

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____
(повна назва)

Кафедра _____ програмної інженерії _____
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський) _____

_____ Дослідження методів прогнозування _____
_____ рекомендаційних систем _____
(тема)

Виконав:
студент (ка) 2 курсу, групи ІІЗМ-22-3

_____ Русанов І.С. _____
(прізвище, ініціали)

Спеціальність 121 – Інженерія програмного
забезпечення
(код і повна назва спеціальності)

Тип програми _____ освітньо-наукова _____

Керівник к.т.н., доц. Лещинська І.О.
(посада, прізвище, ініціали)

Допускається до захисту
Зав. кафедри

_____ _____
(підпис)

_____ З.В.Дудар _____
(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____
Кафедра _____ програмної інженерії _____
Рівень вищої освіти _____ другий (магістерський) _____
Спеціальність _____ 121 – Інженерія програмного забезпечення _____
Тип програми _____ освітньо-наукова програма _____
Освітня програма _____ Інженерія програмного забезпечення _____
(шифр і назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

«____» _____ 2024 р.

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

студентові _____ Русанову Івану Сергійовичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи «Дослідження методів прогнозування для рекомендаційних систем»

Затверджена наказом по університету від 29.03.2024р. № 250 Ст

2. Термін подання студентом роботи до екзаменаційної комісії 18.06.2024

3. Вихідні дані до роботи опис досліджуваних методів прогнозування рекомендаційних систем, загальні критерії та метрики оцінювання для проведення досліджень за обраною предметною областю, мови програмування Java, технологія зборки проекту Maven, бібліотека CF4J, середовища розробки IntelliJ Idea 2023.3.2

4. Перелік питань, що потрібно опрацювати в роботі аналіз та порівняння існуючих методів прогнозування рекомендаційних систем, вибір конкретних реалізацій моделей для досліджень, вибір критеріїв та метрик оцінювання для досліджень, використання програмних рішень, проведення експериментів та аналіз отриманих результатів

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз предметної галузі та постановка задачі	23.01 – 14.02.24	<i>виконано</i>
2	Аналіз та вибір моделей для дослідження	15.02 – 24.02.24	<i>виконано</i>
3	Аналіз та моделювання предметної області	17.02 – 28.02.24	<i>виконано</i>
4	Планування експериментів	25.02 – 28.02.24	<i>виконано</i>
5	Програмна реалізація кожної з обраних для дослідження моделі	25.02 – 01.04.24	<i>виконано</i>
6	Експериментальні дослідження	02.04 – 20.04.24	<i>виконано</i>
7	Аналіз результатів експериментальних досліджень та розробка рекомендацій	20.04 – 23.04.24	<i>виконано</i>
8	Написання та оформлення статті та тез доповіді	17.04 – 23.04.24	<i>виконано</i>
9	Підготовка пояснювальної записки	01.04 – 26.04.24	<i>виконано</i>
10	Підготовка презентації та доповіді	26.04 – 2.05.24	<i>виконано</i>
11	Нормоконтроль	3.05 – 08.05.24	<i>виконано</i>
12	Рецензування	08.05 – 14.05.24	<i>виконано</i>
13	Занесення диплома в електронний архів	15.05.2024	<i>виконано</i>
14	Попередній захист	15.05.2024	<i>виконано</i>
15	Допуск до захисту у зав. кафедри	18.05.2024	<i>виконано</i>

Дата видачі завдання 29 березня 2024р.

Студент (ка) _____
(підпис)

Русанов І.С.

Керівник роботи _____

к.т.н., доц. Лещинська І.О.

(підпис)

(посада, прізвище, ініціали)

РЕФЕРАТ / ABSTRACT

Пояснювальна записка містить: 72 с., 16 рис., 20 джерел.

КОЛАБОРАТИВНА ФІЛЬТРАЦІЯ, КОНТЕНТНА ФІЛЬТРАЦІЯ, МАТРИЧНЕ РОЗКЛАДАННЯ, РЕКОМЕНДАЦІЙНІ СИСТЕМИ, ПРОГНОЗУВАННЯ РЕКОМЕНДАЦІЙ.

Об'єкт дослідження – методи прогнозування рекомендаційних систем.

Мета роботи – дослідження рекомендаційних систем, моделей прогнозування та їх типів, підготовка та проведення теоретичного та практичного досліджень вибору оптимальної моделі прогнозування рекомендаційних систем.

Методами розробки та проектування є аналіз існуючих рекомендаційних систем, обрання конкретних реалізацій різних моделей прогнозування та критеріїв оцінювання для обох типів досліджень та вибір бібліотеки CF4J на Java для проведення практичного дослідження.

Результат роботи – проведено аналіз існуючих рекомендаційних систем, проаналізовано існуючі методи прогнозування рекомендаційних систем, визначено критерії оцінки для проведення дослідження існуючих методів прогнозування, в результаті дослідження обрано найбільш оптимальний метод прогнозування.

COLLABORATIVE FILTERING, CONTENT FILTERING, MATRIX FACTORIZATION, ADVISORY SYSTEM, FORECASTING RECOMMENDATIONS.

Object of research - forecasting models of recommender systems.

The purpose of the work is the study of recommender systems, forecasting models and their types, preparation and conducting of theoretical and practical research on the choice of forecasting models of recommender systems.

The development and design methods are the analysis of existing recommendation systems, the selection of specific implementations of various prediction models and

evaluation criteria for both types of research, and the selection of the CF4J Java library for practical research.

The result of the work - the analysis of existing recommendation systems was carried out, the existing methods of forecasting of recommendation systems were analyzed, the evaluation criteria for the study of existing forecasting methods were determined, as a result of the research, the most optimal forecasting method was chosen.

Заява щодо самостійного виконання кваліфікаційної роботи та можливості її публікації в електронному архіві відкритого доступу EIArKhNURE.

Я, Русанов Іван Сергійович, студент гр. ПЗМ-22-3, здобувач вищої освіти на другому (магістерському) рівні кафедри «Програмна інженерія», заявляю: моя кваліфікаційна робота на тему «Дослідження методів прогнозування рекомендаційних систем», що буде представлена в екзаменаційну комісію для публічного захисту, виконана самостійно, в ній не містяться елементи плагіату і вона може бути опублікована в електронному архіві відкритого доступу EIArKhNURE. Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

Я ознайомлений(на) з діючим положенням «Про протидію академічному плагіату в ХНУРЕ», згідно з яким виявлення плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту та застосування дисциплінарних заходів.

ЗМІСТ

Перелік скорочень	9
Вступ	10
1 Аналіз предметної галузі	12
1.1 Аналіз рекомендаційних систем	12
1.1.1 Колаборативні рекомендаційні системи	13
1.1.2 Рекомендаційні системи, які використовують контентну фільтрацію	14
1.1.3 Демографічні рекомендаційні системи	14
1.1.4 Системи рекомендацій, які використовують знання	15
1.1.5 Системи рекомендацій для груп користувачів	16
2 Проблеми рекомендаційних систем	17
3 Дослідження функціонування та методів прогнозування рекомендаційних систем	19
3.1 Функціонування рекомендаційних систем	19
3.2 Моделі та методи прогнозування рекомендаційних систем	21
3.2.1 Колаборативна фільтрація	21
3.2.2 Контентна фільтрація	22
3.2.3 Гібридні методи	24
3.2.4 Системи на основі знань	30
3.3 Алгоритми колаборативної фільтрації	31
4 Постановка задачі та вибір моделей для дослідження	35
4.1 Постановка технічного завдання	35
4.2 Вибір моделей прогнозування рекомендаційних систем	35
4.2.1 User-KNN	36
4.2.2 Item-KNN	36
4.2.3 Імовірнісне матричне розкладання	37
4.2.4 Нейронна колаборативна фільтрація	37
4.2.5 Фільтрація на основі вмісту	38
5.1 Засоби проведення дослідження	40
5.2 Методи подібності	40
5.2.1 Косинусна подібність	41
5.2.2 Кореляція Пірсона	41
5.2.3 Міра Жаккара	42
5.2.4 Кореляція Спірмана	43

	8
5.3 Обрання показників оцінки моделей прогнозування	44
5.3.1 Середня абсолютна помилка	45
5.3.2 Середньоквадратична помилка	45
6 Практичне дослідження методів прогнозування рекомендаційних систем	47
6.1 Підготовка до проведення експерименту	47
6.2 Дослідження метрик подібності	47
6.2.1 Дослідження метрики подібності для user-KNN моделі	47
6.2.2 Дослідження метрики подібності для item-KNN моделі	48
6.2.3 Дослідження метрики подібності для моделі контентної фільтрації	49
6.2.4 Оцінка дослідження метрик подібності	49
6.3 Проведення загального дослідження	50
Висновки	54
Перелік джерел посилання	56
Перелік джерел посилання за науковими напрямами керівника та науковців кафедри програмної інженерії	59
Додаток А Звіт результатів перевірки на унікальність тексту в базі ХНУРЕ	Error! Bookmark not defined.
Додаток Б Слайди презентації	Error! Bookmark not defined.
Додаток В Апробація результатів роботи	Error! Bookmark not defined.
Додаток Г Експертний висновок результатів перевірки кваліфікаційної роботи на відповідність оформлення вимогам ДСТУ 3008: 2015	Error! Bookmark not defined.

ПЕРЕЛІК СКОРОЧЕНЬ

CBR – case-based recommender systems;

CF – колаборативна фільтрація;

PMF - probabilistic matrix factorization;

KNN – метод k-найближчих сусідів;

User-KNN - user-based collaborative filtering model;

Item-KNN - item-based collaborative filtering model;

NCF - neural matrix factorization;

MAE – середня абсолютна помилка;

RMSE – середньоквадратична помилка.

ВСТУП

Останнє десятиліття відзначається значним зростанням обсягу інформації в глобальному інформаційному просторі. Широке поширення Інтернет-технологій у всіх сферах суспільного життя та доступність інформації вимагають розробки нових методів пошуку інформації. Зауважимо, що пошукові системи, такі як Google, Yahoo, Altavista, не враховують персоналізацію інформації. Розробка рекомендаційних систем стала відповіддю на це виклик.

Рекомендаційні системи представляють собою системи фільтрації, що рекомендують інформаційні елементи, які можуть зацікавити користувача. Такі системи стали альтернативою алгоритму пошуку, дозволяючи користувачам ефективно знаходити потрібну інформацію в мережі Інтернет.

У сучасному світі технологій, де обсяги даних стрімко зростають, роль рекомендаційних систем стає вирішальною в багатьох галузях, від електронної комерції до онлайн-розваг [1]. Ці системи не тільки допомагають користувачам у навігації через величезну кількість можливих виборів, але й значно підвищують ефективність взаємодії з цифровими платформами, забезпечуючи персоналізацію контенту.

Найвідоміші інтернет-портали, які використовують рекомендаційні системи, включають Amazon.com, eBay Inc., MovieLens та Rozetka.ua™ та багато інших. Ці системи виявляються важливим елементом інтелектуальних систем підтримки прийняття рішень, забезпечуючи користувачам персоналізовані рекомендації.

Значення рекомендаційних систем в наш час не може бути переоцінене. Вони забезпечують користувачам релевантний контент, підбирають товари згідно індивідуальних переваг, і навіть допомагають у виборі фільмів та музики, що максимально відповідають їхнім смакам. За допомогою алгоритмів машинного навчання та штучного інтелекту, сучасні системи можуть аналізувати великі обсяги інформації, що дозволяє їм прогнозувати потреби користувачів з високою точністю.

Наукове дослідження в області рекомендаційних систем відкриває нові можливості для підвищення ефективності цих технологій. Розробка нових методів

прогнозування, а також вдосконалення існуючих алгоритмів можуть значно покращити якість рекомендацій. Це, в свою чергу, може призвести до збільшення задоволення користувачів та зростання прибутків бізнесу, який використовує ці системи.

Дана дипломна робота присвячена аналізу та порівнянню різних моделей рекомендаційних систем. Важливість такого дослідження обумовлена потребою в глибокому розумінні механізмів, які дозволяють цим системам ефективно працювати в різноманітних умовах. Вивчення сильних та слабких сторін різних підходів дасть змогу оптимізувати процеси взаємодії з користувачами, що є критично важливим для досягнення високої ефективності комерційних платформ. Отже, здійснення дослідження в цій області є актуальним і важливим завданням, що допоможе у формуванні основ нових інновацій у розвитку рекомендаційних систем.

Ця дослідницька робота спрямована на забезпечення важливого внеску в області персоналізованих рекомендацій, демонструючи як теоретичні так і практичні аспекти реалізації та використання різних методів прогнозування в рекомендаційних системах. Ми прагнемо вивчити і порівняти ефективність кількох моделей, з метою ідентифікації найбільш продуктивних підходів відповідно до сучасних вимог та умов використання.

Такий підхід дозволить не тільки підвищити загальну інформованість у цій важливій області, але й виявити ключові фактори, що впливають на якість та ефективність рекомендаційних систем, сприяючи їхньому подальшому розвитку і оптимізації.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ

1.1 Аналіз рекомендаційних систем

Рекомендаційні системи виникли і почали розвиватися з середини 90-х років минулого століття. Одразу зауважимо, що існують дві основні категорії рекомендацій контенту чи товарів: персоналізовані та неперсоналізовані. Неперсоналізовані рекомендації зазвичай включають пропозиції найбільш популярного контенту або товарів, а також того, що може бути вигідним для бізнесу. Підхід до неперсоналізованих рекомендацій доволі простий і зрозумілий, тому аналізувати їх у нашій роботі сенсу немає, отже ми будемо розглядати лише персоналізовані рекомендації. Головна мета персоналізованої рекомендаційної системи – це надання рекомендацій користувачу, які враховують його уподобання при виборі предметів (товарів, об'єктів або послуг). Основними завданнями рекомендаційних систем є підвищення точності прогнозування рекомендацій, вирішення проблеми "холодного старту" та розширення асортименту рекомендованих товарів [2].

Для інтернет-магазинів додатковими цілями є підвищення конверсії, збільшення лояльності користувачів, ефективне вирішення завдань супутніх продажів (cross-selling), додаткових продажів (up-selling), післяпродажного супроводу (e-mail маркетингу) та вирішення проблеми "довгого хвоста".

У рекомендаційних системах для інтернет-магазинів точність прогнозування залежить від ефективного розрахунку коефіцієнтів подібності між характеристиками користувачів і товарів [3]. Важливим завданням є розробка та вивчення подібності між характеристиками з урахуванням демографічних та якісних параметрів.

Для оптимізації роботи великих інтернет-магазинів, таких як супермаркети і гіпермаркети, важливою є задача пошуку груп користувачів та товарів з схожими характеристиками. Це спрощує прогнозування рекомендацій для груп, що в свою чергу полегшує завдання супутніх і додаткових продажів, а також після продажного супроводу. Використання методів кластеризації є ефективним для виділення груп з подібними характеристиками.

Задача розробки гібридних методів прогнозування рекомендацій, які враховують розрідженість матриці користувач-товар, є важливою для оптимізації ефективності рекомендаційних систем. Однією з ключових задач є підвищення різноманітності рекомендованих товарів для запобігання узагальненню та забезпечення різноманітності вибору для користувачів.

В цьому розділі ми познайомимось з основними принципами роботи рекомендаційних систем та отримаємо поверхневе розуміння цих підходів. Також зазначимо, що на практиці при побудові рекомендаційної системи використовуються декілька підходів одразу, що дає змогу закрити проблеми тих чи інших підходів, про які ми поговоримо в наступному розділі.

1.1.1 Колаборативні рекомендаційні системи

Основна концепція колаборативної фільтрації полягає в тому, що користувачі з аналогічними профілями або інтересами виявляють інтерес до схожих предметів, а предмети, які співпадають, привертають увагу подібних користувачів. У цьому методі використовуються множини профілів користувачів і предметів. Профілі включають числові рейтингові оцінки, які користувачі надають вже вибраним предметам. Ці рейтинги - цілі додатні числа, зазвичай з обмеженого діапазону, такого як від 0 до 5 або 0 до 10. Також можуть використовуватися двійкові значення "подобається" (1) чи "не подобається" (0).

Прогноз рекомендацій для активного користувача або предмета здійснюється на основі векторів профілів подібних користувачів чи подібних предметів. Активний користувач - це той, що звертається до системи для отримання рекомендацій, а активний предмет - той, для якого система повинна здійснити прогноз оцінок користувачів.

Колаборативні рекомендаційні системи найбільш широко використовуються на сьогодні. До переваг цих систем можна віднести те, що вони не вимагають детального опису характеристик предметів, а використовують числові рейтинги, що відображають реальні вподобання користувачів. Однак серед недоліків варто відзначити велику розмірність матриці користувач-предмет і обмеження у

прогнозуванні рекомендацій для нових користувачів і предметів.

1.1.2 Рекомендаційні системи, які використовують контентну фільтрацію

Рекомендаційні системи, що використовують контентну фільтрацію, аналізують описи властивостей предметів, які були раніше відзначені користувачами. На підставі цього аналізу система формує профілі інтересів користувачів, які представляють собою структуровану інформацію про інтереси користувача і використовуються для прогнозування рекомендацій щодо нових предметів. Процес рекомендації полягає в порівнянні профілів користувачів з атрибутами профілів предметів, що призводить до визначення оцінки рівня релевантності. Ця оцінка вказує на ступінь зацікавленості користувача в конкретному предметі.

Рекомендаційні системи, які використовують контентну фільтрацію, не потребують інформації про інших користувачів і можуть рекомендувати як вже відомі, так і менш відомі предмети. Однак до недоліків цих систем можна віднести те, що вони базуються на явному описі характеристик предметів і не модифікують цей опис у процесі експлуатації.

1.1.3 Демографічні рекомендаційні системи

Демографічні рекомендаційні системи класифікують користувачів відповідно до їх демографічних характеристик, таких як вік, стать, освіта, рід занять і інші. У подальшому ці системи використовують числові рейтингові оцінки, які користувачі надають предметам і які зберігаються у їхніх профілях. Для прогнозування, демографічні рекомендаційні системи використовують обчислювальні вирази, аналогічні тим, як це робиться у методі предмет-предмет в колаборативних рекомендаційних системах. Відмінною рисою є використання коефіцієнтів подібності між векторами демографічних профілів користувачів, на відміну від методу предмет-предмет, який застосовується в колаборативних системах.

Серед переваг демографічних рекомендаційних систем можна відзначити

відсутність потреби в історії оцінок, які користувачі давали предметам. Однак ці системи рекомендують аналогічні предмети для користувачів зі схожими демографічними характеристиками, не враховуючи індивідуальні рівні інтересів користувачів в межах однакових демографічних груп, що значно обмежує гнучкість у виборі предметів для користувачів.

1.1.4 Системи рекомендацій, які використовують знання

Традиційні рекомендаційні системи, такі як контентно-орієнтовані та колаборативні, успішно застосовуються для рекомендацій предметів, які мають конкретні властивості та відповідають уподобанням користувачів, таких як книги, музика, фільми та новини. Проте ці підходи не ефективні для предметів, таких як автомобілі, комп'ютери та квартири. Наприклад, купівля квартири – це рідкісна подія, яка не дозволяє накопичити достатньо оцінок для застосування колаборативної фільтрації. Додатково, рекомендації стають менш ефективними, якщо вони базуються на оцінках за рік чи старших.

До рекомендаційних систем, які використовують знання, відносяться системи на основі прецедентів CBR (case-based recommender systems) та системи, що базуються на вмісті факторів, що характеризують предметну область (constraint-based recommender systems). CBR-системи передбачають рекомендації на основі метрик подібності між вже вирішеними проблемами. У системах, заснованих на вмісті, передбачення рекомендацій здійснюється на основі бази знань, яка містить явні правила про взаємозв'язок між вимогами користувачів і властивостями предметів [4].

CBR-системи використовують методології, аналогічні експертним системам, базуючись на збереженому досвіді. Однак, на відміну від експертних систем, які працюють за логічними правилами, CBR-системи зберігають успішні рішення реальних проблем у вигляді прецедентів і, при появі нової проблеми, вибирають найбільш відповідні прецеденти, пропонуючи модифіковану комбінацію їхніх рішень. Недолік CBR-систем полягає в тому, що вони не створюють моделей або правил, що узагальнюють накопичений досвід.

1.1.5 Системи рекомендацій для груп користувачів

У багатьох випадках виникає необхідність у передбаченні рекомендацій для груп користувачів. Серед таких завдань можна виділити передбачення літературних творів певної тематики для груп користувачів у бібліотеках та інтернет-ресурсах, рекомендації музичних творів для аудиторій, підбір новин для інтернет-користувачів, рекомендації туристичних маршрутів і товарів для груп покупців у сфері електронної комерції. Системи передбачення рекомендацій для груп користувачів, на відміну від раніше згаданих підходів до створення рекомендаційних систем, вимагають вирішення конкретних завдань, що є характерними лише для цієї конкретної сфери. Серед таких завдань варто відзначити виділення груп користувачів із схожими смаками, об'єднання уподобань групи в єдине інтегроване уподобання та передбачення таких рекомендацій, які задовольняли більшість членів групи, і уникання варіантів, які не враховують індивідуальних особливостей користувачів групи. З урахуванням зростання кількості користувачів у мережі Інтернет приділяється збільшена увага розробці рекомендаційних систем для груп користувачів.

2 ПРОБЛЕМИ РЕКОМЕНДАЦІЙНИХ СИСТЕМ

2.1 Проблеми рекомендаційних систем

Для того, щоб краще зрозуміти постановку задачі, нам треба спочатку проаналізувати усі труднощі, з якими стикаються рекомендаційні системи. У сфері рекомендаційних систем виникають значущі виклики, які включають проблеми "холодного старту", розрідженості матриці користувач-предмет, масштабованості та "довгого хвоста".

2.1.1 Проблема "холодного старту"

Проблема "холодного старту" є найпоширенішою в рекомендаційних системах. Вона виникає при введенні нового предмета або користувача в систему [5]. У таких випадках профілі нового предмета та користувача порожні, ускладнюючи прогнозування рекомендацій, особливо в системах колаборативної фільтрації.

Для вирішення цієї проблеми існують кілька підходів, зокрема:

- запрошення нових користувачів вказати свої переваги щодо певних елементів;
- пропозиція новим користувачам оцінити кілька елементів на початку взаємодії;
- збір демографічної інформації чи метаданих від користувачів для подальшого рекомендування відповідних елементів [6].

2.1.2 Проблема розрідженості

Розрідженість матриці користувач-предмет виникає через те, що кожен конкретний користувач не може оцінити всі предмети. Ця проблема виникає, коли активні користувачі оцінюють дуже мало предметів. Наприклад, матриця користувач-предмет у методі колаборативної фільтрації може містити лише приблизно 6-7% ненульових елементів, що потребує розробки спеціальних методів обробки таких структур даних, адже в них відсутні деякі очікувані значення. Це впливає на точність рекомендацій. Щоб вирішити цю проблему, можна застосувати

кілька методів, включаючи демографічну фільтрацію, сингулярне розкладення та модельні методи колаборативних технік.

2.1.3 Проблема масштабованості

Проблема масштабованості виникає в зв'язку з необхідністю рекомендаційних систем ефективно обробляти постійно зростаючий обсяг інформації. Це є дуже поширеною проблемою в рекомендаційних системах, адже в наш час кількість даних щодо нових елементів і користувачів стрімко збільшується. Наприклад, компанія Amazon успішно рекомендує понад 18 мільйонів предметів для понад 20 мільйонів користувачів, що вимагає високої масштабованості системи. Також ті рекомендаційні системи, які базуються на колаборативній фільтрації, вимагають значної кількості тренувальних даних. Для розв'язання проблеми масштабованості часто використовують такі методи, як зменшення розмірності даних і кластеризація, що дозволяє обробляти дані користувачів у менших кластерах замість усієї бази даних.

2.1.4 Проблема "довгого хвоста"

Традиційні рекомендаційні системи пропонують користувачам предмети, що найточніше відповідають їхнім уподобанням. Однак такий підхід може призводити до прогнозування лише найпопулярніших предметів, утворюючи "довгий хвіст" менш популярних предметів, які можуть бути цікавими для користувачів. Множина таких предметів не перевищує 20% від усіх предметів, які може запропонувати інтернет-магазин. 80% предметів, це предмети, які не користуються великою популярністю, але можуть представляти інтерес для користувачів. Такі предмети належать до множини предметів «довгого хвоста».

3 ДОСЛІДЖЕННЯ ФУНКЦІОНУВАННЯ ТА МЕТОДІВ ПРОГНОЗУВАННЯ РЕКОМЕНДАЦІЙНИХ СИСТЕМ

3.1 Функціонування рекомендаційних систем

Узагальнене функціонування рекомендаційної системи складається з наступних етапів (див. рис. 3.1):

- нагромадження інформації про користувачів і предмети;
- навчання;
- прогнозування;
- зворотний зв'язок.



Рисунок 3.1 – Етапи функціонування рекомендаційної системи (2)

На першому етапі відбувається збирання та накопичення даних про користувачів та предмети для формування їхніх профілів. Ця інформація включає в себе характеристики поведінки користувача, атрибути користувача, деталі щодо ресурсів, до яких користувач звертається, і атрибути самих предметів. Для ефективного функціонування рекомендаційної системи потрібна максимально повна інформація про користувачів і предмети. Система використовує явний і

неявний зворотний зв'язок для збору достовірної інформації про уподобання та інтереси користувачів.

На другому етапі застосовуються методи та алгоритми навчання для обробки інформації про користувачів, яка надходить через зворотний зв'язок (див. рис. 3.2).

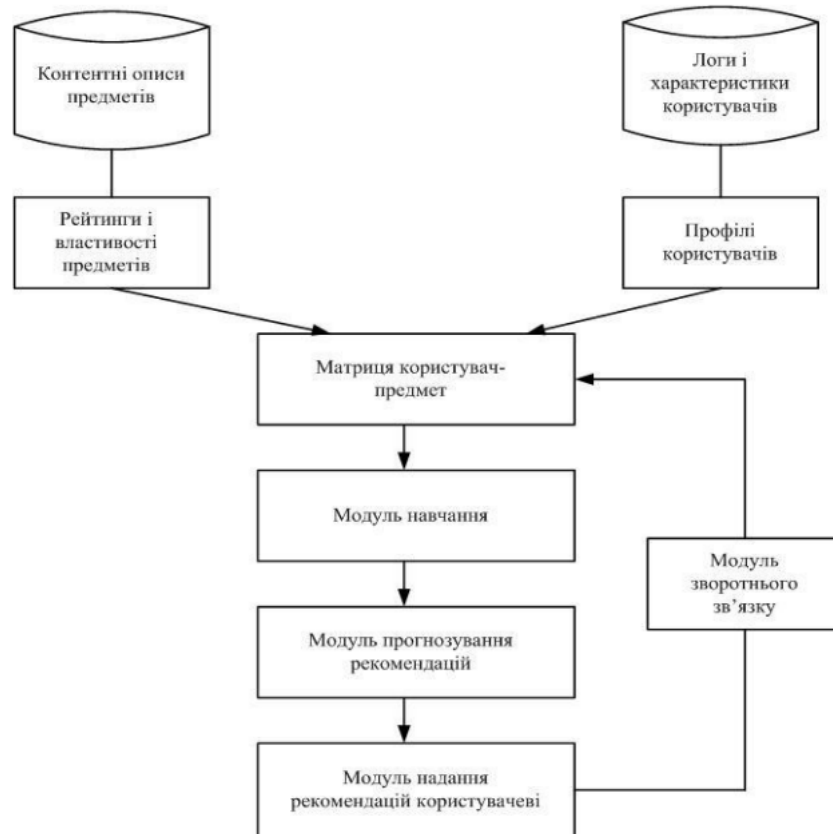


Рисунок 3.2 – Узагальнена архітектура рекомендаційної системи (2)

У рекомендаційних системах використовується два типи зворотного зв'язку: явний і неявний. Явний зворотний зв'язок передбачає, що користувач вручну вносить корективи у прогнозовані рейтинги предметів після їх використання. У випадку неявного зворотного зв'язку система автоматично визначає уподобання користувача, спостерігаючи за його різними діями, такими як історія покупок, маршрут навігації, і час, який користувач витрачає на веб-сторінках, а також посилання, за якими він переходить та послідовність натискань кнопок на веб-сторінках.

3.2 Моделі та методи прогнозування рекомендаційних систем

Прогнозування рекомендаційних систем - це ключовий аспект в галузі інформаційних технологій, спрямований на забезпечення користувачів персоналізованими рекомендаціями. Методи та моделі, що використовуються в цих системах, розглядають користувачів і предмети, а також їхні взаємодії, для надання рекомендацій, які відповідають індивідуальним потребам і смакам кожного користувача.

Усі види рекомендаційних систем можна виділити наступні загальні методи прогнозування рекомендаційних систем: колаборативна фільтрація, контентна фільтрація та гібрид – поєднання перших двох (див. рис. 3.3).

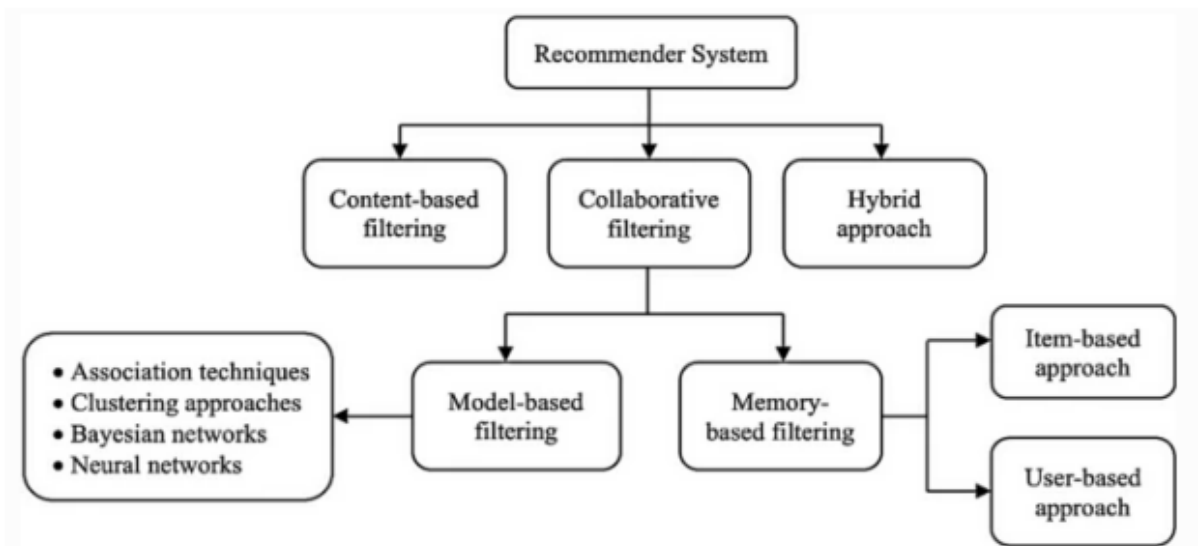


Рисунок 3.3 – Види рекомендаційних систем (2)

Переважає більшість існуючих рекомендаційних систем використовує всередині або колаборативну фільтрацію, або фільтрацію на основі вмісту, або їх поєднання. Однак, існують і інші системи, як то системи на основі знань.

3.2.1 Колаборативна фільтрація

Колаборативна фільтрація — це метод рекомендаційних систем, що базується на зборі та аналізі інформації про поведінку, діяльність або переваги різних користувачів. Цей метод використовує зібрані дані для прогнозування, як

користувачі можуть оцінити певний об'єкт, якого вони ще не оцінили. Основна ідея полягає в тому, що користувачі, які схожим чином оцінили один об'єкт або групу об'єктів, ймовірно, матимуть схожі уподобання і в інших випадках.

Принцип роботи колаборативної фільтрації зосереджений на створенні прогнозів, виходячи з рейтингів інших користувачів. Це може бути здійснено через визначення схожості між користувачами або об'єктами, засноване на історії їх взаємодій. Такий підхід дозволяє системі вивчати та адаптуватися до змінних переваг користувачів без необхідності розуміння вмісту об'єктів.

Колаборативна фільтрація важлива для розуміння соціальної динаміки споживачів і може допомогти підвищити точність рекомендаційних систем, забезпечуючи користувачам більш цілеспрямовані та відповідні пропозиції. Цей метод є основою багатьох успішних комерційних рекомендаційних систем і є центральним елементом в багатьох інтернет-сервісах, зокрема у стрімінгових сервісах, онлайн-магазинах та соціальних медіа.

Ця техніка залучає методи обробки великих даних та математичне моделювання для виявлення закономірностей у великих наборах інформації про користувачів та їхні взаємодії з контентом. Основні виклики, які виникають при реалізації колаборативної фільтрації, включають обробку розріджених даних, де багато користувачів мають взаємодію з обмеженою кількістю об'єктів, та здатність моделі адаптуватися до нових і змінних даних.

3.2.2 Контентна фільтрація

Контентна фільтрація в рекомендаційних системах заснована на аналізі характеристик об'єктів, які рекомендуються. В основу цього підходу лягає припущення, що якщо користувач проявляв інтерес до певних об'єктів в минулому, подібні об'єкти також можуть йому сподобатися. Для реалізації цього методу важливим є створення точного та охоплюючого профілю об'єкта.

Принцип роботи полягає в екстракції характеристик з контенту об'єктів, що може включати текст, зображення, метадані тощо. Наприклад, для фільмів можуть використовуватися такі атрибути, як жанр, режисер, ключові актори, а також

текстовий опис сюжету. Ці дані перетворюються на вектори характеристик за допомогою методів таких, як TF-IDF (термін-частота, обернена документальна частота) для тексту, або глибокі нейронні мережі для аналізу зображень [7].

Зазвичай в контентній фільтрації для аналізу використовуються косинусна подібність та класифікація за допомогою машинного навчання.

Цей метод є особливо корисним у ситуаціях, де потрібно ефективно порівнювати текстовий чи мультимедійний контент, що дозволяє системам рекомендацій визначати релевантний контент на основі вмісту, який користувачі раніше оцінили позитивно.

Класифікація за допомогою машинного навчання в контентній фільтрації рекомендаційних систем використовується для того, щоб визначати, які об'єкти можуть сподобатися користувачеві, базуючись на вивченні характеристик цих об'єктів. Застосування моделей машинного навчання, таких як логістична регресія, машини опорних векторів або нейронні мережі, дозволяє системі ефективно генерувати персоналізовані рекомендації. Модель навчається на історичних даних про інтеракції користувача та характеристиках об'єктів, щоб передбачати ймовірність того, що певний об'єкт відповідає інтересам користувача. В результаті, рекомендаційна система може пропонувати користувачам тільки ті об'єкти, які, ймовірно, їм сподобаються, підвищуючи ефективність та точність рекомендацій.

Підхід контентної фільтрації дозволяє системі рекомендацій автоматично адаптувати та оновлювати рекомендації в залежності від зміни контенту, що є особливо корисним у динамічних умовах сучасних медіа-платформ і онлайн-магазинів. Він також забезпечує високий рівень персоналізації, адже він враховує специфічні характеристики контенту, який вже сподобався користувачу.

Таким чином, фільтрація на основі вмісту є важливим елементом сучасних рекомендаційних систем, який дозволяє забезпечити більш цілісний та глибокий аналіз контенту, забезпечуючи точніші та більш релевантні рекомендації для кінцевих користувачів.

3.2.3 Гібридні методи

Поєднують в собі як колаборативні, так і контентні підходи для покращення точності рекомендацій. Гібриди можуть використовувати комбінації моделей або інтегрувати різні методи для отримання оптимальних результатів. Їх використовують для подолання обмежень методів, які базуються на контенті та колаборативній фільтрації, застосовують гібридні рекомендаційні системи, що інтегрують переваги обох підходів [8]. Ці гібридні системи можна класифікувати наступним чином: ваговий (weighted), перемикач (switching), змішаний (mixed), комбінація характеристик (feature combination), доповнення характеристик (feature augmentation), каскадний (cascade).

Гібридний підхід перемикача (switching) обирає одну систему рекомендацій в залежності від конкретної ситуації. Використовується модель для створення конфіденційного набору даних залежно від елементів, і належить встановити критерії вибору рекомендацій на основі профілю користувача чи інших параметрів. Цей підхід додає додатковий рівень у рекомендаційну систему, який визначає, яку модель слід використовувати. Система стає чутливою до сильних і слабких сторін використовуваної моделі рекомендацій.

При використанні перемикаючого гібридного підходу, система рекомендацій може змінювати методи в залежності від конкретної ситуації. Наприклад, для нового користувача, який вперше користується системою, рекомендації можуть базуватися на контенті, пропонуючи різноманітні категорії товарів. Після того як користувач здійснить кілька покупок, система може перейти до колаборативного підходу, рекомендувавши товари, які сподобались іншим користувачам з подібними інтересами. Такий перехід між методами залежить від обсягу та повноти інформації про користувача та його дії в системі.

Цей гібридний підхід дозволяє забезпечити якісні рекомендації для різних користувачів і в різних ситуаціях. Однак існує ризик, що надто часті переходи між методами можуть знизити точність і якість рекомендацій. Тому важливо збалансувати ці переходи, встановивши, наприклад, певний поріг інформації про користувача, після досягнення якого система перейде до колаборативного підходу

(див. рис. 3.4).

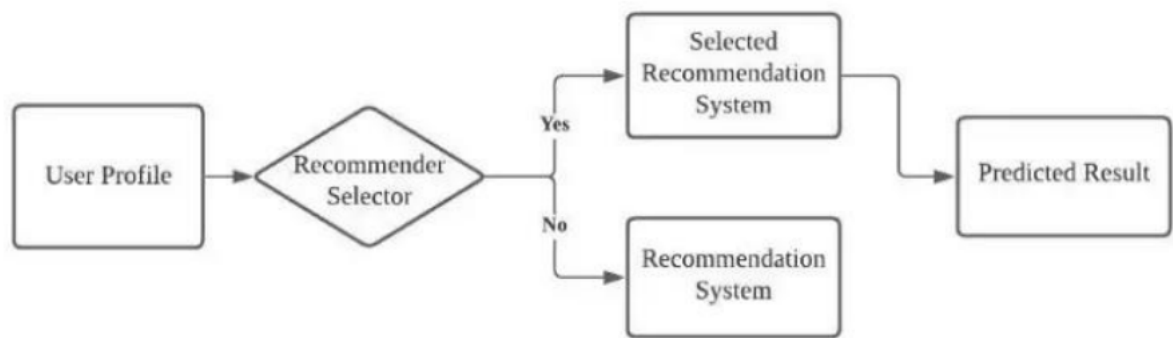


Рисунок 3.4 – Комутаційна гібридна система (switching) (12)

Каскадний гібридний підхід структурує систему рекомендацій ієрархічно: основна система спочатку надає первинний результат, після чого застосовується другорядна модель для виправлення дрібних недоліків цього результату, наприклад, усунення неоднозначностей у оцінках.

Каскадний гібридний метод поєднує кілька різних алгоритмів у послідовних етапах рекомендаційного процесу. На кожному етапі система використовує певний алгоритм для виділення набору елементів, які можуть бути потенційно привабливими для користувача. Наприклад, на першому етапі система може застосувати контент-базований алгоритм для пошуку елементів, що відповідають інтересам користувача. На другому етапі, після попереднього відбору, система може використовувати колаборативний алгоритм для уточнення рекомендацій на основі рейтингів та відгуків користувача.

Цей підхід дозволяє створювати більш точні рекомендації, оскільки поєднує переваги різних методів і мінімізує їхні недоліки. Однак, реалізація цього методу може бути складнішою, оскільки необхідно правильно налаштувати кожен етап і забезпечити, щоб рекомендації на одному етапі не перекривалися з рекомендаціями на наступному (див. рис. 3.5).

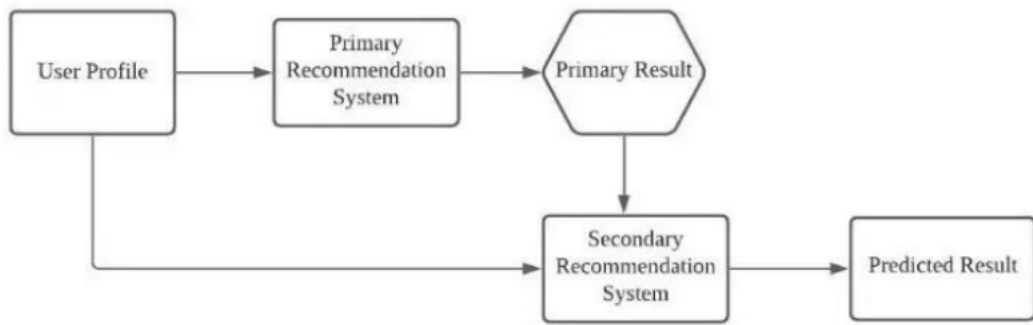


Рисунок 3.5 – Каскадна гібридна система (12)

Гібридний підхід із комбінацією функцій використовує декілька алгоритмів для аналізу різноманітних характеристик продуктів та користувачів. В цьому методі можна застосувати колаборативну та контент-базовану фільтрацію, де кожен з них обчислює різні аспекти. Зібрані характеристики від обох алгоритмів потім інтегруються для формування кінцевої рекомендації. У цьому підході вводиться додаткова віртуальна модель рекомендацій, яка використовується для розробки нових функцій на основі існуючих даних профілю користувача. Це дозволяє інтегрувати функції з моделі колаборативного фільтрування в модель, базовану на вмісті. Або ж навпаки, наприклад, контент-базований алгоритм може ідентифікувати продукти з певної категорії, що сподобались користувачу, тоді як колаборативний алгоритм може визначати фільми з певного жанру, що мають високі оцінки від користувача. Об'єднання цих характеристик дозволяє створити точніші та персоналізовані рекомендації, використовуючи сильні сторони обох підходів і мінімізуючи їхні слабкості. Така гібридна модель може аналізувати додаткові дані, не покладаючись виключно на одну модель (див. рис. 3.6).

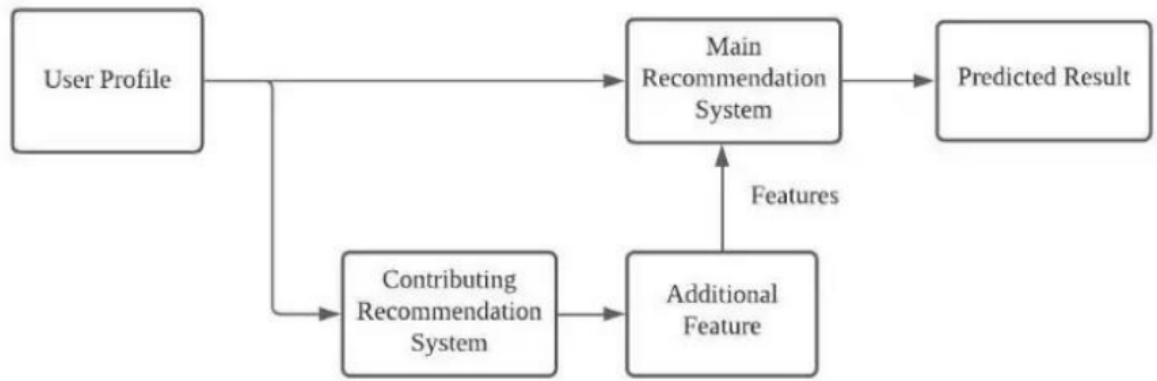


Рисунок 3.6 - Feature Combination гібридна система (12)

Зважений гібрид (Weighted Hybrid) - це підхід до рекомендацій, що об'єднує кілька алгоритмів, зважуючи їх внесок у кінцевий результат. У цьому методі кожен алгоритм отримує певну вагу, яка визначає його вплив на підсумкову рекомендацію.

Для визначення вагових коефіцієнтів можна використовувати різні підходи, включаючи експертну оцінку, кількісні метрики або машинне навчання. Наприклад, експерти можуть оцінювати ефективність кожного алгоритму за шкалою від 1 до 10, і ваговий коефіцієнт буде відповідати цій оцінці. У кількісних метриках вагові коефіцієнти можуть визначатися за допомогою крос-валідації, аналізу кореляцій або інших методів оцінки ефективності алгоритмів.

Зважений гібрид дозволяє підвищити точність рекомендацій у порівнянні з окремими алгоритмами. Наприклад, якщо один алгоритм добре справляється з проблемою холодного старту, а інший - з персоналізованими рекомендаціями, зважений гібрид може поєднати їхні сильні сторони для створення якісніших рекомендацій. Однак, визначення правильних вагових коефіцієнтів може бути складним завданням і вимагати як експертної оцінки, так і налаштування методів машинного навчання.

У ваговій гібридній системі рекомендацій можливе використання декількох моделей, кожна з яких ефективно аналізує даний набір даних. Така система бере результати з кожної моделі та об'єднує їх у єдиний результат з фіксованими вагами, які не змінюються в процесі тестування. Наприклад, можливе поєднання контент-

базованої моделі та моделі колаборативного фільтрування, де кожна модель вносить 50% ваги до кінцевого прогнозу. Перевага використання вагового гібриду полягає в тому, що він дозволяє інтегрувати кілька підходів для стабільної підтримки датасету в процесі видачі рекомендацій лінійним способом (див. рис. 3.7).

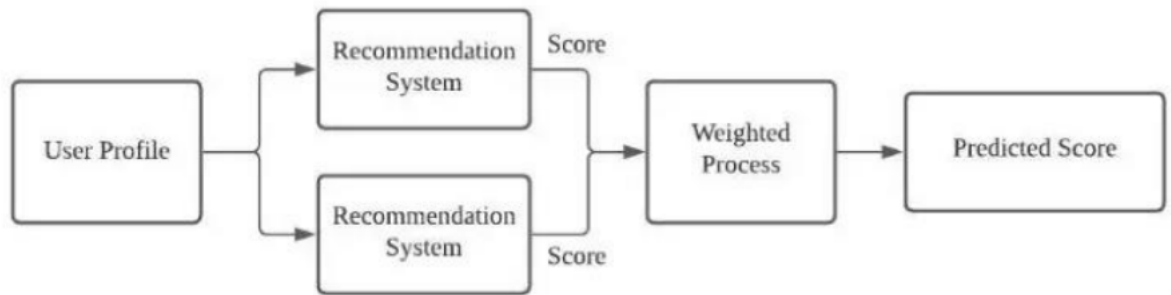


Рисунок 3.7 – Вагова гібридна система (12)

Гібридна система з розширенням функцій інтегрує методи колаборативної та контентної фільтрації, доповнюючи їх додатковими атрибутами, які описують характеристики користувачів та об'єктів. Цей підхід починається зі збору інформації про користувачів та об'єкти, зокрема, таких даних як вік, стать, інтереси, тематика об'єктів і так далі. Після цього, за допомогою алгоритмів машинного навчання, створюється модель, що враховує ці додаткові характеристики, аналізуючи їх вплив на рекомендації. Наприклад, знання про уподобання користувача до певного жанру книг може бути використане для рекомендації книг цього жанру.

Також, цей гібрид може використовувати додаткові атрибути для кращого злиття результатів від колаборативної та контентної фільтрації. Наприклад, вік користувача та його переваги можуть впливати на змішування методів, збільшуючи вагу колаборативної фільтрації для молодших користувачів та контентної для старших.

Цей підхід до гібридної системи рекомендацій забезпечує більш точні та персоналізовані рекомендації завдяки врахуванню різноманітних додаткових

атрибутів, але при цьому вимагає більшої кількості даних і складніших алгоритмів машинного навчання для розробки ефективних моделей.

Гібридний підхід розширення функцій здатне підвищити продуктивність основної системи без необхідності модифікації самої рекомендаційної моделі. Наприклад, використання асоціативних правил може збагатити даний профіль користувача. Це розширення даних сприяє покращенню ефективності моделі рекомендацій, базованої на вмісті. Використання додаткової моделі рекомендацій дозволяє створити оцінки або класифікації для профілів користувачів чи елементів, які потім використовуються в основній системі рекомендацій для генерації кінцевих прогнозів (див. рис. 3.8).



Рисунок 3.8 - Feature augmentation гібридна система (12)

Змішаний гібридний підхід спочатку використовує профіль користувача та характеристики для формування різноманітних даних-кандидатів. Система рекомендацій потім вводить ці набори кандидатів у модель рекомендацій та інтегрує прогнози для виведення остаточної рекомендації. Змішана гібридна система може одночасно надавати багато рекомендацій, використовуючи часткові набори даних у відповідних моделях для забезпечення покращеної продуктивності (див. рис. 3.9).

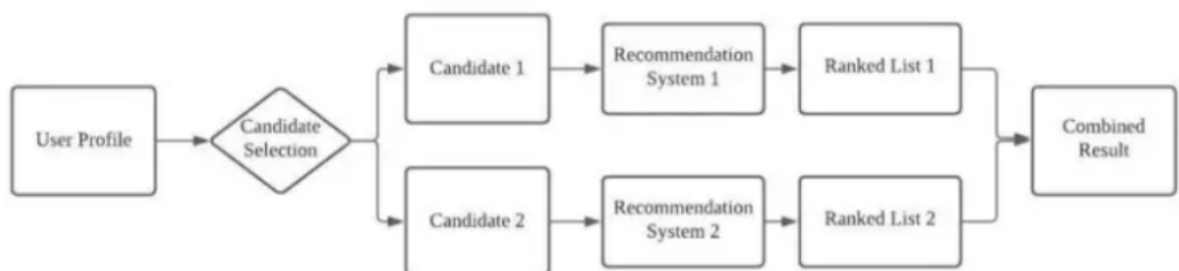


Рисунок 3.9 – Змішана гібридна система (12)

Метод змішаного гібриду інтегрує кілька підходів до рекомендацій в одну систему. Він може включати комбінації різних методів, таких як колаборативна фільтрація та контент-базова фільтрація, а також враховувати додаткові дані, як-от демографічні чи контекстуальні. Наприклад, система може використовувати контент-базову фільтрацію разом з колаборативною, доповнюючи її інформацією про вміст товарів, або інтегрувати зовнішні дані, такі як місцезнаходження користувача чи час доби, для персоналізації рекомендацій.

Змішані гібридні системи забезпечують більш точні рекомендації, оскільки опрацьовують ширший спектр інформації про продукти та користувачів, але їхня реалізація може бути складнішою та вимагати значних обчислювальних ресурсів.

3.2.4 Системи на основі знань

Системи рекомендацій на основі знань використовують знання про властивості користувачів та предметів, а також їх взаємодії, для рекомендацій. Включають методи, які базуються на визначених правилах або прецедентах, використовують детальні описи об'єктів та вимог користувачів для формування рекомендацій, що базуються на логічному виведенні та семантичних правилах. Вони спираються на структуровані бази знань, які можуть включати онтології, правила виводу, а також доменні знання про об'єкти, їхні властивості та взаємозв'язки. Основною відмінністю цих систем є їхня здатність обробляти запити користувачів у формі складних питань, що вимагають аналітичної обробки даних, і використання логічних моделей для виявлення та порівняння релевантності об'єктів.

Ці системи забезпечують високий рівень персоналізації і здатні адаптуватися до специфічних запитів користувача, пропонуючи рекомендації, які враховують не тільки інтереси, але й конкретні умови використання продуктів. Вони особливо ефективні в складних областях, де необхідно розуміння глибоких взаємозв'язків між атрибутами об'єктів.

Прогнозування рекомендацій вимагає не тільки розробки та оптимізації вказаних методів, але і врахування факторів, таких як динаміка зміни виборів

користувачів, обмеження ресурсів і питання конфіденційності даних. В сучасних рекомендаційних системах важливо забезпечити баланс між точністю прогнозувань і використанням обчислювальних ресурсів.

3.3 Алгоритми колаборативної фільтрації

Найширше застосування сьогодні отримали колаборативні рекомендаційні системи. Основна ідея алгоритмів колаборативної фільтрації полягає в пропозиції нових елементів для конкретного користувача на основі попередніх переваг користувача або думки інших однодумців користувача. Сьогодні дослідники розробили низку алгоритмів колаборативної фільтрації, які можна розділити на три основні категорії:

- model-based (побудовані на моделі даних);
- memory-based (побудовані на пам'яті);
- hybrid-based (поєднання model-based та memory-based).

3.3.1. Методи, засновані на побудові моделі даних (Model-based).

Модельно-орієнтовані системи використовують алгоритми обробки даних та машинного навчання для створення моделей, які прогнозують оцінки користувачів для елементів, які вони ще не переглядали. Ці системи вирізняються тим, що для обрахунку рекомендацій вони не потребують доступу до повної бази даних, а використовують лише вибрані характеристики з датасету. Спочатку за сукупністю оцінок формується описова модель переваг користувачів, товарів і взаємозв'язку між ними, а потім формуються рекомендації на підставі отриманої моделі. Процес формування рекомендацій розбитий на два етапи: ресурсомістке навчання моделі в відкладеному режимі і досить просте обчислення рекомендацій на основі існуючої моделі в реальному часі. Такі системи ефективні для групових рекомендацій і можуть швидко обробляти багато елементів. Якість цих систем значно залежить від алгоритмів, що використовуються для навчання моделей, і ці системи здатні вирішувати загальні проблеми рекомендаційних систем, такі як розрідженість даних та масштабованість, за допомогою технік зменшення розмірності та

оптимізації процесу навчання. Ці алгоритми можуть базуватися на імовірнісному підході, кластерному аналізі, аналізі прихованих чинників. Найчастіше ці алгоритми обробляють за допомогою матричної факторизації або за допомогою нейронних мереж.

Матрична факторизація в контексті рекомендаційних систем полягає у розкладанні вихідної матриці, що містить рейтинги, дані користувачами різним елементам, на дві нижчорангові матриці (див. формулу 3.1):

$$R \approx U \times V^T$$

де U – матриця, що представляє латентні фактори користувачів,

V — матриця, що представляє латентні фактори елементів.

Множення цих матриць дає приблизне відновлення вихідної матриці R , що дозволяє прогнозувати рейтинги для комбінацій користувач-елемент, де вихідні рейтинги відсутні. Це особливо корисно для рекомендацій, коли користувач або елемент має обмежену історію взаємодій [9].

Використання матричної факторизації в рекомендаційних системах дозволяє досягати високої точності та ефективності, особливо в умовах великих даних і розріджених матриць, де не всі користувачі взаємодіяли з усіма елементами.

У model-based колаборативній фільтрації нейронні мережі використовуються для моделювання складних взаємозв'язків між користувачами та об'єктами на основі великих обсягів даних. Застосування глибоких навчальних структур дозволяє системам ідентифікувати тонкі, неочевидні патерни поведінки користувачів, що надає змогу підвищити точність рекомендацій.

Принцип роботи полягає в тому, що на вхід нейронної мережі подається інформація про взаємодії користувачів з об'єктами, а на виході отримується оцінка того, як користувачі відреагують на не розглянуті раніше об'єкти. Цей процес включає навчання вагів мережі, яке адаптує модель під конкретні особливості даних, забезпечуючи високу адаптивність та ефективність рекомендаційних систем [10].

Завдяки своїй ефективності у вирішенні загальних проблем рекомендаційних систем, таких як розрідженість даних і потреба в масштабуванні, матрична факторизація та нейронні мережі є ключовими елементами в сучасних model-based колаборативних системах.

3.3.2 Методи, засновані на аналізі наявних оцінок (Memory-based).

Цей підхід ще називають методом найближчих сусідів (KNN): використання попередніх оцінок, зроблених клієнтом, і аналіз оцінок інших користувачів, які мають подібні переваги. Тоді рекомендації (прогноз) для цільового користувача формуються на підставі обчислення певної міри схожості по всіх накопичених даних. Підходи колаборативної фільтрації на основі пам'яті пропонують нові елементи, виходячи з вподобань користувачів у їхньому оточенні. Вони безпосередньо використовують матрицю корисності для визначення прогнозів. В цьому методі першим кроком є створення моделі, яка базується на даній матриці (див. формулу 3.2):

$$\text{Модель} = f(\text{матриця корисності})$$

Далі, рекомендації формуються за допомогою функції, котра використовує зазначену модель та профіль користувача як вхідні дані. Рекомендації можуть бути зроблені тільки для тих користувачів, чий профіль вже є частиною матриці корисності. Тому для рекомендацій новому користувачу його профіль потрібно додати до матриці, а також потрібно перерахувати матрицю схожості, що є обчислювально складним процесом [11].

Колаборативна фільтрація на основі пам'яті поділяється на два типи: фільтрація на основі користувачів (user-based KNN) та фільтрація на основі елементів (item-based KNN). У випадку фільтрації на основі користувачів, оцінка нового елемента визначається шляхом пошуку інших користувачів зі схожими вподобаннями, які вже оцінили цей елемент. Якщо новий елемент отримує високі

оцінки від цих користувачів, він рекомендується користувачу.

У методі, заснованому на елементах, формується кластер елементів, які є схожими на ті, що користувач вже оцінив. Потім рейтинг для нового елемента визначається через визначення зваженого середнього всіх рейтингів в цьому кластері подібних елементів.

В обох типах пошук схожого виконується за допомогою метрик подібності.

3.3.3 Методи, засновані на об'єднанні попередніх алгоритмів, – гібридні методи.

Гібридні алгоритми колаборативної фільтрації ефективно поєднують переваги як model-based, так і memory-based підходів, що дозволяє створити більш потужну рекомендаційну систему. Ці алгоритми використовують структуровані моделі для передбачення рейтингів за допомогою математичних моделей, а також зберігають і аналізують великі обсяги даних про попередні взаємодії користувачів для визначення схожості між ними. Завдяки поєднанню цих підходів, система може забезпечувати більш точні рекомендації, адаптуючи аналітичні моделі з урахуванням конкретних умов та поведінки користувачів у реальному часі. Гібридні моделі особливо ефективні в умовах, коли одиничні підходи не здатні адекватно адресувати усі аспекти задачі, таким чином забезпечуючи гнучкість та широкий спектр аналітичних можливостей для рекомендаційних систем [12].

4 ПОСТАНОВКА ЗАДАЧІ ТА ВИБІР МОДЕЛЕЙ ДЛЯ ДОСЛІДЖЕННЯ

4.1 Постановка технічного завдання

Головною метою нашого загального дослідження є оцінка ефективності різних прогнозуючих моделей у рекомендаційних системах, проведення аналізу на тому ж наборі даних, щоб визначити відповідність використання конкретної моделі в таких системах. Розглянемо завдання, які потрібно виконати задля проведення дослідження, оминувши теоретичний матеріал:

- обрати декілька найпоширеніших моделей прогнозування, (кожна з яких представляє окрему модель), які будуть приймати участь у дослідженні;
- обрати метрики оцінювання для проведення практичного дослідження;
- знайти конкретні реалізації обраних моделей прогнозування, що були обрані у першому пункті;
- обрати та підготувати програмне середовище, за допомогою якого можна буде перевірити моделі прогнозування;
- порівняти обрані моделі прогнозування рекомендаційних систем на однакових даних з метою виявлення доцільності використання тих чи інших моделей у цих системах;
- обґрунтувати висновки зроблені з результату виконаного практичного дослідження;

Після створення технічного завдання магістерського дослідження, перейдемо безпосередньо до його виконання.

4.2 Вибір моделей прогнозування рекомендаційних систем

Для того щоб виконати саме дослідження методів прогнозування для рекомендаційних систем, спочатку необхідна сама така система, що буде досліджуватись.

Для виконання поставленої мети відразу зрозуміло, що необхідні конкретні реалізації моделей для прогнозування в рекомендаційних системах.

З усіх існуючих моделей для прогнозування в рекомендаційних системах,

було обрано наступні п'ять реалізацій, таким чином, що кожна з них представляє окрему модель: дві реалізації CF за методом k-найближчих сусідів з фільтрацією на основі користувачів та на основі елементів, реалізація CF на основі імовірнісного матричного розкладання (PMF), реалізація нейронної колаборативної фільтрації (NCF) та реалізація фільтрації на основі вмісту.

Вибрані реалізації покривають дві найпоширеніші моделі – і контентну фільтрацію, і усі класичні підходи колаборативної фільтрації – обидва варіанта memory-based колаборативної фільтрації та найчастіше використовувані варіанти model-based колаборативної фільтрації: за допомогою матричної факторизації та нейронних мереж. Цей вибір моделей забезпечує всебічне покриття основних типів рекомендаційних систем і дає можливість оцінити різноманітні аспекти їхньої ефективності в різних сценаріях використання.

4.2.1 User-KNN

User-KNN визначає подібності між користувачами на основі їхніх рейтингів, використовуючи метрики подібності, такі як косинусна подібність та кореляція Пірсона. Цей метод відноситься до класу пам'яті заснованих систем, де прогнози для користувача формуються на основі рейтингів від подібних до нього користувачів. Це допомагає зберегти індивідуальний підхід до кожного користувача.

Розрахунок схожості між користувачами проводиться за допомогою векторів їхніх оцінок, а прогнози робляться шляхом зважування цих оцінок проти оцінок, які подібні користувачі дали товару. Увесь принцип побудований на припущенні, що користувачі, які згодилися в минулому, погодяться і в майбутньому [13].

Використання User-KNN дозволяє оцінити класичний підхід колаборативної фільтрації з точки зору здатності знаходити і використовувати користувальницькі зв'язки в даних.

4.2.2 Item-KNN

Item-KNN розраховує схожість між предметами, що заснована на оцінках

користувачів. Це включає аналізування як предмети оцінюються користувачами та використання цих оцінок для рекомендацій. Підхід зосереджений на знаходженні шаблонів рекомендацій між користувачами. Замість використання даних про взаємодії між користувачами, як це робить User-KNN, Item-KNN визначає, як товари подібні один до одного на основі оцінок, які вони отримують від користувачів.

Вимірювання схожості між товарами здійснюється на основі їх оцінок усіма користувачами, зазвичай використовуючи косинусну схожість або скориговану косинусну схожість для нормалізації. Рекомендації генеруються на основі цих оцінок схожості та існуючих оцінок користувача [14].

Цей класичний метод memory-based CF демонструє, як можна використовувати структурні зв'язки між предметами для формування рекомендацій, що є особливо корисним у випадках, коли існує мало даних про користувачів.

4.2.3 Імовірнісне матричне розкладання

PMF моделює взаємодії між користувачами і товарами за допомогою прихованих факторів, але з використанням ймовірнісного підходу. Він розглядає проблему як стохастичний процес, інтегруючи байєсівський фреймворк, який надає ймовірнісну інтерпретацію прихованим факторам. Цей підхід добре підходить для обробки розріджених наборів даних, які є загальними в багатьох реальних сценаріях.

PMF включає гауссівські розподіли для моделювання помилкових термінів і байєсівське виведення для оцінки параметрів. Це призводить до моделі, яка може виражати невизначеність у своїх прогнозах, що може бути важливим для забезпечення надійних рекомендацій [15].

PMF важливий для демонстрації, як можна ефективно використовувати статистичні моделі у рекомендаціях, забезпечуючи більшу точність і масштабування.

4.2.4 Нейронна колаборативна фільтрація

NCF поєднує класичні техніки матричної факторизації з нейронними мережами, зокрема з багат шаровим перцептроном (MLP). Ця модель використовує два окремі шляхи: один для матричної факторизації, яка вловлює загальні взаємодії, та інший, який моделює нелінійні взаємодії через MLP. Виходи обох шляхів комбінуються для прогнозування кінцевої оцінки. NCF ефективний завдяки своїй здатності вчитися складним і абстрактним особливостям з даних, потенційно покращуючи точність у порівнянні з традиційними методами.

NCF використовує вектори прихованих факторів користувачів і товарів та передає їх через нейронну архітектуру для вивчення і прогнозування взаємодій користувач-товар. Нейронний шлях часто включає кілька щільних шарів з нелінійними функціями активації, такими як ReLU, для моделювання складних паттернів [16].

Включення NCF у наше дослідження дозволяє оцінити вплив глибокого навчання на рекомендаційні системи, демонструючи передові методи виявлення складних неявних зв'язків.

4.2.5 Фільтрація на основі вмісту

Контентна фільтрація використовує інформацію про властивості об'єктів та користувачів для рекомендацій. Модель аналізує характеристики об'єктів та враховує вподобання користувачів, пропонуючи ті об'єкти, які відповідають їхнім особистим уподобанням. Модель бере інформацію з характеристик об'єктів та вподобання користувачів (текстовий опис, категорії тощо).

Для реалізації фільтрації на основі вмісту часто застосовуються техніки обробки природної мови для аналізу і вилучення змістовних шаблонів з описів контенту. Моделі машинного навчання, такі як TF-IDF або косинусна схожість, використовуються для обчислення схожості між товарами на основі їх характеристик [17].

Додавання контент-базованої фільтрації до нашого дослідження додає йому більше охопленості в контексті рекомендаційних систем, адже вона є головною альтернативою колаборативній фільтрації. Також вона дозволяє більш комплексно

аналізувати як поведінкові, так і контентні аспекти предметів, що рекомендуються, забезпечуючи глибше розуміння контексту користувача і контенту.

5 ОПИС ВИКОРИСТАНИХ МЕТРИК ТА ТЕХНОЛОГІЙ ДЛЯ ПРОВЕДЕННЯ ДОСЛІДЖЕННЯ

5.1 Засоби проведення дослідження

Проведення даного магістерського дослідження буде виконуватись завдяки мові програмування Java у середовищі розробки IntelliJ Idea.

Java є однією з найпопулярніших мов програмування у світі, відомою своєю портативністю, продуктивністю та великою спільнотою. Це дозволяє легко знаходити ресурси, бібліотеки та підтримку для розробки складних наукових додатків. Управління пам'яттю в Java на основі збору сміття забезпечують високу надійність під час виконання довготривалих експериментів.

Для проведення практичного дослідження була обрана бібліотека CF4J на Java [18], що дозволяє ефективно виконувати дослідження моделей прогнозування рекомендаційних систем, забезпечуючи зручні інструменти для оцінки та аналізу результатів. Також вона надає прямий доступ до широкого спектру алгоритмів та методів, які можна легко інтегрувати та порівняти в рамках одного дослідження.

Завдяки зручності Java в CF4J є можливість легко інтегрувати додаткові модулі та бібліотеки, що є критично важливим для адаптації та розширення функціональності системи під специфічні потреби дослідження. Можливість модифікації та додавання нових алгоритмів у CF4J без значних зусиль забезпечує гнучкість у виборі дослідницьких методів.

5.2 Методи подібності

Методи визначення подібності - це техніки, що застосовуються для оцінки рівня схожості між елементами в масивних дата-сетах. У контексті машинного навчання та аналізу даних, ці методи застосовують для обчислення відстаней або індексів подібності між об'єктами, які можуть бути представлені у формі числових даних. Ці методи використовуються в багатьох моделях прогнозування, щоб оцінити подібність. Серед наших обраних моделей вони використовуються в контентній фільтрації, в user-KNN та item-KNN. Найбільш вживаними в сфері

рекомендаційних систем вважаються косинусна подібність та кореляція Пірсона. Але існує ще багато розповсюджених метрик таких, як міра Жаккара та кореляція Спірмена. Кожна з цих метрик має свої унікальні характеристики та переваги, які роблять їх придатними для конкретних сценаріїв використання у рекомендаційних системах.

5.2.1 Косинусна подібність

Косинусна подібність дозволяє оцінювати, наскільки два об'єкта є схожими, шляхом вимірювання косинуса кута між їх векторами характеристик. Ці вектори репрезентують об'єкти у багатовимірному просторі, де кожна вимірювання відповідає певній характеристиці або властивості об'єкта. Чим менший кут між векторами, тим вища подібність, тобто косинус цього кута наближається до одиниці, що вказує на високу схожість між об'єктами.

Формула косинусної подібності виглядає наступним чином (див. формулу 5.1):

$$\cos(\vec{a}, \vec{b}) = \frac{\vec{a} \cdot \vec{b}}{\|\vec{a}\|^2 * \|\vec{b}\|^2}$$

де $\vec{a} \cdot \vec{b}$ позначає скалярний добуток векторів,

$\|\vec{a}\|$ і $\|\vec{b}\|$ є нормами (довжинами) цих векторів.

Косинусна подібність не чутлива до масштабу і ефективна при великій кількості нульових значень. Особливо корисна у системах з розрідженими даними, такими як рекомендаційні системи з великою кількістю користувачів та об'єктів.

5.2.2 Кореляція Пірсона

Кореляція Пірсона є статистичним показником, який вимірює ступінь лінійної залежності між двома змінними. Вона використовується для визначення сили та напрямку (позитивного чи негативного) лінійного зв'язку між двома змінними.

Коефіцієнт кореляції Пірсона r розраховується за наступною формулою:

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2 \sum(Y_i - \bar{Y})^2}}$$

де X_i та Y_i є значеннями двох змінних,

\bar{X} та \bar{Y} є середніми значеннями змінних X та Y відповідно.

Різниця між спостереженням та його середнім значенням вимірює наскільки кожне значення відхиляється від середнього, а добуток цих різниць вказує на напрямок зв'язку між змінними, позитивний чи негативний. Сума всіх цих добутків показує загальний лінійний зв'язок між змінними. Наприкінці ділення суми добутків на добуток квадратних коренів сум квадратів різниць нормалізує результат, забезпечуючи, що значення коефіцієнта кореляції Пірсона завжди знаходиться в межах від -1 до $+1$, де: $+1$ вказує на ідеальний позитивний лінійний зв'язок, -1 вказує на ідеальний негативний лінійний зв'язок, а 0 свідчить про відсутність лінійного зв'язку.

Цей коефіцієнт корисний для аналізу великих даних та виявлення зв'язків між змінними, що допомагає в прогнозуванні рекомендаційних систем та інших аналітичних дослідженнях. Також ця кореляція добре підходить для систем, де потрібно розглядати відносні відхилення від середнього рівня оцінювання.

5.2.3 Міра Жаккара

Міра Жаккара, також відома як індекс Жаккара або коефіцієнт Жаккара, є статистичною мірою, що використовується для порівняння подібності та різноманітності між двома множинами. Цей індекс визначає, наскільки дві множини схожі одна на одну шляхом порівняння розміру перетину множин до розміру їхнього об'єднання [19].

Індекс Жаккара J між двома множинами A та B визначається як:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

де $|A \cap B|$ - це кількість елементів у перетині множин A та B , тобто кількість елементів, які присутні в обох множинах,

$|A \cup B|$ - це кількість елементів в об'єднанні множин A та B , тобто всі унікальні елементи, які присутні в одній або обох множинах.

Розрахунок перетину множин дозволяє визначити, скільки елементів спільно присутні в обох множинах. Це основа для визначення ступеню подібності між множинами. Розрахунок об'єднання множин дозволяє врахувати всі унікальні елементи, які зустрічаються в одній або обох множинах. Це показує потенційну різноманітність між множинами.

Індекс Жаккара вираховується як відношення кількості елементів у перетині до кількості елементів в об'єднанні. Чим більше індекс, тим більша подібність між множинами. Індекс приймає значення від 0 до 1, де 0 означає відсутність спільних елементів, а 1 - ідентичність множин.

Індекс Жаккара цінний для систем, де важлива відмінність між наявними і відсутніми елементами, наприклад, в класифікаціях з обмеженими атрибутами.

5.2.4 Кореляція Спірмана

Кореляція Спірмена — це непараметричний метод вимірювання статистичної залежності між рангами двох змінних. Вона використовується для визначення монотонності зв'язку між двома кількісними або порядковими змінними [20].

Коефіцієнт рангової кореляції Спірмена ρ між двома змінними X і Y можна визначити за формулою:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

де d_i — різниця рангів кожного спостереження в двох наборах даних,

n — кількість спостережень.

Спочатку кожному значенню змінних X і Y присвоюється ранг. Якщо два або більше значень однакові (тобто виникає зв'язка), то їм присвоюється середній ранг. Для кожного спостереження визначається різниця рангів d_i між X і Y . Потім розраховується квадрат різниці рангів для кожного спостереження і вони сумуються.

У рекомендаційних системах кореляція Спірмена може використовуватися для оцінювання схожості у ранжуванні предметів різними користувачами. Також вона не вимагає нормального розподілу даних і є стійкою до викидів, роблячи її ідеальною для непараметричних даних, які часто зустрічаються у рекомендаційних системах.

5.3 Обрання показників оцінки моделей прогнозування

Для того, щоб оцінити практично методи прогнозування, нам треба обрати оцінити значення прогнозу, які вони створюють. Це робиться шляхом обчислення відповідних показників помилок. Показник помилки – це спосіб кількісної оцінки ефективності моделі та надає прогнозісту спосіб кількісного порівняння різних моделей. Вони дають нам спосіб об'єктивніше оцінити, наскільки добре модель виконує свої завдання.

В прогнозуваннях рекомендацій одними найчастіше використовуються середня абсолютна помилка (MAE) та середньоквадратична помилка (RMSE). Обидві метрики дозволяють оцінювати точність прогнозів, які генерує модель, і є широко визнаними в індустрії та науковому співтоваристві за їх ефективність і зрозумілість. За допомогою цих похибок ми і будемо порівнювати точність прогнозування в наших моделях.

Обрання MAE та RMSE як основних показників дослідження дозволяє забезпечити всебічне розуміння точності та надійності моделей прогнозування в рекомендаційних системах. Це важливо для забезпечення, що моделі не тільки точні у середньому, але й ефективні при обробці великих відхилень або непередбачених сценаріїв, що є критично важливим у комерційних додатках.

5.3.1 Середня абсолютна помилка

MAE визначається як середнє значення абсолютної різниці між прогнозованими та справжніми значеннями.

$$MAE = \frac{1}{n} \sum_{t=1}^{t=n} |y' - y|$$

де n — кількість оцінюваних елементів у датасеті,

y' — фактичне значення i -го елемента,

y — прогнозоване значення для i -го елемента,

$|y' - y|$ - абсолютна помилка прогнозу для i -го елемента.

Чим менше значення MAE, тим краща модель; нульове значення означає відсутність помилки в прогнозі. Іншими словами, при порівнянні кількох моделей кращою вважається модель із найнижчим MAE.

MAE є інтуїтивно зрозумілою метрикою, яка прямо вказує на середню помилку в одиницях вимірювання. Вона добре підходить для випадків, де важливо знати абсолютний розмір помилок, і є менш чутливою до викидів, ніж RMSE. Однак MAE не вказує на відносний розмір помилки, і стає важко відрізнити великі помилки від малих. Однак його можна використовувати разом з іншими показниками (наприклад з RMSE), щоб визначити, чи є помилки більшими.

5.3.2 Середньоквадратична помилка

Середня квадратична помилка (MSE) визначається як середнє квадратів помилки. Він також визначається як показник, який оцінює якість моделі прогнозування або предиктора. MSE також включає як дисперсію (розкид прогнозованих значень одне від одного), так і зміщення (відстань прогнозованого значення від його справжнього значення).

RMSE показник є розширенням MSE і визначається як квадратний корінь середньої квадратичної помилки:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^{t=n} (y' - y)^2}$$

де n — кількість оцінюваних елементів у датасеті,

y' — фактичне значення i -го елемента,

y — прогнозоване значення для i -го елемента,

$(y' - y)^2$ - квадрат відстані між фактичним та прогнозованим значеннями для i -го елемента.

RMSE помічає більші помилки точніше, надаючи кращу картину про помилки моделі в сценаріях, де великі відхилення є критично небажаними. Це робить RMSE особливо корисною в дослідженнях, де важливіша точність великих прогнозів. RMSE також можна порівняти з MAE, щоб визначити, чи містить прогноз великі, але рідкісні помилки. Чим більша різниця між RMSE і MAE, тим більше суперечливий розмір помилки.

6 ПРАКТИЧНЕ ДОСЛІДЖЕННЯ МЕТОДІВ ПРОГНОЗУВАННЯ РЕКОМЕНДАЦІЙНИХ СИСТЕМ

6.1 Підготовка до проведення експерименту

Для проведення експерименту було обрано датасет MovieLens100k, який є дуже популярним у сфері прогнозування рекомендаційних систем. Наше дослідження має за мету покрити усі загальні підходи прогнозування, саме тому ми обрали різні моделі. Ми змогли знайти загальні метрики для оцінювання, використовуючи похибки, але ми також маємо різні метрики подібності, які використовуються в трьох з п'яти обраних моделях: в контентній фільтрації, в user-KNN та item-KNN. В залежності від обраної метрики подібності, ми будемо мати різні результати, оскільки вони напряду впливають на прогнозування рекомендацій. В реалізаціях PMF та NCF ці метрики подібності не приймають участь, тому було наше дослідження було розбито на два етапи: спочатку ми порівнюємо окремо кожен модель, яка використовує метрики подібності, і оберемо реалізацію з тією метрикою, які дають найменшу похибку. Після цього будуть визначені найкращі реалізації моделей для контентної фільтрації, user-KNN та item-KNN. На фінальному етапі дослідження ми будемо порівнювати їх з реалізаціями PMF та NCF.

6.2 Дослідження метрик подібності

В дослідженні будуть порівнюватись наступні обрані нами метрики подібності (косинусна схожість, міра Жаккарта, кореляція Пірсона та кореляція Спірмана) для кожної моделі з трьох, в яких вони використовуються. Також важливим параметром, який впливає на прогнозування в усіх трьох моделях, є кількість сусідів. Для усіх моделей було обрано діапазон від 10 сусідів до 50 з шагом 10.

6.2.1 Дослідження метрики подібності для user-KNN моделі

Результати дослідження метрик подібності для user-KNN моделі (див. рис. 6.1):




Рисунок 6.1 – Значення помилок MAE та RMSE для User-KNN моделі в залежності від обраної метрики подібності

На графіках видно, що для обох помилок загальна динаміка зміни значень дуже схожа, майже однакова. В обох випадках, моделі з індексом Жаккара та кореляцією Спірмана суттєво переважають кореляцію Пірсона та косинусну подібність. Модель з кореляцією Спірмана на протязі усього діапазону має найменше значення, тому саме її ми оберемо для другого етапу дослідження.

6.2.2 Дослідження метрики подібності для item-KNN моделі

Дослідження метрик подібності для item-KNN моделі (див. рис. 6.2):

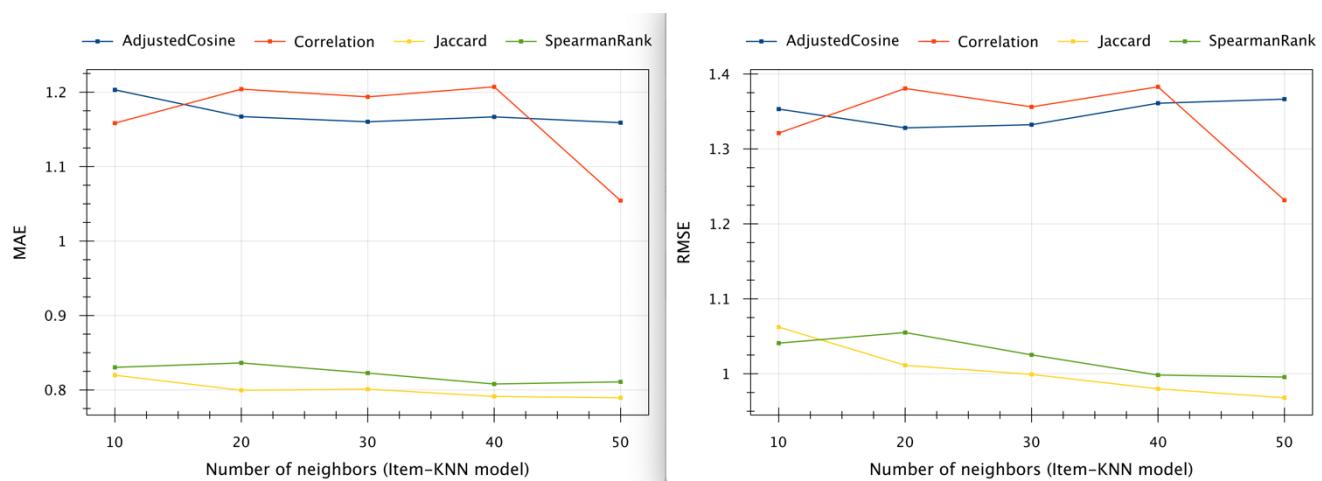


Рисунок 6.2 - Значення помилок MAE та RMSE для item-KNN моделі в залежності від обраної метрики подібності

Як і для user-KNN, для item-KNN на цьому діапазоні значень сусідів моделі з індексом Жаккара та кореляцією Спірмана мають значно менше значення похибок, ніж косинусна подібність та кореляція Пірсона, тут навіть різниця між ними ще більша. Однак для item-KNN моделі метрика подібності, за допомогою якої вона найменше значення похибки протягом усього діапазону, є індекс Жаккара. Тому для дослідження другого етапу ми оберемо модель з цією метрикою подібності.

6.2.3 Дослідження метрики подібності для моделі контентної фільтрації

Дослідження метрик подібності моделі контентної фільтрації (див. рис. 6.3):

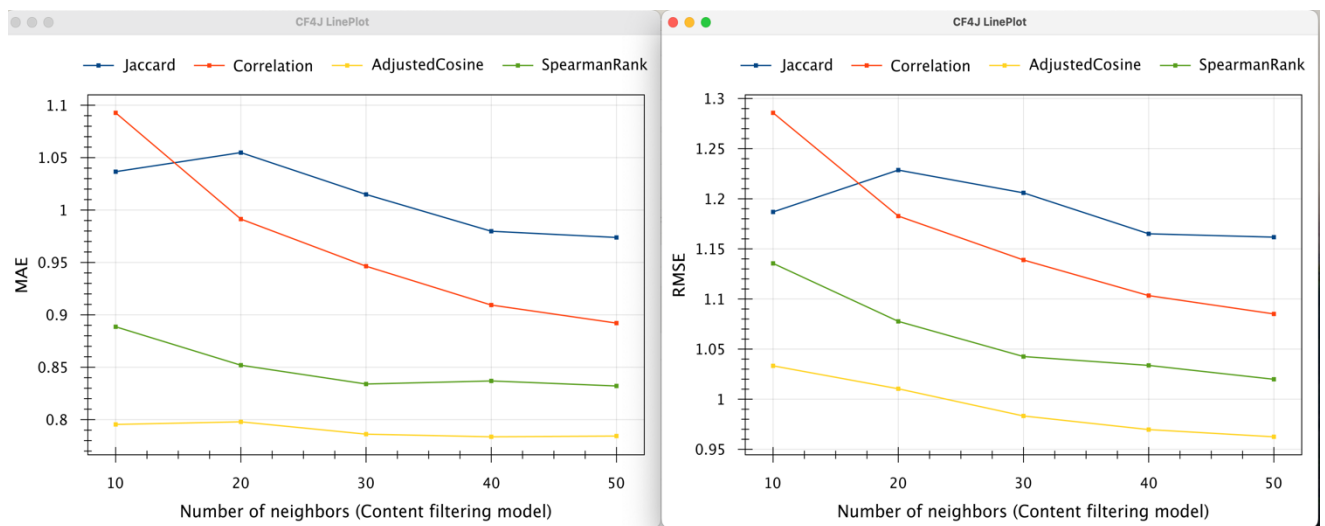


Рисунок 6.3 - Значення помилок MAE та RMSE для content filtering моделі в залежності від обраної метрики подібності

Тут ми бачимо значно інші результати, ніж в попередніх KNN моделях колаборативної фільтрації. Гірші результати показали індекс Жаккара, а також кореляція Пірсона, кореляція Спірмана як і в попередніх системах має непоганий результат, а найкращою метрикою подібності виявилась косинусна схожість, тобто модель з нею буде приймати участь у другому етапі дослідження.

6.2.4 Оцінка дослідження метрик подібності

Після обрання метрик подібностей з найменшими похибками для наших KNN моделей та моделі контентної фільтрації можемо оцінити це дослідження та

зробити проміжкові висновки. Перша найочевидніша тенденція, це динаміка зміни значень похибки. Ця динаміка зміни однакова для MAE та RMSE на кожній метриці, що пояснюється однаковою математичною основою цих похибок. Також видно що значення похибок не в залежності від метрики зі збільшенням кількості сусідів зменшується, що теж є очевидно, адже зі збільшенням кількості сусідів збільшується кількість інформації і система стає більш точною.

По кореляції Пірсона можна зробити висновок, що для починаючих рекомендаційних систем, або систем які мають діапазон, схожий на наш, це не є оптимальним варіантом для жодної моделі. На нашому обраному діапазоні обидві похибки більше 1, для item KNN взагалі майже увесь діапазон значення похибок тримається на такому ж високому рівні як і для початкового значення кількості сусідів. Також видно що для user-KNN на кінці діапазону значення похибки починає трохи збільшуватись, що теж є погано. Однак для item-KNN та контентної фільтрації в кінці динаміка значення впевнено зменшується, тому цілком ймовірно що для інших діапазонів (значно більшої кількості сусідів) кореляція Пірсона може мати перевагу над іншими метриками.

Косинусна подібність неефективна для KNN моделей, але найефективніша для контентної фільтрації, що пояснює чому на практиці для цих моделей використовують саме цю метрику подібності.

Індекс Жаккара навпаки, є доволі ефективним для KNN моделей, для item-KNN він показав найкращий результат, а от для контентної фільтрації має в кінці нашого діапазону найгірші показники.

Кореляція Спірмана показала непогані результати для усіх моделей, якби треба було обрати одну метрику яка підходить найбільш усім, то це була б вона.

6.3 Проведення загального дослідження

Після дослідження метрик подібності, ми виявили, що найкраща user-KNN модель з кореляцією Спірмана, item-KNN модель - з індексом Жаккара, а модель контентної фільтрації – з косинусом подібності. Ці моделі разом з моделями PMF та NCF ми також будемо порівнювати по значенням похибок MAE та RMSE. Для

моделей PMF та NCF не існує такого параметра як кількість сусідів, але я схожа метрика – кількість прихованих факторів. Як і в першому етапі дослідження було обрано діапазон від 10 до 50 з кроком 10.

Ми можемо побачити значення похибок для усіх моделей, що приймають участь в дослідженні (див. рис. 6.4):

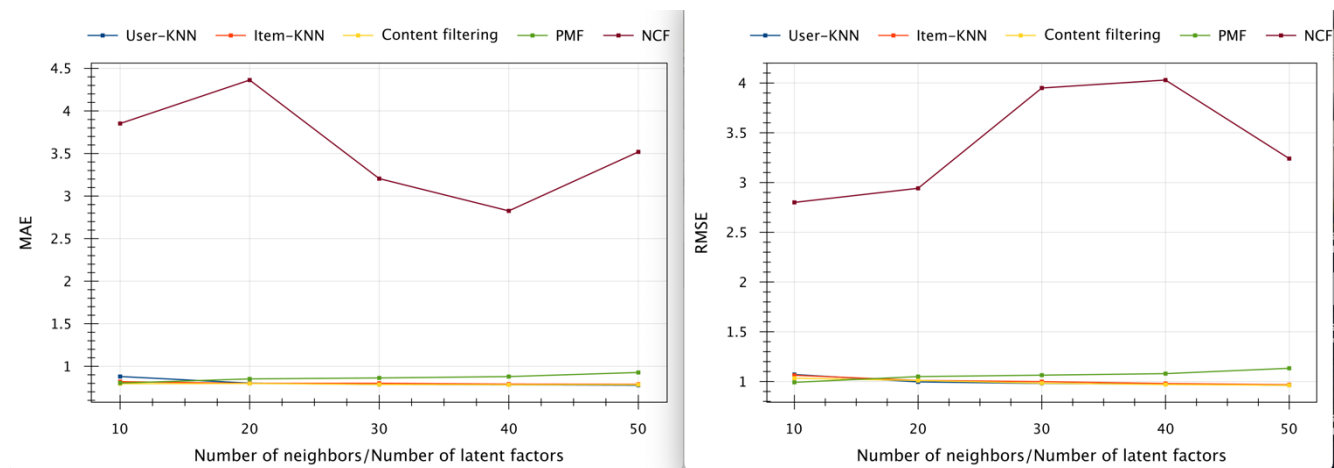


Рисунок 6.4 – Значення похибок MAE та RMSE для усіх моделей

Одразу видно, що для моделі NCF значення похибок є набагато більшими, тому можемо зробити висновок, що використовувати нейронну колаборативну фільтрацію для невеликих рекомендаційних систем (з кількістю прихованих факторів до 50) недоцільно, бо вона буде набагато менш точною, ніж інші моделі. Інші моделі мають схожі значення, лише видно, що для PMF моделі на протязі усього діапазону значення похибок потроху, але стабільно іде вгору, що є поганою тенденцією і можна зробити висновок, що з більшою кількістю сусідів значення буде збільшуватись. Для того щоб краще роздивитись інші моделі приблизимо значення на графіку (див. рис. 6.5):

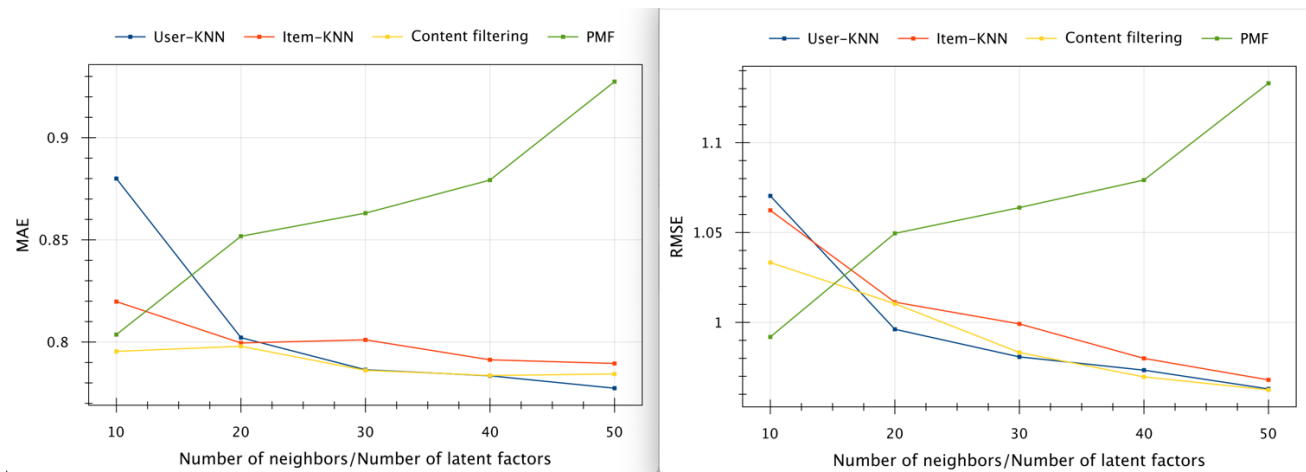


Рисунок 6.5 – Значення похибок MAE та RMSE для усіх моделей, крім NCF

Тут краще видно, що значення похибки для PMF моделі зі збільшенням кількості прихованих факторів усе істотніше відрізняється від похибки для інших моделей і в кінці діапазона різниця вже доволі відчутна, що точно скажеться на точності прогнозів рекомендацій. Значення похибок для user-KNN, item-KNN та контентної фільтрації майже однакові, для кращого розуміння подивимось абсолютні значення (див. рис. 6.6 і 6.7):

Number of N/LF	User-KNN	Item-KNN	Content filtering	PMF	NCF
10	0.8800	0.8198	0.7954	0.8037	4.5584
20	0.8022	0.7996	0.7979	0.8518	4.0679
30	0.7864	0.8011	0.7862	0.8631	3.5097
40	0.7835	0.7913	0.7836	0.8793	3.3459
50	0.7774	0.7895	0.7844	0.9274	3.0277

Рисунок 6.6 – Абсолютні значення похибки MAE для усіх моделей

Number of N/LF	User-KNN	Item-KNN	Content filtering	PMF	NCF
10	1.0704	1.0623	1.0333	0.9919	3.4854
20	0.9962	1.0113	1.0104	1.0495	3.5378
30	0.9808	0.9992	0.9833	1.0639	3.7684
40	0.9734	0.9800	0.9697	1.0792	3.2284
50	0.9630	0.9680	0.9625	1.1330	3.5803

Рисунок 6.7 – Абсолютні значення похибки RMSE для усіх моделей

Видно, що значення похибок для user-KNN, item-KNN та моделі контентної фільтрації зі збільшенням кількості сусідів стають майже ідентичними та в кінці діапазону вже не відрізняються не більше ніж на 0,01. Це говорить нам про те, що при виборі моделі прогнозування серед цих трьох моделей, треба звертати увагу в першу чергу на предметну галузь рекомендаційної системи. Адже знаючи як влаштована кожна з цих моделей можна обирати ту модель, для якої в рекомендаційній системі буде більше взаємодії, потрібної для неї. Тобто, якщо це система, де головна задача якої є активна взаємодія користувачів між собою, наприклад соцмережі, то тут доречніше обрати user-KNN. Для інтернет-магазину, скоріше підійде item-KNN, адже в системі тоді буде більше інформації про взаємодію юзера з товаром. А для якогось сервісу з перегляду фільмів найімовірніше найбільше підійде контентна фільтрація. Тобто тут головне обрати ту модель, для якої рекомендаційна система зможе дати більше інформації, адже чим більша система, тим більше точність прогнозування. Якщо порівнювати ці три традиційні моделі без контексту, як це зроблено у нашому дослідженні, то можна зробити висновок, що на даному діапазоні точність прогнозування однакова. Найважливіше для кожної моделі обрати правильну метрику подібності, що ми зробили на першому етапі дослідження.

ВИСНОВКИ

Рекомендаційні системи відіграють ключову роль у численних галузях від електронної комерції до соціальних мереж, де вони впливають на вибір споживачів, підвищуючи задоволеність користувачів та оптимізуючи процеси продажу. Актуальність теми дослідження підкреслюється стрімким розвитком цифрових технологій та потребою в розробці більш ефективних і точних систем рекомендацій, що зумовлює вибір цієї теми для детального вивчення в магістерській роботі.

У перших трьох розділах було проведено глибокий аналіз існуючих підходів до створення рекомендаційних систем, включаючи колаборативну фільтрацію, контент-базовані системи та гібридні моделі. Основні теоретичні концепції і моделі, що були розглянуті в цих розділах, заклали фундамент для подальших емпіричних досліджень та аналізу ефективності конкретних методів прогнозування.

В ході практичного дослідження було проведено аналіз п'яти різних моделей прогнозування рекомендаційних систем. Основне дослідження полягало у порівнянні для цих моделей показників похибок MAE та RMSE на одному наборі даних.

Для моделей, що використовують метрики подібності, було проведено їх аналіз для визначення ефективніших метрик для кожної з цих моделей і під час дослідження було визначено, що для моделей, які використовують метрики подібності, що вибір методу подібності має значний вплив на результати точності моделей прогнозування.

Згідно з результатами основного дослідження було визначено, що контентна фільтрація та memory-based моделі CF виявились більш точними, ніж model-based моделі CF, реалізовані за допомогою PMF та NCF. Результати дослідження забезпечують цінний внесок у розуміння різних аспектів рекомендаційних систем, підкреслюючи, що більш прості і традиційні методи можуть бути більш ефективними у певних сценаріях.

Робота також підкреслює важливість правильного вибору та налаштування параметрів рекомендаційних систем для досягнення оптимальних результатів. На прикладі нашого дослідження, в якому три моделі з п'яти отримали майже однакові похибки, також можна зробити висновок, що для вибору моделі прогнозування, треба в першу чергу враховувати домен рекомендаційної системи, щоб визначити, яка модель може дати більше інформації. Ці висновки можуть бути корисними при проектуванні та оптимізації рекомендаційних систем у комерційних застосуваннях.

В подальших дослідженнях пропонується зосередити увагу на дослідженні гібридних моделей, які ми детально проаналізували в теоретичній частині. Такий підхід може допомогти розширити можливості рекомендаційних систем та виявити нові шляхи їх вдосконалення, адже в гібридних системах відчутний потенціал до підвищенні точності та адаптивності. Також можна розширити діапазон дослідження, щоб побачити як ведуть себе різні моделі у великих рекомендаційних системах.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Chalyi S., Leshchynskyi V., Leshchynska I. “Multilevel personalization of explanations in recommender systems”. Сучасні інформаційні системи. 2020. Т. 4. № 2. С. 170-175.
2. Лобур М.В., Шварц М.Є., Стех Ю.В., "Моделі і методи прогнозування рекомендацій для колаборативних рекомендаційних систем" // Вісник Національного університету «Львівська політехніка»: «Інформаційні системи та мережі», Львів, 2018, випуск 901, с. 68-75
3. Чалий С.Ф., Лещинський В.О., Лещинська І.О., Моделювання контексту в рекомендаційних системах - Проблеми інформаційних технологій, 2018, с.21-26
4. S. Chalyi, V. Leshchynskyi, I. Leshchynska, "DETAILING EXPLANATIONS IN THE RECOMMENDER SYSTEM BASED ON MATCHING TEMPORAL KNOWLEDGE" Eastern-European Journal of Enterprise Technologies, 2020, 4(2-106), с. 6–13
5. Hyung Jun Ahn, “A new similarity measure for collaborative filtering to alleviate the new user cold-starting problem”, Information Sciences, Volume 178, Issue 1, 2008, Pages 37-51, ISSN 0020-0255. URL: <https://doi.org/10.1016/j.ins.2007.07.024> (дата звернення 28.04.2024).
6. Chalyi, S., Leshchynskyi, V., Leshchynska, I. "Method of forming recommendations using temporal constraints in a situation of cyclic cold start of the recommender system", EUREKA, Physics and Engineering, 2019, 2019(4), с. 34-40
7. K. Kosim and Reza Prihandi, “Recommendation System Algorithm Content-Based Filtering Method to Provide Drink Menu Recommendations”, J.Math.Instr.Soc.Res.Opin., vol. 2, no. 2, pp. 158–168, Jul. 2023.
8. MeleshkoE.V. Дослідження методів побудови рекомендаційних систем в мережі інтернет / MeleshkoE.V., S.G. Semenov, V.D. Khokh // Системи управління, навігації та зв'язку. Збірник наукових праць. – Полтава: ПНТУ, 2018. – Т. 1 (47). – С. 131-136. URL: <https://doi.org/10.26906/SUNZ.2018.1.131> (дата звернення 28.04.2024).

9. Xueyi Liu, Jie Tang, “Network representation learning: A macro and micro view”, *AI Open*, Volume 2, 2021, Pages 43-64, ISSN 2666-6510. URL: <https://doi.org/10.1016/j.aiopen.2021.02.001> (дата звернення 28.04.2024).
10. Hong-Jian Xue, Xin-Yu Dai, Jianbing Zhang, Shujian Huang, Jiajun Chen, "Deep Matrix Factorization Models for Recommender Systems" // *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, 2017: 2437–2444. URL: <https://www.ijcai.org/proceedings/2017/0447.pdf> (дата звернення 28.04.2024).
11. Bobadilla, J., Ortega, F., Hernando, A. and Arroyo, Á. (2012), "A Balanced Memory-Based Collaborative Filtering Similarity Measure", *Int. J. Intell. Syst.*, 27: 939-946. URL: <https://doi.org/10.1002/int.21556> (дата звернення 28.04.2024).
12. Li, Lianhuan, Zhang, Zheng, Zhang, Shaoda, “Hybrid Algorithm Based on Content and Collaborative Filtering in Recommendation System Optimization and Simulation”, *Scientific Programming*, 2021, 7427409, 11 pages, 2021. URL: <https://doi.org/10.1155/2021/7427409> (дата звернення 28.04.2024).
13. Hael Al-bashiri, Hasan Kahtan, Mansoor Abdullateef Abdulgaber, Awanis Romli and Mohammad Adam Ibrahim Fakhreldin, “Memory-based Collaborative Filtering: Impacting of Common Items on the Quality of Recommendation” *International Journal of Advanced Computer Science and Applications(IJACSA)*, 10(12), 2019. URL: <http://dx.doi.org/10.14569/IJACSA.2019.0101218> (дата звернення 28.04.2024).
14. S. Chalyi, V. Leshchynskyi, I. Leshchynska, “Modeling explanations for the recommended list of items based on the temporal dimension of user choice” - *Control, navigation and communication systems*, 2019, p. 97-101
15. O.C. Carasco, "PMF for Recommender Systems," *Towards Data Science*, May 7, 2020. URL: <https://towardsdatascience.com/pmf-for-recommender-systems-cbaf20f102f0> (дата звернення 28.04.2024).
16. He, Xiangnan, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu and Tat-Seng Chua. “Neural Collaborative Filtering.” *Proceedings of the 26th International Conference on World Wide Web (2017)*: n. pag. 48-54
17. Jieun Son, Seoung Bum Kim, “Content-based filtering for recommendation systems using multiattribute networks”, *Expert Systems with Applications*, Volume 89,

2017, Pages 404-412, ISSN 0957-4174. URL: <https://doi.org/10.1016/j.eswa.2017.08.008> (дата звернення 28.04.2024).

18. Fernando Ortega, Jorge Mayor, Daniel López-Fernández, and Raul Lara-Cabrera, "CF4J 2.0: Adapting Collaborative Filtering for Java to new challenges of collaborative filtering based recommender systems," Knowledge-Based Systems 215 (2021): 106629, <https://doi.org/10.1016/j> (дата звернення 28.04.2024).

19. M. Jadeja "Jaccard Similarity Made Simple: A Beginner's Guide to Data Comparison" // Medium, Nov 18, 2022. URL: <https://medium.com/@mayurdhvajsinhjadeja/jaccard-similarity-34e2c15fb524> (дата звернення 28.04.2024).

20. E. McClenaghan "Spearman Rank Correlation" // Technology Networks, Apr 22 2024. URL: <https://www.technologynetworks.com/tn/articles/spearman-rank-correlation-385744> (дата звернення 28.04.2024).

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ ЗА НАУКОВИМИ
НАПРЯМАМИ КЕРІВНИКА ТА НАУКОВЦІВ КАФЕДРИ
ПРОГРАМНОЇ ІНЖЕНЕРІЇ**

1. Chalyi S., Leshchynskyi V., Leshchynska I. "Multilevel personalization of explanations in recommender systems". Сучасні інформаційні системи. 2020. Т. 4. № 2. С. 170-175.
3. Чалий С.Ф., Лещинський В.О., Лещинська І.О., "Моделювання контексту в рекомендаційних системах" - Проблеми інформаційних технологій, 2018, с.21-26
4. S. Chalyi, V. Leshchynskyi, I. Leshchynska, "DETAILING EXPLANATIONS IN THE RECOMMENDER SYSTEM BASED ON MATCHING TEMPORAL KNOWLEDGE" Eastern-European Journal of Enterprise Technologies, 2020, 4(2-106), с. 6–13
6. Chalyi, S., Leshchynskyi, V., Leshchynska, I. "Method of forming recommendations using temporal constraints in a situation of cyclic cold start of the recommender system", EUREKA, Physics and Engineering, 2019, 2019(4), с. 34-40
14. S. Chalyi, V. Leshchynskyi, I. Leshchynska, "Modeling explanations for the recommended list of items based on the temporal dimension of user choice" - Control, navigation and communication systems, 2019, p. 97-101