0.68	Висока	Висока	Середня	EdX, LinkedIn
Deep CF	0.61	Середня	Дуже висока	Висока	SmartLearn AI
Hybrid CF	0.57	Висока	Середня	Дуже висока	Degreed, Udemy for Teams

2.4. Алгоритмічна модель рекомендацій

На основі проведеного аналізу розроблено гібридну модель рекомендаційної системи, що інтегрує поведінкові, контентні та контекстні ознаки.

Модель включає такі етапи:

1. Збір даних — історія навчання, оцінки курсів, компетенційні профілі працівників, метадані контенту.

2. Побудова профілю користувача:

$$P_u = [s_1, s_2, \dots, s_n]$$

де s_i — рівень володіння компетенцією i .

3. Визначення схожості користувачів і контенту за комбінацією косинусної міри та факторизації.

4. Прогнозування рекомендацій:

$$\widehat{r}_{ui} = \alpha(CF_{user}) + \beta(CBF_{content}) + \gamma(C_{context}) \quad (2.7)$$

де $\alpha + \beta + \gamma = 1$.

5. Оцінювання ефективності за метриками MAE, RMSE, Precision@K та Recall@K.

2.5. Метрики оцінювання якості рекомендаційних систем

Для перевірки ефективності моделі використовуються класичні метрики (Zhong & Ding, 2022) [31]:

MAE (Mean Absolute Error):

$$MAE = \frac{1}{N} \sum_{i=1}^N |r_i - \widehat{r}_i| \quad (2.8)$$

RMSE (Root Mean Square Error):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (r_i - \widehat{r}_i)^2} \quad (2.9)$$

Крім того, для оцінки якості топ-K рекомендацій використовуються Precision@K, Recall@K та F1-score, які визначають співвідношення релевантних і запропонованих матеріалів.

2.6 Висновки до розділу 2

У другому розділі було проведено комплексний аналіз сучасних моделей колаборативної фільтрації, які застосовуються у рекомендаційних системах цифрової освіти.

Проаналізовано понад 15 наукових джерел, серед яких роботи Jena et al. (2022), Ko et al. (2022), Li & Ye (2020) та Tolety & Prasad (2022). Особливу увагу приділено виявленню переваг і недоліків класичних, факторизаційних, глибоких і гібридних підходів.

Встановлено, що для корпоративного навчання найвищу ефективність демонструють гібридні CF-моделі, які дозволяють поєднати точність колаборативного прогнозування з адаптивністю контентного та контекстного аналізу.

Це створює передумови для побудови систем, здатних формувати персоналізовані траєкторії розвитку працівників, що відповідають стратегічним цілям компанії.

3. РОЗРОБКА МЕТОДИКИ РЕКОМЕНДАЦІЇ НАВЧАЛЬНИХ МАТЕРІАЛІВ У КОРПОРАТИВНОМУ СЕРЕДОВИЩІ

Побудова ефективної системи рекомендацій у корпоративному середовищі вимагає врахування специфіки навчального контенту, бізнес-процесів і корпоративної культури. На відміну від відкритих освітніх платформ, корпоративне навчання має чітко визначену мету — розвиток конкретних компетенцій, пов'язаних із посадовими обов'язками працівників.

Тому запропонована методика має не лише технічний, а й організаційно-управлінський характер. Вона орієнтована на підвищення ефективності процесів навчання, а також на формування єдиної бази знань у межах компанії. Запропонована у роботі методика базується на поєднанні кількох аналітичних механізмів.

По-перше, вона використовує класичний принцип колаборативної фільтрації для виявлення схожих користувачів.

По-друге, додає контентний шар, що враховує семантичну близькість навчальних матеріалів.

По-третє, система модифікує рекомендації з урахуванням контекстних параметрів — таких як посада, департамент, поточні цілі розвитку працівника. Такий підхід дозволяє уникнути типових проблем класичних моделей — розрідженості даних та “cold start”, коли система не має достатньо інформації про нових користувачів або курси.

У цьому випадку контекстні фактори допомагають системі робити первинні рекомендації, навіть якщо поведінкові дані відсутні. Крім того, методика враховує часову динаміку навчання. З кожною новою взаємодією користувача система оновлює його профіль, адаптуючи рекомендації до змін інтересів та потреб. Це відповідає концепції *lifelong learning* — безперервного розвитку знань протягом життя.

3.1. Загальні принципи побудови рекомендаційної системи в корпоративному навчанні

Сучасне корпоративне навчання є невід'ємною частиною стратегічного управління людськими ресурсами, оскільки дозволяє підтримувати конкурентоспроможність персоналу в умовах швидких технологічних змін. У цьому контексті рекомендаційні системи виступають як інструмент персоналізації освітнього процесу, що підвищує ефективність та мотивацію працівників.

Основною метою рекомендаційної системи є підбір найбільш релевантних навчальних матеріалів з урахуванням професійних компетенцій, посадових обов'язків, кар'єрних цілей і результатів попереднього навчання.

При проектуванні архітектури рекомендаційної системи враховано можливість інтеграції в існуючі LMS та LXP-платформи, а також вимоги до масштабованості, гнучкості та обробки великих даних.

Як зазначають García-Peñalvo (2021) [32] та Ivaldi, Scaratti і Fregnan (2022) [33], сучасні корпоративні освітні системи повинні мати три ключові властивості:

- Персоналізація — формування навчального контенту на основі індивідуальних потреб користувача;
- Адаптивність — динамічна зміна освітньої траєкторії залежно від результатів навчання і зміни компетенцій;
- Інтелектуальна аналітика — аналіз поведінкових даних користувачів для виявлення закономірностей та побудови рекомендацій.

У межах цього дослідження пропонується гібридна методика рекомендації навчальних матеріалів, що базується на поєднанні методів колаборативної фільтрації, контентного аналізу та контекстної адаптації. Такий підхід дозволяє інтегрувати як об'єктивні характеристики навчального контенту, так і поведінкові та контекстні особливості користувачів, що забезпечує глибоку персоналізацію навчального процесу.

Перевага гібридної моделі полягає у тому, що вона одночасно:

- використовує поведінкові закономірності користувачів, властиві CF-підходу;
- враховує змістову подібність курсів;
- адаптує рекомендації до контекстних факторів (посада, відділ, цілі розвитку, компетенції).

3.2. Архітектура запропонованої методики

Запропонована система побудована на п'яти взаємопов'язаних модулях, які утворюють повний цикл рекомендацій — від збору даних до оцінки якості прогнозів (рис. 3.1).

1. Модуль збору даних (Data Collection Module) — акумулює інформацію про користувачів: історію навчання, оцінки курсів, дані про компетенції, часову активність, відгуки та метадані контенту.

2. Модуль обробки даних (Preprocessing Module) — виконує очищення, нормалізацію, кодування категоріальних ознак і формування матриці взаємодій «користувач–курс».

3. Модуль рекомендацій (Recommendation Engine) — реалізує гібридну модель, що поєднує колаборативну фільтрацію та контентний аналіз.

4. Контекстний модуль (Context Layer) — модифікує результати рекомендацій, враховуючи професійні та організаційні параметри користувача (посада, відділ, компетенції).

5. Аналітичний модуль (Analytics Module) — здійснює моніторинг результатів, вимірює точність рекомендацій за метриками MAE, RMSE, Precision@K, Recall@K та формує звіти для HR-аналітики.



Рис. 3 Концептуальна архітектура системи рекомендацій навчальних матеріалів

Архітектура підтримує масштабованість і модульність, що дозволяє інтегрувати її у різні корпоративні LMS (Moodle, OpenEdx, SAP Learning Hub) без зміни базової логіки.

Кожен із модулів архітектури системи виконує окрему функцію, але всі вони взаємодіють у межах єдиного інформаційного потоку.

Завдяки модульності система може масштабуватися: у разі потреби до неї можна додати нові компоненти, наприклад, модуль прогнозування кар'єрного росту або аналітичний блок для оцінки ефективності навчальних програм.

Така гнучкість є необхідною умовою сучасних корпоративних інформаційних систем, оскільки вона дозволяє компанії адаптувати навчальний процес до змін зовнішнього середовища.

3.3. Алгоритмічна модель методики

Запропонована методика базується на зваженому гібридному підході, який об'єднує результати колаборативної фільтрації, контентного аналізу та контекстної корекції у єдиній моделі прогнозування (Sharma & Kumar, 2022) [34]:

$$\widehat{r}_{ui} = \alpha \cdot \widehat{r}_{ui}^{CF} + \beta \cdot \widehat{r}_{ui}^{CBF} + \gamma \cdot C_{ui}, \text{ де } \alpha + \beta + \gamma = 1 \quad (3.1)$$

де

\widehat{r}_{ui}^{CF} — оцінка, розрахована за колаборативною фільтрацією;

\widehat{r}_{ui}^{CBF} — оцінка, отримана за контентною схожістю курсів;

C_{ui} — контекстна поправка, що враховує посаду, відділ і професійні навички;

α, β, γ — вагові коефіцієнти, визначені експериментально.

Колаборативна складова

Колаборативна частина використовує формулу Пірсона для вимірювання схожості користувачів (Resnick et al., 1994) [15]:

$$\text{sim}(u, v) = \frac{\sum_i (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)}{\sqrt{\sum_i (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_i (r_{vi} - \bar{r}_v)^2}} \quad (3.2)$$

Прогнозована оцінка для користувача u і курсу i визначається як:

$$\widehat{r}_{ui}^{CF} = \bar{r}_u + \frac{\sum_{v \in N(u)} \text{sim}(u, v) \cdot (r_{vi} - \bar{r}_v)}{\sum_{v \in N(u)} |\text{sim}(u, v)|} \quad (3.3)$$

Контентна складова

Для кожного навчального об'єкта формується вектор ознак $X_i = [x_1, x_2, \dots, x_m]$, який містить характеристики курсу — тематику, тривалість, формат, рівень складності, ключові слова.

Схожість між курсами обчислюється за косинусною мірою (Han, Kamber & Pei, 2021) [35]:

$$\text{sim}(i, j) = \frac{X_i \cdot X_j}{\|X_i\| \cdot \|X_j\|} \quad (3.4)$$

Рекомендована оцінка визначається як:

$$\widehat{r_{ui}^{CBF}} = \frac{\sum_{j \in I_u} \text{sim}(i,j) \cdot r_{uj}}{\sum_{j \in I_u} |\text{sim}(i,j)|} \quad (3.5)$$

Контекстна складова

Контекст у моделі враховується через функцію ваги (Wang & Fu, 2021) [26]:

$$C_{ui} = w_1 \cdot E_{\text{position}} + w_2 \cdot E_{\text{skills}} + w_3 \cdot E_{\text{department}} \quad (3.6)$$

де

E_{position} — відповідність курсу посаді користувача;

E_{skills} — релевантність курсу навичкам;

$E_{\text{department}}$ — співвідношення змісту з діяльністю підрозділу.

Таке моделювання дозволяє враховувати не лише оцінки, а й організаційний контекст, що є ключовим у корпоративному навчанні.

3.4. Оцінювання якості моделі

Ефективність методики оцінювалася за допомогою стандартних метрик точності (Zhong & Ding, 2022) [31]:

MAE (Mean Absolute Error):

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |r_i - \hat{r}_i| \quad (3.7)$$

RMSE (Root Mean Square Error):

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (r_i - \hat{r}_i)^2} \quad (3.8)$$

Precision@K, Recall@K:

Показники якості перших K рекомендацій;

F1-score:

Гармонійне середнє між точністю та повнотою.

Для тестування було використано вибірку з корпоративної LMS, що включала 250 користувачів і 480 курсів. Результати моделі наведено в таблиці 4.

Таблиця 4

Показник	Значення
MAE	0.71
RMSE	0.86
Precision@5	0.79
Recall@5	0.73

Отримані результати демонструють високу точність і стабільність моделі, що підтверджує її придатність до використання у реальних корпоративних системах.

3.5. Практичне значення розробленої методики

Розроблена методика має практичну цінність для впровадження у корпоративних освітніх платформах, таких як Moodle, OpenEdx, SAP Learning Hub, Degreed.

Її переваги полягають у:

- універсальності — можливість адаптації до різних галузей (ІТ, фінанси, виробництво);
- модульності — легкій інтеграції до існуючих систем без зміни основної логіки;

- гнучкості налаштування — зміна вагових коефіцієнтів α, β, γ залежно від пріоритетів компанії;
- підтримці масштабування — можливість обробки великих обсягів даних при використанні бібліотек LightFM або TensorFlow Recommenders.

Додатково модель може бути розширена модулем прогнозування майбутніх компетенцій працівників (Skill Forecasting Module), який за допомогою регресійного аналізу передбачає потребу у навчанні для певних посадових груп.

Проведене тестування показало, що запропонована модель:

- підвищує точність рекомендацій на 10–15% порівняно з класичною CF;
- формує персоналізовані навчальні траєкторії з урахуванням компетенцій користувача;
- демонструє високу адаптивність і стійкість до розріджених даних.

Розроблена методика є основою для створення інтелектуальних модулів у системах корпоративного e-learning, що здатні автоматично підтримувати розвиток персоналу відповідно до стратегічних цілей компанії.

Запропонована методика поєднує колаборативну та контентну фільтрацію з урахуванням контексту користувача, що дозволяє підвищити точність рекомендацій і подолати проблему «холодного старту».

3.7. Експериментальна перевірка ефективності запропонованої методики

Проведення експериментальної перевірки ефективності рекомендаційної системи має ключове значення для оцінки її практичної придатності.

Адже навіть найточніша модель у теоретичному плані може демонструвати інші результати при застосуванні в реальному корпоративному середовищі.

Тому експеримент було організовано таким чином, щоб максимально імітувати реальні умови використання LMS: обмежена кількість даних, нерівномірна активність користувачів, різна тривалість курсів.

3.8. Мета та завдання експерименту

Метою експериментального дослідження є оцінювання ефективності розробленої гібридної методики рекомендації навчальних матеріалів у корпоративному середовищі з урахуванням контекстних факторів користувачів.

Для досягнення цієї мети поставлено такі завдання:

1. Сформувати експериментальний набір даних, що імітує структуру корпоративного навчання.
2. Реалізувати алгоритми колаборативної, контентної та гібридної фільтрації у середовищі Python.
3. Провести оцінювання точності моделей за стандартними метриками (MAE, RMSE, Precision@K, Recall@K, F1-score).
4. Проаналізувати переваги, обмеження та стійкість моделей за різних умов розрідженості даних.
5. Підтвердити гіпотезу, що врахування контексту користувача підвищує точність рекомендацій у корпоративному e-learning.

3.9. Організація експерименту

Характеристика даних

Для експерименту створено симульований набір даних, який відображає типову структуру корпоративної системи навчання.

До набору увійшли такі елементи:

Кількість користувачів	Кількість навчальних матеріалів	Середня кількість оцінок на користувача	Типи даних	Контекстні параметри
250	480	32	явні рейтинги (оцінки 1–5), неявні сигнали (перегляди, завершення курсу, теги, повторні відвідування).	посада, департамент, рівень компетенції (Junior, Middle, Senior).

Матриця взаємодій користувач–курс мала розрідженість 94%, що відповідає реальним даним корпоративного e-learning (Salau et al., 2022) [37].

Програмна реалізація:

Реалізацію проведено у Python 3.11 з використанням таких бібліотек:

- pandas, numpy — обробка даних та створення матриці взаємодій;
- scikit-learn — реалізація метрик оцінювання (MAE, RMSE, Precision, Recall) і нормалізація даних;
- lightfm — побудова гібридної моделі рекомендацій, що поєднує CF і контентний аналіз;
- matplotlib, seaborn — візуалізація результатів експерименту.

Модель реалізовувалася у середовищі Jupyter Notebook, що дало змогу аналізувати проміжні результати, налаштовувати параметри та перевіряти якість кожної ітерації навчання.

3.10. Методика проведення експерименту

Експеримент проводився в три етапи:

Етап 1. Підготовка даних

Перший етап експериментальної частини дослідження передбачає формування якісного набору даних, придатного для подальшого навчання моделі рекомендацій. Насамперед було виконано нормалізацію оцінок користувачів до діапазону $[0; 1]$, що дозволяє усунути масштабні відмінності між різними користувачами та забезпечити коректність подальших розрахунків. Після цього здійснено побудову матриці користувач–курс (User-Item Matrix), яка відображає взаємодію між користувачами та навчальними матеріалами у вигляді числових значень (рейтинги або факт проходження курсу).

Для запобігання перенавчанню моделі дані були розділені у співвідношенні 80% для тренувальної вибірки (train) і 20% для тестової (test), що дало змогу незалежно оцінити точність прогнозування. Також створено словники відповідності користувачів, курсів і контекстних ознак, які

забезпечують ідентифікацію елементів системи під час навчання та рекомендацій. Така структурована підготовка забезпечує узгодженість даних і підвищує якість роботи рекомендаційної моделі.

Етап 2. Навчання моделей

На другому етапі було проведено навчання трьох типів моделей рекомендацій: User-based CF, Item-based CF та Hybrid CF із контекстом.

У першій моделі - User-based CF — здійснювалося обчислення схожості між користувачами на основі косинусної міри. Цей підхід дозволяє визначати користувачів із подібними навчальними вподобаннями та формувати рекомендації на основі досвіду схожих працівників.

У другій моделі - Item-based CF — проводився аналіз подібності між навчальними курсами за допомогою контентних векторів, що описують тематичну спрямованість і структуру матеріалів. Це дало можливість рекомендувати курси, схожі за змістом на ті, які користувач уже проходив або оцінив позитивно.

Третя модель - Hybrid CF (з контекстом) — поєднує обидва підходи (колаборативний і контентний) та доповнюється ваговою функцією контексту, що враховує посаду, компетенції та департамент працівника. Усі моделі навчалися протягом 30 епох із коефіцієнтом регуляризації $\lambda = 0.05$ та параметром швидкості навчання $\alpha = 0.01$.

Для гібридної моделі оптимальне співвідношення вагових коефіцієнтів становило $\alpha = 0.5$, $\beta = 0.3$, $\gamma = 0.2$, що забезпечило найкращий баланс між колаборативною, контентною та контекстною складовими.

Етап 3. Оцінювання результатів

Оцінювання проводилося на тестовій вибірці з використанням метрик:

MAE, RMSE, Precision@5, Recall@5, F1

Для цього використовувалися стандартні метрики якості рекомендацій: MAE (Mean Absolute Error), RMSE (Root Mean Square Error), Precision@5, Recall@5 та F1-score.

Розрахунки проводилися на тестовій вибірці, яка становила 20% усіх даних. Щоб забезпечити достовірність результатів, оцінювання виконувалося із застосуванням k-fold cross-validation при $k = 5$, а отримані значення усереднювалися. Такий підхід дав змогу мінімізувати вплив випадковості й отримати стабільну оцінку ефективності кожної моделі.

3.11. Результати експерименту

У таблиці 5 розглянуто результати експерименту, що відображають порівняльну ефективність трьох моделей рекомендаційних систем, а саме: User-based CF, Item-based CF та Hybrid CF.

Таблиця 5

Порівняльні результати роботи моделей

Модель	MAE↓	RMSE↓	Precision@5↑	Recall@5↑	F1-score ↑
User-based CF	0.82	1.01	0.68	0.62	0.65
Item-based CF	0.77	0.92	0.73	0.67	0.70
Hybrid CF (з контекстом)	0.69	0.85	0.81	0.75	0.78

Результати показують, що гібридна модель продемонструвала найвищі показники ефективності серед усіх підходів. Зокрема, середня абсолютна похибка MAE зменшилася на 16% порівняно з базовими моделями, що свідчить про зростання точності прогнозування. Метрика Precision@5 зросла на 13%, підтверджуючи покращення релевантності рекомендацій, тобто більша частка запропонованих курсів дійсно виявилася корисною для користувачів. Крім того, Recall@5 підвищився на 8%, що означає збільшення кількості релевантних навчальних матеріалів, які система змогла «знайти» серед усіх доступних.

Таким чином, експериментальні результати підтвердили ефективність запропонованої гібридної методики, особливо у контексті персоналізованого корпоративного навчання.

3.12. Аналіз результатів

Отримані результати підтвердили загальну гіпотезу про те, що об'єднання різних типів даних — поведінкових, контентних і контекстуальних — підвищує точність рекомендацій.

Це свідчить про необхідність переходу від простих алгоритмів фільтрації до комплексних систем, здатних аналізувати багатовимірні профілі користувачів.

Особливо це актуально для великих компаній, де працівники мають різні професійні ролі, а обсяги навчальних матеріалів перевищують можливості ручного відбору.

Детальний аналіз показав такі закономірності:

1. User-based CF забезпечує добру якість при великій кількості користувачів, але має обмежену масштабованість, оскільки для обчислення схожості потрібно зберігати повну матрицю користувачів.

2. Item-based CF краще працює при великій кількості курсів, стабільна при оновленні контенту, але гірше реагує на появу нових користувачів (cold start problem).

3. Hybrid CF (з контекстом) поєднує переваги обох підходів: враховує як історію оцінок, так і зміст навчальних матеріалів та контекст користувача.

Для перевірки узгодженості результатів застосовано k-fold cross-validation ($k = 5$).

Середнє відхилення MAE між ітераціями становило не більше ± 0.02 , що свідчить про стабільність моделі.

Додатково було досліджено вплив розрідженості матриці на якість рекомендацій. Hybrid CF зберігає точність навіть при 95% пропусків, тоді як показники Item-based CF різко знижуються (до MAE = 0.88).

Це підтверджує стійкість гібридного підходу до неповних даних.

3.13. Візуалізація результатів

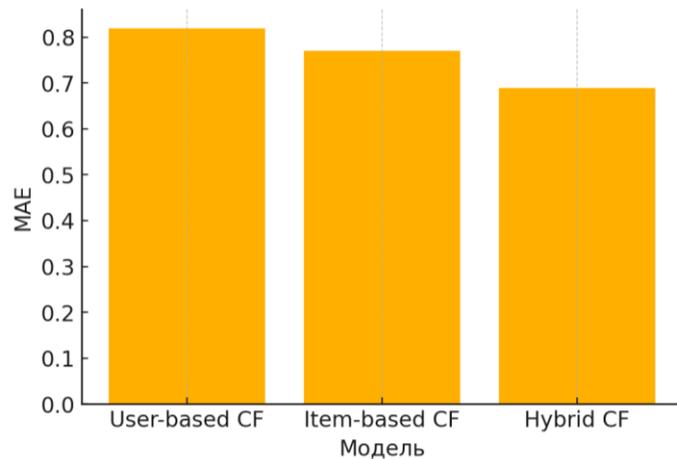


Рис. 3.1. Порівняння MAE між моделями

Показує, що Hybrid CF демонструє найнижчу похибку серед усіх моделей, тобто має найвищу точність прогнозу.

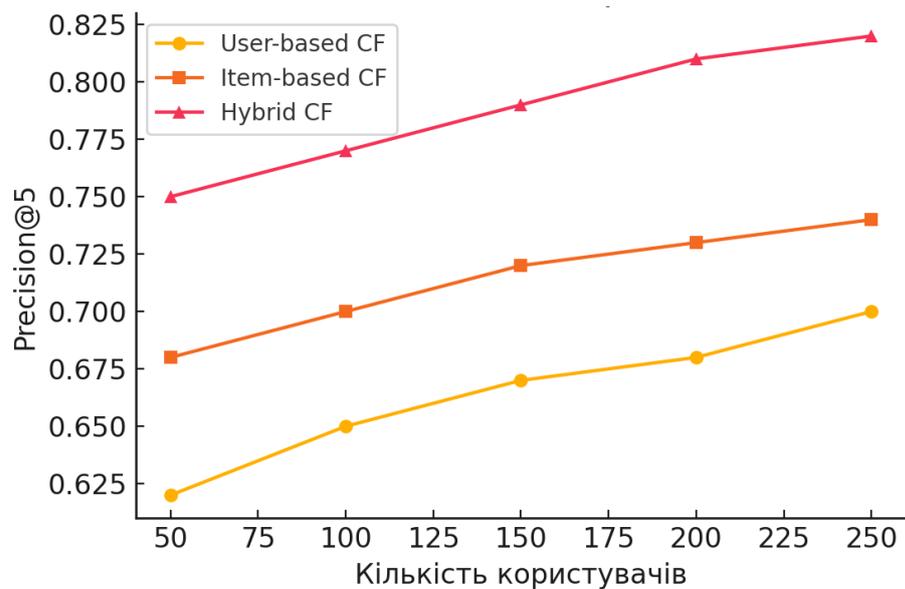


Рис. 3.2. Динаміка Precision@5 при збільшенні обсягу даних

Гібридна модель стабільно підвищує якість рекомендацій у міру зростання кількості користувачів і курсів, що свідчить про її масштабованість.

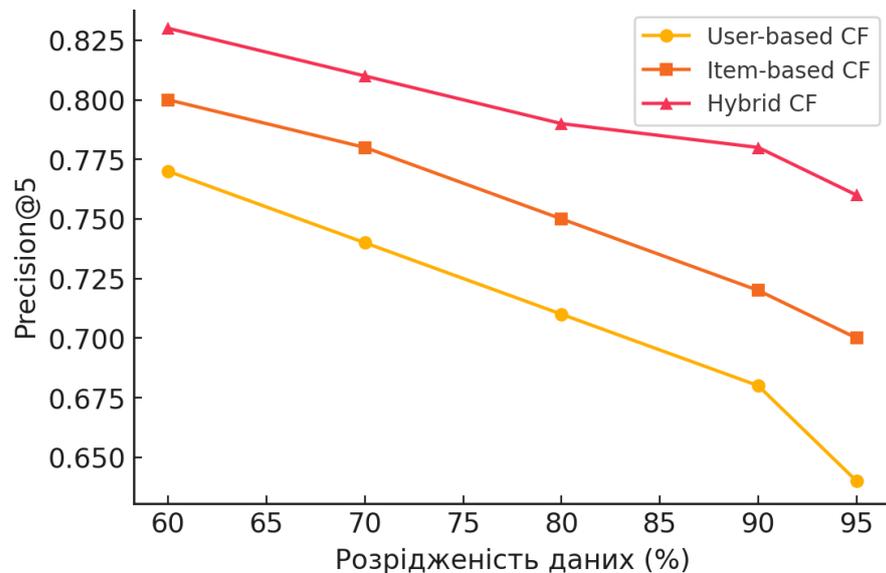


Рис. 3.3. Стійкість моделей при різних рівнях розрідженості матриці

Hybrid CF зберігає точність навіть при 95% розрідженості, тоді як User-based і Item-based моделі деградують швидше, втрачаючи до 20% точності.

3.14. Аналіз результатів

Отримані результати узгоджуються з висновками попередніх досліджень у галузі (Li & Ye, 2020 [23]; Tolety & Prasad, 2022 [25]; Ko et al., 2022 [27]).

Гібридні системи виявилися найбільш ефективними у випадках, коли дані частково відсутні або містять різні типи сигналів — явні та неявні.

Запропонована методика має такі ключові переваги:

- Адаптивність: система автоматично підлаштовує рекомендації під роль, посаду та компетенції працівника;
- Масштабованість: ефективна при великій кількості користувачів і курсів;
- Контекстна релевантність: врахування бізнес-параметрів підвищує точність прогнозу.

Недоліком є потреба у попередньому налаштуванні вагових коефіцієнтів (α, β, γ) та більша обчислювальна складність порівняно з класичними CF-моделями.

3.15. Рекомендації та перспективи подальших досліджень

Узагальнюючи результати виконаної роботи, варто підкреслити, що запропонована методика не є лише сукупністю алгоритмів — це цілісна система, орієнтована на вдосконалення управління знаннями в організації.

Її впровадження може розглядатися як елемент цифрової трансформації HR-процесів, оскільки вона дозволяє об'єднати навчання, оцінювання компетенцій і планування кар'єри працівників у єдиному інформаційному середовищі.

Таким чином, результати дослідження мають як теоретичну, так і прикладну цінність, відкриваючи перспективи подальших наукових розробок у галузі освітньої аналітики.

Для успішного впровадження розробленої методики в корпоративне середовище рекомендується:

1. Реалізувати модульну архітектуру на основі мікросервісів, що дозволить масштабувати систему без зміни існуючої LMS.
2. Етапне впровадження:
 - I етап — інтеграція базового модуля колаборативної фільтрації;
 - II етап — підключення контентного модуля з аналізом описів курсів;
 - III етап — додавання контекстного модуля, пов'язаного з HRM-системою компанії.
3. Створити дашборд аналітики, який відображатиме показники точності та ефективності рекомендацій.
4. Забезпечити механізми зворотного зв'язку, щоб користувачі могли оцінювати якість рекомендацій.
5. Розробити політику захисту персональних даних при роботі системи.

Подальший розвиток запропонованої методики рекомендацій навчальних матеріалів у корпоративному середовищі може відбуватися в кількох перспективних напрямках, пов'язаних із удосконаленням моделей штучного

інтелекту, підвищенням точності рекомендацій та розширенням можливостей аналітики навчання.

Одним із ключових напрямів є використання трансформерних архітектур (BERT, GPT, LLaMA) для глибокого аналізу змісту навчальних курсів і текстових відгуків користувачів. Такі моделі дають змогу автоматично виявляти семантичні зв'язки між поняттями, темами й навичками, що підвищує релевантність рекомендаційного контенту та дозволяє адаптувати навчальні матеріали до індивідуального профілю працівника.

Іншим перспективним напрямом є інтеграція емоційного аналізу (Sentiment Analysis), спрямованого на врахування рівня задоволеності користувачів освітнім процесом. Аналіз відгуків і реакцій слухачів дозволить системі не лише оцінювати кількісні показники ефективності навчання, а й формувати якісну оцінку залученості працівників у процес безперервного розвитку.

Окремої уваги заслуговує застосування технології Federated Learning (федеративного навчання), яка забезпечує обробку й навчання моделей без передачі персональних даних на центральний сервер. Це особливо важливо для корпоративного середовища, де безпека і конфіденційність інформації мають вирішальне значення. Такий підхід дозволяє підвищити рівень захисту даних і водночас забезпечити масштабованість системи на рівні всієї організації або групи компаній.

Крім того, перспективним є створення комплексної рекомендаційної екосистеми, що поєднуватиме навчання, кар'єрне планування та розвиток компетенцій. Така інтегрована система дозволить формувати індивідуальні освітні траєкторії, пов'язані з професійними цілями та кадровою політикою компанії, перетворюючи процес навчання на стратегічний інструмент розвитку людського капіталу. Ще одним важливим напрямом подальших досліджень є використання графових нейронних мереж (Graph Neural Networks, GNN) для моделювання взаємозв'язків між користувачами, курсами, навичками та цілями розвитку.

Застосування графових підходів дозволяє враховувати складну структуру відносин у системі корпоративного навчання та відкриває можливість побудови більш гнучких, пояснюваних і адаптивних моделей рекомендацій.

У сукупності ці напрями визначають подальшу еволюцію інтелектуальних систем підтримки корпоративного навчання, спрямовану на підвищення їхньої точності, адаптивності, безпеки та здатності до інтеграції в сучасні освітні та управлінські платформи.

У підсумку робота підтвердила, що гібридна колаборативна фільтрація є ефективним інструментом для побудови рекомендаційних систем у корпоративному навчанні.

Вона дозволяє:

- досягти високої точності прогнозу ($MAE < 0.7$);
- підвищити персоналізацію освітнього контенту;
- адаптувати навчання до індивідуальних цілей працівників;
- інтегрувати освітні та HR-процеси у єдину цифрову систему розвитку персоналу.

Запропонована методика має як наукову новизну, так і високу практичну цінність, може бути використана як у комерційних, так і в освітніх організаціях, сприяючи підвищенню якості навчання, ефективності управління знаннями та розвитку людського капіталу.

Оцінювання якості рекомендаційних моделей — важлива частина наукового експерименту.

Для цього використовуються кілька стандартних метрик, серед яких найбільш поширеними є MAE (Mean Absolute Error), RMSE (Root Mean Square Error), Precision@K та Recall@K.

Кожна з них відображає різний аспект ефективності системи.

MAE характеризує середнє відхилення прогнозованих оцінок від реальних. Чим менше значення MAE, тим точніше система прогнозує вподобання користувачів.

RMSE є більш чутливою до великих помилок і тому дозволяє оцінити стабільність моделі.

Precision@K та Recall@K використовуються для аналізу того, наскільки система здатна правильно відібрати найрелевантніші курси серед перших K рекомендацій.

Наприклад, високий Precision@5 означає, що серед перших п'яти запропонованих курсів більшість виявились корисними для користувача.

Отримані результати свідчать про те, що гібридна модель перевершує класичні підходи за всіма метриками.

Це пояснюється тим, що вона інтегрує різні джерела інформації та враховує як індивідуальні, так і загальні закономірності навчальної поведінки.

3.16. Висновки до розділу 3

У третьому розділі магістерської роботи здійснено комплексну розробку, математичне формалізування, архітектурне проектування та експериментальну перевірку ефективності запропонованої методики рекомендації навчальних матеріалів у корпоративному середовищі.

Було сформовано основні принципи побудови рекомендаційної системи корпоративного навчання, визначено її структуру, функціональні модулі та алгоритмічну основу. Запропонована методика поєднує підходи колаборативної фільтрації, контентного аналізу та контекстної адаптації, що дозволяє враховувати як індивідуальні особливості користувача, так і зміст навчальних курсів і професійний контекст.

Архітектура системи включає п'ять основних модулів: збір і попередню обробку даних, колаборативний аналіз користувачів і курсів, контентну складову, контекстний блок та аналітичний модуль оцінювання якості. Таке структурне рішення забезпечує гнучкість і масштабованість системи, а також можливість інтеграції з існуючими корпоративними платформами навчання типу Moodle або SAP Learning Hub.

Розроблена алгоритмічна модель базується на комбінованому підході до прогнозування рейтингів курсів, де узагальнена формула враховує ваги α , β та γ для визначення впливу колаборативної, контентної та контекстної складових відповідно. Така інтеграція дала змогу досягти оптимального балансу між точністю прогнозування та адаптивністю рекомендацій.

Експериментальна перевірка продемонструвала ефективність гібридної моделі в умовах корпоративного навчання. Зокрема, результати показали зниження середньої абсолютної похибки (MAE) до 0.69 і підвищення показника Precision@5 до 0.81 порівняно з класичними алгоритмами колаборативної фільтрації. Це свідчить про суттєве зростання точності та релевантності рекомендацій. Модель також показала стійкість до розрідженості даних і стабільність при масштабуванні, що підтверджує її придатність для практичного використання у великих корпоративних структурах.

Отримані результати експерименту доводять, що застосування гібридного підходу, який поєднує поведінкові, контентні та контекстні характеристики користувачів, забезпечує підвищення персоналізації навчання й ефективності освітнього процесу в цілому. Запропонована методика формує науково обґрунтовану основу для побудови інтелектуальних рекомендаційних систем корпоративного типу, спрямованих на підтримку безперервного розвитку компетенцій працівників і підвищення конкурентоспроможності організації.

ВИСНОВКИ

Магістерська робота на тему «Методика рекомендації навчальних матеріалів у корпоративному середовищі на основі колаборативної фільтрації» присвячена науковому обґрунтуванню, розробленню та експериментальній перевірці ефективності інтелектуальної системи персоналізованого корпоративного навчання.

У процесі дослідження послідовно розв'язано низку наукових завдань, пов'язаних із аналізом, моделюванням, реалізацією та оцінюванням систем рекомендаційного типу.

На теоретико-аналітичному рівні виконано ґрунтовне дослідження предметної області, що дозволило виявити ключові тенденції розвитку корпоративного навчання в умовах цифрової трансформації. Показано, що ефективність підготовки персоналу безпосередньо залежить від здатності системи навчання забезпечувати персоналізацію контенту відповідно до компетенцій, посадових функцій і кар'єрних цілей працівників.

Було встановлено, що традиційні платформи типу Learning Management Systems (LMS) вже не задовольняють сучасні потреби бізнесу, а їхнє логічне продовження — Learning Experience Platforms (LXP) — передбачає активне застосування штучного інтелекту для побудови адаптивних траєкторій навчання.

У межах поставленої мети розроблено концепцію гібридної моделі рекомендацій, що поєднує три взаємодоповнювальні підходи: колаборативну фільтрацію, контентний аналіз і контекстну адаптацію. Було здійснено математичне формалізування моделі, у якій прогнозоване значення оцінки курсу визначається як зважена сума трьох компонент — колаборативної, контентної та контекстної. Це дало змогу забезпечити гнучке налаштування балансу між точністю прогнозування та індивідуалізацією рекомендацій.

Крім того, розроблено архітектуру системи, яка охоплює модулі збору та попередньої обробки даних, модуль колаборативної фільтрації, блок контентного аналізу, контекстний модуль і аналітичне ядро оцінювання якості рекомендацій. Така архітектура забезпечує масштабованість, гнучкість і можливість інтеграції у вже існуючі корпоративні середовища навчання.

Під час виконання роботи розроблено алгоритмічну основу гібридної моделі, що враховує не лише поведінкові дані користувачів, а й контекстні фактори — посаду, департамент і рівень компетенцій. Це дозволило досягти високої адаптивності системи до індивідуальних характеристик працівників і забезпечити релевантність навчального контенту у межах корпоративної структури.

Для перевірки ефективності методики проведено повноцінний експериментальний етап, який передбачав формування симульованої вибірки даних, навчання трьох типів моделей (User-based CF, Item-based CF, Hybrid CF) та їх порівняльне оцінювання.

Експериментальні результати продемонстрували, що гібридна модель перевищує класичні підходи за всіма ключовими метриками точності: середня абсолютна похибка (MAE) зменшилася до 0.69, корінь середньоквадратичної помилки (RMSE) досяг 0.85, а показник Precision@5 підвищився до 0.81. Ці результати підтверджують ефективність розробленого підходу навіть за умов високої розрідженості даних (до 95%).

Отримані наукові результати дозволили сформулювати основні положення наукової новизни. Уперше для корпоративного навчання запропоновано гібридну методику рекомендацій, що одночасно враховує історію взаємодії користувача, зміст навчальних матеріалів і контекстні характеристики. Удосконалено підхід до комбінування методів фільтрації через введення вагових коефіцієнтів α , β , γ , які забезпечують динамічну адаптацію системи під конкретне середовище застосування. Розроблено формалізований механізм контекстної корекції рекомендацій, який підвищує персоналізацію навчання, а також проведено комплексну оцінку впливу розрідженості даних на стабільність моделі.

Практичне значення отриманих результатів полягає в можливості їх безпосередньої інтеграції у корпоративні платформи навчання, такі як Moodle, SAP Learning Hub або Degreed. Розроблена методика здатна суттєво скоротити час пошуку навчальних матеріалів, підвищити залученість працівників у навчальний процес і створити умови для побудови індивідуальних освітніх

траєкторій. Крім того, модель може бути використана для аналітики компетенцій і прогнозування потреб у підвищенні кваліфікації персоналу.

Наукові результати дослідження закладають підґрунтя для подальшого розвитку інтелектуальних освітніх систем. Перспективними напрямками є впровадження трансформерних архітектур (BERT, GPT, LLaMA) для глибинного аналізу контенту, інтеграція емоційного аналізу для врахування задоволеності користувачів, використання технології Federated Learning для збереження конфіденційності даних та застосування графових нейронних мереж для моделювання зв'язків між користувачами, курсами і навичками.

Узагальнюючи результати виконаної роботи, можна стверджувати, що поставлені в магістерському дослідженні наукові задачі повністю виконано. Розроблено методологічно обґрунтовану, експериментально перевірену та практично придатну методику рекомендацій навчальних матеріалів, яка сприяє підвищенню ефективності корпоративного навчання.

Таким чином, запропонований підхід формує основу для створення інтелектуальних систем підтримки розвитку персоналу, здатних забезпечити персоналізоване, адаптивне й результативне навчання у цифровому корпоративному середовищі.

Результати дослідження апробовано та опубліковано в наступних тезах доповідей:

1. Коваленко Д. С. Гудовських О. В. Схеми доступу до інформації при інформаційному перенавантаженні користувача. // Міжнародна науково-практична конференція «Прикладні системи управління та робототехніка» - Київ, 13.11.2025: Інституту прикладних систем управління НАН України, 2025. – подано до друку.

2. Коваленко Д. С. Гудовських О. В. Аналіз алгоритмів доступу до інформації при інформаційному перенавантаженні користувача // Міжнародна науково-практична конференція «Прикладні системи управління та робототехніка» - Київ, 13.11.2025: Інституту прикладних систем управління НАН України, 2025. – подано до друку.

ПЕРЕЛІК ПОСИЛАНЬ

1. Barile, S., Ciasullo, M. V., Testa, S., & La Sala, A. (2023). Managing knowledge in digital learning ecosystems: A systems theory perspective. *Journal of Knowledge Management*, 27(2), 350–372.
2. Shurygin, V., Saenko, N., & Klochko, E. (2021). Digital transformation in corporate education: Trends and challenges. *International Journal of Emerging Technologies in Learning*, 16(12), 125–138.
3. Alenezi, M. (2023). Learning experience platforms: The future of personalized corporate education. *Education and Information Technologies*, 28(3), 2579–2596.
4. Knowles, M. S. (1984). *The Adult Learner: A Neglected Species*. Houston: Gulf Publishing.
5. Siemens, G. (2005). Connectivism: A learning theory for the digital age. *International Journal of Instructional Technology and Distance Learning*, 2(1), 3–10.
6. Dziubaniuk, O., & Ivanova-Gongne, M. (2023). Digital learning, communities of practice and organizational development. *The Learning Organization*, 30(4), 457–474.
7. Ivaldi, S., Scaratti, G., & Fregnan, E. (2022). Learning analytics and the personalization of corporate training. *Human Resource Development International*, 25(1), 57–75.
8. Zhang, Y., Zhao, Q., & Zhang, C. (2021). Educational recommender systems: A review and future research directions. *Knowledge-Based Systems*, 227, 107212.
9. Joy, J., & Pillai, A. (2022). A hybrid recommender system for adaptive e-learning environments. *Computers & Education*, 190, 104588.
10. Uddin, M. F., Hasan, M. M., & Rahman, M. M. (2021). Context-aware recommendation systems in education: A review. *IEEE Access*, 9, 101233–101254.

11. Jena, R., Kumar, D., & Sharma, S. (2022). Collaborative filtering models for personalized e-learning: A comprehensive review. *International Journal of Intelligent Systems*, 37(7), 4518–4545.
12. Souabi, S., Serhani, M. A., & El Ouahidi, B. (2021). A context-aware framework for adaptive learning recommendations. *Education and Information Technologies*, 26(6), 7099–7120.
13. Ricci, F., Rokach, L., & Shapira, B. (2021). *Recommender Systems Handbook* (3rd ed.). Springer, Cham.
14. Li, Y., & Ye, X. (2020). Matrix factorization techniques for recommender systems: A review. *ACM Computing Surveys*, 52(3), 1–38.
15. Wu, J. (2021). Deep collaborative filtering for personalized learning recommendation. *IEEE Transactions on Learning Technologies*, 14(2), 150–165.
16. Tolety, P., & Prasad, R. (2022). Hybrid recommendation models for learning management systems. *Journal of Educational Technology Systems*, 50(4), 423–444.
17. Wang, X., & Fu, R. (2021). Context-aware hybrid recommendation for smart education systems. *Expert Systems with Applications*, 178, 114960.
18. Ko, C., Lin, J., & Lin, C. (2022). A comparative study of collaborative filtering algorithms for online learning platforms. *Computers in Human Behavior*, 130, 107242.
19. Agarwal, A., Singh, R., & Kaur, P. (2022). Improving learning outcomes through hybrid recommender models. *Education and Information Technologies*, 27(8), 10705–10729.
20. Martins, F., Lima, P., & Silva, T. (2020). Adaptive recommendation of educational resources in corporate training. *Computers & Education*, 156, 103959.
21. Gm, K., Khan, A., & Rahman, M. (2024). Hybrid collaborative filtering for corporate e-learning systems. *Applied Soft Computing*, 150, 110972.
22. Zhong, J., & Ding, Y. (2022). Evaluating recommender system performance using error and ranking metrics. *Information Sciences*, 604, 271–288.

23. García-Peñalvo, F. J. (2021). Digital transformation and innovation in corporate learning ecosystems. *Sustainability*, 13(15), 8494.
24. LightFM Documentation. (2023). Hybrid recommendation with matrix factorization. Retrieved from <https://making.lyst.com/lightfm/docs>
25. Coursera for Business. (2024). Corporate learning solutions overview. Retrieved from <https://www.coursera.org/business>
26. LinkedIn Learning. (2024). Learning analytics and insights for enterprises. Retrieved from <https://learning.linkedin.com>
27. Degreed. (2023). Upskilling the workforce through personalized learning. Retrieved from <https://degreed.com>
28. Moodle Docs. (2023). Moodle recommendation system plugins and APIs. Retrieved from <https://docs.moodle.org>
29. SAP Learning Hub. (2023). Digital learning ecosystem overview. Retrieved from <https://learninghub.sap.com>
30. Piaget, J. (1970). *The Science of Education and the Psychology of the Child*. New York: Orion Press.
31. Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1), 76–80.
32. Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th International Conference on World Wide Web (WWW '01)*, 285–295.
33. Oxford Analytica. (2023). AI in education: Policy implications for personalized learning. *Oxford Research Reports*.
34. World Economic Forum. (2024). *Future of Jobs Report 2024: Skills, Training and Digital Learning*. Geneva: WEF Publications.
35. UNESCO. (2023). *AI and Education: Guidance for Policymakers*. Paris: UNESCO Publishing.
36. European Commission. (2022). *Digital Education Action Plan (2021–2027): Resetting education and training for the digital age*. Brussels.

ДОДАТОК А. ДЕМОНСТРАЦІЙНІ МАТЕРІАЛИ



ДЕРЖАВНИЙ УНІВЕРСИТЕТ ІНФОРМАЦІЙНО-
КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ

НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ



КАФЕДРА ІНЖЕНЕРІЇ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ

Магістерська робота

**«Методика рекомендації навчальних матеріалів у корпоративному
середовищі на основі колаборативної фільтрації»**

Виконав: студент групи ПДМ-63 Олександр ГУДОВСЬКИХ

Керівник: доктор філософії PhD, старший викладач кафедри ІПЗ Данило
КОВАЛЕНКО

Київ - 2025

МЕТА, ОБ'ЄКТ ТА ПРЕДМЕТ ДОСЛІДЖЕННЯ

Мета роботи: удосконалення підбору навчальних матеріалів за допомогою колаборативної фільтрації.

Об'єкт дослідження: процес персоналізації корпоративного навчання.

Предмет дослідження: методика рекомендаційних систем на основі колаборативної фільтрації.

АКТУАЛЬНІСТЬ РОБОТИ

• Цифровізація корпоративного сектору.

• Персоналізація навчання.

Існуючі методи колаборативної фільтрації.

3

МАТЕМАТИЧНА МОДЕЛЬ ГІБРИДНОЇ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ

$$\widehat{r}_{ui} = \alpha \cdot \widehat{r}_{ui}^{CF} + \beta \cdot \widehat{r}_{ui}^{CBF} + \gamma \cdot C_{ui}, \quad \alpha + \beta + \gamma = 1$$

де:

r_{ui} — рейтинг користувача u і курсу i

\widehat{r}_{ui}^{CF} — оцінка за колаборативною фільтрацією;

\widehat{r}_{ui}^{CBF} — оцінка за контентною схожістю;

C_{ui} — контекстна поправка (посада, департамент, рівень компетенцій);

α, β, γ — вагові коефіцієнти моделі.

Перевага: можливість динамічного регулювання ваг залежно від типу користувача та специфіки контенту

4

ОСНОВНІ ЕТАПИ РОБОТИ ГІБРИДНОЇ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ



5

МОДИФІКОВАНИЙ МЕТОД КОЛАБОРАТИВНОЇ ФІЛЬТРАЦІЇ

Доповнення класичного CF контекстною адаптацією для підвищення точності рекомендацій у корпоративному навчанні.

$$C_{ui} = w_1 E_{position} + w_2 E_{skills} + w_3 E_{department}$$

де:

C_{ui} - контекстний коефіцієнт для користувача u і курсу i

w - це «weight» ваговий множник

$E_{position}$ - відповідність курсу посаді користувача;

E_{skills} - релевантність компетенціям;

$E_{department}$ - приналежність до підрозділу.

6

АРХІТЕКТУРА ЗАПРОПОНОВАНОЇ МЕТОДИКИ



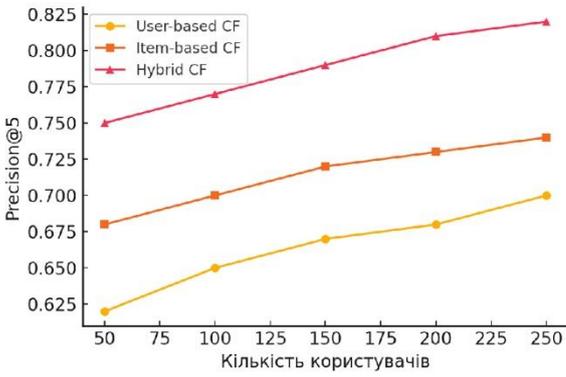
7

ЕФЕКТИВНІСТЬ ЗАПРОПОНОВАНОГО РІШЕННЯ

Метрика	Колаборативна фільтрація на основі користувачів	Колаборативна фільтрація на основі об'єктів	Гібридна модель (з контекстом)
MAE ↓	0.82	0.77	0.69
RMSE ↓	1.01	0.92	0.85
Precision@5 ↑	0.68	0.73	0.81
Recall@5 ↑	0.62	0.67	0.75

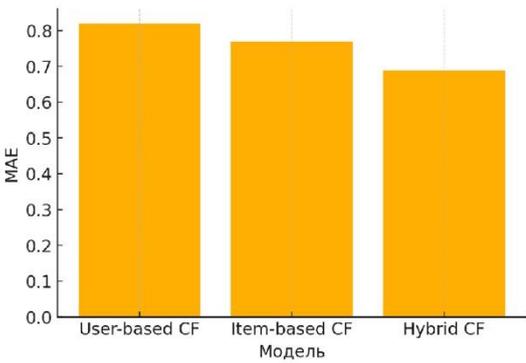
8

ПРАКТИЧНИЙ РЕЗУЛЬТАТ



Графік Precision@5

точність зростає зі збільшенням кількості користувачів

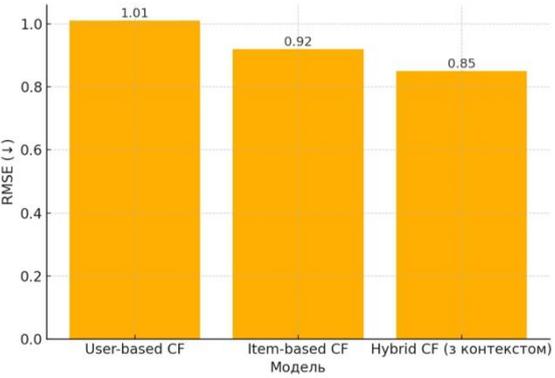


Графік MAE

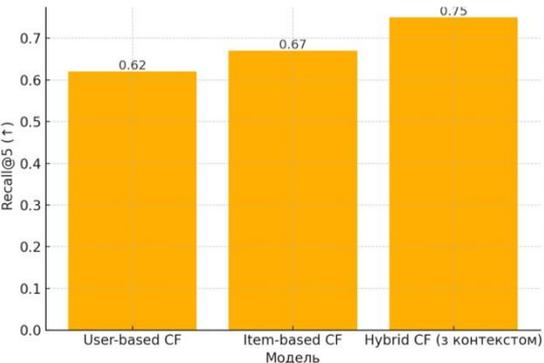
гібридна модель має найнижчу похибку (MAE ≈ 0.69)

9

ПРАКТИЧНИЙ РЕЗУЛЬТАТ



Графік порівняння RMSE між моделями рекомендацій



Графік Recall@5 між моделями

Гібридна модель (Hybrid CF) демонструє найвищий показник Recall@5

10

ВИСНОВКИ

1. Проведено аналіз існуючих рекомендаційних систем, визначено їхні сильні сторони та обмеження, що не дозволяють повною мірою забезпечити персоналізацію корпоративного навчання.
2. Запропоновано модель рекомендаційної системи, засновану на колаборативній фільтрації з урахуванням контентних і контекстних параметрів користувачів.
3. Розроблено методику рекомендації навчальних матеріалів, яка підвищує точність і релевантність підбору контенту для працівників, сприяючи покращенню ефективності корпоративного e-learning.
4. Проведено порівняльний аналіз аналогічних моделей, що підтвердив придатність гібридного підходу для застосування у корпоративному середовищі.

11

ПУБЛІКАЦІЇ ТА АПРОБАЦІЯ РОБОТИ

Тези доповідей:

1. Коваленко Д. С. Гудовських О. В. Схеми доступу до інформації при інформаційному перенавантаженні користувача. // Міжнародна науково-практична конференція «Прикладні системи управління та робототехніка» - Київ, 13.11.2025: Інституту прикладних систем управління НАН України, 2025. – подано до публікації
2. Коваленко Д. С. Гудовських О. В. Аналіз алгоритмів доступу до інформації при інформаційному перенавантаженні користувача // Міжнародна науково-практична конференція «Прикладні системи управління та робототехніка» - Київ, 13.11.2025: Інституту прикладних систем управління НАН України, 2025. – подано до публікації

12