

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ ЕКОНОМІЧНИЙ УНІВЕРСИТЕТ  
ІМЕНІ ВАДИМА ГЕТЬМАНА**

**Інститут інформаційних технологій в економіці**

**Кафедра штучного інтелекту, моделювання та статистики**

**Освітньо-професійна програма «Економічна кібернетика і Дата Сайнс»**

Галузь знань 05 «Соціальні та поведінкові науки»  
Спеціальність 051 «Економіка»

Форма здобуття освіти: очна (денна)

**КВАЛІФІКАЦІЙНА МАГІСТЕРСЬКА РОБОТА**

на тему «**Побудова та аналіз моделей для рекомендаційних систем у сфері  
електронної комерції**»

*(назва теми)*

здобувача Музики Іванни Петрівни

*(ПІБ, підпис)*

Науковий керівник: к. е. н., доцент Ольга КАТУНІНА

*(підпис)*

**Робота допущена до захисту перед екзаменаційною  
комісією з атестації здобувачів вищої освіти (ЕК)**

Завідувач кафедри: к. ф.-м. н., професор  
Галина ВЕЛИКОІВАНЕНКО

*(підпис)*

**Київ 2025**

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ ЕКОНОМІЧНИЙ УНІВЕРСИТЕТ  
ІМЕНІ ВАДИМА ГЕТЬМАНА**

**Інститут інформаційних технологій в економіці**

**Кафедра штучного інтелекту, моделювання та статистики**

**Освітньо-професійна програма «Економічна кібернетика і Дата Сайнс»**

Галузь знань 05 «Соціальні та поведінкові науки»  
Спеціальність 051 «Економіка»

**ПОГОДЖЕНО**

Керівник проектної групи (гарант)  
освітньо-професійної програми  
Олена ПІСКУНОВА

*(підпис)*

\_\_\_\_\_ 2025 р.

**ЗАТВЕРДЖУЮ**

Завідувач кафедри штучного інтелекту,  
моделювання та статистики  
Галина ВЕЛИКОІВАНЕНКО

*(підпис)*

\_\_\_\_\_ 2025 р.

**ІНДИВІДУАЛЬНЕ ЗАВДАННЯ**

**здобувача вищої освіти**

Музики Іванни Петрівни  
*(прізвище, ім'я, по батькові)*

очної (денної)

**форми здобуття освіти**

*очної (денної), заочної, дистанційної*

на підготовку кваліфікаційної магістерської роботи

**на тему**

«Побудова та аналіз моделей для рекомендаційних систем у сфері електронної комерції»

Тему затверджено наказом ректора Університету від «19» вересня 2025 р. № 1464-ст

**Кваліфікаційна магістерська робота виконується на матеріалах**

відкритого набору даних Amazon Reviews 2023 року у категорії «Health and Personal Care»  
<https://amazon-reviews-2023.github.io/> та інших відкритих джерел.

## План кваліфікаційної магістерської роботи

|          |                                                                                                         |
|----------|---------------------------------------------------------------------------------------------------------|
| Розділ 1 | Теоретичні засади аналізу споживчої поведінки для створення рекомендацій товарів у електронній торгівлі |
| Розділ 2 | Математичне моделювання персоналізованих рекомендацій у електронній комерції                            |
| Розділ 3 | Практичне застосування моделей формування рекомендацій для товарного сегменту косметичних засобів       |

|                                                      |                                                                                                                                                                                                                              |
|------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Об'єкт дослідження:                                  | процес надання персоналізованих рекомендацій споживачам у системах електронної торгівлі                                                                                                                                      |
| Предмет дослідження:                                 | методи та моделі побудови рекомендаційних систем з використанням архітектур різної складності для оптимізації балансу між точністю ранжування та якісними показниками пропозицій                                             |
| Мета виконання кваліфікаційної магістерської роботи: | розробка дворівневої персоналізованої рекомендаційної системи в окремому сегменті електронної комерції на підґрунті методів Data Science для підвищення прибутковості та ефективності економічної діяльності у сфері ритейлу |

**Конкретні завдання, які здобувач повинен виконати для досягнення поставленої мети:**

**У розділі 1:** 1) дослідити роль рекомендаційних систем в електронній комерції та поведінкові аспекти споживчого вибору; 2) провести класифікацію та порівняльний аналіз методів побудови рекомендаційних систем; 3) проаналізувати наукові підходи до формування релевантних персоналізованих пропозицій на базі математичного моделювання.

**У розділі 2:** 1) охарактеризувати структуру та особливості формування інформаційної бази для моделювання персоналізованих товарних пропозицій; 2) побудувати рекомендаційні моделі на базі машинного та глибокого навчання; 3) обґрунтувати використання метрик для оцінювання ефективності та релевантності товарних рекомендацій.

**У розділі 3:** 1) провести побудову розподілів та аналіз залежностей на даних про взаємодію користувачів з товарами; 2) проаналізувати результати практичної реалізації моделей формування рекомендацій для товарів сегменту «Health and Personal Care»; 3) оцінити ефективність побудованої системи рекомендаційних моделей; 4) сформулювати рекомендації щодо використання побудованих моделей для прийняття рішень та управління у сфері ритейлу.

Завдання підготував  
науковий керівник

\_\_\_\_\_  
(підпис)

Ольга КАТУНІНА  
(ініціали, прізвище)

«\_\_» \_\_\_\_\_ 2025 р.

Завдання одержав  
здобувач

\_\_\_\_\_  
(підпис)

Іванна МУЗИКА  
(ініціали, прізвище)

«\_\_» \_\_\_\_\_ 2025 р.

## Реферат

Кваліфікаційна магістерська робота містить 82 сторінки, 15 таблиць, 42 рисунки, перелік використаних джерел з 119 найменувань, додатки.

### **«Побудова та аналіз моделей для рекомендаційних систем у сфері електронної комерції»**

*Об'єктом дослідження* є процес надання персоналізованих рекомендацій споживачам у системах електронної торгівлі.

*Предметом дослідження* є методи та моделі побудови рекомендаційних систем з використанням архітектур різної складності для оптимізації балансу між точністю ранжування та якісними показниками пропозицій.

*Мета та завдання виконання дослідження.* Метою виконання кваліфікаційної магістерської роботи є розробка дворівневої персоналізованої рекомендаційної системи в окремому сегменті електронної комерції на підґрунті методів Data Science для підвищення прибутковості та ефективності економічної діяльності у сфері ритейлу.

Відповідно до поставленої мети визначені такі *завдання*:

- розкрити роль рекомендаційних систем у сучасній електронній комерції та проаналізувати існуючі методи побудови персоналізованих товарних пропозицій;
- визначити структуру та особливості формування інформаційної бази про взаємодію користувачів з товарами, властивості товарів та характеристики споживачів;
- побудувати комплекс рекомендаційних моделей на базі інструментів машинного та глибокого навчання;
- обґрунтувати використання метрик для оцінювання ефективності та релевантності товарних пропозицій;
- проаналізувати результати рекомендаційних моделей для конкретного ритейлера та товарного сегменту косметичних засобів;
- оцінити вплив поведінкових факторів на формування системи переваг споживачів та сформулювати рекомендації щодо використання побудованих моделей для прийняття рішень та управління у сфері електронної комерції.

*Теоретична, методична та практична значущість отриманих результатів.* Теоретична значущість роботи полягає у поглибленні розуміння застосування технологій математичного моделювання, машинного навчання та Data-Driven підходу для вдосконалення методології аналізу ринку та поведінки споживачів. Методична значущість дослідження полягає у розробці методики комплексного застосування машинно-навчальних та нейромережових технологій для формування системи персоналізованих рекомендацій.

Практичні результати дослідження полягають в розробці бази моделей для побудови персоналізованих рекомендацій та формуванні релевантного ранжованого переліку пропозицій. У роботі реалізовано гібридну двоступеневу архітектуру, що інтегрує семантичний аналіз тексту (BERT) та поведінкові ознаки. Для етапу генерації кандидатів розроблено та протестовано комплекс алгоритмів: базову модель популярності (Popularity Baseline), методи k-найближчих сусідів (User-Based та Item-Based k-NN), матричну факторизацію (ALS, LightFM) та моделі глибокого навчання (Two-Tower, SASRec). Фінальна оптимізація видачі здійснена за допомогою алгоритму реранкінгу на базі градієнтного бустингу (LightGBM), що дозволяє підвищити точність ранжування та ефективність управлінських рішень у сфері ритейлу.

Рік виконання кваліфікаційної магістерської роботи – 2025.

Рік захисту роботи – 2025.

*Ключові слова:* рекомендаційна система, електронна комерція, машинне навчання, глибоке навчання, Data Science, реранкінг, персоналізація, BERT, матрична факторизація, поведінка споживачів.

В і д г у к  
про кваліфікаційну магістерську роботу  
здобувача освітньо-професійної програми «Економічна кібернетика і Дата  
Сайнс»  
навчально-наукового інституту «Інститут інформаційних технологій в  
економіці КНЕУ імені Вадима Гетьмана»  
Музики Іванни Петрівни  
на тему «Побудова та аналіз моделей для рекомендаційних систем у сфері  
електронної комерції»

**1. Актуальність теми:** у сучасному цифровому просторі, що характеризується інформаційним перенасиченням та жорсткою конкуренцією, ефективність електронної комерції значною мірою залежить від здатності надавати споживачам персоналізовані товарні пропозиції. Розробка та впровадження рекомендаційних систем стає не просто конкурентною перевагою, а необхідною умовою виживання бізнесу. Актуальність роботи зумовлена необхідністю застосування новітніх методів глибокого навчання та реранкінгу для підвищення точності прогнозування споживчих вподобань та оптимізації бізнес-процесів онлайн-платформ у сфері електронної торгівлі.

**2. Позитивні риси кваліфікаційної магістерської роботи:** робота вирізняється системним підходом до вирішення поставленого завдання. У дослідженні Музика І.П. продемонструвала глибоке розуміння предметної області, провівши ґрунтовний аналіз теоретичних засад побудови рекомендаційних систем. До позитивних рис слід віднести комплексне дослідження структури інформаційної бази та ретельний препроцесинг вхідних даних. Особливої уваги заслуговує реалізація комплексу моделей різної архітектури, зокрема, базових інструментів машинного навчання та Deep Learning, проведення їх порівняльного аналізу, що дозволило обґрунтовано обрати оптимальне рішення.

**3. Наявність самостійних розробок автора:** магістерська робота Музика І.П. є самостійним завершеним дослідженням. Автором особисто сформовано та оброблено репрезентативну вибірку даних сегменту електронної комерції, реалізовано програмний код у середовищі Python. Ключовою самостійною розробкою є побудова комплексної дворівневої персоналізованої рекомендаційної системи. На першому етапі реалізовано моделі генерації кандидатів, а на другому – на основі трьох найефективніших моделей першого рівня впроваджено механізм реранкінгу, що дозволило суттєво покращити точність ранжування товарних пропозицій. Автором розроблено комплекс метрик для комплексної оцінки ефективності алгоритмів надання рекомендацій.

**4. Цінність теоретичних висновків та практичних рекомендацій:** теоретична та методична цінність роботи полягає у розвитку Data-Driven підходів до аналізу ринку та розробці методики застосування нейромережових технологій для задач персоналізації в e-commerce. Практична значущість результатів визначається створенням прикладної бази моделей для автоматизованого ранжування пропозицій, що є готовим інструментом для компаній у сфері електронної торгівлі з метою оптимізації маркетингових стратегій. Результати дослідження Музики І.П. пройшли апробацію на XIII Всеукраїнській науково-практичній конференції форумі молодих економістів-кібернетиків «Моделювання економіки: проблеми, тенденції, досвід» (21-22 листопада 2025 року, Львів). За

результатами роботи опубліковано тези у збірнику конференції.

**5. Наявність недоліків:** у роботі недостатньо уваги приділено питанню масштабування запропонованого рішення для роботи в режимі реального часу при високих навантаженнях. Також доцільно було б розширити аналіз впливу зовнішніх факторів (сезонність, акції) на точність рекомендацій. Вказані недоліки не є критичними і не впливають на загальну позитивну оцінку роботи.

**6. Загальна оцінка кваліфікаційної магістерської роботи та її допущення до захисту перед ЕК:** Зважаючи на те, що кваліфікаційна магістерська робота здобувача Музики І.П. на тему «Побудова та аналіз моделей для рекомендаційних систем у сфері електронної комерції» є актуальною, дослідження є самостійним і ґрунтовним, поставлені завдання виконано у повному обсязі, вважаю, що робота повністю відповідає усім вимогам. Рівень якості виконання роботи є високим, вона може бути допущена до захисту перед ЕК. Робота свідчить про відповідність набутих здобувачем компетентностей вимогам освітньої програми «Економічна кібернетика і Дата Сайнс», а її автор Музика І.П., за умови успішного захисту, заслуговує на присвоєння освітньої кваліфікації «Магістр з економіки».

Науковий керівник доцент кафедри штучного інтелекту, моделювання та статистики, доцент,  
кандидат економічних наук

\_\_\_\_\_  
(підпис)  
“ \_\_\_\_ ” \_\_\_\_\_ 2025 р.

\_\_\_\_\_  
Ольга КАТУНІНА  
(ім'я, ПРІЗВИЩЕ)

**Рецензія**  
на кваліфікаційну магістерську роботу  
здобувача вищої освіти  
Музики Іванни Петрівни

Тема: «Побудова та аналіз моделей для рекомендаційних систем у сфері електронної комерції»

**Актуальність теми кваліфікаційної магістерської роботи і доцільність її розроблення.** Стрімкий розвиток ринку електронної комерції та збільшення обсягів товарного асортименту актуалізують проблему інформаційного перевантаження споживачів. Тема магістерської роботи є актуальною, оскільки традиційні методи продажів втрачають ефективність без використання технологій персоналізації. Розробка комплексних рекомендаційних систем дозволяє вирішити задачу точного прогнозування вподобань користувачів, що безпосередньо впливає на економічні показники бізнесу.

**Якість проведеного дослідження.** У роботі побудовано комплекс рекомендаційних моделей, що охоплює як класичні підходи колаборативної фільтрації, так і сучасні методи глибокого навчання. Автором здійснено ґрунтовний порівняльний аналіз ефективності алгоритмів на репрезентативній вибірці даних, що дозволило обґрунтувати вибір оптимальної архітектури системи для вирішення прикладних бізнес-завдань.

**Позитивні риси кваліфікаційної магістерської роботи.** Сильною стороною дослідження є реалізація повного циклу розробки рекомендаційної системи, від аналізу розподілів та залежностей в даних до побудови моделей машинного та глибокого навчання. Перевагою є практична реалізація етапу реранкінгу, що дозволило суттєво оптимізувати видачу товарних пропозицій. Автор продемонстрував глибоке володіння сучасним інструментарієм Data Science та здатність інтегрувати результати математичного моделювання для вирішення прикладних бізнес-задач.

**Зауваження.** Загалом позитивно оцінюючи роботу, варто зазначити, що у дослідженні доцільно було б детальніше розглянути аспекти обчислювальної складності запропонованих моделей при їх масштабуванні на великі високонавантажені системи. Також бажано було б дослідити адаптивність запропонованого комплексу моделей до умов динамічної зміни асортименту товарів. Вказані зауваження не впливають на загальну високу оцінку отриманих результатів.

**Практична значимість висновків і рекомендацій.** Одержані результати, зокрема розроблені моделі та алгоритми реранкінгу, мають прикладний характер і можуть бути імплементовані в IT-інфраструктуру компаній сегменту e-commerce для підвищення конверсії та середнього чеку.

У кваліфікаційній магістерській роботі Музики Іванни Петрівни на тему: «Побудова та аналіз моделей для рекомендаційних систем у сфері електронної комерції» продемонстровано глибокі знання в галузі сучасних технологій Data Science, математичного моделювання та методів машинного навчання, сформульовано логічні висновки та рекомендації. Проведене дослідження є повним та обґрунтованим, виконано на високому рівні та відповідає вимогам до кваліфікаційної магістерської роботи. Вважаю, що робота Музики І.П. заслуговує високої оцінки.

*ITM*

**Павло КУЧЕР,**

PhD, доцент кафедри інформаційних систем і технологій  
факультету транспортних та інформаційних технологій  
Національного транспортного університету

Підпис засвідчую:



*(посада, підпис)*

Місце печатки організації, де працює рецензент

## ЗМІСТ

|                                                                                                                                       |           |
|---------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>ВСТУП.....</b>                                                                                                                     | <b>3</b>  |
| <b>РОЗДІЛ 1. ТЕОРЕТИЧНІ ЗАСАДИ АНАЛІЗУ СПОЖИВЧОЇ ПОВЕДІНКИ<br/>ДЛЯ СТВОРЕННЯ РЕКОМЕНДАЦІЙ ТОВАРІВ У ЕЛЕКТРОННІЙ<br/>ТОРГІВЛІ.....</b> | <b>7</b>  |
| 1.1 Роль рекомендаційних систем у електронній комерції та поведінкові<br>аспекти споживчого вибору.....                               | 7         |
| 1.2 Класифікація та порівняльний аналіз методів побудови персоналізованих<br>пропозицій товарів .....                                 | 14        |
| <b>РОЗДІЛ 2. МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ПЕРСОНАЛІЗОВАНИХ<br/>РЕКОМЕНДАЦІЙ У ЕЛЕКТРОННІЙ КОМЕРЦІЇ .....</b>                               | <b>26</b> |
| 2.1 Структура та особливості формування інформаційної бази для<br>моделювання персоналізованих товарних пропозицій .....              | 26        |
| 2.2 Побудова рекомендаційних моделей на базі інструментів машинного та<br>глибокого навчання .....                                    | 31        |
| 2.3 Метрики оцінювання ефективності та релевантності товарних<br>рекомендацій.....                                                    | 45        |
| <b>РОЗДІЛ 3. ПРАКТИЧНЕ ЗАСТОСУВАННЯ МОДЕЛЕЙ ФОРМУВАННЯ<br/>РЕКОМЕНДАЦІЙ ДЛЯ ТОВАРНОГО СЕГМЕНТУ КОСМЕТИЧНИХ<br/>ЗАСОБІВ .....</b>      | <b>49</b> |
| 3.1 Побудова розподілів та аналіз залежностей на даних про взаємодію<br>користувачів з товарами.....                                  | 49        |
| 3.2 Результати практичної реалізації моделей формування рекомендацій для<br>товарів сегменту «Health and Personal Care» .....         | 54        |
| 3.3 Аналіз результатів реранкінгу та ефективності побудованих<br>рекомендаційних моделей .....                                        | 73        |
| <b>ВИСНОВКИ .....</b>                                                                                                                 | <b>80</b> |
| <b>ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ .....</b>                                                                                              | <b>83</b> |
| <b>ДОДАТКИ .....</b>                                                                                                                  | <b>97</b> |

## ВСТУП

*Актуальність теми.* Стрімке зростання обсягів інформації в цифровому просторі, що створює проблему інформаційного перевантаження та ускладнює прийняття рішень споживачами, а також жорстка конкуренція в умовах електронної торгівлі перетворила рекомендаційні системи з допоміжного інструменту та стратегічний актив для бізнесу. Такі системи виступають одним з основних драйверів доходу для онлайн-платформ. Впровадження ефективних алгоритмів дозволяє не лише персоналізувати користувацький досвід, але й монетизувати нішевий асортимент «довгого хвоста».

*Аналіз останніх досліджень і публікацій.* Фундаментальні підходи та методи побудови рекомендаційних систем широко висвітлюються у зарубіжній науковій літературі. Класичні підходи матричної факторизації описано у працях Y. Koren, R. Bell та C. Volinsky. Обмеженість лінійних методів стала поштовхом до розвитку складних архітектур, а саме моделі на основі автокодувальників (AutoRec) запропоновані S. Sedhain, нейронна колаборативна фільтрація X. He та інші. Проблематику моделювання динамічних послідовностей розкрито у роботах B. Hidasi та W. Kang і J. McAuley, що використали механізм самоуваги (SASRec). Новітні концепції пов'язані з використанням навчання з підкріплення та великих мовних моделей (LLM), знайшли відображення у дослідженнях L. Zou, Y. Hou та J. Liu, які аналізували потенціал генеративного ШІ для задач довгострокової оптимізації та пояснюваності. Персоналізовані рекомендації досліджувати і українські науковці, так К. В. Червіцька запропонувала гібридну модель для електронної бібліотеки, а у роботі І. О. Пишнограєва та А. Е. Ширалієва було доведено переваги простіших моделей над складними архітектурами в умовах масштабованості.

*Метою виконання кваліфікаційної магістерської роботи є* розробка дворівневої персоналізованої рекомендаційної системи в окремому сегменті електронної комерції на підґрунті методів Data Science для підвищення прибутковості та ефективності економічної діяльності у сфері ритейлу.

Для досягнення поставленої мети поставлено такі завдання:

- 1) розкрити роль рекомендаційних систем у сучасній електронній комерції та проаналізувати існуючі методи побудови персоналізованих товарних пропозицій;
- 2) визначити структуру та особливості формування інформаційної бази про взаємодію користувачів з товарами, властивості товарів та характеристики споживачів;
- 3) побудувати комплекс рекомендаційних моделей на базі інструментів машинного та глибокого навчання;
- 4) обґрунтувати використання метрик для оцінювання ефективності та релевантності товарних пропозицій;
- 5) проаналізувати результати рекомендаційних моделей для конкретного ритейлера та товарного сегменту косметичних засобів;
- 6) оцінити вплив поведінкових факторів на формування системи переваг споживачів та сформулювати рекомендації щодо використання побудованих моделей для прийняття рішень та управління у сфері електронної комерції.

*Об'єкт дослідження* – процес надання персоналізованих рекомендацій споживачам у системах електронної торгівлі.

*Предмет дослідження* – методи та моделі побудови рекомендаційних систем з використанням архітектур різної складності для оптимізації балансу між точністю ранжування та якісними показниками пропозицій.

Основними методами дослідження, які використовуються в роботі, є BERT модель для генерації семантичних ембедингів, базовий алгоритм врахування популярності, підходи на основі k-найближчих сусідів (User-Based та Item-Based k-NN), матрична факторизація (ALS, LightFM), глибоке навчання (Two-Tower, SASRec) та градієнтний бустинг LightGBM. Практична цінність магістерської роботи полягає у розробці гібридної двоступеневої архітектури, яка інтегрує семантичний аналіз тексту та поведінкові ознаки для підвищення точності ранжування. Запропонована система моделей дозволяє платформам електронної торгівлі збільшити конверсії та покращити користувацький досвід.

*Теоретична, методична та практична значущість отриманих результатів.* Кваліфікаційна робота має теоретичну значущість, оскільки поглиблює розуміння застосування технологій математичного моделювання, машинного навчання та Data-Driven підходу для наукових досліджень та вдосконалення методології аналізу та прогнозування ринку предметів споживання та поведінки споживачів.

Дослідження має методичну значущість, адже розроблена методика комплексного застосування машинно-навчальних та нейромережевих модельних технологій може використовуватись для формування системи персоналізованих рекомендацій у електронній комерції.

Практична значущість роботи полягає в обґрунтуванні та розробці бази моделей для створення автоматизованої системи оцінювання уподобань та споживчих переваг численної аудиторії відвідувачів платформ електронної комерції (сайтів, додатків) та побудови персоналізованих рекомендацій, що формують релевантний ранжований перелік найкращих пропозицій з урахування передісторії поведінки споживачів та проєкцій колективних переваг і стійких патернів уподобань на ринку. Дослідження передбачає аналіз та ідентифікацію ключових факторів, що впливають на формування споживчих переваг, що дозволяє розробити стратегії підвищення ефективності управлінських рішень на базі своєчасного виявлення комерційних ризиків і формування стабільного розвитку компаній у сфері ритейлу. Отримані результати можуть бути використані як керівництвом компаній, так і R&D підрозділами та аналітичними центрами для впровадження інтелектуальних інформаційних та модельних технологій у практику, а, отже, можуть стати підґрунтям розбудови більш ефективної інфраструктури цифрової економіки.

Інформаційною базою дослідження є роботи вчених, дослідників, науковців, економістів, роботи авторів статей та монографій, які досліджували питання поведінки споживачів на товарних ринках, функціонування платформ електронної комерції, алгоритми математичного моделювання для надання персоналізованих рекомендацій. Для практичної частини даної роботи використано статистичні дані

про поведінку користувачів системи електронної торгівлі, а саме результати вибору ними товарів з широкого переліку груп категорій, що представлено у наборі даних Amazon Reviews 2023 року, у категорії «Health and Personal Care».

Робота складається зі вступу, трьох розділів, висновків, переліку використаних джерел та додатків. Обсяг кваліфікаційної роботи складає 82 сторінки. Робота містить 42 рисунки, 15 таблиць, 6 формул та 119 літературних джерел.

## **РОЗДІЛ 1**

### **ТЕОРЕТИЧНІ ЗАСАДИ АНАЛІЗУ СПОЖИВЧОЇ ПОВЕДІНКИ ДЛЯ СТВОРЕННЯ РЕКОМЕНДАЦІЙ ТОВАРІВ У ЕЛЕКТРОННІЙ ТОРГІВЛІ**

#### **1.1 Роль рекомендаційних систем у електронній комерції та поведінкові аспекти споживчого вибору**

У сучасному, швидкому та цифровізованому світі все більшої ваги надають інформації як ресурсу, для підвищення ефективності бізнесу, збільшення показників прибутку та рівня задоволеності користувачів. З кожним роком невідомо зростає кількість платформ для онлайн торгівлі товарами та послугами в Україні та світі. Також, кількість цих товарів та послуг на одній платформі може досягати сотень, десятків чи навіть мільйонів одиниць. Таке різноманіття товарів та послуг дозволяє продавцям з дуже великою ймовірністю задовільнити потреби користувачів, оскільки вони найімовірніше знайдуть на одній платформі якщо не всі то більшість товарів, які їх цікавлять. Але тут з'являється велика проблема – інформаційне перевантаження, оскільки користувач не хоче переглядати ці мільйони товарів поки знайде те, за що дійсно готовий заплатити. В таких ситуаціях і приходять на допомогу рекомендаційні системи, які можуть запропонувати користувачу товари, які він переглядав чи шукав раніше, або ж на попередніх взаємодіях з онлайн платформою визначити вподобання та запропонувати те, що з великою ймовірністю відвідувачу платформи сподобається.

Рекомендаційні системи – вид інформаційних систем, які надають персоналізовані рекомендації щодо різних видів товарів та послуг, які найімовірніше зацікавлять цього конкретного покупця у поточний момент часу. Прогнозування вибору користувача здійснюється на основі доступної про нього інформації або схожих на нього інших клієнтів [1; 2].

Такі системи виглядають досить складними для розуміння та реалізації, але є важливими інструментами залучення користувачів до придбання товарів чи послуг, особливо для великих онлайн-магазинів. Саме тому, рекомендаційні системи невід’ємною частиною сучасного ринку продажів, а їхнє покращення та розвиток є найактуальнішою проблемою для гігантів ринку як фізичних товарів, онлайн послуг, так і стрімінгових платформ, це задача лежить на перетині інформатики, програмування та економіки [3]. З використанням таких систем люди стикаються практично кожного дня, оскільки рекомендаційні системи різного рівня складності зустрічаються в соціальних мережах, сайтах, соціальних медіа, пошукових та стрімінгових сервісах. Наприклад, на всіх відомих сервісах таких як Netflix, YouTube чи Spotify, вони, також, використовуються, бо без персоналізованих рекомендацій на них було б важко знайти потрібний контент: музику, фільм чи відео серед мільйонів інших варіантів [4-6].

Застосовування рекомендаційних систем допомагає як користувачам, так і продавцям. Оскільки з одного боку, вони допомагають користувачам отримувати релевантну інформацію, товари, послуги чи контент, тобто полегшують пошук та скорочують витрати часу на нього. І як наслідок – підвищують задоволеність користувачів від покупки. А з іншого – персоналізований підхід призводить до вищих конверсій та збільшення доходів продавців, оскільки вони мають більше продажів та задоволених покупців [5].

Тобто, можна зробити висновок, що рекомендаційні системи допомагають виконувати кілька важливих функцій ринку, у сфері маркетингової комунікації та цінових механізмів. Оскільки ці системи допомагають робити товари та послуги більш видимими, формувати споживчий вибір та впливати на попит. Це демонструє глобальність використання рекомендаційних систем та їх вплив на конкретні ринки та економіку в цілому [5; 6]. В буремних реаліях, основним дефіцитом є не пропозиція, а увага споживачів, і рекомендаційні системи виступають механізмом який може управляти таким дефіцитним ресурсом, роблячи потрібну фільтрацію товарів для користувачів [5; 7-8].

З точки зору економічної теорії рекомендаційні системи допомагають знизити транзакційні витрати та так звані витрати на отримання інформації. Вони допомагають користувачам подолати чи принаймні зменшити інформаційну асиметрію, яка наявна між продавцями та покупцями, що є однією із поширених проблем на ринку. Рекомендаційні системи не просто допомагають знайти потрібний товар, але і допомагають активно формувати попит. Наприклад, у класичній теорії економіки ціну визначає певна рівновага між попитом та пропозицією, а у цифровій економіці «видимість» товарів завдяки алгоритмам (серед тисяч інших) є необхідною передумовою для стимулювання попиту на цей товар [5; 9-10]. Тобто, вищезгадане зумовлює перетворення транзакційних витрат: споживчі витрати з пошуку релевантних товарів переносяться на оцінку алгоритмів рекомендацій [11].

В мікроекономіці, наприклад в сфері електронної торгівлі, рекомендаційні системи допомагають реалізовувати одну з важливих функцій – управляти споживчим вибором за умов нескінченного вибору, враховуючи так званий ефект «довгого хвосту» [12]. Рекомендаційні системи сприяють перерозподілу ресурсів на ринку, тим самим створюючи значну економічну цінність. Вони дозволяють заробляти не лише на популярних товарах, а й на «довгому хвості», тобто величезній кількості більш нішевих товарів. Оскільки онлайн платформи не обмежені розміром полиць, навіть дуже специфічному товару вдасться знайти свого покупця, перетворюючи рідкісний асортимент на стабільне джерело доходу [3; 12].

Традиційна економічна теорія припускає, що чим більша кількість товару є доступною та надається для споживчого вибору, тим краще, але різні дослідження у сфері психології показують зворотнє, тобто формується «парадокс вибору». Теоретичною базою цього явища став відомий експеримент з джемом, проведений психологами Шиною Айєнгар та Марком Леппер [13]. Вони виявили, що коли покупцям пропонували 24 сорти джему, покупку зробили лише 3%, але коли вибір скоротили до 6 видів, продажі зросли до 30% [13]. Цей феномен Баррі Шварц назвав «парадоксом вибору», він стверджував, що надмірна кількість опцій замість бажаної свободи викликає тривогу, втому та зниження задоволеності від покупки

[13]. В онлайн-торгівлі це переростає у «параліч прийняття рішень», оскільки клієнти просто губляться, збільшується показник відмови від кошика та конверсії падають [14]. Саме тут рекомендаційні системи виступають як економічне рішення, їхня мета – надати добірку релевантних товарів, а не показати весь асортимент [13-14]. Вони спрощують рішення, що дозволяє отримати і комерційний ефект, а саме збільшити продажі через перехресні чи додаткові продажі, що збільшує і загальну конверсію [15-17].

Дослідження 2024 року, що охопило 1,6 млн користувачів виявило, U-подібну залежність, тобто після досягнення піку надмірна кількість пропозицій стрімко знижує конверсію, причому 64% цього падіння спричинено повною відмовою користувачів від вибору (не натискали ні на що) [17-18]. Економічна теорія пояснює це «передбачуваним жалем» (anticipated regret) – страхом зробити неправильний вибір [18]. Рекомендаційні системи нівелюють цей бар'єр, перекладаючи «відповідальність» на алгоритми. А використання соціального доказу (теги «бестселер», «найпопулярніше») додатково знижує тривожність, виконуючи психологічну функцію полегшення транзакції [17].

Класична модель Homo Economicus (людина економічна) є нереалістичною для перенасиченого середовища електронної комерції [19]. Реальні споживчі рішення є хаотичними, емоційними, так, як зазначають дослідники, «передбачувано ірраціональними» [20]. Роботи Нобелівського лауреата Даніеля Канемана (часто у співпраці з Амосом Тверські) пропонують поведінкову економіку як теоретичний фундамент для аналізу рекомендаційних систем, спростовуючи міф про споживача як «раціонального актора» [21]. Цифрові платформи ефективно використовують когнітивні упередження, щоб стимулювати покупки та оминати втому від прийняття рішень [22].

Канеман виділяє дві системи мислення [21; 23-24]:

- Система 1 (швидка) – працює автоматично, емоційно та інтуїтивно. Саме вона генерує більшість щоденних рішень.

- Система 2 (повільна) – відповідає за логічний аналіз та свідомий вибір, але є енергозатратною та лінивою, часто лише пасивно схвалюючи імпульси першої системи.

Рекомендаційні системи адаптовані під цей дуалізм, вони долають «парадокс» вибору, що перевантажує Систему 2, пропонуючи прості евристичні сигнали для Системи 1 (зіркові рейтинги, теги «Бестселер»), які не вимагають глибокого аналізу [20; 25]. Відбувається процес когнітивного делегування як наведено на рис. 1.1, де алгоритм бере на себе складні обчислення та порівняння (функція Системи 2), а результат подає у формі, яку легко сприймає інтуїція (Система 1) [25-27]. Споживач відчуває легкість вибору, делегуючи складну частину роботи раціональному алгоритму.




Рисунок 1.1 – Логіка інтеграції рекомендаційних систем у поведінкову економіку

Джерело: розроблено автором за даними [28-29]

Теорія перспектив Канемана і Тверські фундаментально змінили економічну науку, кинувши виклик класичним уявленням про корисність [30]. Дослідники довели, що люди оцінюють результати не абсолютно, а відносно певної референсної точки, спираючись на два принципи: уникнення втрат (Loss Aversion), де психологічний біль від втрати є приблизно вдвічі сильнішим за радість від еквівалентного прибутку, та ефект обрамлення (Framing Effects), коли спосіб подачі інформації кардинально змінює вибір споживача [31-33]. В електронній комерції

рекомендаційні системи виконують роль своєрідної «фабрики» таких референсних точок [9]. Використовуючи алгоритми цінових рекомендацій, платформи встановлюють психологічні «якорі», які диктують споживачу, що саме вважати «нормальною» ціною, тим самим маніпулюючи вихідним контекстом для оцінки вигідності пропозиції [9]. Яскравим прикладом роботи цього механізму є відображення знижок: показуючи стару ціну поруч із новою, система миттєво змінює референсну точку, через що покупка сприймається не як витрати коштів, а як отримання вигоди [32]. Це активує страх втратити цю уявну перевагу (уникнення витрат) і стимулює імпульсивні дії, подібно до того, як пропозиції гарантій звертаються до бажання мінімізувати ризик [34].

Окрім теорії перспектив, рекомендаційні системи масово застосовують когнітивні упередження для впливу на інтуїтивну Систему 1. Ключовими є ефект якоря (anchoring effect), коли рейтинг товару (наприклад 4,5 зірки) стає базою для оцінки, адже вподобання споживачів є «податливим» і залежать від первинної інформації [29; 35]. Цей вплив посилює упередженням позиції (position bias) та ефектом первинності (primacy effect), де перша рекомендація у списку діє як найсильніший якор, визначаючи подальший пошук [36]. Для зниження тривожності використовується соціальний доказ (social proof), такі теги як «бестселер» чи «з цим купують», що спрощує вибір, тоді як упередження підтвердження (confirmation bias) може замикає користувача у «фільтраційну бульбашку» схожих товарів, підвищуючи короткострокову задоволеність ціною різноманітності [17; 37-38].

Найбільша сила рекомендаційних систем полягає у створенні алгоритмічних циклів зворотного зв'язку, де ці упередження взаємодіють [36]. Типовий сценарій виглядає так: платформа маніпулює позицією, розміщуючи маржинальний товар першим, що стимулює кліки Системи 1. Далі алгоритм інтерпретує ці дії як ознаку якості й автоматично додає тег «популярний», тобто соціальний доказ, який стає новим якорем для наступних користувачів. Так виникає самопідсилювальний цикл, у якому система не просто передбачає популярність продукту, а фактично контролює її, перетворюючи маніпуляції на об'єктивну ринкову реальність.

Персоналізація через рекомендаційні системи виступає ключовим драйвером ефективності в електронній комерції, забезпечуючи компаніям, що швидко ростуть на 40% більше доходу порівняно з конкурентами [39-40]. Загальний приріст доходу від її впровадження оцінюється в 10-15%, а в сесіях з активною взаємодією рекомендації можуть генерувати до 31% усього доходу платформи [40-41]. Окрім цього, технології дозволяють скоротити вартість залучення клієнта до 50%, що суттєво оптимізує маркетинговий бюджет [40]. Сильний вплив спостерігається і на показниках лояльності, 71% споживачів очікують персоналізованого досвіду, а 60% стають постійними покупцями саме після його отримання [40; 42]. Згідно з дослідженнями McKinsey це підвищує задоволеність клієнтів на 20% і стає ґрунтом для стратегії максимізації довічної цінності клієнта, бо лояльна аудиторія купує частіше і менш чутлива до цінової конкуренції [43-44]. Економічний ефект закріплюється через когнітивну втрату переходу, тобто клієнт, який витрачав час на навчання алгоритму під свої вподобання (як у Netflix чи Amazon), стикається з високим бар'єром при спробі змінити сервіс, оскільки це вимагає повторної активації Системи 2.

На глобальному економічному рівні роль рекомендаційних систем є дуже важливо, наприклад Amazon генерує близько 35% доходів завдяки персоналізації, а Netflix отримує через такі алгоритми понад 75% переглядів [45-46]. Тобто, рекомендаційні системи стали фундаментом бізнес-моделей лідерів цифрової економіки. На відміну від статичної концепції Homo Economicus, еволюційна економіка розглядає ринок як динамічну систему, де алгоритми виступають ідеальним адаптивним механізмом, що постійно підлаштовується під зміни інтересів користувачів через процес відбору [47-48]. Ключовим тут є феномен коеволюції, де не тільки система (наприклад, алгоритм Amazon item-to-item) адаптується до людини, але й сама людина формує свої смаки під впливом пропозицій платформи [26; 49]. Користувачі, особливо новачки, навчаються оцінювати продукти саме в процесі взаємодії з алгоритмом, це надає рекомендаційним системам фундаментального економічного значення, вони не

просто виявляють існуючі вподобання, а й активно їх користають, діючи як інструмент ринкового відбору [50-51].

## 1.2 Класифікація та порівняльний аналіз методів побудови персоналізованих пропозицій товарів

У сучасній цифровій екосистемі користувачів електронної комерції, ритейлери стикаються з проблемою інформаційного перевантаження. Рекомендаційні системи виступають інструментом для фільтрації цього шуму, маючи на меті прогнозувати вподобання користувача до конкретних товарів чи послуг [3]. Історично архітектури рекомендаційних систем класифікувались на три основні групи: колаборативну фільтрацію, контентно-орієнтовані системи та гібридні системи (див. рис. 1.2) [52]. Проте з розвитком машинного навчання ця класифікація значно розширилась.




Рисунок 1.2 – Основні типи рекомендаційних систем

Джерело: [53]

Класичні типи рекомендаційних систем, зображені на рис. 1.2. включають колаборативну фільтрацію (CF), що спирається виключно на матрицю взаємодій та припущення, що схожість минулих дій прогнозує майбутні вподобання [54]. Контентно-орієнтовані системи (CBF) рекомендують товари, аналізуючи їхні характеристики та профілі користувача, тоді як гібридні системи комбінують ці методи для максимізації переваг та нівелювання недоліків окремих моделей [54].

Сучасні дослідження виокремлюють фільтрацію на основі знань (Knowledge-Based), яка використовує явні правила предметної області (наприклад, бюджетні обмеження чи сумісність препаратів) [55]. Це ефективно для специфічних сфер, наприклад фінансові послуги чи туристичний бізнес, але створює інженерне «вузьке місце» через складність підтримки бази знань [55]. Контекстно-залежні системи (Context-Aware) вирішують проблеми ігнорування ситуативних факторів традиційними моделями, інтегруючи динамічні дані (час, локацію, пристрій) для підвищення точності прогнозування [56].

Щодо більш класичних підходів, то колаборативна фільтрація історично поділяється на два підкласи: підходи на основі пам'яті (Memory-Based) та на основі моделі (Model-Based). Підходи на основі пам'яті поділяються на два типи, їх ключові відмінності наведені у таблиці 1.1.

Таблиця 1.1 – Відмінності підходів User-Based та Item-Based

| Характеристика                     | User-Based CF (на основі користувачів)                                  | Item-Based CF (на основі товарів/об'єктів)                               |
|------------------------------------|-------------------------------------------------------------------------|--------------------------------------------------------------------------|
| <b>Фокус</b>                       | знаходить схожих користувачів і рекомендує елементи, які їм сподобалися | знаходить схожі елементи та рекомендує на основі попередніх взаємодій    |
| <b>Обчислювальна складність</b>    | висока (особливо при великій кількості користувачів)                    | нижча (оскільки схожість між елементами залишається відносно стабільною) |
| <b>Адаптивність</b>                | часто оновлюється, оскільки вподобання користувачів змінюються          | більш стабільна, оскільки зв'язки між елементами залишаються постійними  |
| <b>Проблема «холодного старту»</b> | має труднощі з новими користувачами, які не мають історії взаємодій     | має труднощі з новими елементами, які не мають даних про взаємодії       |

Джерело: [57]

У масштабних комерційних проектах Item-Based CF виявилась значно ефективнішою, бо зв'язок між товарами (наприклад, фільми однієї франшизи) є більш статичним, ніж змінні смаки людей [58].

Для обчислення схожості в обох підходах найчастіше використовується косинусна схожість (cosine similarity) – ця метрика вимірює косинус кута між двома векторами (користувачів або товарів) у багатовимірному просторі рейтингів [3].

Вона є стандартом для роботи з розрідженими даними, бо враховує спільні ненульові оцінки і розраховується за формулою (1.1) [57]:

$$\text{sim}(A, B) = \frac{A \cdot B}{\|A\| \|B\|}, \quad (1.1)$$

де,  $A$  та  $B$  вектори оцінок користувачів чи товарів.

Також, залежно від типу даних, можуть застосовуватись й інші метрики, наприклад коефіцієнт кореляції Пірсона або коефіцієнт Жаккара [57].

На відміну від методів на основі пам'яті, Model-Based підходи намагаються вивчити приховані латентні патерни у даних. Головна перевага колаборативної фільтрації (CF) – це здатність рекомендувати складні об'єкти без аналізу їхнього вмісту, що забезпечує ефект несподіваних відкриттів [59]. Однак ці методи вразливі до проблеми «холодного старту» та розрідженості матриці, і вимагають значних обчислювальних ресурсів при масштабуванні [59]. «Золотим стандартом» цього напрямку після конкурсу Netflix Prize стала матрична факторизація, її теоретична основа полягає в тому, що за оцінками ховаються латентні фактори, тобто неявні характеристики, які пояснюють вподобання, наприклад складність сюжету для фільмів чи орієнтація на бренд при покупці товарів [60]. Математично кожен користувач і товар представляються вектором цих ознак. Прогнозована оцінка обчислюється як скалярний добуток цих векторів, якщо значення факторів користувача збігаються з факторами товару, то прогноз буде високим [61]. Логіка роботи матричної факторизації візуалізовано на рис. 1.3.




Рисунок 1.3 – Схематичне зображення процесу матричної факторизації

Джерело: [62]

Контентно-орієнтовані системи (CBF) працюють за принципом підбору об'єктів, характеристики яких збігаються з тими, що вже отримали схвалення від користувача [3]. Перевагою цього підходу є незалежність від даних інших учасників системи, що робить його ідеальним інструментом подолання проблеми «холодного старту» [3]. Архітектура процесу реалізується у три етапи (див. рис. 1.4). Спочатку аналізатор контенту вилучає ключові атрибути (бренд, категорію, ключові слова) та структурує їх у векторний профіль елемента. Далі формується узагальнений профіль користувача шляхом агрегації векторів тих об'єктів, з якими він позитивно взаємодіяв. Фінальним етапом є генерація рекомендацій, де система обчислює ступінь схожості між профілем користувача та кандидатами, ранжуючи їх від найбільш релевантних до менш відповідних.




Рисунок 1.4 – Процес роботи контентно-орієнтованої системи

*Джерело: розроблено автором на основі [63]*

Гібридні рекомендаційні системи виникли як відповідь на обмеження вищеписаних підходів, вони компенсують проблему «холодного старту» та розрідженості даних колаборативної фільтрації, додаючи їм характеристики контентних методів працювати з новими об'єктами, долаючи схильність останніх до одноманітних рекомендацій [54; 64]. У сучасних системах використовуються різні стратегії гібридизації, від простого зважування оцінок та змішаної видачі до перемикання між моделями залежно від історії користувача (наприклад контентно-орієнтовані для нових користувачів, а колаборативна фільтрація для постійних)

[65]. Більш складні методи включають комбінацію ознак, мета-рівневе моделювання та каскадний підхід, де простіша модель швидко відбирає кандидатів, а складніша – точно їх ранжує [65]. Одним із найпотужніших методів є Feature-Weighted Linear Stacking (FWLS), який довів свою ефективність у конкурсі Netflix Prize [3; 66]. Його відмінність від звичайного зважування полягає у відмові від фіксованих коефіцієнтів на користь динамічних ваг, що залежать від контексту (мета-ознак), таких як кількість оцінок користувачів чи час доби [67]. Це дозволяє алгоритму автоматично адаптуватись до різних ситуацій. В загальному, формальний прогноз у цьому методі визначається як сума прогнозів усіх базових моделей, де внесок кожної з них коригується індивідуальною ваговою функцією [66]. Сам ця вага розраховується як лінійна функція від мета-ознак та навчених параметрів, а це забезпечує гнучке балансування між різними алгоритмами в реальному часі [66].

Таблиця 1.2 – Порівняльний аналіз класичних типів рекомендаційних систем

| Критерій                                          | Колаборативна фільтрація (CF)                                                                                                  | Контентно-орієнтовані системи (CBF)                                                                                             | Гібридні системи (Hybrid Systems)                                                                              |
|---------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------|
| <b>Основний Принцип</b>                           | Базується на поведінці «схожих» користувачів або схожості товарів за оцінками (люди, яким сподобалось X, також сподобалось Y). | Базується на ознаках (контенті) товарів. Рекомендує товари, схожі за характеристиками на ті, що користувач вподобав у минулому. | Поєднує два або більше методів (найчастіше CF та CBF) для посилення переваг та компенсації недоліків.          |
| <b>Вхідні дані</b>                                | Матриця взаємодій «користувач-товар» (рейтинги, кліки, перегляди).                                                             | Ознаки товарів (теги, жанри, опис) та профіль вподобань користувача.                                                            | І взаємодії (для CF), і ознаки (для CBF).                                                                      |
| <b>«Холодний старт» (Нові користувачі/товари)</b> | Дуже погано. Потрібна попередня історія взаємодій для нових користувачів та нових товарів.                                     | Добре для нових товарів (потрібні лише їхні ознаки). Погано для нових користувачів (потрібно спершу зібрати профіль).           | Добре. Це головна перевага. Може використовувати CBF, коли CF-даних недостатньо, ефективно вирішуючи проблему. |

|                                  |                                                                                                            |                                                                                                                             |                                                                                                                           |
|----------------------------------|------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------|
| <b>Різноманітність / Новизна</b> | Середня/Висока. Може знаходити несподівані товари з різних категорій, які сподобались схожим користувачам. | Низька. Схильна до «фільтраційної бульбашки» та надмірної спеціалізації. Рекомендує лише те, що схоже на минулі вподобання. | Висока. Може збалансувати точність (CBF) з відкриттями (CF) для кращої різноманітності.                                   |
| <b>Пояснюваність</b>             | Середня (для «memory-based»): «Схожі користувачі це вподобали». Низька (для «model-base» як MF).           | Висока: «Тому, що ви вподобали товар X, який має ознаку.»                                                                   | Низька/Складна. Логіка комбінування кількох моделей зазвичай є «чорною скринькою».                                        |
| <b>Переваги</b>                  | Не потребує аналізу контенту товарів. Здатна знаходити складні, неочевидні патерни смаків.                 | Незалежність від інших користувачів. Вирішує проблему «холодного старту» для товарів.                                       | Найвища точність та надійність. Компенсує недоліки окремих підходів (особливо «холодного старту» та розрідженість даних). |
| <b>Недоліки</b>                  | Проблема «холодного старту» та розрідженість даних – коли взаємодій занадто мало.                          | Надмірна спеціалізація. Необхідність у якісних метаданих та інжинірингу ознак.                                              | Висока складність впровадження, налаштування та підтримки.                                                                |
| <b>Коли підходить</b>            | Коли є багато історії взаємодій, інформативні дані від користувачів.                                       | Коли маємо якісні характеристики товарів/контенту і/або недостатньо історії взаємодій.                                      | Коли потрібно поєднати сильні сторони CF і CBF, або маємо різноманітні дані.                                              |

*Джерело: розроблено автором на основі [3; 52-67]*

Перехід від матричної факторизації до моделей глибокого навчання був зумовлений обмеженістю лінійного оператора, тобто скалярного добутку, що лежить в основі матричної факторизації [68]. Це припущення є занадто простим для моделювання складних нелінійних патернів користувацьких вподобань, індустрія звернулась до глибоких нейронних мереж [69]. Вони виступають універсальними апроксиматорами функцій, що дозволяє моделювати взаємодії високого порядку та автоматично вивчати корисні представлення, тобто ембединги безпосередньо з «сирих» даних, усуваючи потребу в ручній побудові ознак [68-69]. Прикладом такої еволюції є Neural Collaborative Filtering (NCF), яка замінює фіксований скалярний добуток на гнучку нейронну мережу [69-70]. Архітектура NCF часто поєднує два паралельні шляхи, а саме лінійний (Generalized Matrix Factorization) та нелінійний (Multi-Layer Perceptron), який пропускає дані через багатопшарову мережу [69-70]. Об'єднання виходів обох потоків дозволяє моделі інтегрувати сильні сторони

факторизації та гнучкість глибокого навчання для точнішого прогнозування взаємодій [69-70].

Ще одним потужним підходом є використання автокодувальників, зокрема моделі AutoRec, яка навчається відновлювати вхідні вектори рейтингів користувача [71]. Процес починається зі стиснення даних енкодером у компактне латентне представлення («вузьке горло») з наступною реконструкцією декодером [71]. Саме проходження через це «вузьке горло» змушує модель виділяти найбільш значущі, узагальнені та нелінійні патерни вподобань [71]. Але варто сказати, що ці методи (матрична факторизація, NCF, AutoRec) зазвичай розглядають взаємодії як статичний набір ознак, ігноруючи часову послідовність, яка є важливою для таких сфер як кіно, музика чи електронна комерція.

Для моделювання динаміки активно використовують рекурентні нейронні мережі (RNN), зокрема модель GRU4Rec [72]. Вона використовує GRU-осередки для акумуляції історії взаємодій у прихований вектор, що прогнозує наступну дію, але такі моделі маю проблему із забування у довгих послідовностях та складнощі із паралелізацією процесів [72].

Ефективнішою альтернативою є моделі на базі self-attention, як наприклад SASRec [73]. Замість стискання історії вони аналізують попередні елементи одночасно, визначаючи через механізм уваги найбільш релевантні взаємодії [73]. Це дозволяє враховувати як локальні, так і довгострокові залежності, а також краще піддається паралелізації.

Більшість методів згаданих вище оптимізують короткострокові метрики (кліки), що створює ризик ігнорування довгострокового утримання клієнта та надмірної експлуатації відомих даних без дослідження нових [74]. Вирішенням є підхід Reinforcement Learning (RL), де система діє як агент, тобто вона обирає рекомендації, отримує винагороду і прагне максимізувати сумарну винагороду у майбутньому [74]. RL дозволяє балансувати між експлуатацією перевіреного та дослідженнями нового, хоча наразі цей метод перебуває переважно на стадії наукових розробок [74].

Отже, в цілому можна сказати, що еволюція від класичної матричної факторизації до моделей глибинного навчання й далі до методів, орієнтованих на послідовності і навчання з підкріпленням, була зумовлена прагненням подолати обмеження лінійності, враховувати часову динаміку та вирішувати проблеми «холодного старту». Але жоден підхід не є універсальним, кожен з них має власні переваги та недоліки, а вибір методу має визначатися конкретним контекстом в якому він має бути використаний, характером даних і бізнес-цілями.

Аналіз наукової літератури, присвяченої рекомендаційним системам, демонструє еволюції дослідницької думки; від порівняльного аналізу та гібридизації фундаментальних алгоритмів до розробки складних нейромережових архітектур, які здатні моделювати динамічні послідовності, і до новітніх парадигм таких, як причинно-наслідковий аналіз та великі мовні моделі (LLM). Всупереч поширеному уявленню, аналіз вітчизняних наукових робіт показує не лише освоєння класичних методів, а й глибоке занурення у найсучасніші архітектури.

Відправною точкою для багатьох українських дослідників часто стає аналіз фундаментальних підходів. Наприклад, часто аналізуються основоположні роботи з матричної факторизації авторів Y. Koren, R. Bell, C. Volinsky та S. Shah [60; 75]. Саме розуміння обмежень матричної факторизації (проблема «холодного старту» та розрідженості даних) стало каталізатором для розробки гібридних рішень. Прикладом такого підходу є робота Червіцької К. В. «Рекомендаційна система для електронної бібліотеки для молодих авторів», де авторка пропонує гібридну модель, що комбінує контентну фільтрацію (Content-Based) та фільтрацію на основі знань (Knowledge-Based) [76].

Інші дослідники обирали й некласичні шляхи. Наприклад, у роботі К.А. Носик «Розробка методів формування рекомендацій в інформаційній системі з використанням інструментів нечіткої логіки» для вирішення задачі персоналізації запропонував алгоритм на основі нечіткої логіки (Fuzzy Logic), зокрема з використанням методів Мамдані [77]. Це демонструє фокус на вирішення конкретних бізнес-задач, а не на простому копіюванні вже відомих алгоритмів.

Одним з найважливіших етапів, що показує рівень розвитку української науки у сфері рекомендаційних систем є критичний аналіз та вдосконалення найсучасніших моделей, наприклад графових нейронних мереж (GNN). У статті П. А. Количева та О. Б. Волощук на тему «Дослідження методів побудови рекомендаційних систем з використанням графових нейронних мереж», автори проводять глибокий аналіз архітектури LightGCN, і виявляють її теоретичну слабкість про те, що стандартний метод оновлення «повністю відкриває початкову інформацію» про вузол користувача, що може призвести до «втрати вподобань користувача» [78]. Для вирішення цієї проблеми автори пропонують модифікувати метод оновлення, об'єднуючи початкове представлення вузла з агрегованих [78]. А у статті І. О. Пишнограєва та А. Е. Ширалієва «A comprehensive benchmark of collaborative filtering methods on implicit feedback datasets», дослідники провели масштабне тестування 13 алгоритмів [79]. Їхні висновки є практичними та неочевидними. На малих щільних датасетах (як MovieLens 100k), GNN-моделі, як от NGCF чи LightGCN, показали високу точність, а на великих, розріджених даних (MovieLens 20M) вони зіткнулись з проблемою масштабованості [79]. У дослідженні вказано, що на великому датасеті найкращу продуктивність, тобто NDCG@10, та значно кращу обчислювальну ефективність показала простіша лінійна модель EASE<sup>R</sup> [79].

У зарубіжній літературі домінування класичної матричної факторизації було поставлено під сумнів через обмеженість скалярного добутку, що дало поштовх до переходу до моделей глибокого навчання [80]. Однією з перших впливових робіт у цьому напрямку стала «AutoRec: Autoencoders Meet Collaborative Filtering» авторів Suvash Sedhain, Aditya Krishna Menon та інших, де автори пропонують змінити факторизацію на використання автокодувальника [81]. В їхній архітектурі вектор рейтингів для одного елемента подається на вхідний шар, проходить через один прихований шар з нелінійною функцією активації та реконструюється на вихідному шарі [81]. Модель навчається мінімізовувати помилку реконструкції лише на спостережуваних рейтингах, що дозволяє їй ефективно працювати з розрідженими даними [81]. Ще однією важливою роботою, що формалізує такий підхід

вважається «Neural Collaborative Filtering» авторів Xiangnan He, Lizi Liao та інших, вони стверджували, що матрична факторизація є лише лінійним та обмеженим випадком колаборативної фільтрації [69]. Вони запропонували узагальнений фреймворк NCF, який замінює скалярний добуток на повноцінну нейронну мережу, здатну вивчати довільну нелінійну функцію взаємодій [69]. У фінальній архітектурі «NeuMF» He та колеги об'єднали два паралельні шляхи: GMF – узагальнену матричну факторизацію з поелементним множенням та MLP – багатошаровий перцептрон, що обробляє конкатенацію векторів [69]. Виходи обох гілок об'єднуються на фінальному шарі, утворюючи гібридну нелінійну модель, яка, як показують експерименти, суттєво перевершує класичні лінійні підходи [69].

Наступним логічним кроком у дослідженнях був перехід від моделювання статичних профілів, де порядок немає значення до динамічних послідовностей. Перший прорив у цій галузі здійснили Balazs Hidasi, Alexandros Karatzoglou та інші у роботі «Session-based recommendations with recurrent neural networks», це була одна з перших праць, де успішно застосували рекурентні нейронні мережі (RNN), а саме Gated Recurrent Unit (GRU) для моделювання анонімних сесій користувачів [72]. В архітектурі GRU4Rec входом є «поточний стан сесії», а виходом – «елемент наступної дії» [72]. GRU оновлює свій прихований стан на кожному кроці, таким чином фіксуючи історію сесії [72]. Важливою інновацією авторів цієї статті стало впровадження «сесійно-паралельних міні-батчів», це коли одна сесія у батчі завершується, на її місце стає нова, а прихований стан цього потоку обнуляється [72].

Незважаючи на успіх, RNN-моделі мають обмеження у моделюванні довгострокових залежностей. Цю проблему вирішила архітектура Transformer. У роботі «Self-Attentive Sequential Recommendation» авторів Wang-Cheng Kang та Julian McAuley, вони замінили рекурентну архітектуру на механізм само-уваги [73]. На відміну від RNN, які послідовно стискали історію в один вектор, SASRec аналізує всю послідовність одночасно, механізм дозволяє адаптивно призначати ваги попереднім елементам в послідовності незалежно від того наскільки «далеко»

він знаходиться [73]. Цей механізм уваги не чутливий до порядку, тому автори ввели «здатні до навчання позиції ембединги» (learnable position embedding) [73].

Сучасні дослідження за 2020-2025 роки виходять за межі простої точності прогнозування, зосереджуючись на більш складних аспектах. Наприклад, статті як «Reinforcement learning to optimize long-term user engagement in recommender systems» авторів Lixin Zou, Long Xia та інших, описують перехід до навчання з підкріпленням (RL), де процес рекомендацій моделюється як Марківський процес прийняття рішень (MDP), замість оптимізації миттєвої винагороди, тобто наступного кліку [82]. У цій постановці Станом (State) є історія переглядів користувачів, Дією (Action) – рекомендація наступного елемента, а Винагородою (Reward) – реакція користувача (клік, час перегляду), з метою максимізації сукупної довгострокової винагороди (long-term user engagement) [82].

Іншим важливим напрямком є використання великих мовних моделей (LLM). Наприклад, у роботі «Large language models are zero-shot rankers for recommender systems» авторів Yupeng Hou та інших, показано, що LLM здатні ранжувати елементи без будь-якого специфічного навчання (zero-shot) за допомогою ретельно розробленого промпт-шаблону [83]. Але автори виявили і серйозні проблеми, LLM страждають від сильних упереджень позиції та популярності, тобто мають труднощі зі сприйняттям порядку [83]. У іншій публікації «Is ChatGPT a good recommender? A preliminary study» Junling Liu та інші провели пряме порівняння ChatGPT із спеціалізованими алгоритмами [84]. Висновки показали, що у завданнях точності LLM значно поступаються профільним моделям. Але у задачах на пояснюваність людська оцінка показала, що ChatGPT перевершує існуючі моделі, він генерує розумні пояснення попри погані результати за автоматичними метриками точності [84].

Наукова спільнота дедалі частіше визнає обмеженість класичних метрик (RMSE, NDCG) зміщуючи фокус дослідження «поза точністю» (beyond-accuracy) [85-86]. Важливими новими цілями стають справедливість (fairness) для уникнення упереджень, гарантуючи справедливе представлення для різних груп користувачів та постачальників контенту, пояснюваність (explainability, XAI) – здатність системи

надавати прозоре обґрунтування рекомендацій, а також, різноманітність (diversity) та новизна (novelty) – для боротьби з «фільтраційними бульбашками», як міра неподібності серед набору рекомендованих елементів [85-86].

Майбутнє рекомендаційних систем визначається переходом до гібридних архітектур, де великі мовні моделі (LLM) як зазначено у «Tutorial on large language models for recommendation» Wenyue Hua та інших, виступають інтерактивними інтерфейсами для пояснення рішень [87]. Паралельно наукова думка зміщується від простої кореляції до причинно-наслідкового виведення для боротьби з упередженнями популярності та показу як зазначається в «A Survey on Causal Inference for Recommendation» [88]. Для цього використовуються фреймворки Potential Outcome (PO) та Structural Causal Model (SCM), а також методи контрфактуальної оцінки (counterfactual evaluation), для відповіді на питання: «що, якби ...?» [88-89].

У відповідь на вимоги захисту даних набуває популярності федеративне навчання (FL), де персональна інформація не залишає пристрою користувача [90]. Модель навчається локально, надсилаючи на сервер анонімізовані оновлення [90].

Третім важливим напрямком розвитку є мультимодальні та крос-доменні рекомендаційні системи (MMRS & CDRS), які мають вирішувати проблеми «холодного старту» та розрідженості даних [91]. Як зазначено в «A comprehensive survey on cross-domain recommendation: taxonomy, progress, and prospects», системи використовують контентну інформацію (текст, зображення, аудіо) [91]. Наприклад, аналіз текстових описів дозволяє знайти схожості між фільмами та книгами, дозволяючи трансфер знань (knowledge transfer) із насичених даними доменів (наприклад, кіно) у сфері з меншою історією взаємодій (наприклад, книги) [91].

Отже, можна зробити висновок, що аналіз наукової літератури демонструє перехід рекомендаційних систем до більш складних архітектур, у вдосконалення яких активно долучаються й українські науковці.

## РОЗДІЛ 2

### МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ПЕРСОНАЛІЗОВАНИХ РЕКОМЕНДАЦІЙ У ЕЛЕКТРОННІЙ КОМЕРЦІЇ

#### **2.1 Структура та особливості формування інформаційної бази для моделювання персоналізованих товарних пропозицій**

Предметною областю дослідження є електронна торгівля (e-commerce), одна з найбільш динамічних та орієнтованих на дані галузей сучасної економіки. У порівнянні з традиційною роздрібною торгівлею, онлайн платформи, як наприклад Amazon, генерують та зберігають великомасштабні обсяги інформації про аспекти взаємодії користувачів із системою. Такі інформаційні системи збирають не просто дані про транзакції, а про поведінкові патерни, явні уподобання, неявні сигнали про зацікавленість та текстові відгуки, що в сукупності формує складний, багатовимірний цифровий слід кожного користувача.

Для цілей побудови та аналізу рекомендаційних систем, ця предметна область є ідеальною експериментальною базою. Вона дає два різні види інформації, які є досить важливими для моделювання. Перший вид – це дані про взаємодію, вони фіксують зв'язки між користувачами та товарами (наприклад, перегляди, покупки, рейтинги). Другий – дані про атрибути, що характеризують самих користувачів та товарів (метадані, описи, відгуки). Як згадувалось в розділі 1, надлишок цієї інформації створює проблему перевантаження вибору, яку рекомендаційні системи мають вирішувати. Перед початком моделювання варто описати інформаційну базу, на якій буде виконуватись дослідження.

Особливістю даних для побудови рекомендаційних систем є суттєва розрідженість внаслідок того, що середньостатистичний користувач взаємодіє лише з невеликою кількістю товарів із загального каталогу. Також ці дані мають чіткий часовий вимір та демонструють «довгий хвіст» розподілу популярності.

Для аналізу та побудови моделей у цій роботі використано масштабний публічний набір даних Amazon Reviews 2023 зібраний McAuley Lab у 2023 році [92]. Цей датасет є оновленою та розширеною версією відомих наборів даних Amazon, які зібрані та підтримуються дослідницькою групою з Університету Каліфорнії в Сан-Дієго (UCSD), зокрема під керівництвом Джуліана МакОлі [93]. Використання цього набору даних є доцільним, бо за довгий час його оновлень, він став певним академічним стандартом для створення рекомендаційних систем. Він містить мільйони відгуків, метаданих, описів товарів та часові мітки – дані зібрані з травня 1996 року до вересня 2023 року включно [92].

Датасет доступний у форматі JSONL (JSON Lines), де кожен рядок файлу є валідним JSON-об'єктом. Дані розподілені за різними категоріями товарів, наприклад, «Electronics», «Books», «Health and Personal Care» тощо. Тому дослідники можуть обирати потрібну область із своїми унікальними поведінковими патернами.

Для даного дослідження була обрана категорія «Health and Personal Care». Цей вибір був продиктований кількома причинами. Насамперед ця категорія досить велика, щоб дослідити, зокрема, масштабованість та розрідженість даних. З іншого боку, кількість даних є обчислювально доступною для проведення експериментів на наявних ресурсах. Також, товари для особистого догляду часто є повторюваними покупками та залежать від довіри користувачів та якості відгуків, що робить рекомендації актуальними у цій ніші. Дана категорія містить багато текстових описів та відгуків, що варто використовувати при побудові контентно-орієнтованих моделей рекомендацій.

У всіх категоріях датасету Amazon Reviews 2023, інформаційна база складається з двох основних файлів, включно з категорією «Health and Personal Care». Вони відповідають двом типам даних: товарам та взаємодіям. Ці файли можна завантажити у вигляді `meta_Health_and_Personal_Care.jsonl.gz` та `Health_and_Personal_Care.jsonl.gz`.

Перший файл, `meta_Health_and_Personal_Care.jsonl.gz`, містить метадані про товари. Він формує каталог або «простір товарів» рекомендаційної системи. Кожен

запис у цьому файлі є JSON-об’єктом, що описує один унікальний товар. Змінні цього файлу наведено у таблиці 2.1.

Таблиця 2.1 – Опис змінних каталогу товарів

| Поле            | Тип   | Пояснення                                                                     |
|-----------------|-------|-------------------------------------------------------------------------------|
| main_category   | str   | основна категорія (тобто домен) товару                                        |
| title           | str   | назва товару                                                                  |
| average_rating  | float | середній рейтинг товару, показаний на сторінці продукту                       |
| rating_number   | int   | кількість залишених рейтингів для товару                                      |
| features        | list  | ключові особливості товару у вигляді маркованого списку                       |
| description     | list  | опис товару                                                                   |
| price           | float | ціна у доларах США (на момент збору даних)                                    |
| images          | list  | зображення товару                                                             |
| videos          | list  | відео товару                                                                  |
| store           | str   | назва магазину, у якому представлений товар                                   |
| categories      | list  | ієрархічні категорії, до яких належить товар                                  |
| details         | dict  | детальна інформація про товар, включно з матеріалами, брендом, розмірами тощо |
| parent_asin     | str   | батьківський ідентифікатор товару                                             |
| bought_together | list  | рекомендовані набори товарів, які часто купують разом                         |

Джерело: розроблено автором на основі [92]

Структуру таблиці даних, що завантажується для моделювання наведено на рис. 2.1:

|   | main_category          | title                                             | average_rating | rating_number | features                                          | description                                       | price | images                                           | videos                                           | store      | categories | details                                             | parent_asin | bought_together |
|---|------------------------|---------------------------------------------------|----------------|---------------|---------------------------------------------------|---------------------------------------------------|-------|--------------------------------------------------|--------------------------------------------------|------------|------------|-----------------------------------------------------|-------------|-----------------|
| 0 | Health & Personal Care | Silicone Bath Body Brush Exfoliator Shower Bac... | 3.9            | 7             | []                                                | []                                                | NaN   | ["thumb": "https://m.media-amazon.com/images/... | []                                               | Rzoeox     | []         | ["Package Dimensions": "15 x 3.3 x 1.5 inches...",  | B07V346GZH  | NaN             |
| 1 | Health & Personal Care | iPhone 7 Plus 8 Plus Screen Protector, ZHXIN T... | 3.8            | 2             | [Tough and Robust: Like all 78X screen protect... | [Features: 2.5D Arc Edge Treatment: The edge l... | NaN   | ["thumb": "https://m.media-amazon.com/images/... | []                                               | ZHXIN      | []         | ["Brand": "ZHXIN", "Compatible Devices": "Cell...   | B075W927RH  | NaN             |
| 2 | Health & Personal Care | Zig Zag Rolling Machine 70mm Size With FREE BO... | 3.9            | 7             | []                                                | []                                                | NaN   | ["thumb": "https://m.media-amazon.com/images/... | []                                               | None       | []         | ["Package Dimensions": "4.1 x 1.8 x 0.3 inches...", | B01F826VKY  | NaN             |
| 3 | Health & Personal Care | Sting-Kill Disposable Wipes 8 Each ( Pack of 5)   | 4.1            | 6             | []                                                | [effective on stings and bites from bees, wasp... | 21.37 | ["thumb": "https://m.media-amazon.com/images/... | []                                               | Sting-kill | []         | ["Brand": "Sting-kill", "Item Form": "Wipe", "...   | B01IAI29RU  | NaN             |
| 4 | Health & Personal Care | Heated Eyelash Curler Mini Portable Electric E... | 3.3            | 8             | []                                                | []                                                | NaN   | ["thumb": "https://m.media-amazon.com/images/... | []                                               | BIBOSS     | []         | ["Package Dimensions": "6.1 x 3.1 x 1.9 inches...", | B08CMN38RC  | NaN             |
| 5 | Health & Personal Care | Balloon Garland Kit Party Event Baby,120 Item ... | 4.6            | 19            | []                                                | []                                                | NaN   | ["thumb": "https://m.media-amazon.com/images/... | []                                               | Tiktaco    | []         | ["Occasion": "Bachelorette Party, Bridal Showe...   | B07YJ5JB26  | NaN             |
| 6 | Health & Personal Care | Disney Mickey Mouse Long Sleeve Thermal Tee fo... | 5.0            | 1             | [We don't know when or if this item will be ba... | [We don't know when or if this item will be ba... | NaN   | ["thumb": "https://m.media-amazon.com/images/... | []                                               | HAARB      | []         | ["Package Dimensions": "10 x 7.5 x 1.6 inches...",  | B013EXXYLG  | NaN             |
| 7 | Health & Personal Care | 3X Replacement Shaver Head Shaver Blade for Ph... | 3.9            | 67            | [✔ Fits for Philips Norelco HQ300, HQ302, HQ...   | [Description: 100% brand new and high quality.... | 18.49 | ["thumb": "https://m.media-amazon.com/images/... | ["title": "how to sharp shaver head", "url": ... | UOnline911 | []         | ["Brand": "UOnline911", "Item Weight": "0.01 ...    | B07FTJB,JKK | NaN             |
| 8 | Health & Personal Care | JOYWA Inadine Dressing - 5cm x 5cm (x25) by Jo... | 5.0            | 3             | []                                                | []                                                | 55.00 | ["thumb": "https://m.media-amazon.com/images/... | []                                               | JOYWA      | []         | ["Is Discontinued By Manufacturer": "No", "Pac...   | B003TSVQK8  | NaN             |

Рисунок 2.1 – Завантажені дані каталогу товарів

Джерело: розроблено автором на основі [92]

Важливою є змінна `parent_asin`, яка використовується для розпізнавання товару та слугує ідентифікатором для зв'язку з файлом відгуків. Окрім `parent_asin`, для аналізу були використані наступні змінні:

- `title`: текстова назва товару, це поле є важливим джерелом інформації для контентно-орієнтованих методів.
- `details`: JSON-об'єкт, що містить різноманітні структуровані атрибути товару, такі як бренд, виробник, форма випуску, колір, смак тощо.
- `description`: текстовий опис товару.
- `price`: ціна товару, яка буде використана як додаткова ознака.
- `main_category`, `categories`, `store`: ці 3 змінні також будуть використані як ключові категорійні ознаки для гібридних моделей.
- `average_rating` та `rating_number`: відображають загальний рейтинг товару.

Другий файл, `Health_and_Personal_Care.jsonl.gz`, містить інформацію про взаємодії користувачів з товарами у вигляді відгуків, стовпці цього датасету наведено в таблиці 2.2.

Таблиця 2.2 – Опис змінних взаємодії користувачів з товарами

| Поле                     | Тип   | Пояснення                                                     |
|--------------------------|-------|---------------------------------------------------------------|
| <b>rating</b>            | float | рейтинг товару (від 1.0 до 5.0)                               |
| <b>title</b>             | str   | заголовок користувацького відгуку                             |
| <b>text</b>              | str   | основний текст відгуку                                        |
| <b>images</b>            | list  | зображення, які користувачі публікують після отримання товару |
| <b>asin</b>              | str   | ідентифікатор товару                                          |
| <b>parent_asin</b>       | str   | батьківський ідентифікатор товару                             |
| <b>user_id</b>           | str   | ідентифікатор користувача, який залишив відгук                |
| <b>timestamp</b>         | int   | час публікації відгуку                                        |
| <b>verified_purchase</b> | bool  | ознака підтвердженої покупки користувачем                     |
| <b>helpful_vote</b>      | int   | кількість голосів «корисний відгук»                           |

*Джерело: розроблено автором на основі [92]*

Такий вигляд мають дані при завантаженні, як наведено на рис. 2.2:

|   | rating | title                                             | text                                               | images | asin       | parent_asin | user_id                      | timestamp                  | helpful_vote | verified_purchase |
|---|--------|---------------------------------------------------|----------------------------------------------------|--------|------------|-------------|------------------------------|----------------------------|--------------|-------------------|
| 0 | 4      | 12 mg is 12 on the periodic table people! Mg f... | This review is more to clarify someone else's ...  | []     | B07TDSJZMR | B07TDSJZMR  | AFKZENTNBQ7A7V7UXW5JJI6UGRYQ | 2020-02-06<br>00:49:35.902 | 3            | True              |
| 1 | 5      | Save the lanet using less plastic.                | Love these easy multitasking bleach tablets. B...  | []     | B08637FWWF | B08637FWWF  | AEVWAM3YWN5URJVVJZZ6XPD2MKIA | 2020-11-02<br>22:03:06.880 | 3            | True              |
| 2 | 5      | Fantastic                                         | I have been suffering a couple months with hee...  | []     | B07KJVGNN5 | B07KJVGNN5  | AHSPLDNW5OOUK2PLH7GXLACFBZNO | 2019-07-24<br>11:13:58.905 | 0            | True              |
| 3 | 4      | It holds the water and makes bubbles. That's ...  | It's cheap and it does what I wanted. The "ma...   | []     | B007HY7GC2 | B092RP73CX  | AEZGPLOYTSAPR3DZHKKXEFPAUAA  | 2022-09-04<br>02:29:02.725 | 7            | True              |
| 4 | 1      | Not for me                                        | Didn't do a thing for me. Not saying they don't... | []     | B08KYJLF5T | B08KYJLF5T  | AEQAYV7RXZEBXMQIPL6KCT2CFWQ  | 2022-01-20<br>23:53:07.262 | 0            | True              |
| 5 | 5      | Every home should have these                      | I have never been big on vitamins, with the ex...  | []     | B09GBMG83Z | B09GBMG83Z  | AFSKPY37N3C43SOI5IEXEK5JSIYA | 2022-02-21<br>00:14:54.796 | 1            | False             |
| 6 | 4      | Versatile shaver                                  | To be honest, my husband did not use this for ...  | []     | B09FKT5PQ9 | B09FKT5PQ9  | AFSKPY37N3C43SOI5IEXEK5JSIYA | 2022-02-07<br>20:38:46.005 | 0            | False             |
| 7 | 4      | Makes a nice compact noise machine to take wit... | This is a nice basic sound machine. I have use...  | []     | B08THJD1MH | B08THJD1MH  | AFSKPY37N3C43SOI5IEXEK5JSIYA | 2021-04-08<br>18:45:34.645 | 0            | False             |
| 8 | 5      | Great drawstring holiday bags!                    | This are super colorful great gift giving holi...  | []     | B08FCQML37 | B08FCQML37  | AFSKPY37N3C43SOI5IEXEK5JSIYA | 2020-12-15<br>21:15:39.529 | 0            | False             |
| 9 | 3      | Not as good as the name brand whitening strips... | I guess the only product I have in my history ...  | []     | B08GYM3HVP | B08GYM3HVP  | AFSKPY37N3C43SOI5IEXEK5JSIYA | 2020-10-14<br>21:25:18.369 | 0            | False             |

## Рисунок 2.2 – Завантажені дані взаємодій користувачів з товарами

*Джерело: розроблено автором на основі [92]*

Вищезазначений файл формує інформаційну базу у більш вузькому сенсі, по суті, він є представленням матриці взаємодії «користувач-товар», кожен запис якого відповідає одному відгуку.

У дослідженні були використані наступні змінні:

- **user\_id**: унікальний ідентифікатор користувача.
- **parent\_asin**: ідентифікатор товару, що є зовнішнім ключем до файлу з метаданими.
- **rating**: явний числовий рейтинг, наданий користувачем від 1.0 до 5.0.
- **title** та **text**: заголовок та текстовий зміст самого відгуку, що є джерелом для аналізу контентних ознак.
- **timestamp**: часова мітка, що демонструє хронологію подій.
- **helpful\_vote**: кількість голосів «корисності», наданих іншими користувачами цьому відгуку. Ця змінна є певним неявним сигналом якості до відгуку.

Поєднання цих двох файлів з атрибутами товарів та відгуків користувачів про них формує повну інформаційну базу для побудови рекомендаційних систем.

Необроблені дані, незважаючи на їхнє багатство, не можуть бути використані для аналізу, фрагменти цих даних наведені у таблицях А.1 та А.2 (Додаток А). Структура даних вимагає суттєвої обробки, тобто препроцесингу та інжинірингу ознак. Для початку було вирішено кілька важливих проблем. Датасет містить явних зворотний зв'язок (explicit feedback) у вигляді рейтингів (rating) від 1

до 5. У цьому дослідженні використовувався гібридний підхід, тобто сам факт наявності відгуку розглядався як позитивна неявна взаємодія, що, в цілому, є загальноприйнятою практикою. Ще одним важливим аспектом є обробка часового виміру. Традиційний спосіб поділу, даних на навчальний та тестовий датасети має низку недоліків, зокрема призводить до витоку даних з майбутнього, де модель навчатиметься на майбутніх взаємодіях, щоб передбачити минулі. Тому всі дані були розподілені на навчальну (train), валідаційну (validation) та тестову (test) вибірки виключно на основі часової мітки. У дослідженні використано часове відсікання (temporal split) у пропорції 80% (найстаріші дані) для навчання, 10% для валідації (налаштування гіперпараметрів) та 10% (найновіші дані) для фінального тестування.

Отже, інформаційна база має великий обсяг, високу розрідженість та «довгий хвіст». Обрана категорія «Health and Personal Care» містить 494121 відгук та 60293 товари, що є репрезентативною вибіркою для моделювання.

## **2.2 Побудова рекомендаційних моделей на базі інструментів машинного та глибокого навчання**

Ефективність моделей залежить не лише від їхньої архітектури, але й від якісно підготовлених даних тому етап інжинірингу ознак є дуже важливим, бо він перетворює необроблені дані, описані в розділі 2.1 в інформативні вектори, які моделі можуть «зрозуміти» та використати для того, щоб виявити приховані закономірності. Ця частина обробки даних та всі інші моделі у роботі були реалізовані на мові програмування Python. У дослідженні є як структуровані, так і неструктуровані дані, тому було виконано багатоетапний підхід до підготовки ознак. Атрибути отримані після обробки наведені у таблиці А.3 (Додаток А).

Застосовано підхід до створення семантичних ознак, який базується не на статичних метаданих, тобто описах товарів, а на колективному сприйнятті цих товарів, вираженому через відгуки користувачів.

Щоб алгоритми машинного навчання могли працювати з текстовими даними, їх варто перетворити у числову інформації, тобто вектори або ембединги.

Було прийнято рішення відмовитись від «класичних» підходів, таких як TF-IDF (Term frequency-inverse document frequency) або статичних ембедингів (Word2Vec, GloVe), на користь SOTA (State-of-the-Art) моделі BERT (Bidirectional encoder representations from transformers) [94]. В певній мірі це не зовсім класичний підхід, оскільки, наприклад TF-IDF – це метод, який базується на «мішку слів» (bag-of-words). Він може визначити важливість слів на основі їх частоти, але йому недоступний аналіз слів та їх контекст. Також, цей метод не розуміє семантичного зв'язку між словами, наприклад між «крем» та лосьйон.

Методи Word2Vec/GloVe є більш ефективними, бо вони навчаються семантичному векторному представленню слів, наприклад  $\text{vector}(\text{'король'}) - \text{vector}(\text{'чоловік'}) + \text{vector}(\text{'жінка'}) \approx \text{vector}(\text{'королева'})$  [95]. Але їхнім недоліком є статичність [95]. Наприклад, слово «маска» буде мати однаковий вектор незалежно від контексту, чи це маска для обличчя, чи медична маска, а в описі товарів така багатозначність слів може зустрічатись досить часто. Тому було вирішено використовувати BERT, бо це мовна модель, яка ґрунтується на архітектурі трансформера – її перевага у розумінні контексту. Ця модель не аналізує слово ізольовано, а в контексті всього речення, тобто дивиться на слова як зліва, так і справа. Тому ембединги слова «олія» у реченнях «ефірна олія для лаванди для ароматерапії» буде сильно відрізнятись від ембедингу «кокосова олія для смаження». Для відгуків, де потрібно врахувати тон та специфікацію слів, здатність BERT розуміти тонкий контекст є вирішальною.

BERT використовує механізм само-уваги (self-attention), він допомагає динамічно зважувати важливість кожного слова відносно інших [96]. Це допомагає моделі розуміти, що у фразі «вітамін D3 для дітей», слова «дітей» є ключовим модифікатором для «вітамін D3».

У даному дослідженні використано одну з попередньо навчених моделей BERT з бібліотеки sentence-transformers – all-MiniLM-L6-v2 – це легка швидка модель, що забезпечує якісні семантичні вектори для речень.

Процес створення ембедингів мав кілька етапів, і ґрунтувався на семантиці текстів відгуків з тренувальної вибірки (train). На першому етапі, кожен відгук, який є комбінацією даних із стовпців title та text, був проаналізований моделлю BERT, як наслідок для кожного індивідуально відгуку було згенеровано 384-вимірний семантичний вектор. Наступним важливим аспектом була підготовка самих взаємодій, тобто відгуків. Як зазначалось в підрозділі 2.2 дані містять явні рейтинги від 1.0 до 5.0, використання таких сигналів має ряд недоліків, наприклад зміщеність через переважання рейтингу 5, що може призвести до упередженості моделі. Також, він може бути неоднозначним, бо важко інтерпретувати середні оцінки, наприклад 3.0 – це позитивний чи негативний сигнал. Часто може бути проблема, що відсутній негативний фідбек, тобто немає інформації про товари, які користувач бачиш, але проігнорував чи не купив.

Тому у наукових роботах з використанням рекомендаційних систем, і в цій зокрема, відмовляються від задач прогнозування рейтингу на користь задач прогнозування взаємодії (ranking). Дослідники вважають сам факт залишення відгуку позитивним неявним сигналом (implicit feedback) [97]. Такий підхід є стандартним для сучасних систем, бо вони краще демонструють реальну поведінку [97]. Для цього потрібно трансформувати явні, зміщені рейтинги у більш надійний диференційований неявний сигнал. Проте, не всі неявні взаємодії є однаково цінними. Але не всі взаємодії є однаково цінними, наприклад відгук з 5 зірками та 100 голосами за його корисність має більше інформаційного сигналу, аніж відгук з 3 зірками та 0 голосів.

Для того, щоб врахувати такий гетерогенний сигнал у дослідженні була введена «вага взаємодії». Замість бінарного сигналу, де 1 – взаємодія користувач, а 0 – ні. Кожна взаємодія отримала вагу на основі її корисності, яка розрахована за формулою (2.1):

$$w_{ui} = 1.0 + \log(1 + \text{helpful\_vote}_{ui}), \quad (2.1)$$

де  $w_{ui}$  – фінальна вага взаємодії користувача  $u$  з товаром  $i$ ;

$\text{helpful\_vote}_{ui}$  – кількість голосів «корисності» для цього відгуку.

Всі взаємодії, тобто відгуки, навіть, якщо не мають жодного голосу про корисність, отримують мінімальну вагу 1.0, це означає, що жодна взаємодія не буде проігнорована. Використання логарифму є дуже важливим, оскільки, різниця між 0 та 10 голосами є суттєвою і сильно збільшить вагу, але різниця між 100 та 110 є менш значущою. Тому логарифм стискає ці великі значення, і не допускає, щоб такі поодинокі, надзвичайно популярні відгуки домінувати у функцій втрат моделі.

Далі, ці зважені ембединги були агреговані для створення фінальних профілів. Для кожного товару, був розрахований вектор (`item_embeddings_bert_weighted`) як зважене середнє ембедингів усіх відгуків, залишених для нього в `train`. Такий вектор, показує колективну думку користувачів про товар, а не його статичний опис. Аналогічним способом було обраховано вектори для кожного користувачі (`user_embeddings_bert_weighted`) як зважене середнє ембедингів усіх відгуків, які цей користувач написав, що фактично створює його унікальний «семантичний відбиток».

Наступним етапом є побудова моделей, або як його ще називають етап «генерації кандидатів» (`candidate generation`) або «пошуку» (`retrieval`). Він є першим і, мабуть, найважливішим кроком у сучасній двоступеневій архітектурі рекомендаційних систем [98]. Метою даного етапу є швидко знайти та відібрати з усього каталогу товарів невелику кількість найбільш релевантних кандидатів для користувача. Потім ці кандидати передаються на другий етап – реранкінгу, який шукатиме правильний порядок розміщення цих товарів. Складність моделі повинна корелювати з її якістю, в інакшому випадку вся додана обчислювальна складність буде невиправданою. [99].

Для початку варто встановити «точку відліку». У даному дослідженні `Popularity Baseline` є найпростішим, але водночас найважливішим бейзлайном. Його метою є перевірка ефективності найпростішого припущення про те, щоб рекомендувати всім користувачів однакові найбільш популярні товари. Логіка

роботи цього методу є неперсоналізованою і базується на простому підрахунку частоти взаємодій, програмний код наведений у додатку Б. Логіка її роботи полягає у тому, що спочатку для кожного товару підраховуються загальна кількість відгуків, на основі чого формується єдиний великий відсортований список від найпопулярнішого до найменш популярного товару. При запиті рекомендацій для будь-якого користувача, модель повертає Топ-К товарів з цього списку, виключаючи ті, з якими користувач вже взаємодіяв.

Процес оцінки цієї моделі відбувався на тестовій вибірці. Де для кожного користувача з тестового датасету, який мав історію взаємодій в навчальній вибірці, модель надавала список рекомендацій. Цей список був сформований виключенням товарів, який користувач бачив на навчанні, з глобального списку рекомендацій. Згенерований список довжиною у Топ-К потім порівнювався зі списком «правдивих» взаємодій користувача з тестового набору даних. На базі такого порівняння і були розраховані всі метрики.

Наступними моделями є класичні персоналізовані моделі k-Nearest Neighbors (k-NN) або k-найближчих сусідів, вони є фундаментальним підходом до колаборативної фільтрації. У даному дослідженні класична взаємодія була модифікована, оскільки замість використання розріджених взаємодій, схожість обчислювалась на основі щільних векторів, отриманих із SBERT. Інтерпретованість, тобто здатність пояснити рекомендації та можливість вловлювати семантичну схожість, є перевагами такого методу. Також, важливо сказати, що такий підхід не вирішує проблему «холодного старту», бо для створення ембедингу потрібно хоча б один відгук, на відміну від використання метаданих товарів. Було використано два варіанти моделей: Item-kNN та User-kNN.

Item-kNN (Item-based k-NN) ґрунтується на думці, що користувачах, яким сподобався товар А, також сподобається товар Б, бо він схожий на А, цей підхід був детально описаний у роботі [100]. Для фільтрації десятків тисяч товарів, BERT-вектори усіх товарів завантажуються в індекс FAISS. FAISS – це бібліотека, що дозволяє миттєво знаходити найближчих сусідів у багатовимірному просторі, навіть для мільярдів векторів [101]. Для генерації рекомендацій, для кожного товару

з історії користувача, FAISS знаходить певну кількість найближчих сусідів, тобто найбільш схожих товарів. Далі усіх знайдених сусідів збираються в один список, ранжуються за частотою їх появи, фільтруються ті, що користувач ще не бачив, і видаються Топ-К рекомендацій (див. Додаток Б).

User-kNN (User-based k-NN), маю іншу логіку, що для користувача А варто рекомендувати те, що сподобалось користувачу Б, бо у них схожі смаки – цей підхід є одним з перших у колаборативній фільтрації [102]. З технічної сторони процес дуже схожий, у FAISS-індекс завантажуються усереднені BERT-вектори користувачів, далі для цільового користувача  $u$  знаходиться  $K$  найбільш схожих користувачів (сусідів), тоді система агрегує всі товари з історій цих сусідів, ранжує їх за частотою і видає Топ-К. Основою для обчислення схожості в обох випадках є косинусна схожість. Оцінка обох моделей k-NN моделей проводилася за тією ж загальною методологією, що й Popularity baseline, з використанням тестових користувачів та даних про вже відомі взаємодії, але рекомендації були персоналізованими. Для Item-kNN, модель брала BERT-вектори для кожного користувача, шукала 50 схожих товарів для кожного товару з історії. Потім ці сусідів агрегувались і отримувалася фінальний відсортований за частотою появи кандидатів, який порівнювався з відомими взаємодіями. Для User-kNN – для кожного користувача, модель брала його власний BERT-вектор, шукала схожі користувачі, агрегувала їхні історії покупок, і цей новий, відсортований за популярністю серед сусідів, список порівнювався з реальними взаємодіями. На основі цього і були розраховані метрики.

Наступною була використана модель, яка використовує латентні фактори. Найвідомішим представником таких моделей є матрична факторизація. Схематичний процес роботи матричної факторизації наведено на рис. 1.3. На відміну від k-NN, які шукали сусідів, матрична факторизація намагається пояснити всю матрицю взаємодій «користувач-товар» (User-Item matrix) через набір прихованих (латентних) ознак. Основна ідея в тому, що смаки користувачів і характеристика товарів можна представити у спільному низькорозмірному

векторному просторі. І рекомендації створюються обчислення того, наскільки вектор користувача близький до вектора товару у такому латентному просторі [60].

У даному дослідженні була використана ALS (Alternating Least Squares), яка спеціалізується на роботі з неявними даними (implicit feedback), це детальніше описано у роботі [97]. Рішення про використання таких методів було прийнято, бо підготовлений набір складається не з явних рейтингів, а зі зважених неявних взаємодій.

Модель розкладає велику розріджену матрицю взаємодій  $R$  (де  $N$  – користувачі,  $M$  – товари) на дві менші, але щільні матриці: матрицю факторів користувачів  $U$  ( $N \times D$ ) та матрицю факторів товарів  $V$  ( $M \times D$ ), де  $D$  – кількість латентних факторів. На вхід моделі подається одна розріджена матриця, де рядками є `item_id`, стовпцями – `user_id`, а значеннями – розраховані ваги  $w_{ui}$ . (див. формулу (2.1)). Для цієї моделі був виконаний підбір гіперпараметрів, замість ручного підбору, використано бібліотеку Optuna [103]. Optuna – це фреймворк, що автоматично та ефективно може знайти оптимальну комбінацію гіперпараметрів, максимізуючи чи мінімізуючи цільову функцію. Цей метод працює циклічно, на кожній ітерації створюється нова версія моделі з певним набором налаштувань, яка навчалась на тренувальному наборі 15 епох. Після навчання якість моделі перевіряється на валідаційній вибірці за допомогою метрики точності  $NDCG@10$ , тобто Optuna допомагає знайти таку комбінацію гіперпараметрів, яка дасть найвищий показник точності. Тюнігувались кілька параметрів, перший – розмір латентного простору, то те скільки прихованих ознак вивчає модель: 32, 64, 128 чи 256. Та коефіцієнт регуляризації, щоб запобігти перенавчанню з діапазону від 0.001 до 1. Було проведено 15 ітерацій, найвищу точність дали параметри 64 та 0.9815 відповідно. На найкращих параметрах була навчена модель протягом 15 епох на повній тренувальній матриці, де для кожного `user_id` викликався метод `.recommend()`, який повертав Топ-К індексів товарів. Ці індекси перетворювались назад у ID товару за допомогою словника і порівнювались із справжніми взаємодіями.

Наступною була використана модель LightFM, яка згадується в статті [104], вона є гібридною моделлю, яка поєднує в собі як колаборативну інформацію (хто з чим взаємодівав), так і контентні ознаки (атрибути користувачів та товарів). Її було використано у цьому дослідженні, щоб перевірити чи додавання контентних ознак покращить якість рекомендацій. Дана модель ґрунтується на ті ж ідеї матричної факторизації, де користувачі та товари знаходяться у спільному латентному просторі, але з доповненням, що фінальний латентний вектор товару є сумою вектора самого ID товару та латентних векторів його ознак, тобто модель навчається не лише на відгуках про товари, а й на контенті [104]. Для цієї моделі замість класичних logistic або bpr функцій втрат була використана  $\text{loss} = \text{'warp'}$ . WARP (Weighted Approximate-Rank Pairwise) – це просунутий алгоритм, який створений спеціально для неявних даних та оптимізації під списки рекомендацій (Top-K) [105]. Щоб не порівнювати кожен позитивну взаємодію з тисячами негативних, WARP бере позитивну пару (користувач  $u$ , товар  $i$ ), випадково вибирає негативний товар  $j$ , який  $u$  не бачив, і, якщо модель неправильно ранжує ( $j$  вище за  $i$ ), вона робить крок градієнтного спуску, щоб виправити цю конкретну помилку [105]. Цей підхід допомагає моделі фокусуватися на найбільш складних прикладах у верхній частині списку, що має добре впливати на метрику точності – NDCG@10.

Модель LightFM використовує метод `.fit()` для навчання, який дає більше можливостей для додавання контентних фічів. У даному дослідженні реалізований досить складний гібридний підхід для створення матриці ознак, тобто була створена одна розріджена матриця, яка поєднує два типи інформації. Перша – це семантичні ознаки BERT, які представляють собою 384-вимірні вектори, вони були перетворені у першу розріджену матрицю, та друга – 11 категоріальних ознак, таких як категорія, магазин, бренд тощо. Вони були витягнуті із даних та перетворені за допомогою OneHotEncoder у другу розріджену матрицю. Тобто фінальна матриця, яка була подана у модель, створена горизонтальним об'єднанням двох вищезазначених матриць. Тобто, модель навчалась не лише на колективному сприйнятті товару (ембединги відгуків), а і на конкретних атрибутах.

Цю модель, також, було протюнінговано за допомогою Optuna, логіка цього процесу така ж як було описано для ALS моделі, але з декількома змінами, було виконано 5 спроб тюнінгу по 5 епох в кожній, та оцінювалось на 100 користувачах для максимізації метрики NDCG@10. Така мала кількість спроб та епох було вимушеним рішенням, через значні обчислювальні обмеження, а саме через нестачу оперативної пам'яті у середовищі. Експерименти з 10-30 спроб та 10 і більше епох призводили до помилок, тому такі значення були компромісними для того, щоб провести експеримент до кінця з використанням наявних ресурсів. Але фінальна модель була навчена на 15 епохах, це дозволило моделі більш глибоко вивчити закономірності в даних.

Процес оцінки відбувався наступним чином: для кожного користувача `user_id` з тестового набору був реалізований спеціальний цикл. Метод `lightfm_model.predict()` викликався з масивом ID користувача, повтореним  $N$  разів (де  $N$  – загальна кількість товарів), та повним списком ID всіх товарів. Далі отриманий масив балів сортувався, ключова логіка була реалізована по цих відсортованих індексах, перевірялось чи містить товар у множині вже бачених товарів з трейнового набору даних. Лише, ті що пройшли перевірку додавались до фінального списку рекомендацій, допоки не було отримано Топ- $K$ . Отримані списки порівнювались з реальними взаємодіями для розрахунку метрик.

Наступним кроком стало впровадження більш сучасних підходів у галузі глибокого навчання (Deep Learning). Було використано двовежеву модель (Two-Tower Model), яка є стандартною архітектурою для задач великомасштабного пошуку, популяризованою такими компаніями, як Google (YouTube) [106]. Логіка двовежевої моделі відрізняється від, наприклад, LightFM, яка використовувала BERT-ембединги як статичні ознаки, ця модель навчається перетворювати або, інакше кажучи, проектувати ці ембединги у новий, оптимізований латентний простір призначений саме для задачі рекомендацій. Модель навчає дві окремі нейронні мережі, умовні «вежі», для генерації латентних векторів для користувачів та товарів відповідно. Ці вектори генеруються у спільному латентному просторі, де

скалярний добуток (косинусна схожість) між вектором користувача та вектором товару безпосередньо відповідає ймовірності їхньої взаємодії.

У дослідженні була реалізована не стандартна, і гібридна та асиметрична двовежева модель, особливість полягає у складнішій підготовці ознак для «вежі» товару. Для представлення одного товару використовувались 3 джерел даних: перше – це базові 384-вимірні BERT вектори, що являють собою усереднені ембединги відгуків про товари, друге – набір 11 категоріальних ознак, таких як бренд, категорія, колір, розмір, матеріал і т.д., де кожна ознака була перетворена на індекси і отримала власний шар `nn.Embedding`, і третє – числова ознака – логарифм ціни. Аналіз даних моделлю також відрізнявся від простих пар «користувач - товар», була створена функція, яка реалізувала послідовний підхід. Використовувалась історія взаємодій у форматі «контекст – позитивний приклад», для кожної взаємодії «контекстом» виступали до 30 товарів, що передували їй, а «позитивним прикладом» був сам товар, з яким взаємодіяли.

Як вже згадувалось раніше архітектура моделі дещо асиметрична. «Вежа» користувача (`UserTower`) є відносно простою: вона приймає на вхід послідовність 384-вимірних BERT-ембедингів усереднених відгуків, далі застосовується певний механізм усереднення для обчислення єдиного усередненого вектора, що репрезентує інтереси користувача. Цей вектор пропускається через багат шарову нейронну мережу для проекції у фінальних латентний простір та L2-нормалізується. «Вежа» товару (`ItemTower`) є складнішою та приймає три типи даних, які були описані раніше. Категоріальні індекси пропускаються через відповідні `nn.Embedding` шари, і отримані вектори сумуються в один. Оброблена ціна, сума категоріальних векторів та BERT-вектор об'єднуються в один довгий гібридний вектор. Цей комбінований вектор пропускається через шари нейронної мережі та L2-нормалізується і проектується у той самий фінальний простір.

Для навчання моделі було використано використовувався механізм контрастивного навчання (`contrastive learning`) на основі функції втрат `InfoNCELoss` [108]. Модель обчислює матрицю схожості  $N * N$ , для батчу з  $N$  пар «користувач-товар». Використано функцію втрат `nn.CrossEntropyLoss`, яка змушує модель

максимізувати значення на діагоналі, де правильні пари «користувач-товар» і мінімізувати всі інші  $N-1$  значень у рядку, які виступають як «негативні семпли». Для цього є гіперпараметр *temperature*, який контролює «гостроту» такого розрізнення. Для цієї моделі, також, було проведено тюнінг параметрів, 15 спробами по 15 епох. Як результат було отримано найкращі параметри, а саме розмірність фінального простору = 128, розмірність для категорій=16, швидкість навчання = 0.00015, розмір батчу = 128, *temperature* = 0.09. Фінальна модель була навчена на цих найкращих гіперпараметрах протягом 15 епох.

Оцінка моделі відбувалась у два етапи, де спочатку «вежа» товару використовувалась для генерації фінальних 128-вимірних векторів для всіх 60 тис. товарів у каталозі, з всіма гібридними ознаками. Далі ці вектори для кожного користувача з тестового датасету навчена «вежа» користувача генерувала його персональний 128-вимірний вектор на основі історії взаємодій з трейну, цей вектор використовувався для пошуку у FAISS-індексі, щоб отримати Топ-К кандидатів, потім фільтрувався та оцінювався.

Останньою моделлю для генерації кандидатів стала SASRec модель (Self-Attentive Sequential Recommendation). Ця модель належить до класу послідовних або сіквенсних моделей. Вона вловлює динаміку вподобань користувача, враховуючи його точний порядок взаємодій [73]. Основою цього підходу є твердження про те, що наступна дія користувача сильно залежить від його кількох останніх дій [73]. По суті, модель використовує механізм Self-Attention з моделі Transformer для створення персональних рекомендацій. Варто зазначити, що ця модель є «чистою» ID-моделлю, оскільки вона не використовує попередньо навчені BERT-ембединги чи інші створені контентні ознаки. Ця модель навчає власні ембединги для кожного товару з нуля, враховуючи лише послідовність взаємодій. Процес підготовки даних використовував метод ковзного вікна (sliding window), а не статичні пари «користувач-товар» [108]. Тобто для кожної історії взаємодій користувача довжиною  $N$ , було згенеровано  $N-1$  тренувальних прикладів. Кожен приклад складався з  $i$ -того товару у послідовності та 50 товарів що передували йому, як наслідок модель навчалась прогнозувати товар  $B$  на основі  $A$ , потім  $C$  на основі

А і Б і т.д. Архітектура SASRecModel є прямою реалізацією Transformer Encoder і складається з двох ключових шарів ембедингів, перші – ембединги по товарах та ембединги позиції, для врахування порядку. Тобто, на виході отримуємо суму ембедингів та їхніх позицій. Цей комбінований вектор пропускається через шари трансформера, який за допомогою механізму self-attention «зважує» важливість кожного попереднього товару для розуміння поточного контексту.

Логіка прогнозування така: отримуючи вектор від трансформера модель бере лише вектор, що відповідає останньому товару у кожній послідовності. Цей вектор, що назбирав весь релевантний історичний контекст множиться на всю матрицю ваг. В результаті, отримано бали розмірністю батч на номер товару, тобто прогноз схожості користувача з кожним товаром у каталозі. Навчання відбувається шляхом оптимізації `nn.CrossEntropyLoss`, що змушує модель максимізувати бал для цільової метрики.

Для цієї моделі також був проведений тюнінг гіперпараметрів за допомогою Optuna, де реалізовано 15 спроб по 15 епох. Найкращою комбінацією параметрів є: розмірність ембедингу = 64, кількість шарів = 3, кількість голів уваги = 2, `dropout` = 0.243, швидкість навчання = 0.0001, та розмір батчу = 128. Фінальна модель була навчена на цих параметрах протягом 15 епох.

Оцінка моделі базується на логіці ретроспективного тестування. Для кожного тестового користувача, як вхідні дані, тобто контекст бралась його повна історія взаємодій з трейну. Цей підхід моделює ситуацію, щоб відповісти на запитання: «Що найімовірніше купить користувач, якщо подивитись на всю історію його взаємодій?», а отже ця вся історія для кожного юзера перетворювалась на вхідних тензор і модель генерувала бали для всіх товарів. З цих балів виключено індекси які користувач вже бачив раніше. Згенеровані Топ-К потім порівнюються реальними даними про взаємодії користувача з товарами.

Переходимо до другого етапу – «Реранкінгу» (Reranking), оскільки всі попередні моделі відносились до першого етапу «Генерації кандидатів» (Retrieval), де потрібно було з усього каталогу відібрати невеликий список релевантних товарів. Етап «Реранкінгу» є класичним підходом у сучасних двоступеневих

рекомендаційних системах [109]. Він не шукає кандидатів, а сортує їх. Реранкер бере відносно невеликий пул кандидатів, який згенерований на першому етапі, і використовуючи широкий набір ознак, пересортовує список, щоб надати фінальний, максимально релевантний список товарів для користувача.

У даному дослідженні для задачі реранкінгу була обрана модель LightGBM (Light Gradient Boosting Machine) [110]. LightGBM є однією з найбільш ефективних впроваджень градієнтного бустингу на деревах рішень (GBDT) [110]. Варто зазначити, що ця модель була використана, не як класифікатор, який би прогнозував 1 чи 0, а в режимі Learning to Rank (LTR) з цільовою функцією `lambdarank`, цей підхід також відомий як LambdaMART [111]. Перевагою такого методу є те, що він оптимізує порядок усього списку кандидатів, максимізуючи метрики ранжування, як наприклад NDCG.

Перед навчання потрібно сформувати набір даних для реранкера. Як джерело кандидатів, було взято 2 найкращі моделі на основі їхнього `NDCG@10`. З кожного джерела було взято до 100 кандидатів. Ці списки отримані від різних моделей були об'єднані в один загальний пул, де товари були впорядковані відповідно до їхніх початкових рангів, а дублікати – видалені. Щоб отримати 200 унікальних кандидатів на користувача.

Мабуть, головним етапом став інжиніринг ознак, який показує силу реранкера. Він може «дивитись» на пару «користувач-товар» з багатьох різних ракурсів. Для цього було згенеровано багато ознак, куди увійшли базові сигнали ретривалу, бали та ранги від моделей генераторів, ознаки популярності, наприклад популярність товару, середній рейтинг і т.д. Також, сюди були додані семантичні ознаки, а саме косинусна схожість між 384-вимірним BERT-вектором користувача (що репрезентує його стиль письма) та 384-вимірним BERT-вектором товару (що репрезентує усереднені відгуки про товар). І контентні ознаки: логарифм ціни, категорія, виробник, магазин, смак, колір, матеріал, розмір бренд тощо. Всі ці ознаки допоможуть моделі знайти складні нелінійні залежності.

Для `lambdarank` важливо вказувати групи, тобто списки, що показують, скільки кандидатів, у цьому дослідженні 200, належать кожному користувачі, щоб

модель оптимізувала порядок в середині цих груп. Для цієї моделі також був виконаний тюнінг Optuna для 15 спроб. Фінальна модель була навчена з використанням найкращих гіперпараметрів протягом 500 ітерацій з механізмом ранньої зупинки. Після навчання модель використано для прогнозування балів тестового набору даних, тобто для кожного користувача його 200 кандидатів були відсортовані за новим балом ранкера, які й були використані для розрахунку метрик.

На рис. 2.3 наведена блок-схема реалізованих моделей.




Рисунок 2.3 – Алгоритм розробки рекомендаційних систем

Джерело: розроблено автором на основі [75-111]

## 2.3 Метрики оцінювання ефективності та релевантності товарних рекомендацій

Оцінка рекомендаційних систем сильно відрізняється від задач класичного машинного навчання, таких як регресії чи класифікація. У даному дослідженні, як вже описано раніше, проведено роботу з неявними даними (implicit feedback), тобто фактами взаємодії (відгуками), а не явними числовими оцінками. Як було обґрунтовано раніше в п.п. 2.1-2.2, явні рейтинги є досить неоднозначними та зміщеними. Тому робота побудована на задачі ранжування, а не прогнозу рейтингу. І тому ми такі похибки, як RMSE чи MAE є непридатними для такої задачі, бо ці метрики вимірюють те, наскільки близьке прогнозоване число знаходиться до реального [112]. Оскільки у роботі немає прогнозування числових значень, а наявне створення оптимального списку Топ-К товарів, які користувач найбільш ймовірно придбає, то варто використовувати інший клас метрик, а саме метрики ранжування. Ці метрики не оцінюють індивідуальні прогнози, а якість згенерованого списку рекомендацій у порівнянні з «ідеальним» список, з яким користувач реально взаємодівав у тестовому періоді.

Було використано комплексний набір метрик, які можна розділити на дві основні групи:

1. Метрики точності – оцінюють наскільки релевантними є товари, що рекомендуються, це такі метрики: Precision@k, Recall@k, MAP@k, MRR та NDCG@k.
2. Метрики поза точністю – оцінюють якісні аспекти списку, а саме новизну, можливість покривати каталог та різноманітність, які у виводах вказані як Coverage@k, AvgNoveltyRank@k, AvgDiversity@k відповідно.

Використання обох груп метрик є дуже важливим, як зазначено в роботі [113], що надмірна оптимізація лише точності може призвести до створення «нудних» систем та тих, що не будуть приносити ніякої користі, бо

рекомендуватимуть лише хіти та бестселери. Тому ці метрики є основою для порівняння ефективності використаних алгоритмів для моделювання.

Precision@k (Точність@k) є найпростішою метрикою і відповідає на питання: «Яка частка рекомендованих товарів у списку Топ-К є релевантною?». Вона аналізує лише сам згенерований список, незважаючи на те, скільки тих релевантних товарів насправді існувало (формула 3.2) [114]:

$$\text{Precision@k} = \frac{|R_u \cap T_u|}{k} = \frac{\text{Кількість релевантних у Топ-}k}{\text{Загальна } k\text{-сть рекомендованих товарів у Топ-}k}, \quad (3.2)$$

де  $k$  – позначає розмір списку рекомендацій;

$R_u$  – це множина рекомендованих товарів для користувача  $u$ ;

$T_u$  – це множина релевантних товарів користувача  $u$ .

Recall@k (Повнота@k) дає відповідь на протилежне питання: «Яка частка всіх релевантних товарів знайдемо у списку Топ-К рекомендацій?». Ця метрика є дуже важливою на етапі генерації кандидатів, для того, щоб не пропустити релевантні товари (формула 3.3) [114]:

$$\text{Recall@k} = \frac{|R_u \cap T_u|}{|T_u|} = \frac{\text{Кількість релевантних у Топ-}k}{\text{Загальна кількість релевантних}}, \quad (3.3)$$

де  $k$  – позначає розмір списку рекомендацій;

$R_u$  – це множина рекомендованих товарів для користувача  $u$ ;

$T_u$  – це множина релевантних товарів користувача  $u$ .

Ці метрики є простими та інтуїтивно зрозумілими, але вони мають один важливий недолік, оскільки повністю ігнорують порядок рекомендацій. Тобто, цим метриками немає різниці чи релевантний товар на 1-й чи на 10-й позиції, вони матимуть однакову вагу. Тому, було вирішено використовувати й інші метрики.

Наступною використаною метрикою є середня точність (Average Precision, AP@k – це перша метрика, що враховує порядок, вона винагороджує модель за розміщення релевантних товарів у списку на вищих позиціях. AP@k обчислюється як середнє значення Precision@i для кожної позиції  $i$ , де був знайдений релевантний товар. І відповідно Mean Average Precision (MAP@k) є усередненням AP@k по всіх користувачах.

Ще однією метрикою є Середній зворотний ранг (Mean Reciprocal Rank, MRR) – ця метрика, також, враховує порядок, але трішки з іншою метою ніж

MAP@k. Вона зосереджена виключно на першому знайденому релевантному товарі. Тобто, вона може розповісти про те, наскільки високо у списку є перший потрібний товар. Це важливо, коли користувач шукає якусь один конкретний товар, метрика розраховується за формулою (3.4) [115]:

$$\text{MRR} = \frac{1}{|U|} \sum_{u \in U} \frac{1}{\text{rank}_{u,1}}, \quad (3.4)$$

де  $|U|$  – кількість користувачів в загальному;

$\text{rank}_{u,1}$  – це ранг, або позиція першого релевантного товару для користувача  $u$ , за умови якщо жодного релевантного товару у списку не знайшлося, то ранг вважається нескінченним і значення дорівнюватиме 0.

Однією з найважливіших та найчутливіший до порядку використаних метрик є Нормалізований дисконтований накопичений виграш (Normalized Discounted Cumulative Gain, NDCG), саме ця метрика використовувалась як цільова функція для тюнінгу гіперпараметрів в моделях ретривалу. Однією із її переваг є те, що вона не просто враховує порядок, як, наприклад, попередня метрика, а штрафує за кожну позицію логарифмічно, тобто важливість між 1-ю та 2-ю позицією значно більша, ніж, наприклад, між 10-ю та 11-ю. Розрахунок даної метрики складається з трьох частин, спочатку розраховується сума релевантностей або Cumulative Gain (CG), у даній роботі релевантність бінарна (1, якщо товар на позиції  $i$  релевантний, 0 – якщо ні), то це значення буде збігатись з кількістю релевантних товарів у Топ-К. Наступним обчислюється Discounted Cumulative Gain (DCG), де сума релевантностей ділиться на логарифмічний штраф за позицію, у даній роботі використано  $\log_2(i+2)$ . Останнім кроком є розрахунок Normalized DCG (NDCG), де отриманий DCG ділиться на «ідеальний» DCG (IDCG) – це максимально можливий бал, який можна було отримати, коли б всі релевантні товари стояли на перших позиціях, тобто формула 3.5 для цих обчислень виглядає наступним чином [116]:

$$\text{NDCG}@k = \frac{\text{DCG}@k}{\text{IDCG}@k}, \quad (3.5)$$

Така формула дає нормалізовану оцінку від 0 до 1 – це дозволяє порівнювати якість ранжування для користувачів з різною кількістю релевантних товарів [116].

Першою з метрик якості, є Покриття ( $Coverage@k$ ), вона вимірює, яку частку від усього каталогу товарів модель здатна порекомендувати. Низьке покриття, як, наприклад, у Popularity baseline показує, що модель постійно рекомендує невеликий набір одним і тих же товарів, ігноруючи «довгий хвіст» каталогу. Вона розраховується як кількість унікальних товарів, що потрапили у Топ-К всіх тестових користувачів, поділена на загальну кількість унікальних товарів у навчальній вибірці [117].

Іншою якісною метрикою є Новизна ( $AvgNoveltyRank@k$ ), вона оцінює те, наскільки рекомендовані товари є неочікуваними чи нішевими для користувача [118]. Пряме вимірювання новизни є досить складним, тому в дослідженні використовується поширений проксі-метод такий, як середній ранг популярності. Для цього спочатку обчислюється глобальний рейтинг популярності всіх товарів, де нульовий ранг означає найпопулярніший товар [118]. А потім, для кожного користувача розраховується середній ранг популярності його Топ-К рекомендованих товарів [118]. У такому розрахунку вища оцінка є кращою, оскільки вона означає, що модель в середньому рекомендує менш популярні, тобто більш «нові» товари.

І останньою метрикою, яка була використана у роботі є Різноманітність ( $AvgDiversity@k$ ) [119]. Вона вимірює наскільки товари в середині одного списку рекомендацій схожі між собою. Бажаною є висока різноманітність, бо вона пропонує користувачу ширший вибір [119]. У роботі ця метрика реалізована через косинусну відстань у семантичному просторі BERT, тобто для списку з 10 рекомендацій, беруться їхні 10 відповідних векторів, далі розраховується матриця попарної косинусної схожості. В загальному, різноманітність – це середня відстань (схожість) між усіма унікальними парами товарів у списку.

## РОЗДІЛ 3

### ПРАКТИЧНЕ ЗАСТОСУВАННЯ МОДЕЛЕЙ ФОРМУВАННЯ РЕКОМЕНДАЦІЙ ДЛЯ ТОВАРНОГО СЕГМЕНТУ КОСМЕТИЧНИХ ЗАСОБІВ

#### 3.1 Побудова розподілів та аналіз залежностей на даних про взаємодію користувачів з товарами

Першим етапом практичної частини стала побудова розподілів та аналіз залежностей у даних. Він використовувався для того, що виявити закономірності в даних, розподіли, викиди тощо. Тобто знайти те, що може впливати на вибір методів обробки даних та вибір моделей рекомендаційних систем. Аналіз проводився на двох наборах даних з таблиці взаємодій та метаданих товарів, описаних в п.п. 2.1, що містить 494121 запис відгуків та 60293 унікальні продукти. Для початку варто розглянути статистику для числових змінних, які наведено у таблиці 3.1.

Таблиця 3.1 – Статистичний аналіз змінних

|              | rating    | helpful_vote | length_review_text | average_rating | rating_number | price    |
|--------------|-----------|--------------|--------------------|----------------|---------------|----------|
| <b>count</b> | 494121,00 | 494121,00    | 494121,00          | 60293,00       | 60293,00      | 10536,00 |
| <b>mean</b>  | 4,00      | 1,13         | 188,23             | 3,98           | 61,92         | 43,74    |
| <b>std</b>   | 1,48      | 15,44        | 284,93             | 0,85           | 479,55        | 168,44   |
| <b>min</b>   | 1,00      | 0,00         | 0,00               | 1,00           | 1,00          | 0,10     |
| <b>25%</b>   | 3,00      | 0,00         | 45,00              | 3,50           | 3,00          | 11,99    |
| <b>50%</b>   | 5,00      | 0,00         | 107,00             | 4,10           | 10,00         | 19,99    |
| <b>75%</b>   | 5,00      | 1,00         | 225,00             | 4,60           | 32,00         | 36,09    |
| <b>max</b>   | 5,00      | 7326,00      | 19956,00           | 5,00           | 60033,00      | 4449,00  |

*Джерело: розроблено автором за даними [92]*

З таблиці 3.1 стає відомо, що середній рейтинг становить 4. із стандартним відхиленням 1,48, при цьому медіана та 75-й перцентиль дорівнює 5,0, тобто максимуму. Це вказує на характерну для електронної комерції зміщеність у бік позитивних оцінок. Така асиметрія розподілу, ускладнює використання явних рейтингів для різних товарів, бо більшість з них мають високі оцінки, що і

підтверджується середнім середнє `average_rating` 3,98, медіана 4,10). Показники активності користувачів показують наявність «довгого хвоста». Медіана корисності відгуків (`helpful_vote`) дорівнює 0, але середнє – 1,13, а максимум – 7326, це вказує на наявність малої кількості дуже впливових відгуків на фоні загальної «мовчазної» маси оцінок. Така ж ситуація і з ціною, при медіанній вартості товару 19,99, середнє більше вдвічі 43,74, бо є дуже дорогі товари до 4449, і також дані про ціни доступна лише для 17% товарів від загальної кількості, тобто ознака дуже розріджена і вимагатиме очищення перед використанням у моделях. Щодо аналізу текстових відгуків (`text_length`), то середня довжина становить 188,23, а медіана 107, тобто присутня правостороння асиметрія розподілу. Хоча є дуже детальні відгуки до 19956 символів, все ж більшість відгуків є досить лаконічними. Також, мінімальна довжина 0, показує що є порожні або некоректні відгуки.

Візуалізація розподілу оцінок (рис. 3.1), також, показує асиметрію в сторону високих балів. Найчастіше товарам ставлять 5 або 1 зірку, від 2 до 4 зірок користувачі ставлять найрідше. Такий розподіл є очікуваним для даних електронної комерції, але створює дисбаланс класів, що робить недоцільним використання класичних методів регресії.




Рисунок 3.1 – Розподіл рейтингів у відгуках

*Джерело: розроблено автором за даними [92]*

З рис. 3.2 видно, що зростання активності користувачі з 2010 року, з максимальним значенням у 2020 році, більше 75000 відгуків, це може вказувати на підвищений попит на товари з категорії «Health and Personal Care» під час пандемії

COVID-19. Після 2020 спостерігається досить різке зниження попиту на товари цієї категорії, можливо через зміни у поведінці користувачів чи вплив зовнішніх факторів, наприклад тієї ж пандемії, чи перенасиченням ринку тощо.




Рисунок 3.2 – Динаміка кількості відгуків за 2001-2023 роки

Джерело: розроблено автором за даними [92]

Найактивніші користувачі з рис. 3.3 залишають 50-120 відгуків, хоча їхні відгуки можуть бути корисними, це може створити певний ризик упередженості, особливо для простіших моделей, які можуть надмірно фокусуватись на смак активної меншості, викривляючи рекомендації для інших користувачів.




Рисунок 3.3 – Топ-10 користувачів за кількістю відгуків

Джерело: розроблено автором за даними [92]

Наступний рис. 3.4 демонструє топ-10 товарів з категорії «Health and Personal Care», лідером є «ASUTRA Yoga Mat Cleaner», для якого наявно більше

3000 відгуків, другий та третій товари: «GermGuardian» та «US Organic». Розподіл між лідерами є відносно рівномірним. Для рекомендаційних моделей, ці товари є важливими, бо можуть вирішити проблему «холодного старту», хоча їх використання варто балансувати, щоб уникнути зміщення рекомендацій лише в бік популярних товарів. Табличне представлення товарів-хітів наведено у таблиці В.1 (Додаток В).




Рисунок 3.4 – Топ-10 товарів за кількістю відгуків

Джерело: розроблено автором за даними [92]

На рис. 3.5, піки на початку свідчать про те, що більшість відгуків має нульову або мінімальну кількість голосів корисності і лише невелика кількість відгуків набрала значно більше ніж один голос.




Рисунок 3.5 – Логарифмічний розподіл «корисності голосів» для відгуків

Джерело: розроблено автором за даними [92]

Аналіз залежності між рейтингом на логарифмованою корисністю на рис. 3.6, виявив відсутність прямої кореляції між емоційною оцінкою товару (зірками)

та цінністю відгуків про нього, на це вказує ідентична структура розподілів у всіх категоріях з медіанами наближеними до нуля. Візуалізація зв'язку та довжини відгуку наведено у додатку Д.




Рисунок 3.6 – Зв'язок рейтингу товарів та «корисності» відгуків

Джерело: розроблено автором за даними [92]

Рис. 3.7 демонструє гістограму розподілу цін товарів, логарифмування нівелює вплив викидів і дозволяє оцінити реальну структуру розподілу. Пік на рівні 3, що відповідає ціні приблизно \$20, чітко показує домінування бюджетного сегменту в цій категорії, незважаючи на загальний широкий діапазон цін.




Рисунок 3.7 – Розподіл цін товарів

Джерело: розроблено автором за даними [92]

На рис. 3.8 наведена кореляційна матриця, яка показала відсутність лінійного зв'язку, тобто мультиколінеарності між основними характеристиками товарів. Наявний лише слабкий зв'язок на рівні 0,10 між довжиною відгуку та його корисністю, тобто розгорнуті відгуки дещо частіше оцінюються як корисні.




Рисунок 3.8 – Кореляційна матриця числових ознак товарів

*Джерело: розроблено автором за даними [92]*

Отже, можна зробити висновок, що наявна типова для електронної комерції структура даних: значна розрідженість, «довгий хвіст» та зміщення рейтингів. Відсутність кореляції показує недостатність простих методів, це підтверджує доцільність використання складніших архітектур для виявлення прихованих патернів поведінки.

### 3.2 Результати практичної реалізації моделей формування рекомендацій для товарів сегменту «Health and Personal Care»

Відповідно до методики часового розподілу, описаної у розділі 2, загальний масив даних було розділено на 3 вибірки. Навчальна (Train) сформована з 395297 найстаріших взаємодій. Валідаційна (Val) та тестова (Test) вибірки отримали по 49412 записів кожна, що відповідають новішим подіям у часі.

Для того, що підвищити стійкість моделей до шуму було виконане зважування відгуків, тобто перетворення взаємодій у неперервні величини, де пріоритет надавався об'єктивній корисності відгуку. У таблиці 3.2 наведено приклад даних, де представлені результати розрахунку ваги взаємодій та основі логарифмічної формули на основі «корисності» відгуків.

Таблиця 3.2 – Приклад розрахунку ваги взаємодій

| № | rating | helpful_vote | interaction_weight |
|---|--------|--------------|--------------------|
| 1 | 3      | 38           | 4,664              |
| 2 | 1      | 58           | 5,078              |
| 3 | 5      | 35           | 4,584              |
| 4 | 4      | 0            | 1,000              |
| 5 | 5      | 27           | 4,332              |

Джерело: розроблено автором за даними [92]

З таблиці 3.2 можна побачити, що негативний відгук із високою корисністю отримує більший пріоритет 5,08, ніж позитивний, але з меншою «корисністю». Відгуки без голосів отримують базову вагу 1. Таке зважування допомагатиме моделі навчатись на найбільш інформативних взаємодіях.

Аналіз ефективності побудованих моделей варто розпочати з оцінки моделі Popularity Baseline результати для якої наведені у таблиці 3.2 та слугують умовним нульовим рівнем для порівняння всіх наступних підходів.

Таблиця 3.3 – Результати моделі Popularity Baseline

| model      | Precisio<br>n@10 | Recall<br>@10 | MAP@<br>10 | NDCG@<br>10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiver<br>sity@10 | Coverage<br>@10 |
|------------|------------------|---------------|------------|-------------|--------|-----------------------|---------------------|-----------------|
| Popularity | 0,0021           | 0,0189        | 0,0048     | 0,0082      | 0,0057 | 5,5260                | 0,5194              | 0,0002          |

Джерело: розроблено автором за даними [92]

Як видно з таблиці 3.2, неперсоналізована стратегія, показує відносно невисокі показники точності ранжування, NDCG@10 становить лише 0,0082, а Recall@10 – 1,89%, тобто модель може «вгадати» менше двох відсотків реальних покупок із тестової вибірки. Низьке значення MRR також підтверджує що навіть вгадані товари знаходяться низько у списку. Дуже суттєвим недоліком є низьке покриття каталогу (Coverage@10=0,0002), фактично модель ігнорує 99,98% всіх товарів і фокусується лише на вузькому наборі хітів. Показники новизни

(AvgNoveltyRank@10=5,53) є низьким, що логічно для моделі популярності, бо вона рекомендує товари про, які користувачі й так могли знати. Тобто, ця модель є не ефективною для рекомендацій нішевих товарів. Це підтверджує доцільність використання більш складних моделей, які будуть проаналізовані далі.

На рис. 3.9 можна побачити чітку залежність рекомендацій від їхньої загальної популярності в даних, тобто ранг рекомендацій (Rank) майже ідеально корелює з рангом популярності товару (Popularity Rank). Для обох користувачів перші сім позицій списку є ідентичними та відповідають товарам з найбільшою кількістю взаємодій у навчальній вибірці, це, наприклад, засіб для чищення килимків для йоги та очищувач повітря GermGuardian. Починаючи з 8 позиції є відмінності, це зумовлено фільтрацією вже бачених користувачем товарів. Порівняння з реальними покупками, наприклад для користувача 1 це був специфічний товар догляду за тваринами (think ECO Pet Washable...), показує відсутність персоналізації, модель ігнорує інтереси користувача, пропонуючи лише бестселери.

| parent_asin |            |                                                   | Title | Popularity Rank | parent_asin |            |                                                   | Title | Popularity Rank |
|-------------|------------|---------------------------------------------------|-------|-----------------|-------------|------------|---------------------------------------------------|-------|-----------------|
| Rank        |            |                                                   |       |                 | Rank        |            |                                                   |       |                 |
| 1           | B0C1HHXQ94 | ASUTRA Natural & Organic Yoga Mat Cleaner (Min... |       | 1               | 1           | B0C1HHXQ94 | ASUTRA Natural & Organic Yoga Mat Cleaner (Min... |       | 1               |
| 2           | B08X9LB1WC | GermGuardian Guardian Technologies GG10002PK G... |       | 2               | 2           | B08X9LB1WC | GermGuardian Guardian Technologies GG10002PK G... |       | 2               |
| 3           | B0B4328BFW | US Organic 100% Pure Peppermint Essential Oil ... |       | 3               | 3           | B0B4328BFW | US Organic 100% Pure Peppermint Essential Oil ... |       | 3               |
| 4           | B004C7MTLA | Glycerin Vegetable - 1 Quart (43 oz.) - Non GM... |       | 4               | 4           | B004C7MTLA | Glycerin Vegetable - 1 Quart (43 oz.) - Non GM... |       | 4               |
| 5           | B0077L8YFI | Fitbit Aria WiFi Smart Scale                      |       | 5               | 5           | B0077L8YFI | Fitbit Aria WiFi Smart Scale                      |       | 5               |
| 6           | B01CKMP406 | Purple Back Cushion   Pressure Reducing Grid D... |       | 6               | 6           | B01CKMP406 | Purple Back Cushion   Pressure Reducing Grid D... |       | 6               |
| 7           | B0047VWYSO | Carlson - The Very Finest Fish Oil, 1600 mg Om... |       | 7               | 7           | B0047VWYSO | Carlson - The Very Finest Fish Oil, 1600 mg Om... |       | 7               |
| 8           | B00O0CK2UM | Nerdwax Stop Slipping Glasses as Seen on Shark... |       | 9               | 8           | B0001ZWPI4 | Avon SKIN-SO-SOFT Bug Guard PLUS IR3535® Insec... |       | 8               |
| 9           | B00BR1FSU8 | Mr Clean Magic Eraser Pads, 8 Count (Pack of 1)   |       | 10              | 9           | B00O0CK2UM | Nerdwax Stop Slipping Glasses as Seen on Shark... |       | 9               |
| 10          | B01N2TN98U | Silicone Makeup Sponge                            |       | 11              | 10          | B00BR1FSU8 | Mr Clean Magic Eraser Pads, 8 Count (Pack of 1)   |       | 10              |

Рисунок 3.9 – Топ-10 рекомендацій Popularity Baseline для двох користувачів

Джерело: розроблено автором за даними [92]

На рис. 3.10 видно, що більшість товарів мають лише одну взаємодію тоді як активність акумулюється у вузькій групі хітів. Така структура є підтвердженням проблеми розрідженості і обґрунтовує важливість використання більш складних алгоритмів, які здатні ефективно працювати з нішевими товарами.




Рисунок 3.10 – Розподіл популярності товарів у навчальній вибірці

Джерело: розроблено автором за даними [92]

Розподіл метрики новизни (Novelty@10) з рис. 3.11 із гострим піком показує ваду простої моделі, оскільки вона статично рекомендує лише найбільш популярні товари. Відсутність «хвоста» розподілу в правій частині рисунку вказує на повну нездатність моделі пропонувати більш нішеві товари, тобто створюється ефект «ехокамери», де користувачу рекомендується лише те, що є загальновідомим. Така поведінка системи, повністю ігнорує індивідуальні інтереси, що є проблемою для побудови якісного персоналізованого досвіду.




Рисунок 3.11 – Розподіл Novelty@10 серед користувачів для Popularity Baseline

Джерело: розроблено автором за даними [92]

Аналіз результатів моделі Item-kNN, наведених у таблиці 3.4, показав компроміс між точністю та здатністю досліджувати каталог. Враховуючи, що

вектори товарів формувались з агрегованих відгуків користувачів, низький показник точності ( $NDCG@10=0,0045$ ) вказує на те, що схожість колективного досвіду (те, як люди пишуть про товар) є слабким сигналом для прогнозування наступної покупки користувача, вони часто генерують семантичні дублікати (наприклад відгуки про швидку доставку чи хорошу ціну), які не завжди відповідають поточним бажанням клієнтів. Але зростання новизни та високе покриття каталогу на рівні 15,01%, показує успішне подолання «тиранії популярності». Однак, низька різноманітність 0,2102 вказує на формування «семантичної бульбашки», знайшовши товар із певним типом відгуків, наприклад, «ефективний засіб від болю», модель заповнює список товарами з ідентичним емоційним та змістовним забарвленням коментарів – це призводить до одноманітності рекомендацій, що сильно звужує реальний вибір користувачів.

Таблиця 3.4 – Результати моделі Item-kNN

| model    | Precision@10 | Recall@10 | MAP@10 | NDCG@10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiversity@10 | Coverage@10 |
|----------|--------------|-----------|--------|---------|--------|-----------------------|-----------------|-------------|
| Item-kNN | 0,0007       | 0,0067    | 0,0038 | 0,0045  | 0,0038 | 6403,5891             | 0,2102          | 0,1501      |

*Джерело: розроблено автором за даними [92]*

Детальний розгляд прикладів рекомендацій підтверджує формування «семантичної бульбашки». Для першого користувача (ліва частина рис. 3.12), наполовину список складається з контейнерів для пігулок бренду «BeeGogo», це пояснюється природою використання BERT-ембедингів відгуків, тобто люди описують ці товари схожими словами (про компактність чи зручність), у векторному просторі вони утворюють щільний кластер. Алгоритм k-NN знаходить цей кластер і заповнює список видачі найближчими сусідами. У випадку другого користувача (права частина рис. 3.12) видно розрив між семантичною близькістю текстів та реальною поведінкою користувача. Рекомендації для цього користувача сфокусовані на захисних рукавичках різних видів (латексні, нітрилові, бавовняні), це вказує на наявність схожих товарів у його історії навчання. Але в тестовий період користувач купив маску для сну і капсули коноплі – ці товари далекі від семантики рукавичок, але в цілому об'єднані ширшим контекстом особистого догляду. Тобто,

модель Item-kNN на відгуках ефективно знаходить текстові аналоги минулих покупок, але не здатна передбачити зміну інтересу до нових товарів або виявити приховані зв'язки між товарами, що не мають спільної лексики.

| Rank | parent_asin | Title                                             | Popularity Rank | Rank | parent_asin | Title                                             | Popularity Rank |
|------|-------------|---------------------------------------------------|-----------------|------|-------------|---------------------------------------------------|-----------------|
| 1    | B07PS88X67  | BeeGogo - Tree of Life Gorgeous Like Leather C... | 6579            | 1    | B07TB6FHTK  | Rubber Gloves-Latex Free Kitchen Cleaning Glov... | 4790            |
| 2    | B07PMYVRK3  | BeeGogo - Flowers Personalized Design New Silv... | 6648            | 2    | B089SNJLN8  | 100 Pcs Nitrile Gloves, 4 mils Disposable Glov... | 2263            |
| 3    | B071ZPPSL1  | A Lot Of Flowers Custom Fashion Bronze Tone Re... | 46638           | 3    | B0779R84XV  | Madholly 12 pairs Moisturizing Cotton Gloves W... | 677             |
| 4    | B07PMYSBQS  | BeeGogo - Abstract Floral Watercolor Painting ... | 3240            | 4    | B07Y5Y2WSG  | Sisfung HSL Waterproof Reuseable Rubber Cleani... | 2384            |
| 5    | B07PMYW9SL  | BeeGogo - Natural Eco Personalized Design New ... | 9885            | 5    | B07Y33962Z  | PACIFIC PPE 4 Pack Household Glove Mixed Packa... | 9126            |
| 6    | B002MC5Z8G  | Shakespeare Pill Box - Compact 1 or 2 Compartm... | 4064            | 6    | B07Y33N7VR  | PACIFIC PPE 4 Pack Household Glove Mixed Packa... | 9059            |
| 7    | B081DR67XX  | BAGR Cool Cheetah Leopard Portable Pill Organi... | 48636           | 7    | B002R0UXDK  | Spontex Neoprene Gloves Blue Neoprene Coating,... | 1218            |
| 8    | B07PS9FZ2K  | BeeGogo - Vintage Floral Custom Round Silver P... | 946             | 8    | B07Y32NCB6  | PACIFIC PPE 4 Pack Household Glove Mixed Packa... | 5891            |
| 9    | B007TBGGP6  | Hawaiian Jewelry and Gift Pill Box - Mother-of... | 16019           | 9    | B07Y32N7Y3  | Pacific PPE 4Pack Household Glove Mixed Packag... | 6363            |
| 10   | B085ZCL5W4  | Gold Clutch Purse Shaped Pocket Purse Portable... | 22309           | 10   | B07Y331P84  | Pacific PPE 4 Pack Household Glove Mixed Reusa... | 6274            |

Рисунок 3.12 – Топ-10 рекомендацій Item-kNN для двох користувачів

Джерело: розроблено автором за даними [92]

На рис. 3.13 наведена гістограма розподілу новизни, яка показує кардинальну зміну в стратегії відбору кандидатів порівняно з бейзлайном. Наявний широкий розподіл з модою 3000-4000 та хвостом понад 30000 – це підтверджує, що модель успішно пройшла бар'єр бестселерів, беручи товари з середини або «довгого хвоста». Модель ефективно знаходить нішеві продукти за специфікою описів, надаючи вищий рівень персоналізації.




Рисунок 3.13 – Розподіл Novelty@10 серед користувачів для Item-kNN

Джерело: розроблено автором за даними [92]

Водночас рис. 3.14 показує структурний недолік моделі k-NN, розподіл зміщений вліво, з концентрацією основної маси користувачів у діапазоні

різноманітності 0,1-0,25, що нижче за бажані показники для збалансованої системи. Це підтверджує ефект «семантичної бульбашки», де через високу щільність схожих векторів у латентному просторі призводить до того, що список формується з товарів-субститутів, що сильно обмежує варіанти вибору для користувача.




Рисунок 3.14 – Розподіл Diversity@10 серед користувачів для Item-kNN

*Джерело: розроблено автором за даними [92]*

Результати моделювання User-kNN наведені у таблиці 3.5 підтверджують, що зміна підходу з «пошуку схожих товарів» на «пошук схожих користувачів» у семантичному просторі не вирішив проблему низької точності прогнозування. NDCG@10 залишився на рівні 0,0045, що є ідентичним результатом item-based та нижчим навіть за бейзлайн. Це показало, що семантична схожість профілів, є слабким предиктором для реальних покупок. Але різноманітність зросла майже вдвічі порівняно з Item-kNN і дорівнює 0,3895 – це можна пояснити через механізм агрегації, який запозичує товари з історії покупок схожих користувачів, на відміну від item-based, який пропонував копії одного товару. Оскільки справжній кошик споживачів є гетерогенним, тобто містить товари з різних категорій, рекомендаційний список, сформований на їхній основі, виходить більш збалансованим та різноманітним, хоча це і не призвело до покращення релевантності.

Таблиця 3.5 – Результати моделі User-kNN

| model    | Precisio<br>n@10 | Recall<br>@10 | MAP@<br>10 | NDCG@<br>10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiver<br>sity@10 | Coverage<br>@10 |
|----------|------------------|---------------|------------|-------------|--------|-----------------------|---------------------|-----------------|
| User-kNN | 0,0008           | 0,0075        | 0,0036     | 0,0045      | 0,0038 | 5582,3899             | 0,3895              | 0,1503          |

Джерело: розроблено автором за даними [92]

Глибший аналіз рекомендації з рис. 3.15 для першого користувача (ліва частина рис. 3.15) показав причину високої метрики різноманітності цієї моделі. Список рекомендацій є різнорідним міксом від звукового нічника та К-поп маски до наколінника для важкої атлетики та засобу для миття посуду. Така розкиданість пояснюється тим, що модель шукає сусідів на основі стилю письма, а не історії спільних покупок. Це забезпечує високу варіативність товарів, але часто шкодить релевантності, бо цільові товари, як для цього користувача – зубна щітка, пропущені. Приклад 2-го користувача (права частина рис. 3.15) показує цікавий феномен «семантичної близькості при функціональній розбіжності». Згенеровані рекомендації присвячені БАДам та пробіотикам (капсули, тоніки, жувальні гумки), що семантично перегукується з реальною покупкою – «Probiotics Surface Cleaner» (очисник поверхонь з пробіотиками). Модель вловила контекст пробіотиків та натуральних компонентів, що домінували у кошиках сусідів, але не змогла відрізнити категорію побутової хімії та харчових добавок.

| Rank | parent_asin | Title                                             | Popularity | Rank | parent_asin | Title                                             | Popularity | Rank |
|------|-------------|---------------------------------------------------|------------|------|-------------|---------------------------------------------------|------------|------|
| 1    | B009JQE6RO  | Dream Tones by Conair Night Light & Sound Machine | 127        | 1    | B08729SVXZ  | Organic Ginger Root Capsules - Strongest DNA V... | 992        |      |
| 2    | B00UJ6K75I  | queenneeup Kpop Fashion Mask Exo Mask Bigbang ... | 443        | 2    | B07SXWQGXZ  | Triphala Capsules (Non-GMO) Super Strength: 50... | 493        |      |
| 3    | B07FY9X5QG  | Tech Love XXL Electric Heating Pad for Neck Sh... | 176        | 3    | B07R7X3GQ8  | VitalWise Probiotics 50 Billion CFU, Vegan, Ma... | 1360       |      |
| 4    | B081F2V7NM  | Pill Case - 2 Pack Portable Travel Medicine an... | 1029       | 4    | B07S4MN4JV  | RESTORE Promotes Gut-Brain Health   Digestive ... | 966        |      |
| 5    | B07PBXPYRF  | Warrior Kingdom   Knee Sleeves for Weightlifti... | 16384      | 5    | B00NVRQGHA  | Yoder's Good Health Recipe Tonic (2 Pack)         | 390        |      |
| 6    | B08TW9W6V3  | Sound Machine with Night Light, White Noise Ma... | 2993       | 6    | B076HZJD2W  | Liver Cleanse Detox & Repair Formula – Detox P... | 9272       |      |
| 7    | B085NPN2VQ  | Car Tissues Facial Tissue RONGCHUANG 6 Packs, ... | 1641       | 7    | B06XP2L8H2  | Swanson Dynamic Balance Blend Soil-Based Organ... | 7119       |      |
| 8    | B08CXGBFL6  | JJ CARE Mouth Tape for Sleeping [Box of 30] Ne... | 11076      | 8    | B074KCWQRG  | Hawaban Harde 100 Gm (Pack of 3)                  | 16307      |      |
| 9    | B081DCBHHH  | 3 Pk. Dawn Ultra Pure Essentials Lemon Essence... | 14524      | 9    | B00O99FWPQ  | Schiff Digestive Advantage Probiotic Gummies -... | 5575       |      |
| 10   | B075T24L2V  | Jade Roller for Face with Blackhead Remover To... | 20189      | 10   | B07WVRB3P9  | Banyan Botanicals Organic Chyavanprash (Chyawa... | 323        |      |

Рисунок 3.15 – Топ-10 рекомендацій User-kNN для двох користувачів

Джерело: розроблено автором за даними [92]

Рис. 3.16 розподілу новизни, також, демонструє широке охоплення каталогу, мода в діапазоні 4000-5000, що вказує на ефективність роботи в нішевому сегменті. Це доводить, що семантичні ембединги здатні нівелювати проблему розрідженості

даних. На відміну від методів, що залежать від статичних даних по продажах, цей підхід успішно додає товари «довгого хвоста у видачу».




Рисунок 3.16 – Розподіл Novelty@10 серед користувачів для User-kNN

*Джерело: розроблено автором за даними [92]*

Метрика Diversity@10 (рис. 3.17) наближається до нормального розподілу, демонструючи значний приріст різноманітності порівняно з item-based підходом. Це доводить, що агрегація різнорідних кошиків схожих користувачів ефективно протидіє «семантичній бульбашці», тобто модель формує список без дублювання товарів, хоча це і досягається ціною зниження точності прогнозів.




Рисунок 3.17 – Розподіл Diversity@10 серед користувачів для User-kNN

*Джерело: розроблено автором за даними [92]*

Аналіз результатів моделі ALS (Alternating Least Squares), наведено у таблиці 3.6, показує, що вона займає проміжну позицію, NDCG@10 (0,0067) кращий за моделі найближчих сусідів, але поступається бейзлайну. Через сильну

розрідженість матриці взаємодій, алгоритм мінімізує функцію втрат, зміщуючись у бік рекомендацій товарів з найбільшою кількістю взаємодій. Якісні метрики чітко показали зміщення в сторону популярності. Низька новизна (486,3) та покриття каталогу (0,82%) вказують на ігнорування «довгого хвоста». Але різноманітність є однією з найвищих серед моделей – 0,5445, тобто факторизація ефективно комбінує різнорідні бестселери, уникаючи створення списків однотипних клонів.

Таблиця 3.6 – Результати моделі ALS

| model | Precisio<br>n@10 | Recall<br>@10 | MAP@<br>10 | NDCG@<br>10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiver<br>sity@10 | Coverage<br>@10 |
|-------|------------------|---------------|------------|-------------|--------|-----------------------|---------------------|-----------------|
| ALS   | 0,0014           | 0,0132        | 0,0045     | 0,0067      | 0,0052 | 486,3262              | 0,5445              | 0,0082          |

*Джерело: розроблено автором за даними [92]*

Як показано на рис. 3.18, приклад 1-го користувача (ліва частина рисунка) пояснює природу високої різноманітності, список рекомендацій є строкатим, він містить захисне скло, подушку для спини, засіб від котів, риб'ячий жир тощо. Але модель не ідентифікувала реальну покупку користувача – медичну маску, «зашумивши» прогноз популярними позиціями через розрідженість даних. Випадок 2-го користувача (права частина рис. 3.18) ілюструє зміщення популярності, у топі рекомендацій – лідери каталогу: очисників килимів для його та ефірна олія. При реальній покупці Blender Bombs (суперфуд), модель запропонувала Amla Powder та Barley Grass Juice, тобто вловила латентний інтерес до здорового харчування або суперфудів, але через тенденцію пропонувати бестселери, віддала перевагу більш відомим аналогам.

| parent_asin | Title                                                        | Popularity Rank | parent_asin | Title                                                        | Popularity Rank |
|-------------|--------------------------------------------------------------|-----------------|-------------|--------------------------------------------------------------|-----------------|
| Rank        |                                                              |                 | Rank        |                                                              |                 |
| 1           | B00XGYV40M (2 Pack) Glass Curve- Screen Protector Made fo... | 49              | 1           | B0C1HHXQ94 ASUTRA Natural & Organic Yoga Mat Cleaner (Min... | 1               |
| 2           | B00WRPIB5W Pure Acres Farm Essential Oils Roller Bottles ... | 13              | 2           | B0B4328BFW US Organic 100% Pure Peppermint Essential Oil ... | 3               |
| 3           | B01CKMP406 Purple Back Cushion   Pressure Reducing Grid D... | 6               | 3           | B07XVVB8W Super Organics Amla (Amalaki) Powder   Organic...  | 93              |
| 4           | B00NBA42TG Digital Glass Bathroom Scale Black - Holds Up ... | 16              | 4           | B01B4FQXG4 6 in 1 Waterproof Electric Facial & Body Clean... | 58              |
| 5           | B0BP9TTQBM 10 Seconds - Disinfectant                         | 62              | 5           | B06XXP8YRL Topical Ancient Minerals Magnesium Lotion – fo... | 71              |
| 6           | B0CCWPQL6X Nature's MACE Cat Repellent 1 Gallon Spray/Tre... | 35              | 6           | B0BR84SRTX Flushable Wipes for Baby and Kids by Kandoo, U... | 40              |
| 7           | B07HS7TGNM Travelon Hand Soap Toiletry Sheets, 50-Count      | 31              | 7           | B00D6NXVRC PURE SYNERGY Barley Grass Juice   5.3 oz Powde... | 144             |
| 8           | B01B4FQXG4 6 in 1 Waterproof Electric Facial & Body Clean... | 58              | 8           | B0BLGM5PDZ SoyLent Nutritionally Complete Meal Replacemen... | 91              |
| 9           | B0047VWYSO Carlson - The Very Finest Fish Oil, 1600 mg Om... | 7               | 9           | B0C35MKB98 Powerstep ProTech Full Length - Plantar Fascii... | 47              |
| 10          | B07G4FNLB5 Caleb Treeze Old Amish Muscle Tonic (Formerly:... | 36              | 10          | B07C8D64F1 Ulla Smart Light for Water Bottle, Small Hydra... | 95              |

Рисунок 3.18 – Топ-10 рекомендацій ALS для двох користувачів

*Джерело: розроблено автором за даними [92]*

Гістограма Novelty@10 (див. рис. 3.19) показує різний регрес новизни, лівостороння асиметрія з піком у зоні низьких рангів 0-500 – це наближає профіль рекомендацій до наївного бейзлайну. Тобто через високу розрідженість даних ALS «колапсує» до пропозиції популярних товарів, мінімізуючи функцію втрат за рахунок рекомендації товарів-хітів.




Рисунок 3.19 – Розподіл Novelty@10 серед користувачів для ALS

*Джерело: розроблено автором за даними [92]*

Розподіл різноманітності з рис. 3.20 демонструє перевагу ALS, він близький до нормально із центром 0,50-0,60 і є одним з найкращих серед аналізованих моделей. Алгоритм ефективно комбінує різноманітні категорії товарів для рекомендацій, забезпечуючи користувачу широту вибору, хоча й сформовану переважно з відомих бестселерів та уникаючи монотонності, як у моделях k-NN.




Рисунок 3.20 – Розподіл Diversity@10 серед користувачів для ALS

*Джерело: розроблено автором за даними [92]*

Важливим аспектом інтерпретації низьких результатів LightFM ( $NDCG@10=0,0053$ ) наведених у таблиці 3.7 є врахування технічних обмежень, що виникли під час навчання, через значене споживання оперативної пам'яті навчання моделі вимушено скорочено до 5 епох, що спричинило недонавчання та перешкодило збіжності алгоритму WARP. Через це гібридна модель поступилась простішій ALS. Незважаючи на це, можна помітити, що модель за точністю все одно краща за k-NN моделі. Додавання метаданих до аналізу покращили покриття каталогу – 3,65% та новизну – 1184,8, покращивши рекомендації підсвітивши частину товарів недоступних для ALS. Падіння різноманітності – 0,375 говорить про те, що через брак навчання модель спростила стратегію до групування за явними ознаками, як бренд чи категорія, ігноруючи глибші латентні зв'язки.

Таблиця 3.7 – Результати моделі LightFM

| model   | Precision@10 | Recall@10 | MAP@10 | NDCG@10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiversity@10 | Coverage@10 |
|---------|--------------|-----------|--------|---------|--------|-----------------------|-----------------|-------------|
| LightFM | 0,001        | 0,0097    | 0,0039 | 0,0053  | 0,0043 | 1184,845              | 0,3751          | 0,0365      |

*Джерело: розроблено автором за даними [92]*

Якісний аналіз рекомендацій наведений на рис. 3.21 для 1-го користувача (ліва частина рисунка) демонструє спробу балансу, де поряд із бестселерами (очисник килимків для йоги, спрей від комах), запропоновані семантичні аналоги такі, як дитяча олія, олія горіха кукуї, вітамін Е, до реальної покупки «Peppermint Essential Oil». Це підтверджує роботу контентних ознак, але недонавчання завадило моделі відсіяти загальну популярність на користь індивідуальних побажань. Для 2-го користувача (права частина рис. 3.21) показує падіння різноманітності, оскільки видача сфокусувалась на інтересі «електроніки для особистого догляду» (4 тонометри і 4 ваги). Модель правильно визначила категорію реальної покупки – електрична пилка для ніг, але регресувала до простої кластеризації, замість того, щоб виявляти складні патерни, LightFM створила ефект «тунельного зору» з функціональними дублікатами, базуючись на явні ознаки.

| Rank | parent_asin | Title                                             | Popularity Rank | Rank | parent_asin | Title                                              | Popularity Rank |
|------|-------------|---------------------------------------------------|-----------------|------|-------------|----------------------------------------------------|-----------------|
| 1    | B0C1HHXQ94  | ASUTRA Natural & Organic Yoga Mat Cleaner (Min... | 1               | 1    | B0156GYY4A  | KEDSUM Wrist Digital Blood Pressure Monitor wi...  | 118             |
| 2    | B07XVTNQYK  | Amazon Basics Baby Oil with Aloe Vera & Vitami... | 177             | 2    | B013CAU9MI  | Wrist Blood Pressure Monitor - Doctor tested & ... | 1064            |
| 3    | B075D1KDFN  | Oils of Aloha Hawaii Kukui Oil No Fragrance 4 ... | 194             | 3    | B00TXHW5Y0  | PureBPM Wrist Blood Pressure Monitor - Fast, A...  | 402             |
| 4    | B01M5JP7TK  | Colonial Dames Concentrated Vitamin E Moisturi... | 1515            | 4    | B0077L8YFI  | Fitbit Aria WiFi Smart Scale                       | 5               |
| 5    | B01LYCSJM8  | Natural Shoe Deodorizer Spray for Foot Odor & ... | 27              | 5    | B0177ZYR5E  | iTro ProStyle 3D Pedometer with Strong Clip - ...  | 253             |
| 6    | B07DPPLTZ9  | EBPP Odor & Stain Eraser - Made in The USA - P... | 45              | 6    | B00NBA42TG  | Digital Glass Bathroom Scale Black - Holds Up ...  | 16              |
| 7    | B0B4Z2PMHZ  | Dreft Stage 1: Newborn Hypoallergenic Baby Lau... | 694             | 7    | B01MSIH72J  | Fam-health Automatic Digital Upper Arm Blood P...  | 890             |
| 8    | B004C7MTLA  | Glycerin Vegetable - 1 Quart (43 oz.) - Non GM... | 4               | 8    | B01LCPYOOE  | Wrist Blood Pressure Monitor from BROADCAST, A...  | 2984            |
| 9    | B015HW5AIW  | The Honest Company All Purposed Balm, 3 oz. (P... | 464             | 9    | B00ITSMER2  | Fitbit Aria WiFi Smart Scale                       | 20316           |
| 10   | B0001ZWPI4  | Avon SKIN-SO-SOFT Bug Guard PLUS IR3535® Insec... | 8               | 10   | B00ZULSFYW  | Fitbit Aria WiFi Smart Scale                       | 10945           |

Рисунок 3.21 – Топ-10 рекомендацій LightFM для двох користувачів

Джерело: розроблено автором за даними [92]

Аналіз рис. 3.22 показує проміжний результат розподілу новизни, розширення «хвоста» розподілу до рангів 5000+ свідчить про те, що метадані допомогли активувати нішеві товари. Мода в зоні 0-1000 показує що через недонавчання модель не змогла подолати зміщення популярності й продовжує спиратись на безпечні бестселери як на основу видачі.




Рисунок 3.22 – Розподіл Novelty@10 серед користувачів для LightFM

Джерело: розроблено автором за даними [92]

Графік Diversity@10 (див. рис. 3.23) показує регрес, бо пік змістився вліво, центр в межах 0,35-0,45, порівняно з ALS – 0,55. Це наслідок недонавчання, не виявивши складні зв'язки модель використовує примітивне групування за явними ознаками, як бренд, категорія, магазин тощо. Це призвело до однорідності списку рекомендацій, знизивши варіативність до рівня контентних підходів.




Рисунок 3.23 – Розподіл Diversity@10 серед користувачів для LightFM

Джерело: розроблено автором за даними [92]

Важливість фічів з рис. 3.24 показує сильний вплив семантичних BERT-ембедингів (вага>3400) на рекомендації моделі, це показує, що відгуки мають високу інформативність для моделювання. Серед метаданих найбільш впливовими виявились: магазин, виробник, бренд та матеріал товару.




Рисунок 3.24 – Важливість фічів для моделі LightFM

Джерело: розроблено автором за даними [92]

Графік динаміки навчання Two-Tower моделі на рис. 3.25 показує успішність тюнінгу, оскільки відбувається плавне та монотонне зниження помилки, що вказує на стабільність навчання. Алгоритм ефективно зближує вектори позитивних пар «користувач-товар» та віддаляє негативні приклади у прихованому просторі.




Рисунок 3.25 – Навчання фінальної моделі Two-Tower

Джерело: розроблено автором за даними [92]

Двовежена модель (Two-Tower) демонструє найрадикальнішу зміну стратегії, хоча і має низьку точність  $NDCG@10=0,0025$  (таблиця 3.8). Через сильну розрідженість даних мережа схильна до надмірного узагальнення, вона знаходить товари, що теоретично підходять за сукупністю ознак, але не вгадує конкретні побажання користувача. Справжня цінність цієї архітектури полягає у глибокому пошуці. Виняткова новизна – 20739, покриття – 20,19% та висока різноманітність – 0,57, доводять повне ігнорування популярності товарів. Модель агресивно досліджує «довгий хвіст», діючи як інструмент відкриття нових нішевих товарів.

Таблиця 3.8 – Результати моделі Two-Tower

| model     | Precisio<br>n@10 | Recall<br>@10 | MAP@<br>10 | NDCG@<br>10 | MRR   | AvgNovelt<br>yRank@10 | AvgDiver<br>sity@10 | Coverage<br>@10 |
|-----------|------------------|---------------|------------|-------------|-------|-----------------------|---------------------|-----------------|
| Two-Tower | 0,0004           | 0,0039        | 0,002      | 0,0025      | 0,002 | 20738,9544            | 0,5744              | 0,2019          |

Джерело: розроблено автором за даними [92]

Аналіз користувача 1 (ліва сторона рис. 3.26) підтверджує роботу з «довгим хвостом», де ранги 1232-34897. Модель виділила латентний концепт «мішок/ємність» (мішечки, урна, кошики), що семантично перегукується з реальною покупкою – змінним мішком (Replacement Bag) для фільтра. Але модель не змогла розрізнити функціональний контекст, пропонуючи декоративні товари

замість технічного аксесуара. Для 2-го клієнта (права частина рис. 3.26) присутній ефект тематичного відкриття. Видача складається з рідкісних нутрієнтів та суперфудів (гриб чага, матча, ехінацея, веганський протеїн) з рангами популярності 10000-48000. Цей набір відповідає реальним покупкам – ашваганда, медові пастилки для горла, які, також належать до сфери натуральної медицини, хоча точний товар не вгадано, модель запропонувала релевантну альтернативу (ехінацею замість меду), діючи як ефективний інструмент для пошуку нових.

| Rank | parent_asin | Title                                             | Popularity Rank | Rank | parent_asin | Title                                             | Popularity Rank |
|------|-------------|---------------------------------------------------|-----------------|------|-------------|---------------------------------------------------|-----------------|
| 1    | B07Y65G8H9  | Tebery 200-Count 4x6 Inches Assorted Color Org... | 6332            | 1    | B0792H5G6G  | GenOne Labs Vegan Protein Powder, for Men and ... | 12488           |
| 2    | B08N9SZ6SC  | Vumdua 100 PCS Non-Woven Nursery Bags, 7.8 x 8... | 20991           | 2    | B08G8BXW5Z  | 200 Pieces Christmas Cellophane Bags Snowflake... | 48132           |
| 3    | B07NRYCF81  | HeroFiber 20-Sets - Easter Plates (7") + Bever... | 12562           | 3    | B07FTNCNMV  | Wild Chaga Powder by Holistic Bin   Pure Wild ... | 14513           |
| 4    | B01KT8TY0E  | Cremation Urn for Human Ashes Adult - Brass Fu... | 23235           | 4    | B0727PHFQR  | Lebon Villa Noacarina (Cinnamon + Mint) Organ...  | 32603           |
| 5    | B07JQGHHR   | 48-Count Thanksgiving Paper Dinner Napkins, Fa... | 6732            | 5    | B08WRH6KTF  | Premium MCT Oil High Octane C8 C10 MCT Oil 500... | 13643           |
| 6    | B08KDGFMX   | Timoo Wicker Wall Hanging Basket for Organizer... | 14850           | 6    | B075SY5CDD  | Herb Essential Pure Haritaki Powder - 100 g       | 10454           |
| 7    | B011F28VU0  | White Linen Gift Bags Drawstring Embroider Sac... | 8732            | 7    | B081HDTTWR  | ProSupps® Whey Matrix Ultra-Pure Premium Whey ... | 20481           |
| 8    | B07L8398S4  | (2 Pack) Green Grass Sports Field Football Soc... | 6317            | 8    | B08PP98YJ3  | UpGo Supplements Apple Cider Vinegar Gummies, ... | 46970           |
| 9    | B07RX8PKRS  | Rifle Paper Set of Party Napkins Garden Party ... | 34897           | 9    | B01KW8TCEE  | Amoda Matcha Energy Blend - is a Remarkable Or... | 15337           |
| 10   | B07H3BF7SC  | Brown Kraft Paper Gift Bags Bulk with Handles...  | 1232            | 10   | B000W4EQG   | Echinacea Throat & Cough Drops Wild Cherry Ech... | 44001           |

Рисунок 3.26 – Топ-10 рекомендацій Two-Tower для двох користувачів

Джерело: розроблено автором за даними [92]

Розподіл новизни з рис. 3.27 візуалізує таку зміну підходу: широкий нормальний розподіл із центром у зоні високих рангів 20000-25000 показує, що нейромережа повністю відкинула ідею використання популярних товарів. Two-Tower досліджує «довгий хвіст» витягуючи товари з мінімальною історією, але максимальною векторною подібністю профілів.




Рисунок 3.27 – Розподіл Novelty@10 серед користувачів для Two-Tower

Джерело: розроблено автором за даними [92]

Графік Diversity@10 з рис. 3.28 фіксує пік у діапазоні 0,55-0,65, підтверджуючи здатність моделі формувати високо різноманітні списки. Це наслідок проекції у латентний простір, де вектори зближуються за ймовірною сумісністю, а не за категоріями. Як результат, видача поєднує функціонально різні, але контекстуально пов'язані нішеві товари, пропонуючи користувачам максимально широкий вибір.




Рисунок 3.28 – Розподіл Diversity@10 серед користувачів для Two-Tower

*Джерело: розроблено автором за даними [92]*

Аналіз важливості фічів з рис. 3.29 для однієї з «веж» Item-Tower підтверджує важливість BERT-ембедингів. Наступною за важливістю є ціна, випереджаючи категорії, що вказує на автоматичну сегментацію пропозицій за платоспроможністю. Низька вага формальних категорій пояснює схильність до крос-доменних рекомендацій, тобто модель орієнтується на відгуки та вартість, а не на «ярлики» каталогу, що і гарантувало високу новизну та різноманітність.




Рисунок 3.29 – Важливість фічів для «вежі» Item Tower моделі Two-Tower

*Джерело: розроблено автором за даними [92]*

На рис. 3.30 наведено динаміку втрат для моделі SASRec, він показує класичну збіжність, де стрімке падіння помилки на старті переходить у стабільне спадання до 15-ї епохи. Відсутність стрибків підтверджує коректність тюнінгу гіперпараметрів, тобто механізм self-attention адекватно засвоїв послідовності патернів поведінки без ознак перенавчання.




Рисунок 3.30 – Навчання фінальної моделі SASRec

*Джерело: розроблено автором за даними [92]*

SASRec модель, як видно з таблиці 3.9, показав найкращу точність ( $NDCG@10=0,0113$ ) випередивши бейзлайн на 38% - це показує що в електронній комерції порядок взаємодій має одне з найважливіших значень. Але успіх досягнуто ціною охоплення, а саме низька новизна – 16,6 та мізерне покриття – 0,09%, вказують на фокус на товарах-бестселерах. Модель діє як умовний снайпер для типових сценаріїв, вгадуючи повторні або супутні товари-хіти, при цьому повністю ігноруючи решту каталогу, і замикає користувача в «бульбашку» з найбільш очевидних послідовностей.

Таблиця 3.9 – Результати моделі SASRec

| model  | Precision@10 | Recall@10 | MAP@10 | NDCG@10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiversity@10 | Coverage@10 |
|--------|--------------|-----------|--------|---------|--------|-----------------------|-----------------|-------------|
| SASRec | 0,0021       | 0,0191    | 0,0086 | 0,0113  | 0,0109 | 16,0587               | 0,1967          | 0,0009      |

*Джерело: розроблено автором за даними [92]*

Аналіз прикладів рекомендацій для 1-го користувача (ліва частина рис. 3.31) пояснює причину низької новизни, список майже повністю складається з загальних хітів. Якщо немає чітких патернів, то механізм self-attention зміщується до

загальних трендів, фактично стає удосконаленим бейзлайном, який ігнорує потребу користувача, який купи змінний фільтр. Для 2-го користувача (права частина рис. 3.31) модель показала усереднення інтересів, вона запропонувала Peppermint Essential Oil, тоді як користувач купив Peppermint Honey. Алгоритм правильно визначив вектор м'яти та натуральності, але через оптимізацію замінив нішевий мед на його популярніший аналог. Це пояснює високу точність моделі, але і демонструє схильність моделі рекомендувати «бульбашку» очевидних рішень.

| Rank | parent_asin | Title                                             | Popularity Rank | Rank | parent_asin | Title                                             | Popularity Rank |
|------|-------------|---------------------------------------------------|-----------------|------|-------------|---------------------------------------------------|-----------------|
| 1    | B00BR1FSU8  | Mr Clean Magic Eraser Pads, 8 Count (Pack of 1)   | 10              | 1    | B0B4328BFW  | US Organic 100% Pure Peppermint Essential Oil ... | 3               |
| 2    | B08X9LB1WC  | GermGuardian Guardian Technologies GG10002PK G... | 2               | 2    | B0047VWYSO  | Carlson - The Very Finest Fish Oil, 1600 mg Om... | 7               |
| 3    | B0047VWYSO  | Carlson - The Very Finest Fish Oil, 1600 mg Om... | 7               | 3    | B0C1HHXQ94  | ASUTRA Natural & Organic Yoga Mat Cleaner (Min... | 1               |
| 4    | B004C7MTLA  | Glycerin Vegetable - 1 Quart (43 oz.) - Non GM... | 4               | 4    | B004C7MTLA  | Glycerin Vegetable - 1 Quart (43 oz.) - Non GM... | 4               |
| 5    | B0C1HHXQ94  | ASUTRA Natural & Organic Yoga Mat Cleaner (Min... | 1               | 5    | B0797M8SFS  | Nectar, Apple Ecstasy, 2 Pounds                   | 37              |
| 6    | B0001ZWPI4  | Avon SKIN-SO-SOFT Bug Guard PLUS IR3535® Insec... | 8               | 6    | B01CKMP406  | Purple Back Cushion   Pressure Reducing Grid D... | 6               |
| 7    | B0BSRPX53Z  | Puffs Plus Lotion Facial Tissue (Old)             | 25              | 7    | B08X9LB1WC  | GermGuardian Guardian Technologies GG10002PK G... | 2               |
| 8    | B08KBQNDJC  | Clear Care Cleaning & Disinfection Solution-12... | 14              | 8    | B09RHV7K91  | DII Women's Adjustable Shower Wrap with Self-F... | 23              |
| 9    | B01CKMP406  | Purple Back Cushion   Pressure Reducing Grid D... | 6               | 9    | B00QJQUOPK  | Tangy Tangerine - 420 G Canister Single           | 41              |
| 10   | B0077L8YFI  | Fitbit Aria WiFi Smart Scale                      | 5               | 10   | B00BR1FSU8  | Mr Clean Magic Eraser Pads, 8 Count (Pack of 1)   | 10              |

Рисунок 3.31 – Топ-10 рекомендацій SASRec для двох користувачів

Джерело: розроблено автором за даними [92]

Розподіл Novelty@10 з рис. 3.32 показує екстремальну концентрацію в зоні рангів 10-25, фактично дублюючи профіль бейзлайну. Відсутність «хвоста» візуалізує «тунельний ефект», де модель визначає пропозицію хітів як найбезпечнішу стратегію прогнозів.




Рисунок 3.32 – Розподіл Novelty@10 серед користувачів для SASRec

Джерело: розроблено автором за даними [92]

Графік Diversity@10 на рис. 3.33, демонструє аномальну бімодальність і зміщення в зону низьких значень 0,18-0,22. Це вказує на генерацію двох типів одноманітних списків: або варіації одного товару, або вузькі групи супутніх товарів бестселерів. Така поведінка підтверджує, що SASRec жертвує шириною охоплення інтересів, заради максимізації точності прогнозу.




Рисунок 3.33 – Розподіл Diversity@10 серед користувачів для SASRec

Джерело: розроблено автором за даними [92]

### 3.3 Аналіз результатів реранкінгу та ефективності побудованих рекомендаційних моделей

Фінальним етапом побудови рекомендаційної системи стала реалізація моделі реранкера – LightGBM. Для формування пулу кандидатів було обрано 3 найкращі моделі першого рівня за метрикою NDCG@10: SASRec, Popularity Baseline, ALS.

Аналіз важливості фічів з рис. 3.34 показує, що найбільшу вагу отримали категоріальні атрибути такі, як магазин, виробник та бренд. Тобто, найсильнішим сигналом для покупки є лояльність користувачів до певного бренду або продавця. Також, значущою виявилась ознака косинусної схожості, що підтверджує важливість семантичної відповідності відгуків. Ознака source\_rank (позиціях

товару у видачі базової моделі), також увійшла в топ, а це означає, що реранкер «довіряє» первинному ранжуванню, але коригує його на основі інших факторів.

LightGBM Reranker підтвердив ефективність двоступеневої архітектури, забезпечивши висок стрибок точності NDCG@10 сягнув рекордного рівня 0,0197, як зазначено у таблиці 3.10. Використання розширених ознак дозволило бустингу ефективно відфільтрувати шум та пріоритизувати найбільш ймовірні покупки. Вплив на структуру виявився подвійним. Новизна знизилась до 159,79, бо реранкер відсіяв ризиковані нішеві товари на користь перевірених популярних товарів. Натомість різноманітність суттєво зросла – 0,5182 значно перевищила SASRec. Це стало наслідком змішування кандидатів від різних моделей (послідовної, колаборативної та популярної), що забезпечило баланс між високою точністю та варіативністю пропозицій.




Рисунок 3.34 – Важливість фічів для LightGBM Reranker

Джерело: розроблено автором за даними [92]

Таблиця 3.10 – Результати моделі LightGBM

| model                     | Precisio<br>n@10 | Recall<br>@10 | MAP@<br>10 | NDCG@<br>10 | MRR    | AvgNovelt<br>yRank@10 | AvgDiver<br>sity@10 | Coverage<br>@10 |
|---------------------------|------------------|---------------|------------|-------------|--------|-----------------------|---------------------|-----------------|
| <b>LGBM_Re<br/>ranker</b> | 0,0038           | 0,0354        | 0,0146     | 0,0197      | 0,0176 | 159,7918              | 0,5182              | 0,0008          |

Джерело: розроблено автором за даними [92]

Ефективність моделі найкраще ілюструє приклад користувача (див. рис. 3.35-3.36), чия реальна потреба була у придбанні Ground Truth: TENS Unit – міостимулятор. Реранкер змінив пріоритети, він опустил нижче по рангу нерелевантні товари такі, як очисник для матів та ефірну олію, і вивів у лідери ортопедичну подушку та магнісвий лосьйон від судом (піднятий з 30-ї позиції). Тобто, модель ідентифікувала латентний намір терапії від болю та сформувала більш релевантний верх списку, замість випадкових бестселерів.

|        | item_id    | Title                                                                                                                                                                                                                                                       | source_model     | source_rank | source_score | reranker_score | label    |
|--------|------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------|-------------|--------------|----------------|----------|
| 126804 | B0B4328BFW | US Organic 100% Pure Peppermint Essential Oil - USDA Certified Organic - 10 ml Pack of 2 - w/Improved caps and droppers (More Size Variations Available)                                                                                                    | SASRec_Tuned     | 1           | 1.00         | 0.11           | 0.000000 |
| 126805 | B0C1HHXQ94 | ASUTRA Natural & Organic Yoga Mat Cleaner (Mindful Lemongrass Aroma), 4 fl oz   Safe for All Mats & No Slippery Residue   Cleans, Restores, Refreshes   Comes w/Microfiber Cleaning Towel   Deep-Cleansing Natural Cleaner for Fitness Gear & Gym Equipment | Popularity       | 1           | 1.00         | -0.30          | 0.000000 |
| 126806 | B07XVVVB8W | Super Organics Amla (Amalaki) Powder   Organic Superfood Powder   Raw Superfoods   Whole Food Supplement   Good Vitamin C Content – Vegan, Non-GMO & Gluten-Free, 8 oz                                                                                      | ALS_Optuna_Tuned | 1           | 0.00         | -0.04          | 0.000000 |
| 126807 | B08X9LB1WC | GermGuardian Guardian Technologies GG10002PK GG1000 Pluggable UV-C Sanitizer and Deodorizer,Kills Germs,Freshens Air and Reduces Odors from Pets,Smoke,Mold,Cooking and Laundry,2-Pack                                                                      | Popularity       | 2           | 0.50         | -0.06          | 0.000000 |
| 126808 | B0BLGMSFDZ | Soylent Nutritionally Complete Meal Replacement Powder, 1 Day (5 Meals), Cacao                                                                                                                                                                              | ALS_Optuna_Tuned | 2           | 0.00         | -0.14          | 0.000000 |
| 126809 | B0047VWYSO | Carlson - The Very Finest Fish Oil, 1600 mg Omega-3s, Liquid Fish Oil Supplement, Norwegian Fish Oil, Wild-Caught, Sustainably Sourced Fish Oil Liquid, Lemon, 200ml, 6.7 Fl Oz                                                                             | SASRec_Tuned     | 3           | 0.33         | -0.20          | 0.000000 |
| 126810 | B06XXP8YRL | Topical Ancient Minerals Magnesium Lotion – for Leg Cramps, Joint Support, & Muscle Soreness – Non-Greasy Magnesium Lotion with Shea Butter, 30 Mg. Mag. per Pump, 5 Oz.                                                                                    | ALS_Optuna_Tuned | 3           | 0.00         | 0.14           | 0.000000 |
| 126811 | B004C7MTLA | Glycerin Vegetable - 1 Quart (43 oz.) - Non GMO - Sustainable Palm Based - USP - KOSHER - PURE - Pharmaceutical Grade - safety sealed HDPE container with resealable cap                                                                                    | Popularity       | 4           | 0.25         | -0.10          | 0.000000 |
| 126812 | B00D6NXVRC | PURE SYNERGY Barley Grass Juice   5.3 oz Powder   USDA Organic   Non-GMO   Vegan   Made and Sourced in The USA   Cold-Juiced and Low-Temperature Dried                                                                                                      | ALS_Optuna_Tuned | 4           | 0.00         | -0.52          | 0.000000 |
| 126813 | B0077L8YFI | Fitbit Aria WiFi Smart Scale                                                                                                                                                                                                                                | Popularity       | 5           | 0.20         | -0.44          | 0.000000 |
| 126814 | B07SQZNSFH | Relaxzen Deluxe Leisure Recliner Chair with 8-Motor Massage & Heat, Brown                                                                                                                                                                                   | ALS_Optuna_Tuned | 5           | 0.00         | -0.54          | 0.000000 |
| 126815 | B01CKMP406 | Purple Back Cushion   Pressure Reducing Grid Designed for Ultimate Comfort   Designed for Chairs, Gaming, and Travel   Made in The USA                                                                                                                      | SASRec_Tuned     | 6           | 0.17         | 0.22           | 0.000000 |
| 126816 | B000F95A4W | Verilux Original Natural Spectrum Deluxe Floor Lamp, Ivory                                                                                                                                                                                                  | ALS_Optuna_Tuned | 6           | 0.00         | -0.44          | 0.000000 |
| 126817 | B0797M8SFS | Nectar, Apple Ecstasy, 2 Pounds                                                                                                                                                                                                                             | SASRec_Tuned     | 7           | 0.14         | -0.39          | 0.000000 |
| 126818 | B01B4FQXG4 | 6 in 1 Waterproof Electric Facial & Body Cleansing Brush with 2 Speeds Setting for Skin Care, Include Detachable Handle & 5 Brush Head and Cute Cosmetic Bag (blue)                                                                                         | ALS_Optuna_Tuned | 7           | 0.00         | -0.48          | 0.000000 |

Рисунок 3.35 – Топ-15 рекомендацій до реранкінгу для 1 користувача

Джерело: розроблено автором за даними [92]

| Rank   | parent_asin | Title                                                                                                                                                                                                   | Reranker Score | Source Model     | Source Rank | Label    |
|--------|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------|------------------|-------------|----------|
| 126816 | B01CKMP406  | Purple Back Cushion   Pressure Reducing Grid Designed for Ultimate Comfort   Designed for Chairs, Gaming, and Travel   Made in The USA                                                                  | 0.2233         | SASRec_Tuned     | 6           | 0.000000 |
| 126811 | B06XXP8YRL  | Topical Ancient Minerals Magnesium Lotion – for Leg Cramps, Joint Support, & Muscle Soreness – Non-Greasy Magnesium Lotion with Shea Butter, 30 Mg. Mag. per Pump, 5 Oz.                                | 0.1434         | ALS_Optuna_Tuned | 3           | 0.000000 |
| 126805 | B0B4328BFW  | US Organic 100% Pure Peppermint Essential Oil - USDA Certified Organic - 10 ml Pack of 2 - w/Improved caps and droppers (More Size Variations Available)                                                | 0.1101         | SASRec_Tuned     | 1           | 0.000000 |
| 126831 | B08MVCGBTV  | RnA ReSet - ReMag High Absorption Magnesium Liquid, Experience The Magnesium Miracle, Magnesium Chloride - by Dr. Carolyn Dean, 8.1 Fl Oz (2-Pack)                                                      | 0.0680         | ALS_Optuna_Tuned | 12          | 0.000000 |
| 126829 | B07BY7ZLYX  | Q-Link Acrylic SRT-3 Pendant (Sleek Blue)                                                                                                                                                               | 0.0497         | ALS_Optuna_Tuned | 11          | 0.000000 |
| 126859 | B0CB33QW6H  | JUNP Hydration Electrolyte Powder, Electrolytes Drink Mix Supplement, Zero Calories Sugar and Carbs, Kosher, Peach Flavor, 90 Servings                                                                  | 0.0190         | SASRec_Tuned     | 24          | 0.000000 |
| 126915 | B08L8D2XQF  | Elaine Wellness Hydrolyzed Collagen Powder Packets for Women, Convenient Single Travel Size Supplement for Skin, Hair, Joints and Nails, Protein Peptides Dissolve Easily, Unflavored (10 Gram, 7 Pack) | 0.0090         | SASRec_Tuned     | 54          | 0.000000 |
| 126846 | B0BQ47DNW2  | Kleenex Expressions Soothing Lotion Facial Tissues, 18 Cube Boxes, 65 Tissues Per Box (1,170 Tissues Total), Coconut Oil, Aloe & Vitamin E                                                              | 0.0058         | SASRec_Tuned     | 19          | 0.000000 |
| 126834 | B0BSRPX53Z  | Puffs Plus Lotion Facial Tissue (Old)                                                                                                                                                                   | 0.0017         | ALS_Optuna_Tuned | 13          | 0.000000 |
| 126961 | B082F2ZCMY  | Keto IV Electrolyte Drops + High Potassium   No Leak Dropper Bottle   500mg Potassium + Magnesium, Sodium & Zinc   Hint of Raspberry   30 Servings                                                      | -0.0201        | ALS_Optuna_Tuned | 77          | 0.000000 |

Рисунок 3.36 – Топ-10 рекомендацій після реранкінгу для 1 користувача

Джерело: розроблено автором за даними [92]

Гістограма новизни з рис. 3. 37 демонструє певне повернення до популярних товарів, виражений пік у діапазоні рангів 50-150 нагадує компроміс між бейзлайном та ALS. Тобто, реранкер оптимізував ймовірність покупки, відфільтрувавши ризиковані позиції з «довгого хвоста» і надав більший пріоритет товарам середнього та високого попиту, що забезпечила стабільнішу точність прогнозів.




Рисунок 3.37 – Розподіл Novelty@10 серед користувачів для LightGBM Reranker

Джерело: розроблено автором за даними [92]

Diversity@10 з рис. 3.38 демонструє значний прогрес у порівнянні з SASRec, наявний широкіший більш симетричний розподіл з центром в межах 0,50-0,55. Це доводить успішність ансамблювання, LightGBM сформувала фінальну видачу, що поєднує популярність із високою внутрішньою різноманітністю. Реранкер забезпечив збалансованіший вибір товарів за різними контекстами, уникаючи одноманітності.




Рисунок 3.38 – Розподіл Diversity@10 серед користувачів для LightGBM Reranker

Джерело: розроблено автором за даними [92]

Фінальний етап дослідження присвячено комплексному аналізу ефективності розроблених алгоритмів та можливих шляхів їхнього використання в електронній комерції. Отримані результати, відображені у таблиці 3.11, дозволяють визначити технічного лідера серед моделей та оцінити економічний потенціал кожного підходу в контексті бізнес-задач, від максимізації конверсії до стимулювання продажів більш нішевих товарів, так званого «довгого хвоста».

Таблиця 3.11 – Фінальні метрики побудованих моделей

| model                | Precision@10 | Recall@10 | MAP@10 | NDCG@10 | MRR    | Coverage@10 | AvgNoveltyRank@10 | AvgDiversity@10 |
|----------------------|--------------|-----------|--------|---------|--------|-------------|-------------------|-----------------|
| <b>LGBM_Reranker</b> | 0,0038       | 0,0354    | 0,0146 | 0,0197  | 0,0176 | 0,0008      | 159,7918          | 0,5182          |
| <b>SASRec</b>        | 0,0021       | 0,0191    | 0,0086 | 0,0113  | 0,0109 | 0,0009      | 16,0587           | 0,1967          |
| <b>Popularity</b>    | 0,0021       | 0,0189    | 0,0048 | 0,0082  | 0,0057 | 0,0002      | 5,5260            | 0,5194          |
| <b>ALS</b>           | 0,0014       | 0,0132    | 0,0045 | 0,0067  | 0,0052 | 0,0082      | 486,3262          | 0,5445          |
| <b>LightFM</b>       | 0,0010       | 0,0097    | 0,0039 | 0,0053  | 0,0043 | 0,0365      | 1184,8450         | 0,3751          |
| <b>User_kNN</b>      | 0,0008       | 0,0075    | 0,0036 | 0,0045  | 0,0038 | 0,1503      | 5582,3899         | 0,3895          |
| <b>Item_kNN</b>      | 0,0007       | 0,0067    | 0,0038 | 0,0045  | 0,0038 | 0,1501      | 6403,5891         | 0,2102          |
| <b>Two_Tower</b>     | 0,0004       | 0,0039    | 0,0020 | 0,0025  | 0,0020 | 0,2019      | 20738,9544        | 0,5744          |

Джерело: розроблено автором за даними [92]

Результати підтверджують перевагу дворівневої архітектури, оскільки лідером став LightGBM Reranker для якого NDCG@10=0,0197, що на 74% перевищує результат найближчого конкурента SASRec модель, і більше ніж удвічі

базову модель популярності, яка показала результат 0,0082. Показник Recall@10 на рівні 3,54% показує, що дворівнева архітектура здатна ідентифікувати найбільшу частку реальних покупок користувачів. Такі результати можна пояснити здатністю алгоритму градієнтного бустингу ефективно агрегувати сигнали від різних моделей-генераторів та враховувати широкий спектр додаткових ознак, таких як бренд, виробник, магазин, рейтинг ціна тощо.

Серед моделей першого рівня, що відповідають за пошук кандидатів, найкращу точність показала SASRec модель, для якої NDCG@10=0,0113. Механізм self-attention ефективно вловлює послідовні патерни поведінки споживачів, тобто дуже важливим є врахування часової динаміки, що підтверджує вища точність цієї моделі над ALS (0,0067) та Two-Tower (0,0025). Проте низька різноманітність – 0,1967 та новизна – 16,06 показують надмірну концентрацію на популярних товарах. Це може створити «фільтраційну бульбашку», обмежуючи видачу однотипними пропозиціями.

Моделі ALS, LightFM та Two-Tower, поступились у точності ранжування, але виявились незамінними для задачі відкриття нових нішевих товарів. Наприклад, Two-Tower продемонструвала феноменальне покриття 20,19% та новизну – 20739, це означає, що глибокі мережі ефективно активували «довгий хвіст» - така властивість є важливою, оскільки працює на розширення взаємодій з асортиментом та підтримки інтересу клієнтів.

Базуючись на технічних характеристиках моделей та аналізі результатів, варто виділити 3 можливі стратегічні напрямки їхнього використання для оптимізації економічних показників. Перша стратегія, спрямована на максимізацію конверсії та короткострокового доходу, передбачає використання LightGBM Reranker у зв'язці з SASRec у зонах високої конкуренції за увагу користувачів, що мінімізує «параліч вибору» та максимізує коефіцієнт клікабельності.

Другий напрямок може фокусувати на утриманні клієнтів та підвищенні середнього чека, базуючись на SASRec завдяки точності прогнозування наступної дії, вона є оптимальним інструментом для формування пропозицій у кошику, що сприяє зростанню позитивної цінності клієнта.

Третя стратегія націлена на монетизацію довгого хвоста за допомогою Two-Tower моделі, яка дозволяє знаходити цільову аудиторію для нішевих товарів, оптимізуючи складські запаси та підвищуючи загальну маржинальність продажів за рахунок товарів, які ігноруються класичними моделями націленими на максимізацію точності.

Для реалізації зазначених стратегій пропонується гібридна архітектура з паралельною генерацією, SASRec для поведінкового контексту, Two-Tower для нішевих товарів та Popularity для нових користувачів. Головним етапом є інтелектуальний реранкінг на базі LightGBM, який виступає фінальним посередником, фільтруючи шум та оптимізуючи видачу під бізнес-метрики. Такий комплексний підхід дозволяє перетворити рекомендаційну систему з пасивного інструменту реакції на попит в активний механізм його формування.

## ВИСНОВКИ

У кваліфікаційній роботі здійснено комплексне дослідження та практичне застосування модельного інструментарію створення рекомендаційних систем, проаналізовано теоретичні підходи до побудови товарних рекомендацій в умовах цифрового економічного середовища, виявлено фактори впливу на поведінку споживачів у системах електронної комерції, для конкретного сегмента побудовано комплекс рекомендаційних математичних моделей та сформовано персоналізовані рекомендації, які сприятимуть підвищенню ефективності економічної діяльності у сфері електронної комерції.

Розкрито роль рекомендаційних систем у сучасній електронній комерції. В умовах інформаційного перевантаження рекомендаційні системи стали основним економічним механізмом управління увагою споживачів. З позиції поведінкової економіки виявлено, що ефективність алгоритмів базується на зниженні когнітивного навантаження та використанні спрощених правил прийняття рішень, як, наприклад, соціальний доказ. Це вимагає від сучасних систем не тільки оптимізації точності, а й вирішення проблеми «парадоксу вибору» через балансування релевантності та різноманітності.

Проаналізовано існуючі методи побудови рекомендаційних систем, а саме класичні підходи: колаборативна фільтрація, матричні методи, а також алгоритми глибокого навчання (RNN, трансформери), навчання з підкріпленням та використання LLM для пропозицій. Досліджено напрями застосування сучасних інструментів математичного моделювання для розробки персоналізованих товарних рекомендацій у сфері електронної комерції, зокрема методи представлення текстів (embeddings), механізм уваги (self-attention) та алгоритмів ранжування. У роботі з'ясовано, що задачі створення товарних рекомендацій виходять за межі простої фільтрації товарів. В сучасну епоху Big Data рекомендаційні технології надають компаніям та платформам можливість застосовувати персоналізовані економічні моделі управління, які враховують

психологічні чинники. Таким чином, рекомендаційні системи заслуговують пильної уваги як перспективний механізм ефективної взаємодії попиту та пропозиції в сучасній економіці.

Визначено структуру та особливості формування інформаційної бази про взаємодію користувачів з товарами, властивості товарів та характеристики споживачів. Побудова розподілів та аналіз залежностей у даних виявив сильну нерівномірність попиту, де невелика кількість популярних товарів акумулює основну масу взаємодій, а також високу розрідженість даних. Встановлено зміщення рейтингів у бік позитивних оцінок, що обґрунтувало необхідність переходу до моделювання неявного зворотного зв'язку (*implicit feedback*). Проведено інжиніринг ознак для побудови товарних рекомендацій, застосовано BERT-ембединги, що дозволило згенерувати щільні вектори, які відображають зміст відгуків.

У роботі побудовано комплекс рекомендаційних моделей на базі інструментів машинного та глибокого навчання. Розроблено багаторівневу архітектуру, що включає низку моделей першого рівня (генерації кандидатів), зокрема Popularity Baseline, Item\_kNN, User\_kNN, ALS, LightFM, Two-Tower та SASRec, а також модель другого рівня (ранжування кандидатів) – LightGBM Reranker. Такий гібридний підхід дозволив поєднати переваги різних алгоритмів для вирішення проблеми «парадоксу вибору» через балансування релевантності та різноманітності пропозицій.

Обґрунтовано використання метрик для оцінювання ефективності та релевантності товарних пропозицій. Для об'єктивного аналізу якості роботи системи застосовано комбінований підхід, що поєднує дві групи показників: метрики точності ранжування (Precision, Recall, MAP, MRR, NDCG) та метрики якості списку (Coverage, Novelty, Diversity). Такий набір дозволив оцінити згенеровані рекомендації не лише за критерієм технічної точності прогнозів, а й за здатністю системи пропонувати різноманітні товари та максимально задовольняти потреби споживача.

Проаналізовано результати рекомендаційних моделей для конкретного ритейлера та сегменту косметичних засобів «Health and Personal Care» компанії Amazon. Порівняльний аналіз архітектур першого рівня виявив відмінності в логіці моделей. Послідовна модель SASRec стала лідером за точністю прогнозування NDCG@10 якої становить 0,0113, це підтверджує важливість врахування часової динаміки, хоча вона показала низьку новизну та різноманітність. Двовежева модель (Two-Tower) показала найкращі результати в метриках якості для відкриття нових товарів, досягнувши покриття каталогу у 20,19%, що робить її незамінною для монетизації більш нішевих товарів, які ігноруються іншими алгоритмами з високою точністю. Вирішальним фактором підвищення якості системи стало впровадження етапу реранкінгу на базі LightGBM. Дана модель другого рівня навчена на базі моделей генерації кандидатів дозволила досягти фінального показника NDCG@10 на рівні 0,0197, що на 74% перевищує результат найкращої моделі першого рівня.

Оцінено вплив поведінкових факторів на формування системи переваг споживачів, оскільки аналіз важливості ознак моделей LightFM, Two-Tower та LightGBM показав, що цінними факторами для прийняття рішення є не лише історія взаємодій, а й атрибути такі, як бренд, магазин, ціна та змістовна подібність текстів, які в повній мірі враховуються на етапі реранкінгу.

У роботі сформовано рекомендації щодо використання побудованих моделей для прийняття рішень та управління у сфері ритейлу. На основі отриманих результатів представлено практичні рекомендації щодо впровадження гібридної системи, які передбачають різне цільове використання моделей для досягнення відмінних бізнес-цілей, наприклад, SASRec разом з LightGBM можна використовувати для максимізації конверсії в сферах високої конкуренції за увагу користувачів, SASRec для підвищення середнього чека та утримання користувачів, Two-Tower модель для стимулювання попиту на товари «довгого хвоста».

Отже, результати роботи доводять що використання комплексних дворівневих систем на базі глибокого навчання є економічно доцільним, оскільки дозволяє платформам перейти від пасивної реакції на попит до його активного формування та забезпечення якісного персоналізованого клієнтського досвіду.

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Лаптев Д. Рекомендаційні системи та їх моделі. С. 152–153. URL: <https://api.dspace.khadi.kharkov.ua/server/api/core/bitstreams/b4d720f0-cb75-48a6-b87e-2b2d657cf6d5/content> (дата звернення: 17.11.2025).
2. Щербак Д. В. Система рекомендації навчальних матеріалів для персоналізації навчального шляху : Магістерська дисертація : 121. Київ, 2018. 94 с. URL: <https://files.core.ac.uk/download/pdf/323532858.pdf> (дата звернення: 17.11.2025).
3. Falk K. Practical Recommender Systems. Shelter Island : Manning Publications, 2019. 500 p. (date of access: 17.11.2025).
4. Голенко М. Ю. Область застосування та види рекомендаційних систем. *Державний університет «Житомирська політехніка»*. URL: <https://surl.li/gdqqr> (дата звернення: 17.11.2025).
5. Pires A. J. G., Mardan M., Tremblay M. Recommender systems and competitive harm: Emerging Challenges for Competition Policy. *Konkurransetilsynet (The Norwegian Competition Authority)*. 2025. URL: <https://konkurransetilsynet.no/wp-content/uploads/2025/10/v2023-6-Pires-et-al.-2025-Recommender-systems-and-competitive-harm.pdf> (date of access: 24.11.2025).
6. Budzinski O., Gänßle S., Lindstädt-Dreusicke N. Data (r)evolution – The economics of algorithmic search and recommender services. *Ilmenau Economics Discussion Papers*. 2021. No. 148. URL: <https://www.econstor.eu/bitstream/10419/228752/1/174515275X.pdf> (date of access: 24.11.2025).
7. Poniszewska-Maranda A., Pakula M., Borowska B. Recommendation systems in e-commerce applications with machine learning methods. *arXiv*. 2025. URL: <https://arxiv.org/pdf/2506.17287> (date of access: 24.11.2025).

8. He Y., Du Y., Pu X. Personalized Recommendation System of E-Commerce in the Digital Economy Era: Enhancing Social Connections with Graph Attention Networks. *Applied Artificial Intelligence*. 2025. Vol. 39, no. 1. Article e2487417. URL: <https://doi.org/10.1080/08839514.2025.2487417> (date of access: 24.11.2025).
9. Hickok N. Algorithm Design Meets Information Design: Price Recommendation Algorithms on Online Platforms. 2024. 1 August. URL: [https://economics.mit.edu/sites/default/files/inline-files/Platform%20Price%20Recommendations\\_1.pdf](https://economics.mit.edu/sites/default/files/inline-files/Platform%20Price%20Recommendations_1.pdf) (date of access: 17.11.2025).
10. The Informational Role of Online Recommendations: Evidence from a Field Experiment / G. Aridor et al. *CESifo Working Papers*. 2024. URL: [https://www.ifo.de/DocDL/cesifo1\\_wp10129.pdf](https://www.ifo.de/DocDL/cesifo1_wp10129.pdf) (date of access: 18.11.2025).
11. Mauro N., Hu Z. F., Ardissono L. Justification of recommender systems results: a service-based approach. *User Modeling and User-Adapted Interaction*. 2022. URL: <https://doi.org/10.1007/s11257-022-09345-8> (date of access: 30.11.2025).
12. Harnessing the Power of User-Centric Artificial Intelligence: Customized Recommendations and Personalization in Hybrid Recommender Systems / C. Troussas et al. *Computers*. 2023. Vol. 12, no. 5. P. 109. URL: <https://doi.org/10.3390/computers12050109> (date of access: 30.11.2025).
13. Pearl C., Relevance: The Remedy for the Paradox of Choice. *Rokt* 2024. URL: <https://www.rokt.com/blog/relevance-the-remedy-for-the-paradox-of-choice> (date of access: 17.11.2025).
14. Wanja I., Too Many Options? The Effect Of The Paradox Of Choice On Ecommerce. *Build Grow Scale*. 2023. URL: <https://buildgrowscale.com/paradox-of-choice> (date of access: 17.11.2025).
15. Басистюк О., Рибчак З. Застосування рекомендаційних системи в електронній комерції. *Вісник Національного університету «Львівська політехніка»*. Серія: Інформаційні системи та мережі. 2024. Vol. 15. P. 252–259. URL: <https://doi.org/10.23939/sisn2024.15.252> (дата звернення: 24.11.2025).
16. Демченко М. О. Дослідження технологій рекомендацій для систем електронної комерції : пояснювальна записка до кваліфікаційної роботи здобувача

вищої освіти на другому (магістерському) рівні, спеціальність 121 – Інженерія програмного забезпечення / М. О. Демченко ; М-во освіти і науки України , Харків. нац. ун-т радіоелектроніки. - Харків, 2024. - 54 с. URL: <https://openarchive.nure.ua/handle/document/29851> (дата звернення: 24.11.2025).

17. Lin Y., The Paradox of Choice: Why Too Many Options Hurt Conversions. 2025. *Cognitive Clicks*. URL: <https://cognitive-clicks.com/blog/the-paradox-of-choice/> (date of access: 17.11.2025).

18. The Choice Overload Effect in Online Recommender Systems / X. Long et al. *Manufacturing & Service Operations Management*. 2024. URL: <https://doi.org/10.1287/msom.2022.0659> (date of access: 17.11.2025).

19. Яковенко Р.В., Homo economicus («людина економічна») та її еволюція. 2020, URL: <https://tusovka.kr.ua/news/2020/04/18/homo-economicus-ljudina-ekonomichna-ta-ii-evoljutsija> (дата звернення: 24.11.2025).

20. Chatterjee D., Daniel Kahneman Changed How We Think About Consumer Choice And Brand Strategy. *Forrester*. 2024. URL: <https://www.forrester.com/blogs/daniel-kahneman-changed-how-we-think-about-consumer-choice-and-brand-strategy/> (date of access: 17.11.2025).

21. Whiting K., What we learned about effective decision making from Nobel laureate Daniel Kahneman. *World Economic Forum*. 2024. URL: <https://www.weforum.org/stories/2024/03/what-we-learned-from-nobel-winner-daniel-kahneman/> (date of access: 17.11.2025).

22. Tamilarasi R. Behavioral Economics and Consumer Decision-Making in the Digital Age. 2025. DOI: 10.25215/2455/1003024. (date of access: 17.11.2025).

23. Daniel Kahneman Explains The Machinery of Thought. *Farnam Street Media Inc*. URL: <https://fs.blog/daniel-kahneman-the-two-systems/> (date of access: 17.11.2025).

24. Shleifer A., Psychologists at the Gate: A Review of Daniel Kahneman's Thinking, Fast and Slow *Journal of Economic Literature* Vol. 50, No. 4, 2012. URL: <http://dx.doi.org/10.1257/jel.50.4.1> (date of access: 26.11.2025).

25. From Page to Practice: Applying 'Thinking, Fast and Slow' to Consumer Behaviour. *The Unconscious Consumer*. 2023. URL: <https://www.theunconsciousconsumer.com/behavioural-economics/2023/6/13/from-page-to-practice-applying-thinking-fast-and-slow-to-consumer-behavior> (date of access: 26.11.2025)
26. Hardesty L., The history of Amazon's recommendation algorithm. *Amazon Science*. 2019. URL: <https://www.amazon.science/the-history-of-amazons-recommendation-algorithm> (date of access: 26.11.2025)
27. Krämer W. Kahneman, D. (2011): Thinking, Fast and Slow. *Statistical Papers*. 2013. Vol. 55, no. 3. P. 915. URL: <https://doi.org/10.1007/s00362-013-0533-y> (date of access: 26.11.2025)
28. Cognitive Biases in Large Language Models for News Recommendation / Y. Lyu et al. *arXiv*. 2024. URL: <https://doi.org/10.48550/arXiv.2410.02897> (date of access: 27.11.2025).
29. Do Recommender Systems Manipulate Consumer Preferences? A Study of Anchoring Effects / G. Adomavicius et al. *Information Systems Research*. 2013. Vol. 24, no. 4. P. 956–975. URL: <https://doi.org/10.1287/isre.2013.0497> (date of access: 27.11.2025).
30. Decision Making in Addictive Behaviors Based on Prospect Theory: A Systematic Review / J. Cabedo-Peris et al. *Healthcare*. 2022. Vol. 10, no. 9. P. 1659. URL: <https://doi.org/10.3390/healthcare10091659> (date of access: 27.11.2025).
31. Gisbert-Pérez J., Martí-Vilar M., González-Sala F. Prospect Theory: A Bibliometric and Systematic Review in the Categories of Psychology in Web of Science. *Healthcare*. 2022. Vol. 10, no. 10. P. 2098. URL: <https://doi.org/10.3390/healthcare10102098> (date of access: 30.11.2025).
32. Purchasing Decisions with Reference Points and Prospect Theory in the Metaverse / T. Tarnanidis et al. *Administrative Sciences*. 2025. Vol. 15, No. 8. P. 287. URL: <https://doi.org/10.3390/admsci15080287> (date of access: 26.11.2025)
33. Berthet V. The Impact of Cognitive Biases on Professionals' Decision-Making: A Review of Four Occupational Areas. *Frontiers in Psychology*. 2022. Vol. 12. URL: <https://doi.org/10.3389/fpsyg.2021.802439> (date of access: 26.11.2025)
34. D. Odom M., Bahmanziari T. Prospect Theory and Risky Choice in the Ecommerce Setting: Evidence of a Framing Effect. *Academy of Accounting and Financial Studies Journal*. 2015. Vol. 19. P. 85–106. URL: [https://www.researchgate.net/publication/265012027\\_Prospect\\_Theory\\_and\\_Risky\\_Choice\\_in\\_the\\_Ecommerce\\_Setting\\_Evidence\\_of\\_a\\_Framing\\_Effect](https://www.researchgate.net/publication/265012027_Prospect_Theory_and_Risky_Choice_in_the_Ecommerce_Setting_Evidence_of_a_Framing_Effect) (date of access: 26.11.2025).

35. Recommender Systems, Consumer Preferences, and Anchoring Effects / G. Adomavicius et al. *ACM Conference on Recommender Systems*. 2011. URL: <https://www.semanticscholar.org/paper/Recommender-systems,-consumer-preferences,-and-Adomavicius-Bockstedt/4552ba5ac5cbb6c556ebd228c8f9116b46793bc2> (date of access: 26.11.2025).
36. The Importance of Cognitive Biases in the Recommendation Ecosystem / M. Schedl et al. 2024. URL: <https://doi.org/10.48550/arXiv.2408.12492> (date of access: 19.11.2025).
37. Кравченко О. В. Нейромережева рекомендаційна система для вибору товару на основі оглядів користувачів і продуктів : Магістерська дисертація. Київ, 2022. 135 с. URL: <https://ela.kpi.ua/server/api/core/bitstreams/d3ba835a-6904-4f66-b8f8-e531a3bbf4bf/content> (дата звернення: 26.11.2025).
38. Ali S., Cognitive Biases in Digital Decision Making: How Consumers Navigate Information Overload (Consumer Behavior). *Advances in Consumer Research*. Vol. 2, No. 1. URL: <https://acr-journal.com/article/cognitive-biases-in-digital-decision-making-how-consumers-navigate-information-overload-consumer-behavior--889> (date of access: 26.11.2025)
39. Пономаренко І.В., Битик О.Б., Використання рекомендаційних систем для оптимізації маркетингової стратегії компанії. *Підприємництво та інновації*. . URL: <https://doi.org/10.37320/2415-3583/19.5> (date of access: 26.11.2025).
40. 31 Personalized Shopping Experience Statistics That Prove AI-Driven Commerce Wins in 2025. *Envive*. URL: <https://www.envive.ai/post/personalized-shopping-experience-statistics> (date of access: 26.11.2025).
41. Vaghasiya K. 50+ E-commerce Personalization Statistics & Trends (2025). *WiserNotify*. URL: <https://wisernotify.com/blog/ecommerce-personalization-stats/> (date of access: 29.11.2025).
42. Ecommerce personalization statistics essential for your online store. *Nosto*. URL: <https://www.nosto.com/blog/ecommerce-personalization-statistics/> (date of access: 29.11.2025).
43. Personalization at Scale: How AI is Enhancing Customer Experiences in 2025. *SuperAGI*. URL: <https://superagi.com/personalization-at-scale-how-ai-is-enhancing-customer-experiences-in-2025/> (date of access: 29.11.2025).
44. Nurdin A. A., Abidin Z. The Influence of Recommendation System Quality on E-commerce Customer Loyalty with Cognition Affective Behavior Theory. *Journal of*

*Advances in Information Systems and Technology*. 2023. Vol. 5, no. 1. P. 1–11.  
URL: <https://doi.org/10.15294/jaist.v5i1.65910> (date of access: 29.11.2025).

45. Ходзіцький О. М. Інтелектуальна рекомендаційна система електронної комерції: Магістерська кваліфікаційна робота: 122. Миколаїв, 2023. 84 с.  
URL: <https://krs.chmnu.edu.ua/jspui/bitstream/123456789/2686/1/Ходзіцький.pdf> (дата звернення: 18.11.2025).

46. Antoniuk S. Netflix's Algorithm: How Does Netflix Use AI to Personalize Recommendations?. *LITSLINK Inc.* URL: <https://litslink.com/blog/all-about-netflix-artificial-intelligence-the-truth-behind-personalized-content> (date of access: 18.11.2025).

47. Wang L., Jiang Z., Qu G. Digital Business Model Innovation in Complex Environments: A Knowledge System Perspective. *Systems*. 2025. Vol. 13, no. 5. P. 379.  
URL: <https://doi.org/10.3390/systems13050379> (date of access: 29.11.2025).

48. Horváth T., de Carvalho A. C. P. L. F. Evolutionary computing in recommender systems: a review of recent research. *Natural Computing*. 2016. Vol. 16, no. 3. P. 441–462. URL: <https://doi.org/10.1007/s11047-016-9540-y> (date of access: 29.11.2025).

49. A Comprehensive Review of Recommender Systems: Transitioning from Theory to Practice / S. Raza, M. Rahman, S. Kamawal et al. *arXiv*. 2024. URL: <https://arxiv.org/abs/2407.13699> (дата звернення: 28.11.2025).

50. Nicoomanesh A. Evolution of Recommendation Algorithms, Part I: Fundamentals , History Overview, Core and Classical Algorithms. *Medium*. URL: <https://medium.com/@anicomanesh/evolution-of-recommendation-algorithms-part-i-fundamentals-and-classical-recommendation-bb1c0bce78a9> (date of access: 20.11.2025).

51. Hazrati N., Ricci F. Recommender systems effect on the evolution of users' choices distribution. *Information Processing & Management*. 2022. Vol. 59, no. 1. P. 102766. URL: <https://doi.org/10.1016/j.ipm.2021.102766> (date of access: 29.11.2025).

52. Review-based Recommender Systems: A Survey of Approaches, Challenges and Future Perspectives / E. Hasan et al. *arXiv*. 2025. URL: <https://doi.org/10.48550/arXiv.2405.05562> (date of access: 19.11.2025).
53. Behera G., Nain N. The State-of-the-Art and Challenges on Recommendation System's: Principle, Techniques and Evaluation Strategy. *SN COMPUT. SCI*. 2023. Vol. 4. 677. URL: <https://doi.org/10.1007/s42979-023-02207-z> (date of access: 20.11.2025).
54. Shah L., Gaudani H., Balani P. Survey on Recommendation System. *International Journal of Computer Applications*. 2016. Vol. 137, no. 7. P. 43–48. URL: <https://scispace.com/pdf/survey-on-recommendation-system-1jy9q1von0.pdf> (date of access: 20.11.2025).
55. М. Даниленко, І. Колесник, «Методи розробки рекомендаційних систем», *ITKI*, вип. 52, вип. 3, с. 10–15, Груд 2021. URL: <https://doi.org/10.31649/1999-9941-2021-52-3-10-15> (дата звернення: 18.11.2025).
56. Context-Aware Recommender Systems / G. Adomavicius et al. *AI Magazine*. 2011. Vol. 32, no. 3. P. 67. URL: <https://doi.org/10.1609/aimag.v32i3.2364> (date of access: 29.11.2025).
57. Himanshu. Collaborative Filtering-Based Recommender Systems: A Deep Dive. *Futureweb AI*. URL: <https://futurewebai.com/blogs/collaborative-filtering-based-recommendation> (date of access: 27.11.2025).
58. What is the difference between user-based and item-based collaborative filtering?. *Milvus*. URL: <https://milvus.io/ai-quick-reference/what-is-the-difference-between-userbased-and-itembased-collaborative-filtering> (date of access: 26.11.2025).
59. Deep Learning based Recommender System: A Survey and New Perspectives / S. Zhang et al. *ACM Computing Surveys*. 2018. Vol. 1, no. 1. P. 35. URL: <https://arxiv.org/pdf/1707.07435> (date of access: 19.11.2025).
60. Koren Y., Bell R., Volinsky C. Matrix Factorization Techniques for Recommender Systems. *Computer*. 2009. Vol. 42, no. 8. P. 30–37. URL: <https://doi.org/10.1109/mc.2009.263> (date of access: 29.11.2025).

61. What is matrix factorization in recommender systems?. *Milvus*. URL: <https://blog.milvus.io/ai-quick-reference/what-is-matrix-factorization-in-recommender-systems> (date of access: 25.11.2025).
62. Athar A. Building Advanced Recommendation Systems: Matrix Factorization and Deep Learning. *Medium*. URL: <https://afafathar.medium.com/building-advanced-recommendation-systems-matrix-factorization-and-deep-learning-19dabbclf4ed> (date of access: 19.11.2025).
63. Lops, P., de Gemmis, M., Semeraro, G. Content-based Recommender Systems: State of the Art and Trends. *Springer*. URL: [https://doi.org/10.1007/978-0-387-85820-3\\_3](https://doi.org/10.1007/978-0-387-85820-3_3) (date of access: 26.11.2025).
64. P V Akhil. A survey of recommender system types and its classification. *International Journal of Advanced Research in Computer Science*. 2017. Vol. 8, no. 9. P. 486–491. URL: <https://doi.org/10.26483/ijarcs.v8i9.5017> (date of access: 30.11.2025).
65. Chiang J. 7 Types of Hybrid Recommendation System. *Medium*. URL: <https://medium.com/analytics-vidhya/7-types-of-hybrid-recommendation-system-3e4f78266ad8> (date of access: 25.11.2025).
66. Feature-Weighted Linear Stacking / J. Sill et al. *arXiv*. 2009. URL: <https://doi.org/10.48550/arXiv.0911.0460> (date of access: 25.11.2025).
67. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. *Springer*. 2009. URL: <https://doi.org/10.1007/978-0-387-84858-7> (date of access: 21.11.2025).
68. Foundation Models for Recommender Systems: A Survey and New Perspectives / C. Huang et al. *arXiv*. 2024. URL: <https://doi.org/10.48550/arXiv.2402.11143> (date of access: 19.11.2025).
69. Neural Collaborative Filtering / X. He et al. *ACM Digital Library*. 2017. P. 173–182. URL: <https://doi.org/10.1145/3038912.3052569> (date of access: 26.11.2025).

70. Xiangnan He et al. Neural Collaborative Filtering. *DeepAI*. URL: <https://deepai.org/publication/neural-collaborative-filtering> (date of access: 30.11.2025).
71. Recommendation System Using Autoencoders / D. Ferreira et al. *Applied Sciences*. 2020. Vol. 10, no. 16. P. 5510. URL: <https://doi.org/10.3390/app10165510> (date of access: 30.11.2025).
72. Session-based recommendations with recurrent neural networks / B. Hidasi et al. *ICLR 2016*. 2016. URL: <https://arxiv.org/pdf/1511.06939> (date of access: 18.11.2025).
73. Kang W.-C., McAuley J. Self-Attentive Sequential Recommendation. *arXiv*. 2018. URL: <https://doi.org/10.48550/arXiv.1808.09781> (date of access: 23.11.2025).
74. Afsar M. M., Crump T., Far B. Reinforcement Learning based Recommender Systems: A Survey. *Association for Computing Machinery*. 2018. Vol. 1, no. 1. P. 37. URL: <https://doi.org/10.1145/1122445.1122456> (date of access: 19.11.2025).
75. Shah S. Introduction to Matrix Factorization for Recommender Systems. 2021. URL: <https://doi.org/10.31219/osf.io/pnd5w> (date of access: 21.11.2025).
76. Червіцька К. В. Рекомендаційна система для електронної бібліотеки для молодих авторів. *Project, Program, Portfolio Management : The Seventh International Scientific-practical Conference*, м. Одеса, 3 груд. 2022 р. Одеса, 2022. С. 22–26. URL: <https://er.chdtu.edu.ua/bitstream/ChSTU/4631/1/Одеса%2022-23.pdf> (дата звернення: 22.11.2025).
77. Носик К. Розробка методів формування рекомендацій в інформаційній системі з використанням інструментів нечіткої логіки : Магістерська кваліфікаційна робота : 122. Харків, 2022. 75 с. URL: <https://openarchive.nure.ua/server/api/core/bitstreams/2da7a79b-a272-4584-bd37-ea6138f7e453/content> (дата звернення: 23.11.2025).
78. Количева П. А., Волощук О. Б. Дослідження методів побудови рекомендаційних систем з використанням графових нейронних мереж. *Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління*.

C. 21. URL: <https://openarchive.nure.ua/server/api/core/bitstreams/flacaca4-1e62-4068-b967-7f3606a6bb4d/content> (дата звернення: 24.11.2025).

79. Pyshnograiev I., Shyralliev A. Comprehensive Benchmark of Collaborative Filtering Methods on Implicit Feedback Datasets. *Electronics and Control Systems*. 2025. Vol. 2, no. 84. P. 34–45. URL: <https://doi.org/10.18372/1990-5548.84.20192> (date of access: 30.11.2025).

80. Personalized Federated Collaborative Filtering: A Variational AutoEncoder Approach / Z. Li et al. *arXiv*. 2024. URL: <https://arxiv.org/html/2408.08931v1> (date of access: 25.11.2025).

81. AutoRec: Autoencoders Meet Collaborative Filtering / S. Sedhain et al. *24th International World Wide Web Conference*, Florence Italy. New York, NY, USA, 2015. URL: <https://doi.org/10.1145/2740908.2742726> (date of access: 30.11.2025).

82. Reinforcement Learning to Optimize Long-term User Engagement in Recommender Systems / L. Zou et al. *arXiv*. 2019. URL: <https://doi.org/10.48550/arXiv.1902.05570> (date of access: 25.11.2025).

83. Large Language Models are Zero-Shot Rankers for Recommender Systems / Y. Hou et al. *arXiv*. 2024. URL: <https://doi.org/10.48550/arXiv.2305.08845> (date of access: 28.11.2025).

84. Is ChatGPT a Good Recommender? A Preliminary Study / J. Liu et al. *arXiv*. 2023. URL: <https://doi.org/10.48550/arXiv.2304.10149> (date of access: 21.11.2025).

85. Beyond-accuracy: a review on diversity, serendipity, and fairness in recommender systems based on graph neural networks / T. Duricic et al. *Frontiers in Big Data*. 2023. Vol. 6. URL: <https://doi.org/10.3389/fdata.2023.1251072> (date of access: 30.11.2025).

86. Kunaver M., Požrl T. Diversity in recommender systems – A survey. *Knowledge-Based Systems*. 2017. Vol. 123. P. 154–162. URL: <https://doi.org/10.1016/j.knosys.2017.02.009> (date of access: 30.11.2025).

87. Tutorial on Large Language Models for Recommendation / W. Hua et al. *RecSys '23: Seventeenth ACM Conference on Recommender Systems*, Singapore

Singapore. New York, NY, USA, 2023.  
URL: <https://doi.org/10.1145/3604915.3609494> (date of access: 30.11.2025).

88. A survey on causal inference for recommendation / H. Luo et al. *The Innovation*. 2024. P. 100590. URL: <https://doi.org/10.1016/j.xinn.2024.100590> (date of access: 30.11.2025).

89. Law C. Causal-Inference-for-Recommendation. *GitHub*. URL: <https://github.com/Chrissie-Law/Causal-Inference-for-Recommendation> (date of access: 30.11.2025).

90. A Comprehensive Survey on Privacy-Preserving Techniques in Federated Recommendation Systems / M. Asad et al. *Applied Sciences*. 2023. Vol. 13, no. 10. P. 6201. URL: <https://doi.org/10.3390/app13106201> (date of access: 30.11.2025).

91. A Comprehensive Survey on Cross-Domain Recommendation: Taxonomy, Progress, and Prospects / H. Zhang et al. *arXiv*. 2025. URL: <https://doi.org/10.48550/arXiv.2503.14110> (date of access: 20.11.2025).

92. Amazon Reviews 23. *McAuley Lab*. URL: <https://amazon-reviews-2023.github.io/> (date of access: 27.11.2025).

93. Lakkaraju H., McAuley J., Leskovec J. Understanding the interplay between titles, content, and communities in social media. *ICWSM*. URL: [https://cseweb.ucsd.edu/~jmcauley/datasets.html#amazon\\_reviews](https://cseweb.ucsd.edu/~jmcauley/datasets.html#amazon_reviews) (date of access: 17.11.2025).

94. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding / J. Devlin et al. *arXiv*. 2019. URL: <https://doi.org/10.48550/arXiv.1810.04805> (date of access: 28.11.2025).

95. Malyha I., Shmatkov S. Analysis of the influence of different word vector representations on the accuracy of text data classification. *Bulletin of V.N. Karazin Kharkiv National University, series «Mathematical modeling. Information technology. Automated control systems»*. 2023. No. 59. P. 49–55. URL: <https://doi.org/10.26565/2304-6201-2023-59-05> (date of access: 30.11.2025).

96. Attention Is All You Need / A. Vaswani et al. *arXiv*. 2023. URL: <https://doi.org/10.48550/arXiv.1706.03762> (date of access: 27.11.2025).

97. Hu Y., Koren Y., Volinsky C. Collaborative Filtering for Implicit Feedback Datasets. *2008 Eighth IEEE International Conference on Data Mining (ICDM)*, Pisa, Italy, 15–19 December 2008. 2008. URL: <https://doi.org/10.1109/icdm.2008.22> (date of access: 30.11.2025).
98. Implement two-tower retrieval for large-scale candidate generation. *Google Cloud Documentation*. URL: <https://docs.cloud.google.com/architecture/implement-two-tower-retrieval-large-scale-candidate-generation> (date of access: 28.11.2025).
99. Dacrema M. F., Cremonesi P., Jannach D. Are we really making much progress? A worrying analysis of recent neural recommendation approaches. *RecSys '19: Thirteenth ACM Conference on Recommender Systems*, Copenhagen Denmark. New York, NY, USA, 2019. URL: <https://doi.org/10.1145/3298689.3347058> (date of access: 30.11.2025).
100. Item-based collaborative filtering recommendation algorithms / B. Sarwar et al. *the tenth international conference*, Hong Kong, Hong Kong, 1–5 May 2001. New York, New York, USA, 2001. URL: <https://doi.org/10.1145/371920.372071> (date of access: 30.11.2025).
101. Faiss. *GitHub*. URL: <https://github.com/facebookresearch/faiss> (date of access: 28.11.2025).
102. GroupLens: an open architecture for collaborative filtering of netnews / P. Resnick et al. *the 1994 ACM conference*, Chapel Hill, North Carolina, United States, 22–26 October 1994. New York, New York, USA, 1994. URL: <https://doi.org/10.1145/192844.192905> (date of access: 30.11.2025).
103. Optuna: A Next-generation Hyperparameter Optimization Framework / T. Akiba et al. *arXiv*. 2019. URL: <https://doi.org/10.48550/arXiv.1907.10902> (date of access: 28.11.2025).
104. Kula M. Metadata Embeddings for User and Item Cold-start Recommendations. *arXiv*. URL: <https://doi.org/10.48550/arXiv.1507.08439> (date of access: 28.11.2025).
105. Weston J., Bengio S., Usunier N. WSABIE: Scaling Up To Large Vocabulary Image Annotation. *Twenty-Second International Joint Conference on*

*Artificial Intelligence*. 2011. P. 2764–2770. URL: <https://doi.org/10.5591/978-1-57735-516-8/IJCAI11-460> (date of access: 28.11.2025).

106. Two-Tower Recommendation System. *GitHub*. URL: <https://github.com/ObliviateRickLin/nano-two-tower-rec> (date of access: 30.11.2025).

107. van den Oord A., Li Y., Vinyals O. Representation Learning with Contrastive Predictive Coding. *arXiv*. 2019. URL: <https://doi.org/10.48550/arXiv.1807.03748> (date of access: 28.11.2025).

108. Petrov A., Macdonald C. Effective and Efficient Training for Sequential Recommendation using Recency Sampling. *RecSys '22: Sixteenth ACM Conference on Recommender Systems*, Seattle WA USA. New York, NY, USA, 2022. URL: <https://doi.org/10.1145/3523227.3546785> (date of access: 30.11.2025).

109. RecSys '16: Proceedings of the 10th ACM Conference on Recommender Systems / S. Sen et al. *Association for Computing Machinery*. 2016. URL: <https://dl.acm.org/doi/proceedings/10.1145/2959100> (date of access: 28.11.2025).

110. LightGBM: A Highly Efficient Gradient Boosting Decision Tree / G. Ke et al. *31st Conference on Neural Information Processing Systems (NIPS 2017)*. 2017. URL: <https://dl.acm.org/doi/pdf/10.5555/3294996.3295074> (date of access: 28.11.2025).

111. Burges C. J. From RankNet to LambdaRank to LambdaMART: An Overview. 2010. URL: <https://scispace.com/pdf/from-ranknet-to-lambdarank-to-lambdamart-an-overview-zdiueds8pr.pdf> (date of access: 28.11.2025).

112. Shani G., Gunawardana A. Evaluating Recommendation Systems. URL: <https://tzin.bgu.ac.il/~shanigu/Publications/EvaluationMetrics.17.pdf> (date of access: 28.11.2025).

113. McNee S. M., Riedl J., Konstan J. A. Being Accurate is Not Enough: How Accuracy Metrics have hurt Recommender Systems. *CHI '06 extended abstracts*, Montréal, Québec, 22–27 April 2006. New York, New York, USA, 2006. URL: <https://doi.org/10.1145/1125451.1125659> (date of access: 30.11.2025).

114. Evidently AI Team. Precision and recall at K in ranking and recommendations. *Evidently AI*. URL: <https://www.evidentlyai.com/ranking-metrics/precision-recall-at-k> (date of access: 30.11.2025).

115. Evidently AI Team. Mean Reciprocal Rank (MRR) explained. *Evidently AI*. URL: <https://www.evidentlyai.com/ranking-metrics/mean-reciprocal-rank-mrr> (date of access: 28.11.2025).

116. Sleightholm E. What is Normalized Discounted Cumulative Gain (NDCG)?. *Marqo*. URL: <https://www.marqo.ai/blog/what-is-normalized-discounted-cumulative-gain-ndcg> (date of access: 28.11.2025).

117. Ge M., Delgado-Battenfeld C., Jannach D. Beyond accuracy: evaluating recommender systems by coverage and serendipity. *the fourth ACM conference*, Barcelona, Spain, 26–30 September 2010. New York, New York, USA, 2010. URL: <https://doi.org/10.1145/1864708.1864761> (date of access: 30.11.2025).

118. Introduction to Novelty in Recommendation Systems. *CodeSignal*. URL: <https://codesignal.com/learn/courses/recommendation-systems-quality-evaluation/lessons/novelty-in-recommendation-systems> (date of access: 30.11.2025).

119. IntraListDiversity. *RecTools*. URL: <https://rectools.readthedocs.io/en/latest/api/rectools.metrics.diversity.IntraListDiversity.html> (date of access: 29.11.2025).

## ДОДАТКИ

## Додаток А

Таблиця А.1 – Фрагмент початкового датасету взаємодії користувачів

| № | rating | review_title                                      | text                                              | images | asin       | parent_asin | user_id                                           | timestamp                  | helpful_vote | verified_purchase | year | log_helpful_vote | text_length |
|---|--------|---------------------------------------------------|---------------------------------------------------|--------|------------|-------------|---------------------------------------------------|----------------------------|--------------|-------------------|------|------------------|-------------|
| 1 | 4      | 12 mg is 12 on the periodic table people! Mg f... | This review is more to clarify someone else's ... | []     | B07TDSJZMR | B07TDSJZMR  | AFKZE<br>NTNBQ<br>7A7V7U<br>XW5JJI6<br>UGRYQ      | 06.02.2020<br>0:49         | 3            | TRUE              | 2020 | 1.386294         | 869         |
| 2 | 5      | Save the planet using less plastic.               | Love these easy multitasking bleach tablets. B... | []     | B08637FWWF | B08637FWWF  | AEVWA<br>M3YWN<br>5URJVJI<br>ZZ6XPD<br>2MKIA      | 02.11.2020<br>22:03        | 3            | TRUE              | 2020 | 1.386294         | 165         |
| 3 | 5      | Fantastic                                         | I have been suffering a couple months with hee... | []     | B07KJVGNN5 | B07KJVGNN5  | AHSPL<br>DNW5O<br>OUK2PL<br>H7GXL<br>ACFBZ<br>NQ  | 24.07.2019<br>11:13        | 0            | TRUE              | 2019 | 0.000000         | 224         |
| 4 | 4      | It holds the water and makes bubbles. That's ...  | It's cheap and it does what I wanted. The "ma...  | []     | B007HY7GC2 | B092RP73CX  | AEZGPL<br>OYTSA<br>PR3DHZ<br>KKXEF<br>PAXUA<br>A  | 04.09.2022<br>2:29         | 7            | TRUE              | 2022 | 2.079442         | 251         |
| 5 | 1      | Not for me                                        | Didn't do a thing for me. Not saying they don'... | []     | B08KYJLF5T | B08KYJLF5T  | AEQAY<br>V7RXZE<br>BXMQUI<br>QPL6KC<br>T2CFW<br>Q | 20.01.2022<br>23:53        | 0            | TRUE              | 2022 | 0.000000         | 66          |
| 6 | 5      | Every home should have these                      | I have never been big on vitamins, with the ex... | []     | B09GBMG83Z | B09GBMG83Z  | AFSKPY<br>37N3C4<br>3SOI5IE<br>XEK5JSI<br>YA      | 21.02.2020<br>0:14         | 1            | FALSE             | 2022 | 0.693147         | 546         |
| 7 | 4      | Versatile shaver                                  | To be honest, my husband did not use this for ... | []     | B09FKT5PQ9 | B09FKT5PQ9  | AFSKPY<br>37N3C4<br>3SOI5IE<br>XEK5JSI<br>YA      | 2022-02-07<br>20:38:46.005 | 0            | FALSE             | 2022 | 0.000000         | 520         |

|    |   |                                                   |                                                   |    |            |            |                              |                  |   |       |      |          |     |
|----|---|---------------------------------------------------|---------------------------------------------------|----|------------|------------|------------------------------|------------------|---|-------|------|----------|-----|
| 8  | 4 | Makes a nice compact noise machine to take wit... | This is a nice basic sound machine. I have use... | [] | B08THJD1MH | B08THJD1MH | AFSKPY37N3C43SOI5IEXEK5JSIYA | 08.04.2021 18:45 | 0 | FALSE | 2021 | 0.000000 | 612 |
| 9  | 5 | Great drawstring holiday bags!                    | This are super colorful great gift giving holi... | [] | B08FCQML37 | B08FCQML37 | AFSKPY37N3C43SOI5IEXEK5JSIYA | 15.12.2021 21:15 | 0 | FALSE | 2020 | 0.000000 | 382 |
| 10 | 3 | Not as good as the name brand whitening strips... | I guess the only product I have in my history ... | [] | B08GYM3HVP | B08GYM3HVP | AFSKPY37N3C43SOI5IEXEK5JSIYA | 14.10.2021 21:25 | 0 | FALSE | 2020 | 0.000000 | 464 |

Таблиця А.2 – Фрагмент початкових даних опису товарів

| № | main_category          | title                                              | average_rating | rating_number | features                                            | description                                        | price | images                                           | videos | store  | categories | details                                            | parent_asin | bought_together |
|---|------------------------|----------------------------------------------------|----------------|---------------|-----------------------------------------------------|----------------------------------------------------|-------|--------------------------------------------------|--------|--------|------------|----------------------------------------------------|-------------|-----------------|
| 1 | Health & Personal Care | Silicone Bath Body Brush Exfoliator Shower Bac...  | 3.9            | 7             | []                                                  | []                                                 | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []     | Rzoeox | []         | {'Package Dimensions': '15 x 3.3 x 1.5 inches;...  | B07V346GZH  | NaN             |
| 2 | Health & Personal Care | iPhone 7 Plus 8 Plus Screen Protector , ZHXIN T... | 3.8            | 2             | [Tough and Robust: Like all 78X screen protect. ... | [Features : 2.5D Arc Edge Treatment: The edge i... | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []     | ZHXIN  | []         | {'Brand': 'ZHXIN', 'Compatible Devices': 'Cell...  | B075W927RH  | NaN             |
| 3 | Health & Personal Care | Zig Zag Rolling Machine 70mm Size With FREE BO...  | 3.9            | 7             | []                                                  | []                                                 | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []     | None   | []         | {'Package Dimensions': '4.1 x 1.8 x 0.3 inches;... | B01FB26VKY  | NaN             |

|    |                        |                                                   |     |    |                                                                                                                                    |                                                   |       |                                                  |                                                     |               |    |                                                     |            |     |
|----|------------------------|---------------------------------------------------|-----|----|------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------|-------|--------------------------------------------------|-----------------------------------------------------|---------------|----|-----------------------------------------------------|------------|-----|
| 4  | Health & Personal Care | Sting-Kill Disposable Wipes 8 Each (Pack of 5)    | 4.4 | 6  | []                                                                                                                                 | [effective on stings and bites from bees, wasp... | 21.37 | [{'thumb': 'https://m.media-amazon.com/images/.. | []                                                  | Sting-kill    | [] | {'Brand': 'Sting-kill', 'Item Form': 'Wipe', '...   | B01IAI29RU | NaN |
| 5  | Health & Personal Care | Heated Eyelash Curler Mini Portable Electric E... | 3.3 | 8  | []                                                                                                                                 | []                                                | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []                                                  | BiBOS         | [] | {'Package Dimensions': '6.1 x 3.1 x 1.9 inches...   | B08CMN38RC | NaN |
| 6  | Health & Personal Care | Balloon Garland Kit Party,Event Baby,120 Item ... | 4.6 | 19 | []                                                                                                                                 | []                                                | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []                                                  | Tikta co      | [] | {'Occasion': 'Bachelorette Party, Bridal Showe...   | B07YJ5JB26 | NaN |
| 7  | Health & Personal Care | Disney Mickey Mouse Long Sleeve Thermal Tee fo... | 5.0 | 1  | [We don't know when or if this item will be ba...                                                                                  | [We don't know when or if this item will be ba... | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []                                                  | HAA RB B      | [] | {'Package Dimensions': '10 x 7.5 x 1.6 inches;...   | B013EXXYLG | NaN |
| 8  | Health & Personal Care | 3X Replacement Shaver Head Shaver Blade for Ph... | 3.9 | 67 | [  Fits for Philips Norelco HQ300, HQ302, HQ... | [Description: 100% brand new and high quality.... | 18.49 | [{'thumb': 'https://m.media-amazon.com/images/.. | [{'title': 'how to sharp shaver head', 'url': '...} | US online 911 | [] | {'Brand': 'USOnline 911', 'Item Weight': '0.01 ...} | B07FTJBWK  | NaN |
| 9  | Health & Personal Care | JOYWA Inadine Dressing - 5cm x 5cm (x25) by Jo... | 5.0 | 3  | []                                                                                                                                 | []                                                | 55.00 | [{'thumb': 'https://m.media-amazon.com/images/.. | []                                                  | JOYWA         | [] | {'Is Discontinued By Manufacturer': 'No', 'Pac...   | B003TSVQK8 | NaN |
| 10 | Health & Personal Care | dgp Eye Mask - FCK Off Valentines Funny Present   | 4.0 | 37 | [The Fuck Off Eye Mask is a black satin eye ma...                                                                                  | [The black satin eye mask has a sequin trim wi... | NaN   | [{'thumb': 'https://m.media-amazon.com/images/.. | []                                                  | dgp           | [] | {'Brand': 'dgp', 'Material': 'Satin', 'Age Ran...   | B004JU776M | NaN |

Таблиця А.3 - Фрагмент набору даних після етапу попередньої обробки та інжинірингу ознак

|                                      | <b>0</b>                                                | <b>1</b>                                                |
|--------------------------------------|---------------------------------------------------------|---------------------------------------------------------|
| <b>parent_asin</b>                   | B07V346GZH                                              | B075W927RH                                              |
| <b>title</b>                         | Silicone Bath Body<br>Brush Exfoliator<br>Shower Bac... | iPhone 7 Plus 8 Plus<br>Screen Protector,<br>ZHXIN T... |
| <b>price_cleaned</b>                 | 19.99                                                   | 19.99                                                   |
| <b>price_log</b>                     | 3.044046                                                | 3.044046                                                |
| <b>main_category_cleaned</b>         | Health & Personal<br>Care                               | Health & Personal<br>Care                               |
| <b>first_subcategory_cleaned</b>     | Unknown                                                 | Unknown                                                 |
| <b>store_cleaned</b>                 | Rzoeox                                                  | ZHXIN                                                   |
| <b>bought_together</b>               | []                                                      | []                                                      |
| <b>average_rating</b>                | 03.сєн                                                  | 03.абг                                                  |
| <b>rating_number</b>                 | 7                                                       | 2                                                       |
| <b>manufacturer_cleaned</b>          | Unknown                                                 | ZHXIN                                                   |
| <b>brand_cleaned</b>                 | Unknown                                                 | ZHXIN                                                   |
| <b>item_form_cleaned</b>             | Unknown                                                 | Unknown                                                 |
| <b>material_cleaned</b>              | Unknown                                                 | Unknown                                                 |
| <b>age_range_description_cleaned</b> | Unknown                                                 | Unknown                                                 |
| <b>color_cleaned</b>                 | Unknown                                                 | Unknown                                                 |
| <b>flavor_cleaned</b>                | Unknown                                                 | Unknown                                                 |
| <b>size_cleaned</b>                  | Unknown                                                 | Unknown                                                 |

## Фрагмент програмного коду, для реалізації простої моделі

```

start_time_pop = time.time()
item_popularity = train['parent_asin'].value_counts()
sorted_popular_items = item_popularity.index.tolist()
user_seen_items = train.groupby('user_id')['parent_asin'].apply(set).to_dict()
pop_index = {item_id: i for i, item_id in enumerate(sorted_popular_items)}
n_pop_items = len(pop_index)
all_train_items_catalog = set(train['parent_asin'].unique())
total_catalog_size = len(all_train_items_catalog)
print(f" Загальний розмір каталогу (з `train`): {total_catalog_size} товарів.")
catalog_vecs_for_diversity = None
item_to_idx_vecs_diversity = {}
item_ids_for_diversity = []
try:
    item_emb_path = os.path.join(DATA_DIR, 'item_embeddings_bert_weighted.npy')
    item_ids_path = os.path.join(DATA_DIR, 'item_ids_bert.csv')
    catalog_vecs_for_diversity = np.load(item_emb_path)
    item_ids_df_diversity = pd.read_csv(item_ids_path)
    item_ids_for_diversity = item_ids_df_diversity['parent_asin'].tolist()
    item_to_idx_vecs_diversity = {id: i for i, id in enumerate(item_ids_for_diversity)}
    print(f" завантажено ({catalog_vecs_for_diversity.shape})")
except FileNotFoundError:
    print("ПОПЕРЕДЖЕННЯ")
except Exception as e:
    print(f"ПОМИЛКА")
eval_users = list(set(test['user_id'].unique()) & set(train['user_id'].unique()))
ground_truth = test.groupby('user_id')['parent_asin'].apply(set).to_dict()
print(f" Буде оцінено {len(eval_users)} користувачів.")
K_list = [5, 10, 20]
TOPK_RECS = max(K_list)
results_pop = []
rec_items_all_pop = set()
novelty_list_pop = []
diversity_list_pop = []
for user_id in tqdm(eval_users, desc="Оцінка Popularity"):
    seen = user_seen_items.get(user_id, set())
    recs = [item for item in sorted_popular_items if item not in seen][:TOPK_RECS]
    true_set = ground_truth.get(user_id, set())
    if not true_set or not recs:
        continue

```

```

user_metrics = {'user_id': user_id}
for k in K_list:
    user_metrics[f'Precision@{k}'] = precision_at_k(true_set, recs, k)
    user_metrics[f'Recall@{k}'] = recall_at_k(true_set, recs, k)
    user_metrics[f'MAP@{k}'] = apk(true_set, recs, k)
user_metrics['NDCG@10'] = ndcg_at_k(true_set, recs, 10)
user_metrics['MRR'] = mrr(true_set, recs)
recs_k10 = recs[:10]
rec_items_all_pop.update(recs_k10)
ranks = [pop_index.get(it, n_pop_items) + 1 for it in recs_k10]
if ranks:
    user_metrics['AvgNoveltyRank@10'] = np.mean(ranks)
    novelty_list_pop.append(user_metrics['AvgNoveltyRank@10'])
else:
    user_metrics['AvgNoveltyRank@10'] = np.nan
avg_diversity = np.nan
if catalog_vecs_for_diversity is not None:
    vecs = []
    for item_id in recs_k10:
        idx_vec = item_to_idx_vecs_diversity.get(item_id)
        if idx_vec is not None and 0 <= idx_vec < catalog_vecs_for_diversity.shape[0]:
            vecs.append(catalog_vecs_for_diversity[idx_vec])
    if len(vecs) >= 2:
        sim_matrix = cosine_similarity(np.array(vecs))
        upper_triangle_indices = np.triu_indices_from(sim_matrix, k=1)
        if len(upper_triangle_indices[0]) > 0:
            avg_diversity = np.mean(1.0 - sim_matrix[upper_triangle_indices])
            diversity_list_pop.append(avg_diversity)
    user_metrics['AvgDiversity@10'] = avg_diversity
    results_pop.append(user_metrics)
df_results_pop = pd.DataFrame(results_pop)
summary_pop = {
    'model': 'Popularity',
    'n_users_evaluated': len(df_results_pop)
}
if not df_results_pop.empty:
    for col in df_results_pop.columns:
        if col != 'user_id':
            summary_pop[col] = np.nanmean(df_results_pop[col].astype(float))
else:
    metric_cols = [f'Precision@{k}' for k in K_list] + [f'Recall@{k}' for k in K_list] + \

```

```

[f'MAP@{k}' for k in K_list] + ['NDCG@10', 'MRR', \
'AvgNoveltyRank@10', 'AvgDiversity@10']
for col in metric_cols: summary_pop[col] = np.nan
summary_pop['Coverage@10'] = len(rec_items_all_pop) / total_catalog_size if total_catalog_size > 0 else 0.0
print(f'Оцінку Popularity завершено за {time.time() - start_time_pop:.2f} секунд.")
summary_pop_json_safe = {k: (v if not pd.isna(v) else None) for k, v in summary_pop.items()}
display(pd.DataFrame([summary_pop_json_safe]).set_index('model').T.style.format("{:.4f}"))

```

### Фрагмент коду, для реалізації та оцінки Item-kNN

```

start_time_item_knn = time.time()
K_NEIGHBORS_ITEM = 50
results_item_knn = []
rec_items_all_item_knn = set()
novelty_list_item_knn = []
diversity_list_item_knn = []
if 'eval_users' not in globals() or 'ground_truth' not in globals():
    raise NameError("Змінні не знайдені.")
for user_id in tqdm(eval_users, desc="Оцінка Item-kNN"):
    history_items = list(user_seen_items.get(user_id, set()))
    history_indices = [item_to_idx_bert.get(item) for item in history_items if item in item_to_idx_bert]
    if not history_indices:
        continue
    query_vectors = item_embeddings_bert[history_indices]
    try:
        distances, indices = index_items.search(query_vectors, K_NEIGHBORS_ITEM)
    except Exception as e:
        print(f"\nПомилка FAISS search для user {user_id}: {e}")
        continue
    candidate_indices = indices.flatten()
    candidate_counts = pd.Series(candidate_indices).value_counts()
    seen = user_seen_items.get(user_id, set())
    recs = []
    scores = []
    for idx, count in candidate_counts.items():
        if 0 <= idx < len(item_ids_bert_list):
            item_id = item_ids_bert_list[idx]
            if item_id not in seen:
                recs.append(item_id)
                scores.append(float(count))
            if len(recs) >= TOPK_RECS:
                break

```

```

else:
    print(f"\nПопередження")
true_set = ground_truth.get(user_id, set())
if not true_set or not recs:
    continue
user_metrics = {'user_id': user_id}
for k in K_list:
    user_metrics[f'Precision@{k}'] = precision_at_k(true_set, recs, k)
    user_metrics[f'Recall@{k}'] = recall_at_k(true_set, recs, k)
    user_metrics[f'MAP@{k}'] = apk(true_set, recs, k)
user_metrics['NDCG@10'] = ndcg_at_k(true_set, recs, 10)
user_metrics['MRR'] = mrr(true_set, recs)
recs_k10 = recs[:10]
rec_items_all_item_knn.update(recs_k10)
ranks = [pop_index.get(it, n_pop_items) + 1 for it in recs_k10]
if ranks: # Novelty
    user_metrics['AvgNoveltyRank@10'] = np.mean(ranks)
    novelty_list_item_knn.append(user_metrics['AvgNoveltyRank@10'])
else:
    user_metrics['AvgNoveltyRank@10'] = np.nan
avg_diversity = np.nan
if catalog_vecs_for_diversity is not None:
    vecs = []
    for item_id in recs_k10:
        idx_vec = item_to_idx_vecs_diversity.get(item_id)
        if idx_vec is not None and 0 <= idx_vec < catalog_vecs_for_diversity.shape[0]:
            vecs.append(catalog_vecs_for_diversity[idx_vec])
    if len(vecs) >= 2:
        sim_matrix = cosine_similarity(np.array(vecs))
        upper_triangle_indices = np.triu_indices_from(sim_matrix, k=1)
        if len(upper_triangle_indices[0]) > 0:
            avg_diversity = np.mean(1.0 - sim_matrix[upper_triangle_indices])
            diversity_list_item_knn.append(avg_diversity)
    user_metrics['AvgDiversity@10'] = avg_diversity
    results_item_knn.append(user_metrics)
df_results_item_knn = pd.DataFrame(results_item_knn)
summary_item_knn = {'model': 'Item_kNN_BERT', 'n_users_evaluated': len(df_results_item_knn)}

```

Таблиця В.1 – Топ-10 найпопулярніших товарів

| №  | ID товару  | кількість відгуків | Назва                                             |
|----|------------|--------------------|---------------------------------------------------|
| 1  | B0C1HHXQ94 | 3192               | ASUTRA Natural & Organic Yoga Mat Cleaner (Min... |
| 2  | B08X9LB1WC | 2901               | GermGuardian Guardian Technologies GG10002PK G... |
| 3  | B0B4328BFW | 2870               | US Organic 100% Pure Peppermint Essential Oil ... |
| 4  | B01CKMP406 | 2755               | Purple Back Cushion   Pressure Reducing Grid D... |
| 5  | B0047VWYSO | 2287               | Carlson - The Very Finest Fish Oil, 1600 mg Om... |
| 6  | B004C7MTLA | 2196               | Glycerin Vegetable - 1 Quart (43 oz.) - Non GM... |
| 7  | B0001ZWPI4 | 2095               | Avon SKIN-SO-SOFT Bug Guard PLUS IR3535® Insec... |
| 8  | B0077L8YFI | 1992               | Fitbit Aria WiFi Smart Scale                      |
| 9  | B00O0CK2UM | 1885               | Nerdwax Stop Slipping Glasses as Seen on Shark... |
| 10 | B00BR1FSU8 | 1731               | Mr Clean Magic Eraser Pads, 8 Count (Pack of 1)   |




Рисунок Д.1 – Зв'язок між рейтингом товару та довжиною відгуку



## Звіт подібності

### Метадані

Назва організації

Kyiv National Economic University named after Vadym Hetman KNEU

Заголовок

Музика\_Катуніна\_плагіат

Автор Науковий керівник / Експерт

МузикаКатуніна

підрозділ

кафедра штучного інтелекту, моделювання та статистики

### Обсяг знайдених подібностей

Коефіцієнт подібності визначає, який відсоток тексту по відношенню до загального обсягу тексту було знайдено в різних джерелах. Зверніть увагу, що високі значення коефіцієнта не автоматично означають плагіат. Звіт має аналізувати компетентна / уповноважена особа.



КП 1

25

Довжина фрази для коефіцієнта подібності 2



КП 2

17837

Кількість слів



КЦ

135017

Кількість символів

### Тривога

У цьому розділі ви знайдете інформацію щодо текстових спотворень. Ці спотворення в тексті можуть говорити про МОЖЛИВІ маніпуляції в тексті. Спотворення в тексті можуть мати навмисний характер, але частіше характер технічних помилок при конвертації документа та його збереженні, тому ми рекомендуємо вам підходити до аналізу цього модуля відповідально. У разі виникнення запитань, просимо звертатися до нашої служби підтримки.

|                        |  |   |
|------------------------|--|---|
| Заміна букв            |  | 3 |
| Інтервали              |  | 0 |
| Мікропробіли           |  | 3 |
| Білі знаки             |  | 0 |
| Парафрази (SmartMarks) |  | 7 |

### Джерела

Нижче наведений список джерел. В цьому списку є джерела із різних баз даних. Колір тексту означає в якому джерелі він був знайдений. Ці джерела і значення Коефіцієнту Подібності не відображають прямого плагіату. Необхідно відкрити кожне джерело і проаналізувати зміст і правильність оформлення джерела.

#### 10 найдовших фраз

Колір тексту

| ПОРЯДКОВИЙ<br>НОМЕР | НАЗВА ТА АДРЕСА ДЖЕРЕЛА URL (НАЗВА БАЗИ)                                                                                                                                                                    | КІЛЬКІСТЬ ІДЕНТИЧНИХ<br>СЛІВ (ФРАГМЕНТІВ) |
|---------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------|
| 1                   | <a href="https://ir.kneu.edu.ua/server/api/core/bitstreams/43a56897-5289-4c50-8d64-5ec57129c1d8/content">https://ir.kneu.edu.ua/server/api/core/bitstreams/43a56897-5289-4c50-8d64-5ec57129c1d8/content</a> | 45 0.25 %                                 |
| 2                   | <a href="https://ir.kneu.edu.ua/server/api/core/bitstreams/43a56897-5289-4c50-8d64-5ec57129c1d8/content">https://ir.kneu.edu.ua/server/api/core/bitstreams/43a56897-5289-4c50-8d64-5ec57129c1d8/content</a> | 39 0.22 %                                 |
| 3                   | Музика_Мазур_плагіат<br>5/29/2024<br>Kyiv National Economic University named after Vadym Hetman KNEU (кафедра математичного моделювання та статистики)                                                      | 16 0.09 %                                 |

|    |                                                                                                                                                        |           |
|----|--------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| 4  | Вілінський_Т_В_КНСШ_21<br>11/22/2024<br>National University "Lviv Politechnika" (NULP2)                                                                | 13 0.07 % |
| 5  | <a href="https://github.com/yasdel/Gen-RecSys">https://github.com/yasdel/Gen-RecSys</a>                                                                | 12 0.07 % |
| 6  | 2022_М_СТ_ІТПм_21-1_Носик_К_А І<br>5/30/2024<br>Kharkiv National University of Radio Electronics (Kharkiv National University of Radio Electronics)    | 12 0.07 % |
| 7  | Adaptive Neural Architectures for Recommender Systems<br>Dimitrios Rafailidis,Stefanos Antaris;                                                        | 11 0.06 % |
| 8  | <a href="https://github.com/yasdel/Gen-RecSys">https://github.com/yasdel/Gen-RecSys</a>                                                                | 10 0.06 % |
| 9  | Вілінський_Т_В_КНСШ_21<br>11/22/2024<br>National University "Lviv Politechnika" (NULP2)                                                                | 7 0.04 %  |
| 10 | Музика_Мазур_плагіат<br>5/29/2024<br>Kyiv National Economic University named after Vadym Hetman KNEU (кафедра математичного моделювання та статистики) | 7 0.04 %  |

### з бази даних RefBooks (0.06 %)

| ПОРЯДКОВИЙ<br>НОМЕР                                          | ЗАГОЛОВОК                                                                                       | КІЛЬКІСТЬ ІДЕНТИЧНИХ<br>СЛІВ (ФРАГМЕНТІВ) |
|--------------------------------------------------------------|-------------------------------------------------------------------------------------------------|-------------------------------------------|
| джерело: <a href="https://arxiv.org/">https://arxiv.org/</a> |                                                                                                 |                                           |
| 1                                                            | Adaptive Neural Architectures for Recommender Systems<br>Dimitrios Rafailidis,Stefanos Antaris; | 11 (1) 0.06 %                             |

### з домашньої бази даних (0.13 %)

| ПОРЯДКОВИЙ<br>НОМЕР | ЗАГОЛОВОК                                                                                                                                              | КІЛЬКІСТЬ ІДЕНТИЧНИХ<br>СЛІВ (ФРАГМЕНТІВ) |
|---------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------|
| 2                   | Музика_Мазур_плагіат<br>5/29/2024<br>Kyiv National Economic University named after Vadym Hetman KNEU (кафедра математичного моделювання та статистики) | 23 (2) 0.13 %                             |

### з програми обміну базами даних (0.26 %)

| ПОРЯДКОВИЙ<br>НОМЕР | ЗАГОЛОВОК                                                                                                                                                  | КІЛЬКІСТЬ ІДЕНТИЧНИХ<br>СЛІВ (ФРАГМЕНТІВ) |
|---------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------|
| 3                   | Вілінський_Т_В_КНСШ_21<br>11/22/2024<br>National University "Lviv Politechnika" (NULP2)                                                                    | 20 (2) 0.11 %                             |
| 4                   | 2022_М_СТ_ІТПм_21-1_Носик_К_А І<br>5/30/2024<br>Kharkiv National University of Radio Electronics (Kharkiv National University of Radio Electronics)        | 12 (1) 0.07 %                             |
| 5                   | Розробка системи виявлення фейкових новин на "Python"<br>2/27/2025<br>Kyiv Junior Academy of Sciences (Kyiv Junior Academy of Sciences)                    | 7 (1) 0.04 %                              |
| 6                   | 2024_Б_ШІ_ІТШІ_20_4_Капін_С_Д_записка<br>12/15/2024<br>Kharkiv National University of Radio Electronics (Kharkiv National University of Radio Electronics) | 7 (1) 0.04 %                              |

### з Інтернету (0.63 %)

| ПОРЯДКОВИЙ<br>НОМЕР | ДЖЕРЕЛО URL                                                                                                                                                                                                 | КІЛЬКІСТЬ ІДЕНТИЧНИХ<br>СЛІВ (ФРАГМЕНТІВ) |
|---------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------|
| 7                   | <a href="https://ir.kneu.edu.ua/server/api/core/bitstreams/43a56897-5289-4c50-8d64-5ec57129c1d8/content">https://ir.kneu.edu.ua/server/api/core/bitstreams/43a56897-5289-4c50-8d64-5ec57129c1d8/content</a> | 90 (3) 0.50 %                             |
| 8                   | <a href="https://github.com/yasdel/Gen-RecSys">https://github.com/yasdel/Gen-RecSys</a>                                                                                                                     | 22 (2) 0.12 %                             |

## Список прийнятих фрагментів (немає прийнятих фрагментів)

| ПОРЯДКОВИЙ НОМЕР | ЗМІСТ | КІЛЬКІСТЬ ОДНАКОВИХ СЛІВ (ФРАГМЕНТІВ) |
|------------------|-------|---------------------------------------|
|------------------|-------|---------------------------------------|

ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ  
ІМЕНІ ІВАНА ФРАНКА  
Економічний факультет  
Кафедра економічної кібернетики



# ТЕЗИ ДОПОВІДЕЙ

ХІІІ ВСЕУКРАЇНСЬКА НАУКОВО-ПРАКТИЧНА КОНФЕРЕНЦІЯ  
ФОРУМ МОЛОДИХ ЕКОНОМІСТІВ-КІБЕРНЕТИКІВ

**«МОДЕЛЮВАННЯ ЕКОНОМІКИ:  
ПРОБЛЕМИ, ТЕНДЕНЦІЇ, ДОСВІД»**

21-22 листопада 2025 року, Львів

## ЗМІСТ

|                               |                                                                                                                |    |
|-------------------------------|----------------------------------------------------------------------------------------------------------------|----|
| Підхомний О.М.<br>Деркач Д.О. | Кібернетичні принципи стійкості фінансової системи в умовах інформаційної асиметрії                            | 11 |
| Замлинна Я.В.                 | Модель LOGIB як інструмент виявлення та оцінки гендерних розривів оплати праці                                 | 13 |
| Бойко А.І.                    | Моделі поведінки вступників при виборі ЗВО: типологія і соціально-демографічні детермінанти                    | 15 |
| Дубина І.О.<br>Чеверда С.С.   | Цифровізація малих транспортних підприємств як фактор підвищення економічної стійкості в умовах воєнного стану | 17 |
| Синицький А.П.                | Оптимізація маркетингових кампаній у ритейлі                                                                   | 19 |
| Зьола М.Б.                    | Впровадження програмних рішень як інструмент оптимізації діяльності місцевих адміністрацій                     | 21 |

| <b>СЕКЦІЯ 1</b><br><b>МОДЕЛЮВАННЯ ЕКОНОМІКО-ВИРОБНИЧИХ СИСТЕМ</b> |                                                                                                                               |    |
|-------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------|----|
| Богданова Г.С.                                                    | Довіра і соціально-економічний розвиток: статистичний аналіз взаємозв'язків показників                                        | 23 |
| Буртняк І.В.<br>Леськів В.В.                                      | Оцінка досягнень циркулярної економіки за допомогою реляційного аналізу Грея                                                  | 25 |
| Джоші О.І.                                                        | Логічна модель бази даних цифрової платформи для набуття навичок обізнаності та реалізації цілей сталого розвитку             | 27 |
| Гой Г.В.<br>Юнькова О.О.                                          | Структурне моделювання впливу податкових інструментів та інновацій на ефективність бізнесу                                    | 29 |
| Нікітенко О.Ю.<br>Гур'янова Л.С.                                  | Розробка моделей аналізу ефективності контент стратегії Youtube каналу                                                        | 31 |
| Moloko Y.R.<br>Paslavska I.M.                                     | Analysis of tacit collusion in ukraine's oligopolistic fuel market using game theory                                          | 32 |
| Косован О.В.                                                      | Перспективи застосування імітаційного моделювання у роздрібній торгівлі                                                       | 35 |
| Троневи́ч К.А.                                                    | Побудова матриці трасування вимог і тест-кейсів в бізнес-аналізі на прикладі підприємства «Coca-Cola»                         | 36 |
| Алексеев О.В.                                                     | Оптимізація структури виробництва у фермерському господарстві засобами економіко-математичного моделювання                    | 39 |
| Музика І.П.                                                       | Побудова моделей рекомендаційних систем в електронній комерції                                                                | 41 |
| Мирка П.В.                                                        | Особливості побудови концептуальної моделі бізнес-аналізу на прикладі Netflix                                                 | 43 |
| Гречина А.Р.                                                      | Імітаційне моделювання оптимізації виробничих ресурсів підприємства в умовах невизначеності                                   | 44 |
| Тіцька А.Я.                                                       | Моделювання фінансового стану підприємства в умовах економічної нестабільності                                                | 46 |
| Телішевська Р.О.<br>Мельничук В.А.                                | Аналіз чинників формування лояльності споживача                                                                               | 48 |
| Чеверда С.С.<br>Бондарь Л.С.                                      | Гібридний підхід до планування ресурсів: комбінація евристичних та точних методів оптимізації для мультипроектного середовища | 50 |

**Музыка І.П.**

**Електронна пошта:** [ivankamuzika7@gmail.com](mailto:ivankamuzika7@gmail.com)

**Науковий керівник:** к.е.н, доцент Катуніна О.С.

**Електронна пошта:** [katunina.olga@kneu.edu.ua](mailto:katunina.olga@kneu.edu.ua)

*Київський національний економічний університет імені Вадима Гетьмана*

**ПОБУДОВА МОДЕЛЕЙ РЕКОМЕНДАЦІЙНИХ СИСТЕМ  
В ЕЛЕКТРОННІЙ КОМЕРЦІЇ**

**Muzyka I. P.**

**BUILDING MODELS OF RECOMMENDER SYSTEMS IN E-COMMERCE**

В умовах сучасної цифрової економіки швидкими темпами розвиваються онлайн-магазини, їхня кількість та об'єми пропонованих товарів та послуг, також, постійно збільшуються. І тому такі платформи стикаються з проблемою – «інформаційного перевантаження». Коли споживачі зіштовхуються з тисячами, а то і мільйонами товарів, виникає парадокс вибору, коли покупець не може вибрати з такої великої кількості товарів, він може передумати купувати все це може призвести до втрати доходу продавця [1]. В таких ситуаціях стають у пригоді рекомендаційні системи (РС), вони є важливим інструментом, який може допомогти відфільтрувати мільйони товарів та надати персоналізовані пропозиції на основі поведінки користувача, це збільшує задоволеність придбанням, і як наслідок – збільшує дохід продавців [2]. Дослідження McKinsey демонструють що персоналізовані пропозиції призводять до збільшення доходу компаній на 5-15%, а покупці, які натискали на такі пропозиції – здійснювали покупку у 4,5 рази частіше [3]. Цікавий факт, що 71% споживачів очікують персоналізованого досвіду, а 76% розчаровуються, коли бренди не виконують його вимоги [3]. Тобто, рекомендаційні системи стають інструментом для максимізації утримання і позитивної цінності клієнта та базуватимуться на Data-Driven підході та моделюванні. Хоча РС мають високу економічну цінність, вони є доволі чутливими до ефекту упередженості популярності, коли користувачі переглядають/взаємодіють з невеликою кількістю товарів-хітів. Алгоритми, особливо прості, підсилюють цей ефект, пропонуючи одні й ті ж товари і не беручи до уваги менш популярні, але можливо більш нішеві та релевантні товари, які входять в «довгий хвіст» [2]. Тому для оцінки моделей використано не лише традиційні метрики точності, а й низку спеціалізованих, зокрема, Novelty (здатність рекомендувати менш очевидне) та Diversity (різноманітність рекомендованих товарів).

Дослідження проведено на наборі даних Amazon Reviews, сфокусованому на категорії «Health and Personal Care», що включає як деталі взаємодій користувачів (рейтинги, час, текст відгуку), так і метадані товарів. Для порівняльного аналізу обрано три моделі. Перша модель – Popularity Baseline, яка ранжує товари за кількістю взаємодій у тренувальній вибірці, ігноруючи персональні вподобання, вона слугує еталоном для оцінки ефекту персоналізації. Item-kNN – це модель, яка для кожного товару, позитивно оціненого користувачем, шукає K=50 семантично найближчих сусідів на основі BERT-ембедингів і формує рекомендації за частотою їх появи. І також, User-kNN використовує User-Based Collaborative Filtering і

21-22 листопада 2025 року, Львів

визначає схожість користувачів за їхніми зваженими BERT-векторами, знаходить K=50 найближчих сусідів і рекомендує товари, популярні серед них, але ще не переглянуті поточним користувачем.

Таблиця 1

Результати моделей рекомендаційних систем

| Назва моделі  | Precision | Recall | MAP    | NDCG   | MRR    | Coverage | AvgNoveltyRank | AvgDiversity |
|---------------|-----------|--------|--------|--------|--------|----------|----------------|--------------|
| Popularity    | 0.0021    | 0.0189 | 0.0048 | 0.0082 | 0.0057 | 0.0002   | 5.5260         | 0.5194       |
| User_kNN_BERT | 0.0008    | 0.0075 | 0.0036 | 0.0045 | 0.0038 | 0.1503   | 5582.3899      | 0.3895       |
| Item_kNN_BERT | 0.0007    | 0.0067 | 0.0038 | 0.0045 | 0.0038 | 0.1501   | 6403.5891      | 0.2102       |

*Джерело: розроблено автором*

Отримані результати з таблиці 1 показали зворотній зв'язок між точністю прогнозування (NDCG) та здатністю до дослідження каталогу (Novelty та Coverage). Базова модель Popularity показала найвищі показники точності NDCG = 0.0082, MRR = 0.0057 – це вказує на домінування більш популярних товарів у вибірці, а моделі Item\_kNN та User-kNN показали майже вдвічі нижчі результати NDCG = 0.0045, звідси можна зробити висновок, що наявна складність прогнозування миттєвої релевантності для товарів-хітів. Незважаючи на низьку точність kNN моделі мають суттєво більші якісні метрики, Popularity мала мінімальне покриття каталогу – 0.0002 і низьку новизну – 5.53), а User-kNN та Item-kNN показав близько 15% Coverage і тисячократне зростання новизни (до 5582.39 та 6403.59 відповідно). Це показує їхню ефективність у просуванні нішевих товарів. Item-kNN мала найнижчу різноманітність (0.2102) через фокус на схожих товарах, тоді як User-kNN досягав 0.3895 завдяки ширшій базі користувачів-сусідів. Зауважимо, що Popularity продемонструвала найбільшу різноманітність (0.5194), що можна пояснити семантичною неоднорідністю найпопулярніших позицій.

Отже, можна зробити висновок, що при побудові моделей для рекомендаційних систем важливим є дотримання компромісу між точністю та якістю результатів. Popularity ефективна для короткострокової конверсії, тоді як моделі kNN критично важливі для довгострокової лояльності та монетизації «довгого хвоста».

*Література:*

1. Alexander R. How recommendation systems are driving change in the retail sector. *Prescouter*. URL: <https://www.prescouter.com/2020/05/how-recommendation-systems-are-driving-change-in-the-retail-sector/> (дата звернення: 11.11.2025).
2. Challenging the long tail recommendation / Н. Yin et al. *Proceedings of the VLDB Endowment*. 2012. Vol. 5, no. 9. P. 896–907. URL: <https://doi.org/10.14778/2311906.2311916> (дата звернення: 11.11.2025).
3. 31 Personalized Shopping Experience Statistics That Prove AI-Driven Commerce Wins in 2025. *Envive*. URL: <https://www.envive.ai/post/personalized-shopping-experience-statistics> (дата звернення: 11.11.2025).



ЛЬВІВСЬКИЙ  
НАЦІОНАЛЬНИЙ  
УНІВЕРСИТЕТ  
імені Івана Франка

# СЕРТИФІКАТ

№ 13-2025/024

що засвідчує участь

## Іванни Музики

у XIII ВСЕУКРАЇНСЬКІЙ НАУКОВО-ПРАКТИЧНІЙ КОНФЕРЕНЦІЇ  
ФОРУМІ МОЛОДИХ ЕКОНОМІСТІВ-КІБЕРНЕТИКІВ

«МОДЕЛЮВАННЯ ЕКОНОМІКИ: ПРОБЛЕМИ, ТЕНДЕНЦІЇ, ДОСВІД»

Професійна програма стажування  
12 год (0,4 кредиту ECTS)



Декан економічного факультету  
Ростислав МИХАЙЛИШИН

21-22 листопада 2025 року  
м. Львів