

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Інформаційних управляючих систем
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА Пояснювальна записка

рівень вищої освіти другий (магістерський)
Дослідження методів оцінки і прогнозування ефективності ІТ-проектів
рекомендаційних систем
(тема)

Виконав:
студент 2 курсу, групи УПГІТМ-21-1
Оксана ПОСИПАЙКО
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)
Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Управління проектами в
галузі інформаційних технологій
(повна назва освітньої програми)

Керівник д.т.н, доц., проф. каф. ІУС Оксана
ЧАЛА
(посада, власне ім'я, прізвище)

Допускається до захисту

Зав. кафедри


(підпис)


Костянтин ПЕТРОВ
(власне ім'я, прізвище)

2023 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
Кафедра Інформаційних управляючих систем
Рівень вищої освіти другий (магістерський)
Спеціальність 122 Комп'ютерні науки
(код і повна назва)
Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)
Освітня програма Управління проектами в галузі інформаційних технологій
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри 
(підпис)

« 03 » квітня 20 23 р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові Посипайко Оксані Вікторівні
(прізвище, ім'я, по батькові)

1. Тема роботи Дослідження методів оцінки і прогнозування ефективності ІТ-проектів рекомендаційних систем
затверджена наказом університету від 03 квітня 2023 р. № 319Ст
2. Термін подання студентом роботи до екзаменаційної комісії 16 05 2023 р.
3. Вихідні дані до роботи методична та технічна література, матеріали конференцій, дані інтернет-мережі, мова програмування Python, середовище розробки Google Collab.
4. Перелік питань, що потрібно опрацювати в роботі Провести огляд літератури та загальний аналіз методів оцінки ефективності ІТ проектів рекомендаційних систем. Провести збір та аналіз даних про ІТ проекти рекомендаційних систем. Дослідити розроблення та застосування моделі прогнозування ефективності ІТ проектів рекомендаційних систем. Провести аналіз та узагальнення результатів дослідження.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Отримання завдання для кваліфікаційної роботи	3.04.2023	Виконано
2	Аналіз предметної області для кваліфікаційної роботи	4.04.2023 – 8.04.2023	Виконано
3	Формування плану роботи на кваліфікаційною роботою	9.04 – 11.04.2023	Виконано
4	Робота над теоретичними відомостями для кваліфікаційної роботи	12.04.2023 – 19.04.2023	Виконано
5	Аналіз існуючих методів оцінки ефективності рекомендаційних систем	20.04.2023 – 22.04.2023	Виконано
6	Аналіз методів для рекомендаційних систем на практиці	22.04.2023 – 25.04.2023	Виконано
7	Оформлення звіту та висновків	25.04.2023 – 30.04.2023	Виконано
8	Захист кваліфікаційної роботи	17.05.2023	Виконано

Дата видачі завдання 3 квітня 2023 р.

Студент



(підпис)

Керівник роботи



(підпис)

Д.Т.Н, доц., проф. каф. ІУС Оксана ЧАЛА

(посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка до кваліфікаційної роботи магістра: 80 с., 30 рис., 12 табл., 30 джерел, 1 додаток.

ЕФЕКТИВНІСТЬ, НАБІР ДАНИХ, ПЕРСОНАЛІЗАЦІЯ,
ПРОГНОЗУВАННЯ, РЕКОМЕНДАЦІЙНА СИСТЕМА

Об'єкт дослідження – процес оцінки ефективності ІТ проектів рекомендаційних систем.

Предмет дослідження – методи оцінки прогнозування ефективності ІТ проектів рекомендаційних систем.

Мета дослідження – виявити недоліки в існуючих методах дослідження прогнозування ефективності рекомендаційних систем практичним шляхом та запропонувати покращення необхідні покращення для їх роботи.

ABSTRACT

Explanatory note: 80 p., 30 fig., 12 tabl., 30 sources, 1 app.

**DATA SET, EFFICENCY, FORECASTING, PERSONALIZATION,
RECOMMENDER SYSTEM**

Object of research - the process of evaluating the effectiveness of IT projects of recommender systems.

Subject of research - methods for evaluating the forecasting of the effectiveness of IT projects of recommender systems.

The purpose of the study is to identify shortcomings in existing methods of researching the prediction of the effectiveness of recommender systems in a practical way and to propose improvements necessary for their operation.

ЗМІСТ

Скорочення та умовні позначки.....	8
Вступ.....	9
1 Аналіз підходів до оцінки ефективності іт-проектів рекомендаційних систем.....	13
1.1 Дослідження властивостей рекомендаційних систем.....	13
1.2 Аналіз процесу функціонування рекомендаційної системи.....	16
1.3 Дослідження методів оцінки ефективності рекомендаційних систем .	18
1.4 Постановка задачі	22
2 Ансамблевий підхід до оцінки ефективності рекомендаційних систем.....	26
2.1 Метрики оцінки рекомендацій на основі помилок	26
2.2 Ансамблевий метод оцінки ефективності та прогнозування ІТ-проекту рекомендаційної системами	28
3 Опис розробки іт-проекту оцінки і прогнозування ефективності рекомендаційної системи.....	35
3.1 Опис ініціації ІТ-проекту.....	35
3.2 Опис результатів планування ІТ-проекту	40
4 Реалізація та експериментальна перевірка вдосконаленого методу оцінки ефективності прогнозування рекомендаційної системи.....	47
4.1 Реалізації модулю оцінки і прогнозування ефективності рекомендаційної системи	47
4.2 Експериментальна перевірка ансамблевого методу роботи з RMSE метрикою в рекомендаційних системах.....	57

4.3 Рекомендації щодо практичного застосування розробленого методу	65
Висновки.....	69
Перелік джерел посилання.....	70
Додаток А Слайди презентації.....	74

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

ІІТ – Інформаційно-пошукові технології;

ІС – інформаційна система;

СВRS – Content based recommender systems;

ІRS – Information Retrieval System;

ІМDB – Internet Movie Database;

RMSE – Root Mean Square Error.

ВСТУП

Інформаційні технології (ІТ) є однією з найважливіших галузей в сучасному світі, яка забезпечує розвиток бізнесу, науки, освіти та інших сфер життєдіяльності. Особливо важливе місце в ІТ займають рекомендаційні системи, які допомагають користувачам знаходити відповідні рекомендації щодо товарів, послуг, контенту та інших різноманітних об'єктів в інтернеті. Застосування рекомендаційних систем може привести до покращення задоволення користувачів, збільшення продажів, залучення нових клієнтів та підвищення конкурентоспроможності бізнесу.

Однак, оцінка та прогнозування ефективності ІТ проектів рекомендаційних систем залишається актуальною проблемою, оскільки вона впливає на успішність впровадження та використання таких систем. Ефективність рекомендаційних систем може бути пов'язана з різноманітними факторами, такими як вибір методів рекомендації, обробка великого обсягу даних, забезпечення якості рекомендацій, врахування контексту користувача та багато інших. Отже, вивчення методів оцінки та прогнозування ефективності рекомендаційних систем є важливим завданням, яке може допомогти вдосконалити їх функціональність та результативність.

В сучасному інформаційному суспільстві рекомендаційні системи використовуються в різних сферах, таких як електронна комерція, соціальні мережі, медіа, реклама, музика, фільми, подорожі та багато інших. Застосування рекомендаційних систем може забезпечити користувачам персоналізований досвід, зекономити час та ресурси, та збільшити рівень задоволення користувачів від використання різноманітних сервісів та продуктів.

Однак, в контексті ІТ проектів рекомендаційних систем, виникає необхідність оцінки та прогнозування їх ефективності, що може стати складною задачею. Незважаючи на широке застосування рекомендаційних систем, відсутність відповідних методів оцінки та прогнозування може призвести до неповної відповідності між очікуваними та отриманими результатами впровадження таких систем. Дефіцит наукових досліджень в цій області робить цю проблему особливо актуальною.

Дослідження методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем може мати значний практичний вплив. Результати такого дослідження можуть бути корисні для розробників рекомендаційних систем, бізнесу, організацій, які використовують такі системи, а також науковців та дослідників в галузі ІТ.

Перш за все, вивчення методів оцінки та прогнозування ефективності рекомендаційних систем може допомогти розробникам систем вибрати оптимальні методи рекомендації, налаштувати параметри системи, та визначити ключові фактори, які впливають на її ефективність. Це може сприяти покращенню якості рекомендацій, забезпечити більш точні та релевантні рекомендації користувачам, та знизити кількість неправильних рекомендацій, що можуть призвести до незадоволення користувачів.

Далі, дослідження в цій області може бути корисним для бізнесу та організацій, які використовують рекомендаційні системи в своїй діяльності. Відповідні методи оцінки та прогнозування можуть допомогти визначити ефективність впровадження рекомендаційних систем у контексті конкретних бізнес-процесів, та забезпечити раціональне використання ресурсів на їхнє впровадження. Це може допомогти бізнесу зекономити кошти, збільшити конкурентоспроможність та вдосконалити взаємодію з клієнтами.

Крім того, результати дослідження можуть бути корисні для науковців та дослідників в галузі ІТ. Вони можуть використовувати вивчені методи оцінки

та прогнозування для розширення теоретичних знань в галузі рекомендаційних систем, розвитку нових підходів та вдосконалення наукових методів. Це може сприяти подальшому розвитку цієї галузі та забезпеченню наукової бази для впровадження рекомендаційних систем у різних сферах діяльності.

Отже, дослідження методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем має важливість та актуальність в сучасному світі, де рекомендаційні системи стали невід'ємною частиною багатьох веб-сервісів та додатків, і їхнє вдосконалення є ключовим фактором для забезпечення високої якості взаємодії між користувачами та системами. Результати дослідження можуть мати практичні застосування для бізнесу, організацій та науковців, допомагаючи впроваджувати ефективні рекомендаційні системи, покращувати їх продуктивність та забезпечувати кращий досвід користувачів.

Дослідження методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем також може внести вагомий внесок у науковий аспект галузі рекомендаційних систем. Воно може допомогти вдосконалювати наявні методи, розробляти нові підходи та техніки оцінки, прогнозування та валідації рекомендаційних систем. Це може сприяти розвитку цієї наукової галузі, забезпечувати актуальність досліджень та сприяти розширенню наукового знання у цій області.

Таким чином, дослідження методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем має важливість та актуальність для різних зацікавлених сторін, таких як бізнес, організації та науковці. Воно може допомогти вдосконалювати рекомендаційні системи, забезпечувати їхню ефективність та вдосконалювати взаємодію між користувачами та системами, а також розвивати науковий аспект галузі рекомендаційних систем.

В даному дослідженні будуть випробовані існуючі методи оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем. Результати цих експериментів дозволять оцінити ефективність різних підходів та методів, які використовуються в сучасних рекомендаційних системах.

Додатково, в рамках дослідження будуть запропоновані покращення для існуючих методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем. Ці покращення можуть включати вдосконалення алгоритмів, використання нових технік або введення додаткових факторів в оцінювання ефективності. Для цього будуть використані результати аналізу літературних джерел, наукових досліджень та експериментів.

Пропоновані покращення можуть бути спрямовані на забезпечення більш точних та надійних оцінок ефективності рекомендаційних систем, покращення їхньої прогнозної здатності, забезпечення більш точних рекомендацій для користувачів, зниження кількості помилкових рекомендацій або підвищення рівня персоналізації рекомендаційних систем.

Такі покращення можуть мати практичне застосування для різних відомств та організацій, що використовують рекомендаційні системи в своїх діяльностях. Вони можуть допомогти забезпечити більш точні та ефективні рекомендації для користувачів, забезпечуючи кращий досвід взаємодії з рекомендаційними системами та сприяючи досягненню поставлених цілей ІТ проектів.

1 АНАЛІЗ ПІДХОДІВ ДО ОЦІНКИ ЕФЕКТИВНОСТІ ІТ-ПРОЕКТІВ РЕКОМЕНДАЦІЙНИХ СИСТЕМ

1.1 Дослідження властивостей рекомендаційних систем

Інформаційно-пошукові технології (Information Retrieval Technologies) набули надзвичайного поширення за останні два десятиліття з появою величезних сховищ інформації в Інтернеті, зокрема, у Всесвітній павутині.

Серед багатьох нових тенденцій, що впливають з цього основного потоку досліджень і розробок, на початку 2000-х років почала розглядатися нова мета пошуку: чи можна передбачити, наскільки якісним буде результат, отриманий за допомогою ІР-системи, до того, як представити його користувачеві [1].

Рекомендаційна система – це програмний алгоритм, який аналізує дані про поведінку користувачів та надає рекомендації щодо товарів, послуг, контенту або будь-яких інших елементів, які можуть зацікавити користувача.

На рис. 1.1 показано схему рекомендаційної системи та принцип її роботи, де зображено, яку роль вона відіграє при взаємодії користувача з веб-сторінками.



Рисунок 1.1 – Модель рекомендаційної системи

Персоналізовані системи рекомендацій мають на меті допомогти користувачам у доступі та відновленні інформації та відповідних об'єктів у величезних колекціях за допомогою автоматичного пошуку продуктів або послуг, що становлять потенційний інтерес, на основі спостережень за вподобаннями користувачів.

Вподобання користувачів важко передбачити з багатьох причин, і тому системи рекомендацій мають значну варіативність, оскільки вони намагаються оцінити смаки та інтереси кожного користувача (рисунок 1.2). У цьому випадку автоматичне прогнозування ймовірності того, що рекомендація буде прийнята до уваги до того, як вона буде надана користувачеві, є цікавим з багатьох точок зору [2].

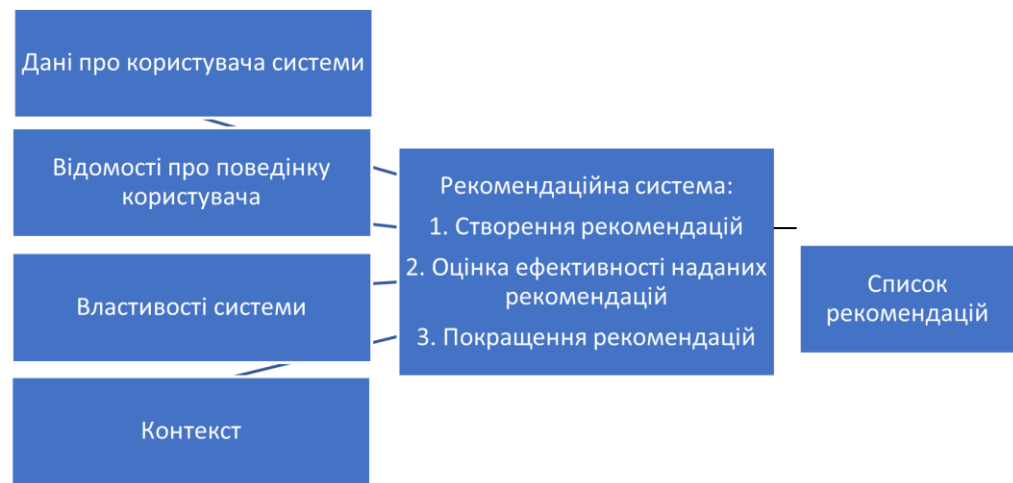


Рисунок 1.2 – Процес роботи рекомендаційної системи

Рекомендаційна система повинна збирати дані про користувачів, їхній профіль, поведінку на сайті та інші дані, які можуть допомогти у визначенні їхніх інтересів.

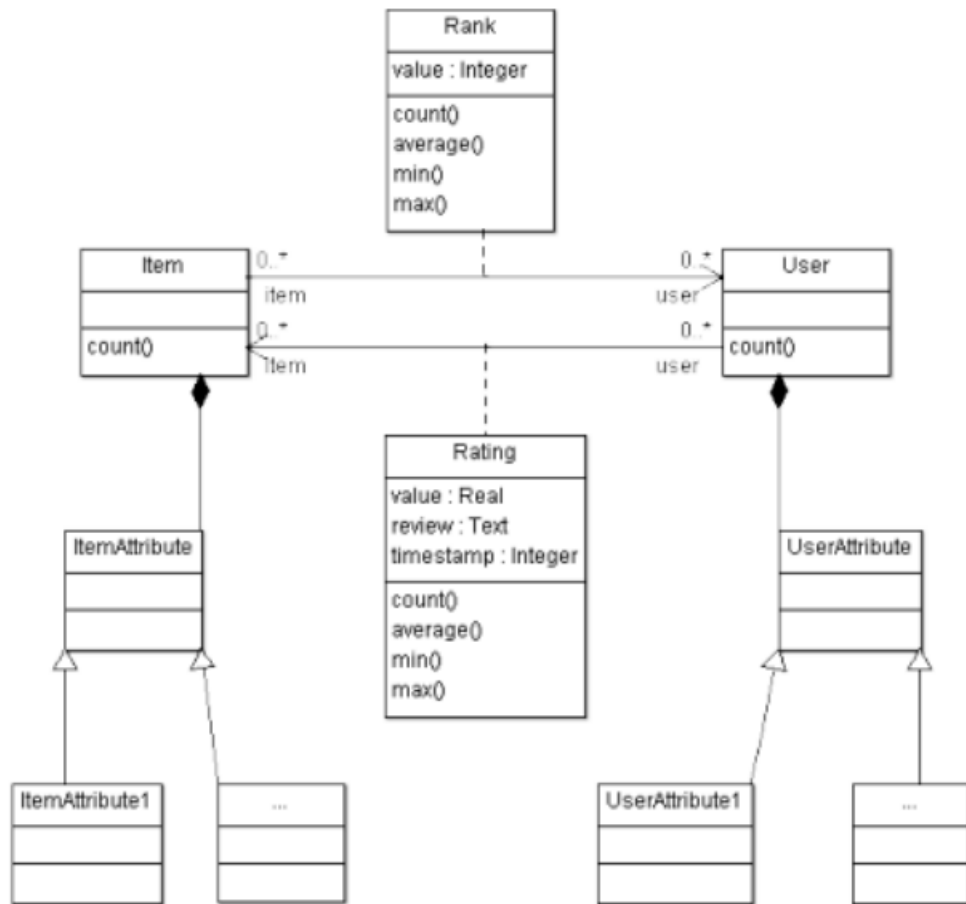


Рисунок 1.3 – Схема класів в рекомендаційних системах

Рекомендаційна система повинна аналізувати зібрані дані, щоб визначити інтереси та поведінку користувачів, їхній смак та вподобання (рисунок 1.3).

Рекомендаційна система повинна створювати персоналізовані рекомендації для кожного користувача, враховуючи його інтереси та поведінку на сайті [3].

Рекомендаційна система повинна оцінювати ефективність своїх рекомендацій та вдосконалюватися на основі результатів.

Рекомендаційна система повинна мати здатність обробляти велику кількість даних в режимі реального часу. Для цього використовуються різні технології, такі як розподілені системи обробки даних та потокова обробка даних.

1.2 Аналіз процесу функціонування рекомендаційної системи

Основні фактори, які відіграють важливу роль в оцінці ефективності рекомендаційної системи (рисунок 1.4):

- точність – показник, який визначає, наскільки точні рекомендації системи;
- різноманітність – показник, який вимірює різноманітність рекомендацій, які надає система. Цей показник важливий для того, щоб уникнути рекомендацій, які повторюються, та забезпечити більш широкий спектр варіантів для користувача;
- новизна – показник, який визначає, наскільки нові рекомендації, які надає система. Нові рекомендації можуть допомогти користувачам відкривати нові інтереси та отримувати новий досвід;
- непередбачуваність – показник, який визначає, наскільки неочікувані рекомендації, які надає система. Непередбачувані рекомендації можуть допомогти користувачам знайти нові речі, які вони не очікували;
- залучення користувача – показник, який визначає, наскільки активно користувачі взаємодіють з системою та наскільки задоволені вони її рекомендаціями. Цей показник можна вимірювати за допомогою метрик, таких як кількість переглядів, кількість кліків на рекомендації та тривалість сесій користувачів [4].



Рисунок 1.4 – Основні фактори для оцінки ефективності рекомендаційної системи

На сьогодні актуальним буде розробити поглиблене дослідження того, як системи рекомендацій можуть бути надійно оцінені з точки зору числових значень метрик, оскільки ми прагнемо передбачити їхню продуктивність. Крім того, необхідно дослідити, чи існує упередженість у способі оцінювання систем – чи то методологією оцінювання, чи то метрикою, оскільки будь-яка упередженість у процесі оцінювання може призвести до непереконливих або оманливих результатів щодо прогностичної сили запропонованих методів прогнозування продуктивності.

Якщо такі упередження існують, потрібно точно визначити їх і розробити методологію для їх ізоляції; потім перевірити ефективність предикторів у порівнянні з відомими базовими показниками і з'ясувати, чи змінюється вона при застосуванні неупереджених методологій.

Крім того, методологічне дослідження експериментального підходу, налаштування та метрик повинно бути виконано таким чином, щоб використовувати відповідні базові методи та експериментальні схеми. Нарешті,

буде оцінено покращення та переваги комбінованих методів при застосуванні предикторів продуктивності.

На рис. 1.5 зображено стислий процес оцінки ефективності рекомендаційних систем.



Рисунок 1.5 – Процес оцінки ефективності рекомендаційної системи

Після того як ми визначили основні метрики ефективності рекомендаційної системи, ми зможемо з впевненістю сказати, чи ефективні використані в подальшому методи в якості рекомендатора.\

1.3 Дослідження методів оцінки ефективності рекомендаційних систем

Оцінка рекомендаційних систем була і залишається об'єктом активних досліджень у цій галузі. З моменту появи перших рекомендаційних систем ефективність рекомендацій зазвичай ототожнювали з точністю прогнозування рейтингу, тобто розраховані рейтинги порівнювали з фактичними рейтингами, а різницю між ними обчислювали за допомогою показників середньої абсолютної похибки та середньоквадратичної похибки [5].

З точки зору ефективної корисності рекомендацій для користувачів зростає розуміння того, що якість (точність) ранжування рекомендованих об'єктів може бути важливішою, ніж точність прогнозування конкретних

значень рейтингу. Як наслідок, метрики, орієнтовані на точність, все частіше розглядаються в цій галузі, і велика кількість останніх робіт зосереджена на оцінюванні списків рекомендацій топ-N за допомогою вищезгаданого типу метрик [6].

Оцінювання рекомендаційних систем було основним об'єктом вивчення в цій галузі з перших днів її існування і досі залишається темою постійних досліджень, в яких залишаються відкриті питання. Зазвичай розглядають два основні протоколи оцінювання: онлайн та офлайн. У цій роботі зосереджено увагу на онлайн оцінюванні.

Спираючись на методологічні підходи, характерні для оцінки алгоритмів класифікації, машинного навчання та пошуку інформації, оцінка онлайн-систем рекомендацій ґрунтується на вилученні з системи частини наявних знань про вподобання користувачів (тестові дані), залишенні решти (навчальні дані) як вхідних даних для алгоритму і вимозі до системи передбачити такі вподобання, так що якість рекомендацій оцінюється з точки зору того, як передбачення системи збігається з вилученими відомими вподобаннями.

У домінуючій практиці це порівняння було орієнтоване на вимірювання точності прогнозування рейтингу, обчислення показників, заснованих на помилках. Однак, з точки зору ефективної корисності рекомендацій для користувачів, зростає розуміння того, що якість (точність) ранжування рекомендованих об'єктів може бути важливішою, ніж точність (похибка) прогнозування конкретних значень рейтингу [7].

У класичному формулюванні проблеми рекомендацій вподобання користувачів щодо товарів представлені у вигляді числових оцінок, а мета алгоритму рекомендацій полягає у прогнозуванні невідомих оцінок на основі відомих оцінок і, в деяких випадках, додаткової інформації про користувачів, товари та контекст.

У цьому сценарії точність рекомендацій зазвичай оцінюється шляхом вимірювання похибки між прогнозованими і відомими рейтингами, використовуючи такі метрики, як середня абсолютна похибка (MAE) і середньоквадратична похибка (RMSE).

Метрики, орієнтовані на точність, вимірюють кількість релевантних і нерелевантних повторно перевірених (рекомендованих) елементів. Протягом багатьох років у галузі інформаційного пошуку було розроблено значну кількість метрик, методологій та наборів даних.

Рекомендація може бути природно сформульована як завдання інформаційного пошуку: користувачі мають неявну потребу в просторі об'єктів, які можуть служити цілям користувача, і завдання рекомендаційної системи полягає в тому, щоб вибрати, ранжувати і представити користувачеві набір об'єктів, які можуть найкращим чином задовольнити його потребу.

Потреба користувача, а також якості або причини, чому той чи інший об'єкт задовольняє її, не можуть бути виявлені в повному обсязі або описані точно і повно, що є визначальною характеристикою проблеми інформаційного пошуку, на відміну від завдань пошуку даних або логічного доведення.

Таким чином, природно адаптувати методологію оцінювання інформаційного пошуку, що базується на релевантності, яка в основному складається з отримання вручну міток релевантності рекомендованих об'єктів відносно потреб користувача та оцінювання різними способами кількості релевантних рекомендованих об'єктів [8].

Найбільш досліджувані методи для оцінки ефективності рекомендаційних систем зображені на рис. 1.6.

Метод на основі помилок

- Порівнянні фактичних дій користувачів з рекомендаціями, що надаються системою, і обчисленні різниці між ними.

Метод на основі точності

- Використовує метрики, такі як точність, відгук та F-міра

Метод на основі одного рейтингу

- В цьому методі використовується лише один рейтинг або оцінка, надана користувачем системою.

Рисунок 1.6 – Існуючі методи для оцінки ефективності рекомендаційних систем

Класичним припущенням у літературі, присвяченій рекомендаційним системам, є те, що користувачі надаватимуть перевагу системам, які надають більш точні прогнози. Методи на основі точності можна розділити на три групи: метрики, які використовують лише один рейтинг, метрики, які порівнюють два рейтинги (як правило, один з них є еталонним або ідеальним рейтингом), і метрики з області машинного навчання.

Прикладами методів на основі одного рейтингу є точність, пригадування, нормалізований дисконтований кумулятивний виграш, середня точність та середній взаємний ранг.

Кожен з цих методів відображає якість ранжування під дещо іншим кутом зору. Зокрема, точність відображає частку релевантних рекомендованих позицій, тоді як взаємний ранг - частку релевантних позицій, які були рекомендовані. Обидва показники є обернено пропорційними, оскільки підвищення рівня пригадування, як правило, призводить до зниження точності.

1.4 Постановка задачі

Проведений аналіз показав, що існуючі методи враховують такі фактори як точність, відгук та рейтинг, що дає можливість оцінити ефективність роботи рекомендаційної системи за умов, коли присутня інформація щодо історії вибору користувачів. Однак для нових користувачів вхідної інформації для роботи цих методів недостатньо, що значно збільшує похибку при обчисленні ефективності роботи рекомендаційної системи [9].

Зазначене свідчить про важливість удосконалення підходів до оцінки ефективності роботи рекомендаційної системи шляхом використання ансамблевого навчання. Ансамблеве навчання дозволяє поєднати декілька існуючих методів для покращення наданого результату.

Метою дослідження є дослідження покращеного методу оцінки ефективності рекомендаційної системи. Для досягнення цієї мети ми плануємо виконати наступні завдання:

- дослідити процес оцінки ефективності IT проектів рекомендаційних систем;
- проаналізувати існуючі методи оцінки та прогнозування ефективності IT проектів, які базуються на використанні рекомендаційних систем, а також їхні переваги та недоліки;
- зробити експериментальну перевірку вдосконаленого методу оцінки ефективності прогнозування рекомендаційної системи, використовуючи ансамблеве навчання.

Однією з перешкод, яка заважає оцінити ефективність того чи іншого методу, являється «холодний старт», що означає недостатню кількість вхідних даних про користувача для того, щоб надати рекомендації і в подальшому оцінити їх.

Проблема холодного старту (рисунок 1.7) є поширеним питанням дослідження рекомендаційних систем, і найбільша проблема холодного старту полягає в тому, що система не може нічого вдіяти, не зібравши достатньо інформації про користувача або не зробивши жодних висновків про проект [10].

На рис. 1.6 показано три категорії проблем холодного старту:

- нова спільнота: коли запускається нова система, в каталозі може бути багато елементів, але мало взаємодії та присутності користувачів, що ускладнює надання надійних рекомендацій;
- нові об'єкти: нові об'єкти системи, може бути релевантна інформація про вміст, але відсутня взаємодія з користувачами;
- нові користувачі: нові користувачі можуть входити в систему без будь-якої взаємодії з системами і без будь-яких персоналізованих рекомендацій для гостей.

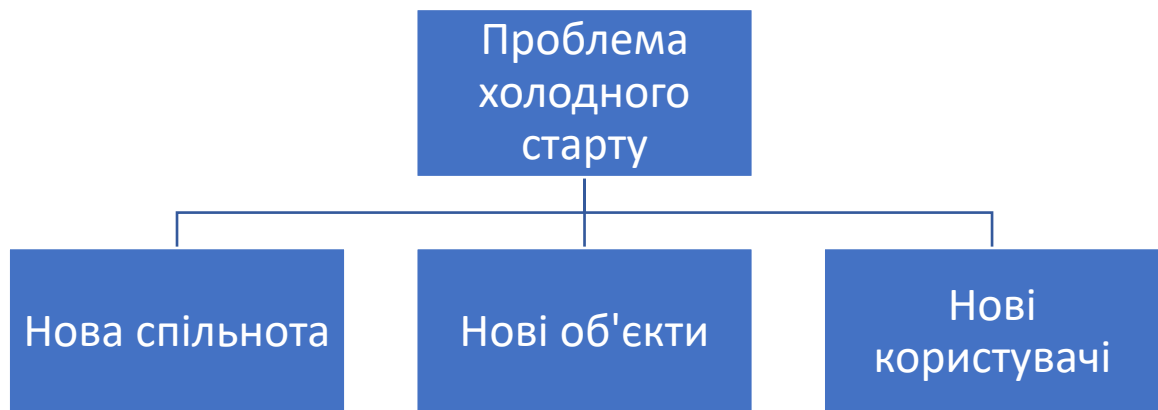


Рисунок 1.7 – Зображення проблеми холодного старту

У нашій роботі ми плануємо використати ансамблевий метод, а саме гетерогенний ансамбль, щоб порівняти декілька існуючих методів та обрати найкращий для оцінки ефективності та прогнозів рекомендаційної системи.

В результаті дослідження ми очікуємо отримати наступні результати:

- огляд та аналіз наявних методів оцінки та прогнозування ефективності рекомендаційних систем;
- порівняльний аналіз різних методів оцінки та прогнозування ефективності рекомендаційних систем на основі експериментальних даних;
- розробку власного методу оцінки та прогнозування ефективності рекомендаційних систем, який базується на підходах глибокого навчання та статистичного аналізу даних;
- проведення експериментального дослідження, щоб порівняти ефективність розробленого методу з наявними методами оцінки та прогнозування ефективності рекомендаційних систем;
- зробити висновки про те, які методи оцінки та прогнозування ефективності рекомендаційних систем є найбільш придатними для різних типів рекомендаційних систем та як різні фактори впливають на ефективність рекомендаційних систем.

Дослідження та покращення ефективності оцінки та прогнозування рекомендаційних систем є дуже важливим завданням в галузі інформаційних технологій. Ось декілька причин, чому це так важливо:

- покращення якості рекомендацій: рекомендаційні системи використовуються в багатьох сферах, таких як електронна комерція, соціальні мережі, медіа, здоров'я, освіта та багато інших. Якість рекомендацій може суттєво впливати на задоволення користувачів та їхню лояльність до певної платформи або бренду. Дослідження та покращення ефективності оцінки та прогнозування можуть допомогти покращити якість рекомендацій;
- зменшення втрат: погані рекомендації можуть привести до втрати бізнесу, якщо користувачі не знаходять те, що вони шукають або не отримують достатньої кількості рекомендацій. Дослідження та покращення ефективності можуть допомогти зменшити втрати бізнесу, забезпечуючи кращі рекомендації та підвищуючи задоволення користувачів;

– зниження залежності від експертів: багато рекомендаційних систем використовують експертні оцінки, щоб допомогти зробити рекомендації. Однак, залежність від експертів може бути дорогим та обмеженим ресурсом. Дослідження та покращення ефективності можуть допомогти розробити більш автоматизовану систему оцінки та прогнозування, що зменшить залежність від експертів;

– розвиток галузі: рекомендаційні системи є важливим елементом багатьох галузей, таких як електронна комерція, соціальні мережі, медіа та здоров'я. Покращення ефективності оцінки та прогнозування може привести до більш точних та зручних рекомендацій, що може вплинути на зростання та розвиток цих галузей;

– напрямки дослідження: дослідження ефективності оцінки та прогнозування рекомендаційних систем може привести до розробки нових методів та алгоритмів, які можуть мати значний вплив на розвиток інформаційних технологій та комп'ютерних наук.

Отже, дослідження та покращення ефективності оцінки та прогнозування рекомендаційних систем є важливим завданням, яке може мати значний вплив на розвиток різних галузей, покращення якості рекомендацій та задоволення користувачів, зменшення втрат бізнесу та залежності від експертів [11].

2 АНСАМБЛЕВИЙ ПІДХІД ДО ОЦІНКИ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНИХ СИСТЕМ

2.1 Метрики оцінки рекомендацій на основі помилок

Традиційно найпопулярнішими метриками для вимірювання точності рекомендаційної системи є середня абсолютна похибка (MAE) та середньоквадратична похибка (RMSE):

$$\text{MAE} = \frac{1}{|T_e|} \sum_{(u,i) \in T_e} |\tilde{r}(u,i) - r(u,i)|, \quad (2.1)$$

$$\text{RMSE} = \sqrt{\frac{1}{|T_e|} \sum_{(u,i) \in T_e} (\tilde{r}(u,i) - r(u,i))^2}, \quad (2.2)$$

де \tilde{r} і r – позначають прогнозований і реальний рейтинг відповідно;

T_e – відповідає тестовому набору.

MAE – це середня величина різниці між рекомендацією та відповідним рейтингом, яку дуже легко інтерпретувати.

Метрика RMSE (рисунок 2.1) вимірює похибку в наших прогнозованих значеннях, коли цільова змінна або змінна відгуку є неперервним числом. Наприклад, при використанні регресійних моделей для прогнозування таких величин, як дохід, вартість/обсяги продажів, обсяги попиту, бали, зріст або вага тощо [12].

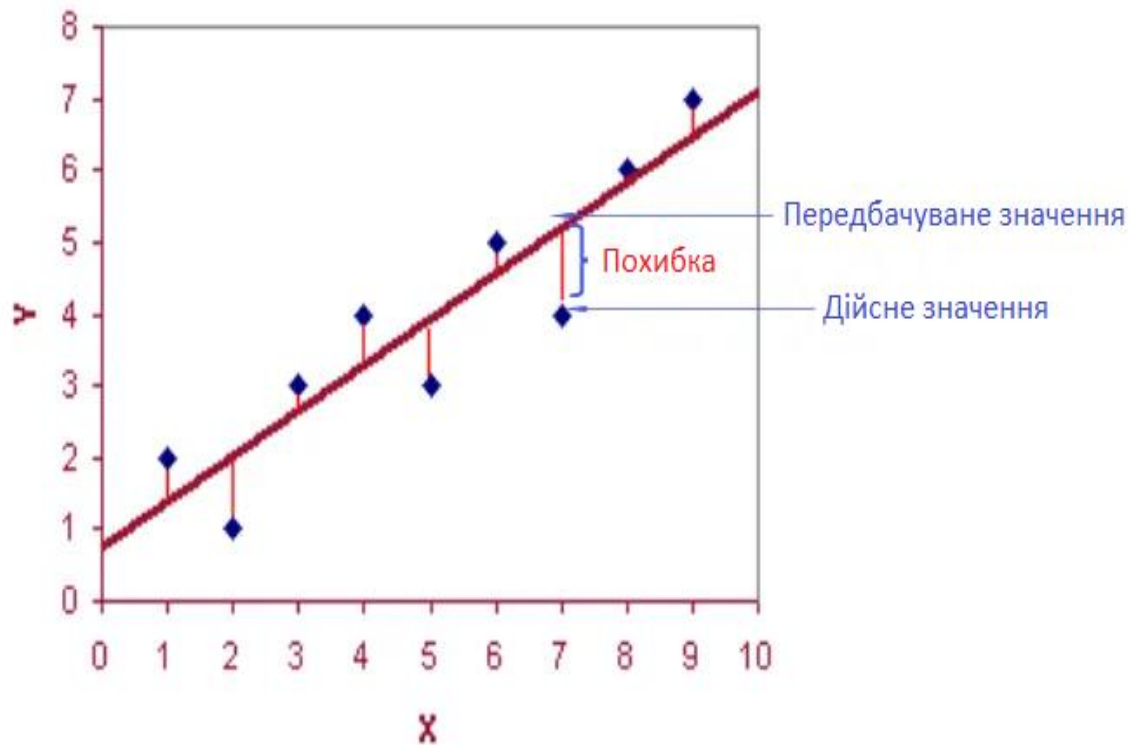


Рисунок 2.1 – Принцип використання RMSE метрики

Ці методи полягають у тому, що для кожної рекомендації, яку рекомендаційна система надає користувачеві, розраховується помилка між прогнозованим значенням та фактичним значенням. Ці помилки потім сумуються та середнє значення помилки використовується як міра ефективності рекомендаційної системи [13].

Крім того, для того, щоб уникнути упереджень, пов'язаних з похибкою (або точністю) для кількох дуже частих користувачів або позицій, були запропоновані середні похибки на користувача і на позицію. Наприклад, середнє значення MAE для користувачів обчислюється наступним чином:

$$uMAE = \frac{1}{|U|} \sum_{v \in U} \frac{1}{|Te_v|} \sum_{i \in Te_v} |\tilde{r}(u, i) - r(u, i)|, \quad (2.3)$$

Критичним обмеженням цих метрик є те, що вони не роблять різниці між помилками, допущеними в найкращих пунктах, передбачених системою, та помилками, допущеними в решті пунктів.

Крім того, вони можуть бути застосовані лише тоді, коли експерт прогнозує оцінку в дозволеному діапазоні значень рейтингу.

Через це лог-орієнтовані, а також деякі контент-орієнтовані та імовірнісні рекомендувачі не можуть бути оцінені таким чином, оскільки $r^{\sim}(u, i)$ представлятиме ймовірність або, в загальному випадку, оцінку переваги. Отже, ці методи можна оцінити лише шляхом вимірювання ефективності згенерованого рейтингу за допомогою метрик, що базуються на точності [14].

Однією з переваг методів на основі помилок є їх легкість у використанні та розумінні. Крім того, вони можуть бути використані для будь-якого типу рекомендаційної системи, яка дає числові прогнози (наприклад, системи рекомендацій фільмів, музики, книг та інших товарів).

Проте методи на основі помилок мають деякі недоліки. Наприклад, вони не враховують різних типів помилок, які можуть бути допущені рекомендаційною системою. Крім того, вони не враховують недоліки системи, які можуть бути пов'язані з її функціонуванням (наприклад, відсутність достатньої кількості даних для рекомендацій для деяких користувачів).

2.2 Ансамблевий метод оцінки ефективності та прогнозування ІТ-проекту рекомендаційної системами

В ході нашого дослідження розроблено ансамблевий метод для оцінки ефективності рекомендаційної системи, а саме гетерогенний ансамбль. Гетерогенний ансамбль дозволяє поєднувати різноманітні тимчасові методи або

моделей (в нашому випадку це методи для створення рекомендацій), де необхідно використовувати один і той же набір даних [15].

Далі за допомогою мажоритарної процедури відбору ми порівняємо досліджувані методи, їх результати та таким чином розробимо вдосконалений метод для оцінки ефективності рекомендаційної системи.

Мажоритарна процедура відбору полягає в виборі одного методу, який отримає найкращий результат, в нашому випадку це найменша похибка для оцінки ефективності рекомендацій.

Ансамблевий метод оцінки ефективності і прогнозування рекомендаційної системи містить у собі такі етапи:

- перший етап – підготовка даних (рисунок 2.2);
- другий етап – відбір даних з урахуванням ситуації холодного старту;
- третій етап – прогнозування ефективності для колаборативної фільтрації (формула 2.4) та гібридного підходу (формула 2.5);
- четвертий етап – оцінка ефективності з використанням метрики RMSE (формула 2.2) в колаборативній фільтрації та гібридному підходах.

$$P_{(u,i)} = \frac{\sum_{all\ similar\ items,N} (S_{i,N} * R_{u,N})}{\sum_{all\ similar\ items,N} (|S_{i,N}|)}, \quad (2.4)$$

де u – користувач;

i – об'єкт;

S – подібність;

N – кількість;

R – рейтинг.

$$P_{u,i} = \frac{\alpha C B_{u,i} + \beta C F_{u,i}}{\alpha + \beta}, \quad (2.5)$$

де u – користувач;

i – об'єкт;

CB – прогноз, використовуючи фільтрацію на основі вмісту;

CF – прогноз, використовуючи колаборативну фільтрацію.

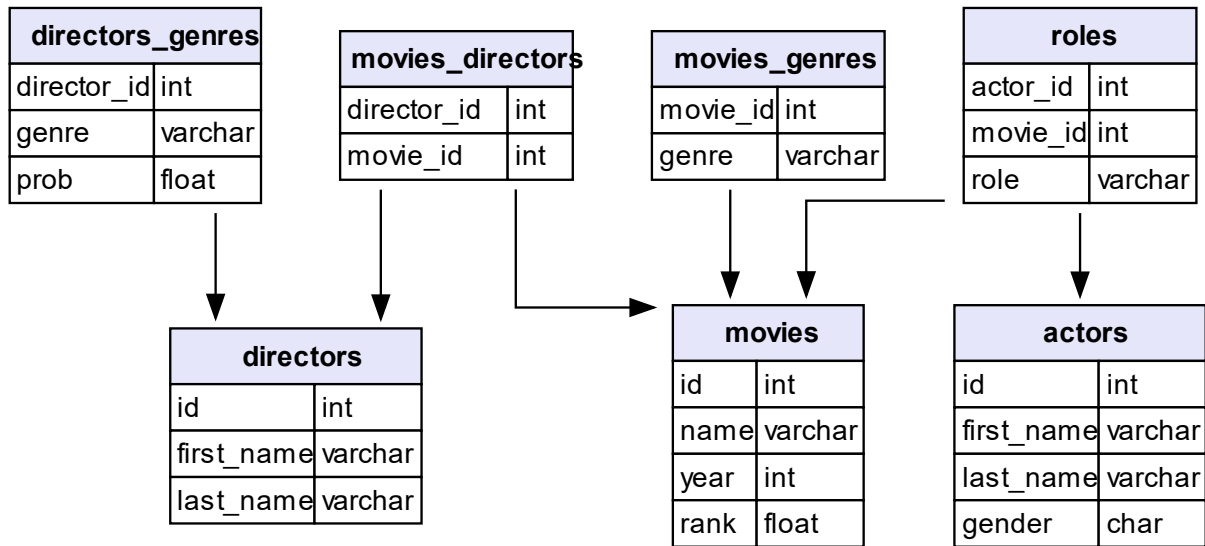


Рисунок 2.2 – Схема бази даних для набору даних IMDb

Неточність в оцінці прогнозів при використанні RMSE може виникнути з кількох причин. Одна з найбільш поширених причин – це використання RMSE в умовах холодного старту, коли в системі немає достатньо даних для точної оцінки користувачів і предметів. В такому випадку RMSE може надавати неправильні оцінки ефективності системи [16].

Інша причина – це відсутність адекватної моделі для прогнозування рейтингів користувачів. Якщо модель недостатньо точна або не враховує певні аспекти взаємодії користувачів з системою, то оцінка RMSE може бути неточною.

Крім того, RMSE не враховує специфіку конкретної задачі, наприклад, може надавати рівні оцінки для рекомендацій, які мають різний ступінь важливості для користувача.

Таким чином, RMSE може бути корисним інструментом для оцінки ефективності рекомендаційної системи, але для точнішої оцінки необхідно враховувати конкретні вимоги та особливості задачі.

Враховуючи вищесказане, очевидним способом для покращення RMSE метрики є усунення холодного старту в рекомендаційній системі, адже саме він дає велику вірогідність похибки при використанні RMSE метрики.

Найпопулярніші методи, які використовуються для рекомендаційних систем є наступні:

- рекомендаційна система на основі вмісту;
- рекомендаційна система з використанням спільної фільтрації та мінімізацією середньоквадратичної похибки;
- гібридний метод.

Нам потрібно виявити, який з методів менш схильний до проблеми холодного старту, а отже який з них зможе покращити точність оцінки ефективності рекомендаційної системи, використовуючи RMSE метрики.

Системи рекомендацій на основі контенту (CBRS – Content based recommender systems) покладаються на профілі об'єктів і користувачів. Профіль об'єкта – це набір ознак об'єкта, тобто характеристик об'єкта, таких як колір об'єкта, автори книги чи актори у фільмі. Профілі користувачів можуть складатися з неявної або явної інформації про вподобання користувачів [17].

CBRS зіставляє профілі користувачів з характеристиками товарів/пропозицій, які їм подобаються, і знаходить товари з однаковими/подібними характеристиками.

Цей метод надання рекомендацій підходить навіть за умови обмеженого обсягу даних, але в цьому випадку рекомендації можуть мати неточності, що ми можемо довести на практиці.

Системи рекомендацій на основі контенту (CBRS) покладаються на співставлення профілів товарів і користувачів. CBRS зіставляє користувачів з характеристиками позицій і знаходить позиції, схожі на ті, які користувач вже купував або переглядав.

CBRS складається з трьох основних компонентів:

- аналізатор елементів витягує характеристики елементів з їхнього вмісту або метаданих;
- конструктор профілів користувачів збирає дані про користувачів та їхні вподобання;
- механізм рекомендацій зіставляє інтереси користувачів з характеристиками об'єктів. Рекомендації надаються на основі оцінок релевантності, розрахованих для кожного елемента.

На рис. 2.3 зображено принцип та алгоритм роботи рекомендаційної системи на основі вмісту.

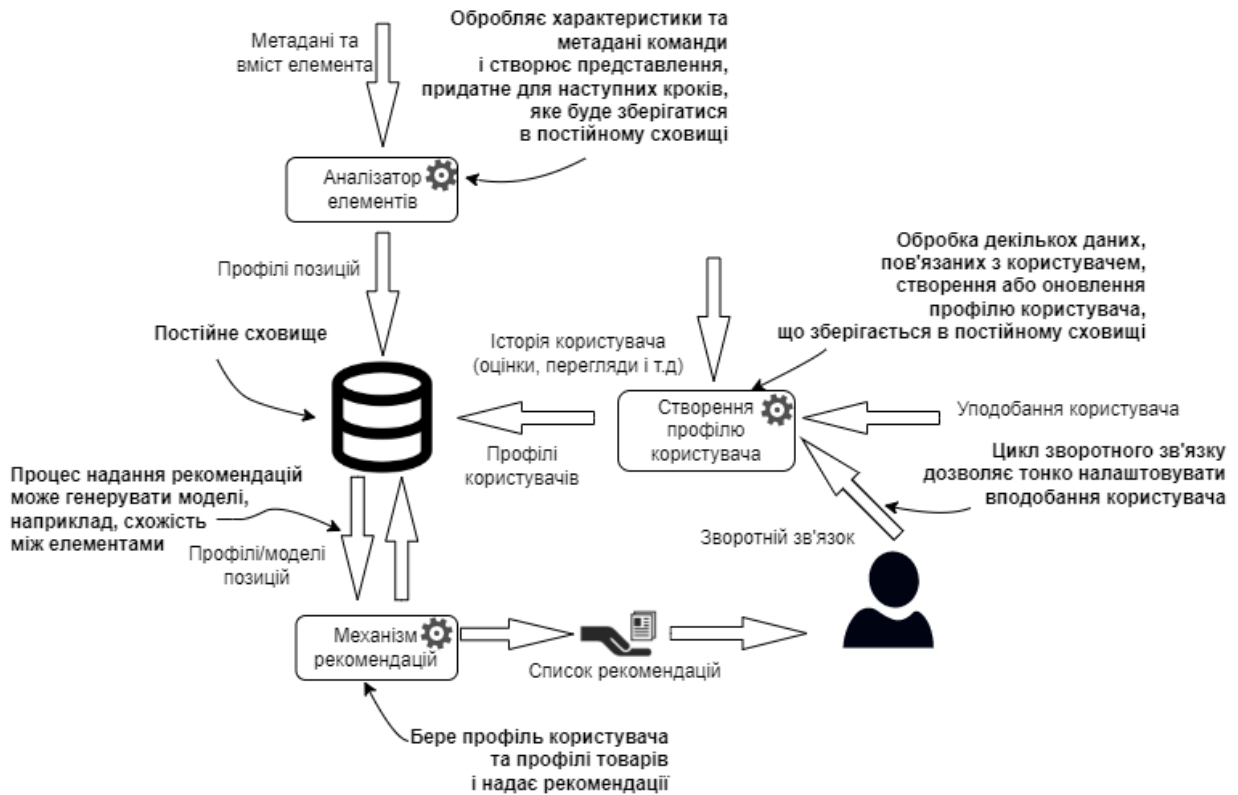


Рисунок 2.3 – Діаграма роботи рекомендаційної системи на основі вмісту

Спільна фільтрація ґрунтується на ідеї, що користувачі, схожі на мене, можуть бути використані для прогнозування того, наскільки мені сподобається певний продукт або послуга, які ці користувачі використовували/переживали, а я – ні. Рекомендації надаються на основі поведінки користувача. Важливу роль відіграє історія користувача [18].

Наприклад, якщо користувачеві "А" подобаються "Coldplay", "The Linkin Park" і "Брітні Спірс", а користувачеві "Б" - "Coldplay", "The Linkin Park" і "Тейлор Свіфт", то вони мають схожі інтереси. Отже, існує величезна ймовірність того, що користувачеві "А" сподобається "Тейлор Свіфт", а користувачеві "Б" - "Брітні Спірс". Так відбувається спільна фільтрація.

У спільній (колаборативній) фільтрації для рекомендацій використовуються оцінки користувачів для різних елементів вмісту. Наприклад, якщо два користувачі оцінили подібні фільми або музичні

композиції, можна припустити, що їм сподобаються інші подібні вмістовні елементи. На основі такого аналізу можна рекомендувати користувачам нові фільми, музику, книги та інші вмістовні елементи.

Однією з особливостей колаборативної фільтрації є те, що вона може забезпечити якісні рекомендації для користувачів, які ще не знають, що саме їм потрібно. Крім того, колаборативна фільтрація може допомогти забезпечити рекомендації для нішевих вмістовних елементів, які можуть бути менш популярними серед загальної аудиторії.

Наукова новизна полягає в тому, що запропоновано ансамблевий метод оцінки ефективності рекомендаційної системи, який оцінює ефективність як з урахуванням схожості користувачів, так і схожості товарів, які запропоновані цим користувачам. Це дає можливість підвищити точність оцінки ефективності для нових користувачів IT-проекту рекомендаційної системи.

3 ОПИС РОЗРОБКИ ІТ-ПРОЕКТУ ОЦІНКИ І ПРОГНОЗУВАННЯ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ

3.1 Опис ініціації ІТ-проекту

Ганта – це інструмент управління проектами, який дозволяє візуалізувати план роботи і дати загальне уявлення про терміни виконання робіт. Використання діаграми Ганта в науково-дослідницькій роботі може допомогти показати часову рамку виконання проекту, відображаючи різні етапи роботи, що потрібно виконати.

Так як тема дослідження стосується ІТ проектів рекомендаційних систем, діаграма Ганта може відображати наступні етапи дослідження:

- перегляд літератури: команда може розпочати проект зі збору літератури щодо різних методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем. Цей етап можна відобразити на діаграмі Ганта в якості першого кроку;

- визначення методів: після аналізу літератури, команда може визначити різні методи оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем;

- збір даних: команда повинна зібрати дані, щоб застосувати вибрані методи оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем;

- аналіз даних: після збору даних, команда може провести аналіз даних та застосувати вибрані методи оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем;

- підготовка результатів: після аналізу даних команда може підготувати результати своєї роботи, такі як таблиці, графіки та звіти;

- аналіз результатів: дослідник повинен провести аналіз результатів своєї роботи і дати висновки про ефективність різних методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем;

- написання звіту: після аналізу результатів команда може написати звіт про свою роботу, в якому будуть включені результати аналізу, висновки та рекомендації;

- відстеження прогресу: діаграма Ганта може допомогти команді відстежувати прогрес своєї роботи, планувати свої дії та дотримуватися термінів виконання робіт.

Отже, діаграма Ганта може бути використана в науково-дослідницькій роботі на тему Дослідження методів оцінки та прогнозування ефективності ІТ проектів рекомендаційних систем, щоб візуалізувати план роботи та дати загальне уявлення про терміни виконання робіт.

Перед тим як приступити до побудови відображення плану проекту в форматі діаграми Ганта, нам потрібно відобразити стислий план роботи в якості діаграми процесу.

Стислий опис процесу дозволяє визначити критичні етапи проекту, тобто етапи, які мають найбільший вплив на досягнення мети проекту. Визначення критичних етапів допомагає сконцентрувати увагу та зусилля на тих завданнях, що мають найбільший вплив на успіх проекту.

Крім того, стислий опис процесу дозволяє визначити залежності між різними етапами та завданнями, що допомагає відобразити ці залежності на діаграмі Ганта. Наприклад, якщо одне завдання не може бути виконане до завершення іншого завдання, то ці дві задачі повинні бути пов'язані на діаграмі Ганта.

Отже, стислий опис процесу є важливим етапом перед підготовкою діаграми Ганта, оскільки він дозволяє визначити послідовність та обсяг задач, а також визначити критичні етапи та залежності між різними завданнями

(рисунок 3.1). Це допомагає побудувати більш точну та ефективну діаграму Ганта. Цей інструмент дозволяє визначити, які завдання можуть виконуватися паралельно, а які потребують послідовності виконання, також діаграма допомагає відслідковувати прогрес виконання проекту та вчасно виявляти затримки, що дозволяє вчасно коригувати плани та відновлювати прогрес проекту.

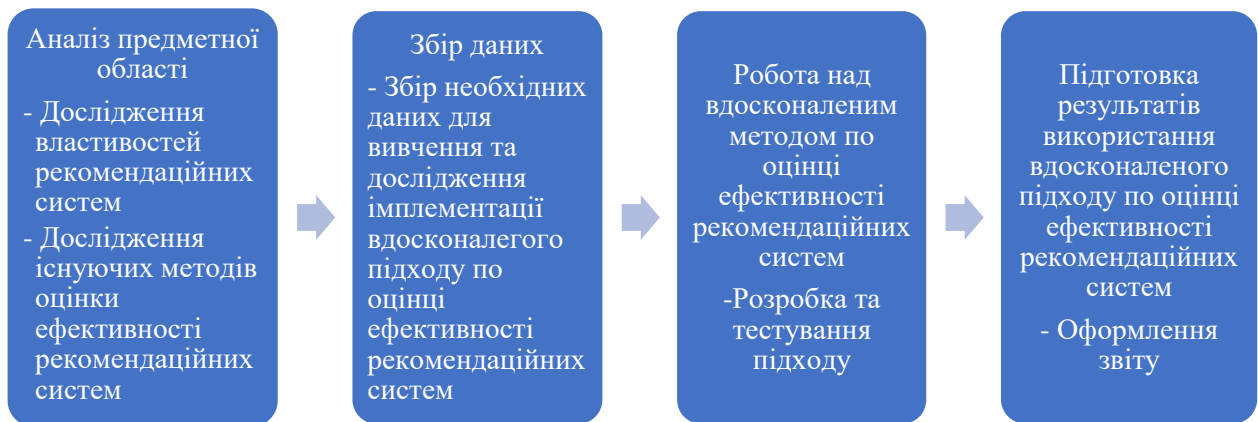


Рисунок 3.1 – Стислий опис процесу над науково-дослідницькою роботою

Важливо також завчасно підготувати опис учасників проекту, які потенційно будуть приймати участь в розробці. Таблиця з учасниками проекту наведена нижче, де виконання – в, прийом – п, задача - з, узгодження – у.

Таблиця 3.1 – Опис учасників проекту

№	Етапи	Замовник	Програміст	Тестувальник	Користувач	Менеджер проекту
1	Ініціація роботи над проектом	в	-	-	-	д
1.1	Формування вимог до ІС	в	-	-	у	в
2	Формування вимог замовника до ІС	в	-	-	-	п;у
2.1	Розробка концепції проектування ІС	-	в	-	-	у
2.2	Вивчення процесу обліку заявок і довідок у даній організації	-	в	-	у	в

Продовження таблиці 3.1

№	Етапи	Замовник	Програміст	Тестувальник	Користувач	Менеджер проекту
3	Розробка і вибір варіантів концепції ІС за вимогами замовника	у	в	-	-	в;у
4	Розробка ескізного проекту	у	в	-	у	у
5	Технічний проект	-	в	-	-	у
5.1	Розробка проектних рішень по системі та її частинам	-	в	-	-	у
5.2	Розробка документації на ІС та на її частини	-	-	-	-	в/з

Продовження таблиці 3.1

6	Робоча документація	п	в/з	-	п	в/з
7	Тестування	-	-	в/з	-	п
8	Впровадження	п	з		п	з
8.1	Підготовка працівників	-	в	-	в	в
9	Укладення договору про використання та здачу функціонального модуля обліку	у/п	-	-	-	в/з

3.2 Опис результатів планування ІТ-проекту

Будь-який проект створюється для досягнення певного результату в певні строки. Завдяки плану проекту можна дізнатися якими заходами будуть досягнуті результати проекту, які спеціалісти та обладнання необхідні для виконання цих робіт, і в який час всі необхідні компоненти можуть розпочати роботу над проектом.

Створення структури декомпозиції робіт (Work Breakdown Structure, WBS) – це процес розділення результатів проєкту та робіт за проєктом на більш мілкі елементи, якими легше керувати.

Таблиця 3.2 – Опис стадій та етапів створення модуля системи

Стадії	Етапи робіт
1.Формування вимог до автоматизованої системи	1.1 Передпроектне обстеження організації 1.2 Формування вимог замовника до системи 1.3 Укладення контракту з замовником
2.Розробка концепції проектування системи	2.1 Вивчення процесу обліку заявок в даній організації 2.2 Розробка і вибір варіантів концепції системи, що задовольняє вимогам замовника
3.Розробка ескізного проєкту (попередніх проєктних рішень по системі і її частинам)	Розробка ескізного проєкту (попередніх проєктних рішень по системі і її частинам)
4.Технічний проєкт	4.1 Розробка проєктних рішень по системі і її частинам 4.2 Розробка документації для системи та її частині
5.Робоча документація	Розробка робочої документації
6. Тестування	Тестування готового додатку
7. Впровадження	7.1 Підготовка співробітників 7.2 Проведення випробувань
8. Укладення контракту з замовником	Укладення контракту з замовником

Таблиця 3.3 – Опис структури декомпозиції робіт ІТ-проекту

№ з/п	Назва елемента	Очікувані результати
1	Формування вимог до системи	Звіт про виконану роботу на стадії «Формування вимог до системи»
1.1	Передпроектна обстеження організації	Звіт про організаційної та функціональної структури організації
1.2	Формування вимог замовника до системи	Каталог вимог до системи
1.3	Укладення контракту з замовником	Контракт з замовником
2	Розробка концепції проектування системи	Звіт про виконану роботу на стадії «Розробка концепції ІВ»
2.1	Вивчення процесу обліку платежів в даній організації	Звіт у вигляді діаграм IDEF0, IDEF3, DFD
2.2	Розробка і вибір варіантів концепції ІС, що задовольняє вимогам замовника	Затверджений варіант концепції системи, який включає UML-діаграми прецедентів, послідовності, діаграми діяльності.
3	Розробка ескізного проекту (попередніх проектних рішень по системі і її частинам)	Звіти про попередніх проектних рішеннях по системі і її компонентів
4	Технічний проект	Звіт про виконану роботу на стадії «Технічне завдання»

Продовження таблиці 3.3

№ з/п	Назва елементу	Очікувані результати
4.1	Розробка проектних рішень по системі і її частинам	Рішення по системі та її частинам (вибір СУБД, мова програмування, технології та середовища виконання)
4.2	Розробка документації для системи та її частини	Розроблена і затверджена документація в обсязі, необхідному для опису прийнятих проектних рішень
5	Робоча документація	Розроблена і затверджена документація для подальшого виконання робіт зі створення системи
6	Впровадження	Акт про впровадження
6.1	Підготовка співробітників	Написання керівництва користувача
6.2	Проведення випробувань	Відгуки користувачів про працездатність системи та відповідності вимогам
7	Укладення контракту з замовником	Контракт з замовником

Для введення даних про роботи використаємо форму представлення даних «Графік Ганта» (рисунок 3.2) . В моделі проекту деякі роботи представимо як складені. А саме: Ініціація проекту, Планування проекту, Виконання проекту, Впровадження, Завершення проекту (рисунок 3.3).

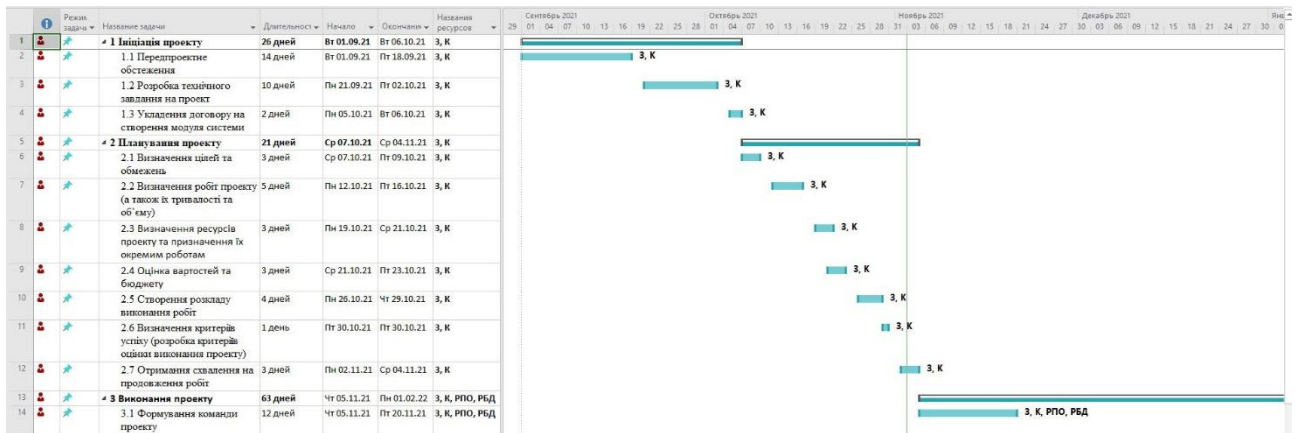


Рисунок 3.2 – Графік Ганта, аркуш 1




Рисунок 3.3 – Графік Ганта, аркуш 2

Декомпозиція робіт в діаграмі Ганта є важливим етапом планування проекту (рисунок 3.4). Це означає розбиття проекту на більш дрібні частини або етапи, які можна легко керувати та відслідковувати. Така декомпозиція дозволяє зрозуміти повну картину проекту, зробити його менш складним та більш керованим.

	Режим задачі	Назва задачі	Длительность	Начало	Окончани	Названия ресурсов
1		1 Ініціація проекту	26 дней	Вт 01.09.21	Вт 06.10.21	З, К
2		1.1 Передпроектне обстеження	14 дней	Вт 01.09.21	Пт 18.09.21	З, К
3		1.2 Розробка технічного завдання на проект	10 дней	Пн 21.09.21	Пт 02.10.21	З, К
4		1.3 Укладення договору на створення модуля системи	2 дней	Пн 05.10.21	Вт 06.10.21	З, К
5		2 Планування проекту	21 дней	Ср 07.10.21	Ср 04.11.21	З, К
6		2.1 Визначення цілей та обмежень	3 дней	Ср 07.10.21	Пт 09.10.21	З, К
7		2.2 Визначення робіт проекту (а також їх тривалості та об'єму)	5 дней	Пн 12.10.21	Пт 16.10.21	З, К
8		2.3 Визначення ресурсів проекту та призначення їх окремим роботам	3 дней	Пн 19.10.21	Ср 21.10.21	З, К
9		2.4 Оцінка вартостей та бюджету	3 дней	Ср 21.10.21	Пт 23.10.21	З, К
10		2.5 Створення розкладу виконання робіт	4 дней	Пн 26.10.21	Чт 29.10.21	З, К
11		2.6 Визначення критеріїв успіху (розробка критеріїв оцінки виконання проекту)	1 день	Пт 30.10.21	Пт 30.10.21	З, К
12		2.7 Отримання схвалення на продовження робіт	3 дней	Пн 02.11.21	Ср 04.11.21	З, К
13		3 Виконання проекту	63 дней	Чт 05.11.21	Пн 01.02.22	З, К, РПО, РБД
14		3.1 Формування команди проекту	12 дней	Чт 05.11.21	Пт 20.11.21	З, К, РПО, РБД
15		3.2 Розробка основного змісту проекту	56 дней	Пн 16.11.21	Пн 01.02.22	З, К, РПО, РБД
16		4 Тестування	41 дней	Вт 08.12.21	Вт 02.02.22	З, К, Т
17		5 Впровадження	13 дней	Ср 03.02.22	Пт 19.02.22	З, К, РПО, РБД
18		5.1 Розгортання системи	3 дней	Ср 03.02.22	Пт 05.02.22	З, К, РПО, РБД
19		5.2 Міграція даних	5 дней	Пн 08.02.22	Пт 12.02.22	З, К, РПО, РБД
20		5.3 Навчання користувачів	5 дней	Пн 15.02.22	Пт 19.02.22	З, К, Т
21		6 Завершення проекту	20 дней	Пн 22.02.22	Пт 19.03.22	З, К, РПО, РБД

Рисунок 3.4 – Декомпозиція робіт

Декомпозиція допомагає розподілити велику роботу на менші, більш керовані та керовані задачі (рисунок 3.5). Це дає можливість розподілити роботу між членами команди та планувати кожен етап робіт окремо. Декомпозиція робіт також дозволяє оцінити час, який потрібний для виконання кожної окремої задачі, та зрозуміти, чи можливо виконати проект у визначені терміни.

22		6.1 Підведення підсумків (здача проекту замовнику)	4 дней	Пн 22.02.22	Чт 25.02.22	З, К
23		6.2 Вирішення конфліктів	12 дней	Пт 26.02.22	Пн 15.03.22	З, К, РПО, РБД
24		6.3 Оформлення та підписання підсумкових документів	4 дней	Вт 16.03.22	Пт 19.03.22	З, К

Рисунок 3.5 – Декомпозиція задач, продовження

Для введення даних про ресурси використаємо форму представлення даних «Аркуш ресурсів» (рисунок 3.6). Візьмемо до уваги визначення типу ресурсу «Матеріальні» чи «Трудові» або «Витрати». Весь склад розробників, тестувальників, менеджера та дизайнера проекту відноситься до «Трудового» типу ресурсів.

		Название ресурса	Тип	Краткое название	Макс. единиц	Стандартная ставка	Ставка сверхурочн	Затраты на исполыз.	Начисление	Базовый календарь
1		Замовник	Затраты	З					Пропорционал	
2		Керуючий проектом	Трудовой	К	100%	150,00 €/ч	150,00 €/ч	0,00 €	Пропорционал	Materials
3		Розробник ПО	Трудовой	РПО	100%	120,00 €/ч	120,00 €/ч	0,00 €	Пропорционал	Materials
4		Розробник БД	Трудовой	РБД	100%	120,00 €/ч	120,00 €/ч	0,00 €	Пропорционал	Materials
5		Тестувальник	Трудовой	Т	100%	105,00 €/ч	105,00 €/ч	0,00 €	Пропорционал	Materials
6		Дизайнер	Трудовой	Д		105,00 €/ч	105,00 €/ч	0,00 €	Пропорционал	Materials

Рисунок 3.6 – «Аркуш ресурсів»

4 РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНА ПЕРЕВІРКА ВДОСКОНАЛЕНОГО МЕТОДУ ОЦІНКИ ЕФЕКТИВНОСТІ ПРОГНОЗУВАННЯ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ

В даному розділі розглянуто оцінку ефективності прогнозування рекомендаційної системи на прикладі «Рекомендаційної системи фільмів» з використанням ансамблевого методу.

Ансамблевий метод обраний, тому що ми можемо порівняти методи, який використовує схожість користувачів і схожість товарів, що зменшує похибку. Буде розглянуто гетерогенний тип ансамблевого методу, оскільки ми будемо порівнювати методи на однакових наборах даних [19].

4.1 Реалізації модулю оцінки і прогнозування ефективності рекомендаційної системи

Для реалізації ансамблевого методу нам необхідно реалізувати декілька методів та протестувати їх на однакових наборах даних. В нашому випадку це буде колаборативна фільтрація та гібридний підхід в рекомендаційних системах. Для обох підходів буде використовуватись той самий набір даних, але в одному випадку це буде повний набір даних, а в іншому – стислий, оскільки ми збираємося зімітувати ситуацію холодного старту.

В цьому розділі ми будемо використовувати техніку під назвою «Спільна фільтрація» для створення рекомендацій для глядачів фільмів [20]. Спільна фільтрація ґрунтується на ідеї, що користувачі, схожі на мене, можуть бути використані для прогнозування того, наскільки мені сподобається певний продукт або послуга, які ці користувачі використовували/переживали, а я – ні.

Кожен тип рекомендаційного методу має свої сильні та слабкі сторони, добре відомі в цій галузі. Ми вже зазначали основні характеристики кожного методу, які значною мірою залежать від джерела інформації, що використовується. У цьому розділі ми проаналізуємо основні обмеження кожного методу, використовуючи ансамблевий підхід.

В даному розділі ми будемо використовувати спільну фільтрацію з мінімізацією середньоквадратичної похибки, яка як раз і оцінює ефективність рекомендаційних систем.

На рис. 4.1 детально зображений принцип роботи підходу спільної фільтрації, який ми використали для нашої рекомендаційної системи для фільмів.



Рисунок 4.1 – Принцип підходу з використанням спільної фільтрації для рекомендаційної системи фільмів

Для імплементації даного підходу нам потрібно підготувати вхідні дані. Оскільки ми орієнтуємось на рекомендаційну систему для фільмів, наші вхідні дані мають наступний вигляд зображений в таблиці нижче.

Таблиця 4.1 – Приклад вхідних даних

Вік 16+ (true/ false)	Бюд жет	Жан р	Сторінка	ID	Оригі нальн а мова	Оригі нальн а назва	Опис	Рей тин г	Кіль кіст ь оцін ок
FAL SE	3000 0000	Ani mati on	http://toystory. disney.com/toy -story	86 2	Englis h	Toy Story	'Descr iption'	7.7	5415
FAL SE	6500 0000	Adv entur e	---	88 44	Englis h	Juman ji	'Descr iption'	6.9	2413
FAL SE	1600 0000	Dra ma	---	31 35 7	Englis h	Waiti ng to Exhal e	'Descr iption'	6.1	34
FAL SE	6000 0000	Acti on	---	94 9	Englis h	Heat	'Descr iption'	7.7	1886

Я не буду впроваджувати спільну фільтрацію з нуля. Замість цього я використаю бібліотеку Surprise, яка використовує надзвичайно потужні алгоритми, такі як розкладання за сингулярним значенням (SVD), щоб

мінімізувати RMSE (середньоквадратичну похибку, яка була розглянута в розділі 2.2) і дати відповідні рекомендації (рисунок 4.2).

```
reader = Reader()

ratings = pd.read_csv('../input/ratings_small.csv')
ratings.head()

  userId  movieId  rating  timestamp
0      1         31     2.5  1260759144
1      1        1029     3.0  1260759179
2      1        1061     3.0  1260759182
3      1        1129     2.0  1260759185
4      1        1172     4.0  1260759205

data = Dataset.load_from_df(ratings[['userId', 'movieId', 'rating']], reader)
data.split(n_folds=5)
```

Рисунок 4.2 – Завантаження вхідних даних

Тепер давайте потренуємося на нашому наборі даних і отримаємо прогнози (рисунок 4.3).

```
trainset = data.build_full_trainset()
svd.train(trainset)
```

Рисунок 4.3 – Функція для тренування на наборі даних

Виберемо користувача з ідентифікаційним номером 5000 і перевіримо оцінки, які він поставив. Ми спробуємо зімітувати ситуацію, коли проблема холодного старту відсутня, тому ми будемо використовувати більш повний набір даних для отримання прогнозованої оцінки [21].

Таблиця 4.2 – Фактичні оцінки користувача для подальшого прогнозування

Ідентифікаційний номер фільму	Оцінка
31	2.5
1029	3.0
1061	3.0
1129	2.0
1172	4.0
1263	2.0
1287	2.0
1293	2.0
1339	3.5
1343	2.0
1371	2.5
1405	1.0

Тепер спробуємо прогнозувати вподобання даного користувача. Для цього ми оберемо фільм з ідентифікаційним номером 302 та поглянемо, яку оцінку може поставити цьому фільму користувач, базуючись на його попередніх оцінках (рисунок 4.4).

```
svd.predict(1, 302, 3)
```

```
Prediction(uid=1, iid=302, r_ui=3, est=2.8779447226327712, details={'was_impossible': False})
```

Рисунок 4.4 – Прогнозування оцінки для методу колаборативної фільтрації

Для фільму з ідентифікатором 302 ми отримали прогноз 2.877. Однією з вражаючих особливостей цієї системи рекомендацій є те, що їй байдуже, що це за фільм (або про що він). Вона працює виключно на основі присвоєного ідентифікатора фільму і намагається передбачити рейтинг на основі того, як інші користувачі спрогнозували фільм [22].

Тепер нам необхідно порівняти отримане прогнозоване значення з фактичним значенням. Наш набір даних свідчить, що фактичне значення оцінки фільму з ідентифікатором 302 (фільм «Аватар») у користувача являється оцінка 2.5, в той час як прогнозована оцінка 2.877.

Далі нам потрібно отримати середньоквадратичну похибку. Для цього ми аналізуємо середньоквадратичну похибку та середню абсолютну похибку, використовуючи алгоритм сингулярного розкладання – SVD (рисунок 4.5).

```
svd = SVD()
evaluate(svd, data, measures=['RMSE', 'MAE'])
```

Рисунок 4.5 – Використання функції SVD для аналізу середньоквадратичної та середньої абсолютної похибок

Отримуємо наступний результат, де Fold – це набір записів в нашому датасеті.

Таблиця 4.3 – Обчислення середньоквадратичної похибки

Набір записів	Середньоквадратична похибка
Fold 1	0.8952
Fold 2	0.8971
Fold 3	0.8946

Продовження таблиці 4.3

Набір записів	Середньоквадратична похибка
Fold 4	0.8951
Fold 5	0.8944

Ми отримали середню квадратичну похибку 0.8953, що більш ніж достатньо для нашого випадку (рисунок 4.6).

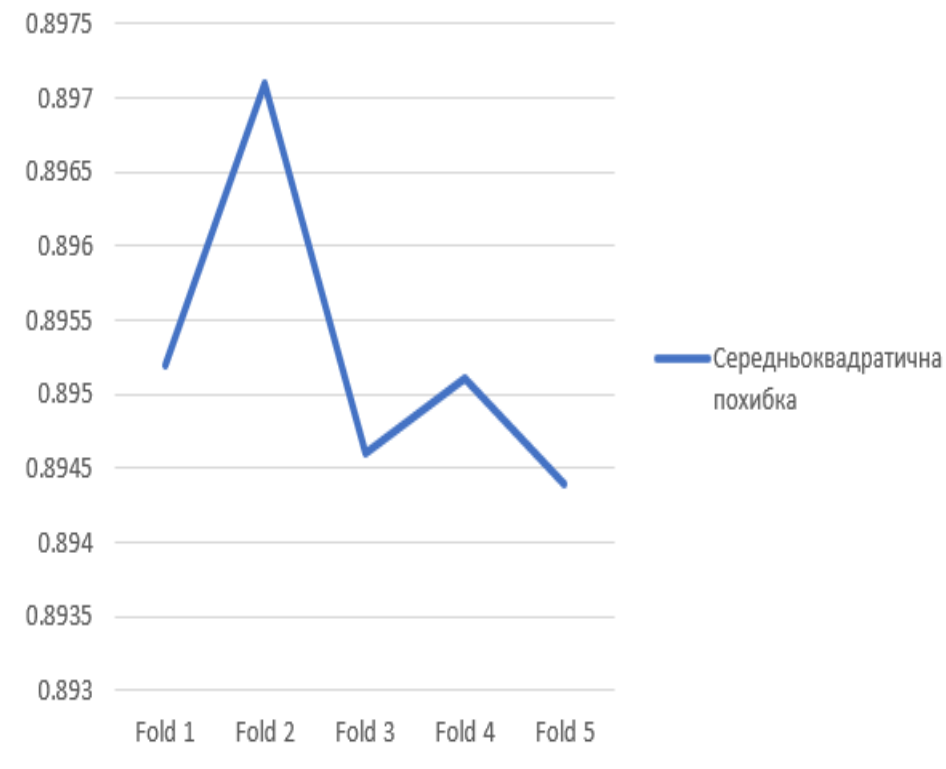


Рисунок 4.6 – Зображення RMSE на графіку

Оскільки основною проблемою оцінки ефективності і прогнозування рекомендаційної системи є саме проблема холодного старту, тому спробуємо знову отримати прогноз для того самого користувача і фільму, але вже використовуючи більш стислий набір даних [23].

Таблиця 4.4 – Стислий набір фактичних оцінок користувача для подальшого прогнозування

Ідентифікаційний номер фільму	Оцінка
31	2.5
1029	3.0
1061	3.0
1129	2.0
1172	4.0
1263	2.0

Даний набір даних містить всього 6 записів, що в 2 рази менше, ніж в попередньому. Цього нам буде достатньо для того, щоб зімітувати ситуацію холодного старту і побачити, як система буде поводити себе в даному випадку та які прогнозовані оцінки ми отримаємо [24].

Спробуємо тепер запустити нашу функцію для отримання прогнозу, використовуючи стислий набір даних (рисунок 4.7).

```
svd.predict(1, 302, 3)
Prediction(uid=1, iid=302, r_ui=3, est=3.011283647283635, details={'was_impossible': False})
```

Рисунок 4.7 – Прогнозована оцінка, використовуючи колаборативну фільтрацію, для стислого набору даних

Порівняємо наші результати для колаборативної фільтрації для користувача та оцінки фільму «Аватар».

Таблиця 4.5 – Порівняння прогнозованої оцінки для колаборативної фільтрації з різним набором даних

Фактична оцінка	Прогнозована оцінка, використовуючи повний набір даних	Прогнозована оцінка в ситуації холодного старту
2.5	2.877	3.011

В результаті ми бачимо, що в ситуації холодного старту колаборативна фільтрація надає не досить точну оцінку.

Ми використали потужну бібліотеку Surprise Library для створення спільного фільтра, заснованого на декомпозиції одного значення. Отримане середньоквадратичне відхилення (RMSE) виявилось меншим за 1, і движок видав оціночні рейтинги для певного користувача та фільму [25].

Даний метод враховує як смаки користувача, так і оцінки фільму, надані іншими користувачами. Тому головною перевагою даного методу є те, що запропоновані фільми будуть відповідати попередній історії перегляду користувача, і скоріш за все вони матимуть популярність в інших користувачів.

Але все ж певний недолік даної системи існує, а саме те що даний метод передбачає рейтинг лише на основі того, як інші користувачі спрогнозували фільм, та не враховує можливий прогноз для конкретного користувача, тобто проблема холодного старту все ще присутня в даному підході [26].

Для того, щоб наша рекомендаційна система була високоефективною, нам потрібно усунути всі недоліки, які притаманні методам описаним раніше, а саме:

- відсутність урахування історії переглядів певного користувача;
- відсутність урахування оцінок фільмів, поставлених певним користувачем для переглянутих фільмів;

- відсутність урахування загального рейтингу фільму та оцінок, які були поставлені іншими користувачами;

- відсутність урахування таких деталей фільму як акторський склад, режисер, жанр, сюжет і тд.

Звісно, в нашому випадку за об'єкт дослідження ми використовуємо рекомендаційні системи для фільмів. Але використані методи можна з легкістю проектувати на інші сфери, де дуже часто використовуються рекомендаційні системи, а саме:

- музичні платформи, де користувач може отримати добірку пісень, які будуть відповідати його смаковим вподобанням;

- різноманітні відеохостинги як YouTube та TikTok, де користувач може побачити в стрічці випадкові відео;

- соціальні мережі;

- онлайн магазини;

- електронні бібліотеки і т.д.

В результаті ми бачимо необхідність в покращенні даного методу для вдосконалення результатів, які отримані за допомогою RMSE метрики, оскільки спільна фільтрація має наступні недоліки:

- обмежений контент-аналіз: рекомендації, що базуються на контент-аналізі, залежать від наявних ознак, явно пов'язаних з елементами. Ці ознаки повинні бути в такій формі, щоб їх можна було автоматично проаналізувати за допомогою комп'ютера або виділити вручну. що, залежно від домену, може бути нездійсненним або дуже складним у підтримці;

- новий користувач: користувач повинен показати певні вподобання (рейтинги) для достатньої кількості об'єктів, перш ніж рекомендації зможуть створити надійне профайл користувача на основі контенту;

- вузька спеціалізація: оскільки контент-рекомендатори знаходять лише ті об'єкти, які користувач вже оцінив, рекомендації є дуже схожими і, ймовірно,

добре відомими користувачеві, що не забезпечує новизни з точки зору користувача (або взагалі не забезпечує її);

– ефект портфоліо: пов'язаний з попереднім обмеженням, іноді рекомендовані позиції дуже схожі між собою, що призводить до набору недостатньо різноманітних або надлишкових пропозицій.

4.2 Експериментальна перевірка ансамблевого методу роботи з RMSE метрикою в рекомендаційних системах

Повертаючись до теми рекомендаційної системи для фільмів, ми спробуємо створити гібридний рекомендактор, який об'єднає в собі методи, які ми реалізували в попередньому розділі, а саме для рекомендаційні системи на основі вмісту і спільних фільтрів [27].

Ось як він буде працювати:

– вхідні дані: ідентифікатор користувача і назва фільму;
– вихідні дані: схожі фільми, відсортовані на основі очікуваних оцінок цього користувача.

Тобто в даному методі ми будемо враховувати історію переглядів конкретного користувача, щоб уникнути проблеми холодного старту.

Далі ми проаналізуємо оцінки, які були виставлені користувачем переглянутим фільмам.

Після цього ми оберемо будь-який фільм. Ми проаналізуємо жанр фільму, акторський склад та інші деталі надані в датасеті. На основі цих даних ми отримаємо список подібних фільмів.

Нижче наведено процес комбінування існуючих методів для роботи з рекомендаційними системами в гібридному підході (рисунок 4.8).

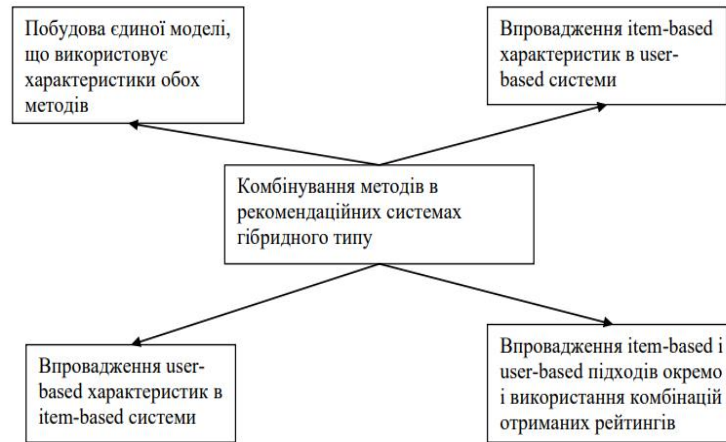


Рисунок 4.8 – Процес комбінування методів роботи рекомендаційних систем в гібридному підході

Після цього використовуючи методи для рекомендаційних систем на основі вмісту і спільних фільтрів (рисунок 4.9) , ми отримаємо прогнозовані оцінки для фільмів, які подібні заданому нами, та відсортуємо їх за прогнозованою оцінкою наданою конкретним користувачем [28].

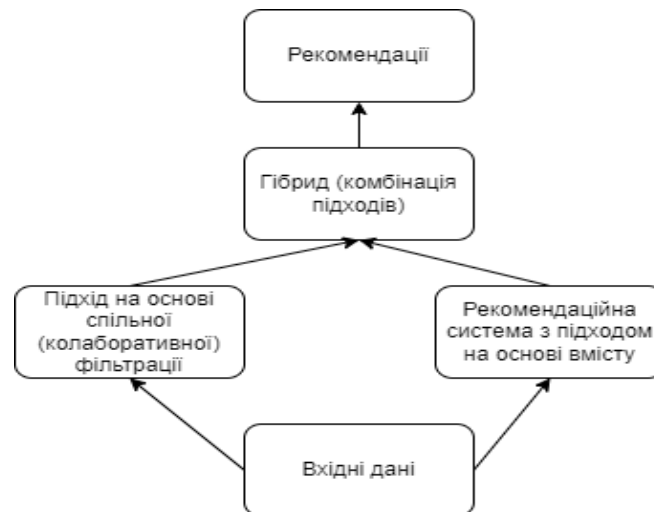


Рисунок 4.9 – Модель гібридного підходу

Гібридні рекомендаційні системи містять колаборативну складову, але також враховують дані фільтрації вмісту в профілі користувача (рисунок 4.10).

Також вони поєднують в собі переваги різних типів рекомендаційних систем, тому є більш універсальними і ефективними у порівнянні зі стандартними системами.

```
def convert_int(x):
    try:
        return int(x)
    except:
        return np.nan

id_map = pd.read_csv('../input/links_small.csv')[['movieId', 'tmdbId']]
id_map['tmdbId'] = id_map['tmdbId'].apply(convert_int)
id_map.columns = ['movieId', 'id']
id_map = id_map.merge(smd[['title', 'id']], on='id').set_index('title')
#id_map = id_map.set_index('tmdbId')

indices_map = id_map.set_index('id')

def hybrid(userId, title):
    idx = indices_map[title]
    tmdbId = id_map.loc[title]['id']
    #print(idx)
    movie_id = id_map.loc[title]['movieId']

    sim_scores = list(enumerate(cosine_sim[int(idx)]))
    sim_scores = sorted(sim_scores, key=lambda x: x[1], reverse=True)
    sim_scores = sim_scores[1:26]
    movie_indices = [i[0] for i in sim_scores]

    movies = smd.iloc[movie_indices][['title', 'vote_count', 'vote_average', 'year', 'id']]
    movies['est'] = movies['id'].apply(lambda x: svd.predict(userId, indices_map.loc[x]['movieId']).est)
    movies = movies.sort_values('est', ascending=False)
    return movies.head(10)
```

Рисунок 4.10 – Імплементация гібридного методу

Перевіримо наш метод, задавши ідентифікаційний номер для користувача 500 та фільм для порівняння «Аватар» (рисунок 4.11).

В якості фактичних оцінок ми будемо використовувати той самий повний набір вхідних даних, що і в таблиці 4.3, оскільки ми керуємося ансамблевим гетерогенним підходом.

```

svd.predict(1, 302, 3)
Prediction(uid=1, iid=302, r_ui=3, est=2.6896745637842423, details={'was_impossible': False})

```

Рисунок 4.11 – Прогнозування оцінки для методу гібридного підходу

Порівняємо отримані прогнозовані значення отримані завдяки колаборативній фільтрації та гібридного підходу з фактичним значенням. Фактичне значення оцінки фільму з ідентифікатором 302 (фільм «Аватар») у користувача являється оцінка 2.5.

Колаборативна фільтрація видала прогнозовану оцінку 2.877, в той час як гібридний підхід видав результат 2.689, як ми бачимо гібридний підхід дозволяє нам отримати більш точну рекомендацію.

Тепер спробуємо знову зімітувати проблему холодного старту, використовуючи вхідні дані зазначені в таблиці 4. та поглянемо на прогнозовану оцінку, отриману завдяки гібридному підходу (рисунок 4.12).

```

svd.predict(1, 302, 3)
Prediction(uid=1, iid=302, r_ui=3, est=2.87137263647726, details={'was_impossible': False})

```

Рисунок 4.12 – Прогнозована оцінка, використовуючи гібридний підхід в ситуації холодного старту

Тепер порівняємо наші прогнозовані оцінки з фактичними в умовах холодного старту для колаборативної фільтрації та гібридного підходу. Порівняння в умовах холодного старту важливе тим, що існуючі методи для оцінки ефективності рекомендаційних систем не можуть надавати точну оцінку саме в ситуації холодного старту. Тому цим ми ставимо собі на меті виявити кращий підхід для рекомендаційних систем, завдяки якому можна буде ефективніше використовувати методи для оцінки ефективності наданих рекомендацій [29].

Таблиця 4.6 – Порівняння прогнозованої оцінки в умовах холодного старту для колаборативної фільтрації та гібридного підходу

Підхід	Фактична оцінка	Прогнозована оцінка для повного набору даних	Прогнозована оцінка в умовах холодного старту
Колаборативна фільтрація	2.5	2.877	3.011
Гібридний підхід	2.5	2.689	2.871

Ми бачимо, що прогнозована оцінка рекомендації, використовуючи спільну фільтрацію та гібридний метод дещо відрізняється як у випадку використання повного набору даних, так і за умови холодного старту.

Тепер потрібно ще раз виміряти середньоквадратичну похибку після використання гібридного методу, щоб переконатися, що результат використання даної метрики дійсно кращий, ніж для колаборативної фільтрації (рисунок 4.13).

```
svd = SVD()
evaluate(svd, data, measures=['RMSE', 'MAE'])
```

Рисунок 4.13 – Повторне визначення середньоквадратичної та середньої абсолютної похибок

Отримуємо наступний результат, де `Fold` – це набір записів в нашому датасеті.

Таблиця 4.7 – Обчислення середньоквадратичної похибки

Набір записів	Середньоквадратична похибка
Fold 1	0.8786
Fold 2	0.8782
Fold 3	0.8798
Fold 4	0.8798
Fold 5	0.8735

Ми отримали середню квадратичну похибку 0.8779, що дійсно краще, ніж в попередньому розглянутому методі колаборативної фільтрації (рисунок 4.14).

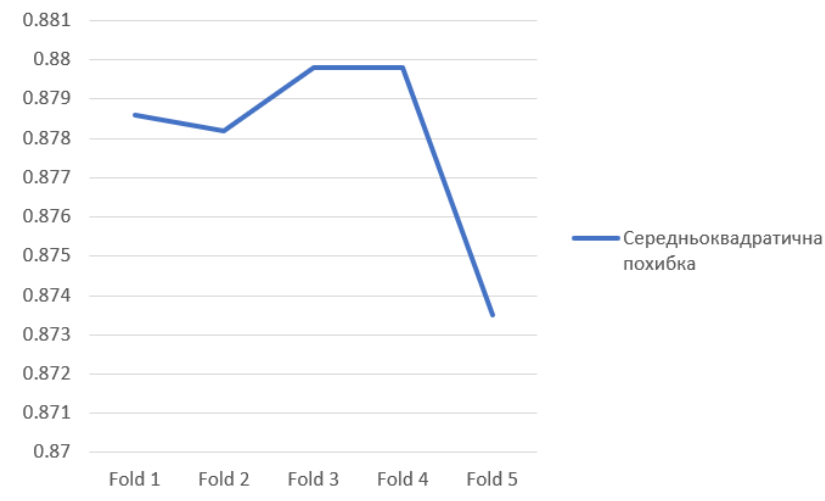


Рисунок 4.14 – Зображення RMSE на графіку

З точки зору нового користувача, який тільки нещодавно зареєструвався в системі та не надав достатньо даних для аналізу, саме гібридний підхід краще справляється з наданням більш точних рекомендацій. Дослідити це нам вдалося завдяки гетерогенного ансамблевого методу, порівнявши два існуючі методи та протестувавши їх на однакових наборах даних.

В табл. 4.8 наведені етапи та результати перевірки ансамблевого методу.

Таблиця 4.8 – Результати перевірки ансамблевого методу для оцінки ефективності рекомендаційної системи

Назва етапу	Опис етапу	Результат
Збір вхідних даних	Підібрати датасет з вхідними даними, які будуть містити інформацію по користувачу та об'єктам.	Зібрані вхідні даних з датасету IMDb
Збір вхідних даних для імітації ситуації холодного старту	Холодний старт означає відсутність достатньої кількості даних для проведення ефективної оцінки роботи рекомендаційної системи	Зменшено кількість вхідних даних вдвічі, щоб зімітувати ситуацію холодного старту
Прогнозування оцінки рекомендації для повного набору даних	Використати колаборативну фільтрацію та гібридний метод для отримання прогнозованої оцінки, використовуючи повний набір ланих	Отримано прогнозовані оцінки для рекомендації, використовуючи колаборативну та фільтрацію та гібридний метод

Продовження таблиці 4.8

Назва етапу	Опис етапу	Результат
Порівняння фактичної оцінки рекомендації з прогнозованою, використовуючи повний набір даних	Співставити існуючу фактичну оцінку рекомендації з отриманим результатом прогнозованої оцінки, використовуючи колаборативну фільтрацію та гібридний підхід	Фактична оцінка – 2.5, прогнозована оцінка використовуючи колаборативну фільтрацію – 2.877, гібридний підхід – 2.689
Порівняння фактичної оцінки рекомендації з прогнозованою в ситуації холодного старту	Співставити існуючу фактичну оцінку рекомендації з отриманим результатом прогнозованої оцінки, використовуючи колаборативну фільтрацію та гібридний підхід в ситуації холодного старту	Фактична оцінка – 2.5, прогнозована оцінка використовуючи колаборативну фільтрацію – 3.011, гібридний підхід – 2.871

Продовження таблиці 4.8

Назва етапу	Опис етапу	Результат
Провести оцінку ефективності рекомендаційної системи для ансамблевого підходу, використовуючи RMSE метрику	Оцінити ефективність рекомендацій для колаборативної фільтрації та гібридного підходу, використовуючи RMSE метрики	Похибка для колаборативної фільтрації, використовуючи RMSE метрику – 0.8953, похибка гібридного підходу – 0.8779

4.3 Рекомендації щодо практичного застосування розробленого методу

Під час використання гетерогенного ансамблевого методу ми порівняли результати отримані колаборативною фільтрацією та гібридним підходом в рекомендаційних системах [30].

Оцінка ефективності показала, що гібридний підхід являється більш ефективним для використання в рекомендаційних системах. Колаборативна фільтрація і гібридні методи – це дві популярні стратегії в рекомендаційних системах. Вибір між ними залежить від багатьох факторів, таких як об'єм даних, доступність контенту та особливості користувачів. Нижче наведено таблицю з порівнянням, в який випадках краще використовувати колаборативну фільтрацію або ж гібридний підхід.

Таблиця 4.9 – Порівняння використання колаборативної фільтрації та гібридного підходу

Назва методу	Сфера використання
Спільна (колаборативна) фільтрація	Є достатньо інформації про користувачів та їхні взаємодії з системою, така як: <ul style="list-style-type: none"> – історія покупок; – оцінки; – відгуки; – інші форми зворотного зв'язку.
Гібридний метод	Є необхідність враховувати більше факторів у рекомендаційному алгоритмі, таких як: <ul style="list-style-type: none"> – тематика; – контекст; – інші метадані.

Якщо ми говоримо про випадок, коли в системі є багато нових користувачів, про яких недостатня кількість даних, то вибір повинен бути в бік гібридного методу. Оскільки гібридний метод не є таким вразливим як колаборативна фільтрація, то саме його краще використовувати в ситуації великого притоку нових користувачів.

Не дивлячись на те, що гібридний підхід використовується багатьма популярними компаніями як Netflix, Amazon, Spotify, YouTube та Airbnb, він все ж має свої недоліки.

Основним недоліком гібридного підходу є складність його реалізації та відлагодження. Для побудови гібридної рекомендаційної системи потрібно

об'єднати різні типи даних та алгоритмів, що може бути дуже складним завданням. Також потрібно вирішити питання взаємодії між різними алгоритмами та забезпечити їхню взаємодію та сумісність.

Інший недолік гібридного підходу полягає в необхідності вибору оптимальних ваг для різних алгоритмів та типів даних. Це може бути досить складним завданням, оскільки різні алгоритми можуть відноситися до різних типів даних та мати різні масштаби значень.

Також в гібридній системі можуть виникати проблеми зі сумісністю даних. Якщо, наприклад, один алгоритм працює з текстовими даними, а інший – з відео, може виникнути проблема зі сумісністю даних та їх обробкою.

Нарешті, гібридні системи можуть бути більш обчислювально складними та вимагати більше ресурсів, що може бути проблемою для певних застосувань.

Наша створена рекомендаційна система на основі гібридного підходу є доволі оптимізованою, оскільки для її реалізації було використано невеликий набір даних через відсутність достатніх обчислювальних можливостей. Але навіть враховуючи це, ми все ж можемо визначити недоліки цього підходу, які вказані вище.

Основна можливість вдосконалити гібридний підхід в рекомендаційних системах – це використання більш нових технологій та алгоритмів. Для покращення гібридного підходу можна використовувати більш точні алгоритми машинного навчання, які забезпечать більш точні рекомендації користувачам.

Також забезпечити кращі результати в гібридних рекомендаційних системах може допомогти глибинне навчання (Deep learning). Воно може допомогти зрозуміти більш складні залежності між користувачами та об'єктами, що може привести до більш точних рекомендацій.

Більш точні рекомендації можуть бути зроблені за допомогою більш широкого спектру даних, таких як додаткові характеристики товарів або більш детальна інформація про користувачів. У майбутньому можна використовувати

більше інформації про контекст для зроблення рекомендацій, таку як геолокація, час доби, настрої користувача тощо.

Рекомендаційні системи повинні постійно розвиватися і оновлюватися, оскільки вони мають тенденцію застарівати дуже швидко. Тому важливо постійно вдосконалювати алгоритми та збільшувати масштаб системи, щоб забезпечити більш точні та різноманітні рекомендації для користувачів.

Крім того, хоча в ідеалі гібридні методи рекомендацій мали б подолати проблеми комбінованих методів, існують певні обмеження, притаманні проблемі рекомендацій, а отже, їх потрібно вирішувати окремо. Крім того, при поєднанні різних методів виникають додаткові проблеми, а також більше обмежень.

ВИСНОВКИ

В ході виконання даної кваліфікаційної роботи було виявлено, що методи оцінки ефективності рекомендаційних систем, засновані на помилках, широко використовуються в цій галузі, та мають як ряд значних переваг, так і недоліки. Основним недоліком при використанні методу являється проблема холодного старту, яка заважає надати точну інформацію по оцінці ефективності тієї чи іншої рекомендаційної системи.

В ході дослідження було проаналізовано шляхи уникнення холодного старту для використання методу оцінки рекомендаційної системи на основі помилок, який зможе надавати більш точну інформацію.

Було використано ансамблевий метод оцінки ефективності рекомендаційної системи, який оцінює ефективність як з урахуванням схожості користувачів, так і схожості товарів, які запропоновані цим користувачам. Це дало можливість підвищити точність оцінки ефективності для нових користувачів ІТ-проекту рекомендаційної системи.

Було досліджено 2 популярні підходи в рекомендаційних системах, а саме колаборативну фільтрацію та гібридний підхід, для того, щоб встановити, який саме з даних методів являється кращим при оцінці ефективності і прогнозування рекомендаційної системи, щоб мінімізувати середньоквадратичну похибку.

В результаті експериментальної перевірки були отримані висновки по кожному з методів та продемонстровані результати оцінки рекомендаційної системи, де вони використовувалися.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Rendle, S. (2019). Neural factorization machines for sparse predictive analytics. In Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. C. 1-10.
2. Dipanjan Sarkar (2020). Building Recommender Systems with Machine Learning and AI: Help People Discover New Products and Content with Deep Learning, Neural Networks, and Machine Learning Recommendations. C. 102-145.
3. Kim Falk (2019). Practical Recommender Systems. C. 56-89.
4. Michael Jahrer, Alexandros Karatzoglou, and Markus Weimer (2018). Machine Learning for Recommender Systems. C. 188-245.
5. Dietmar Jannach, Markus Zanker, Alexander Felfernig, and Gerhard Friedrich (2019). Recommender Systems: An Introduction. C. 230-249.
6. Julian McAuley and Jure Leskovec (2018). Effective feature engineering for recommender systems. C. 10-15.
7. Francesco Ricci, Lior Rokach, and Bracha Shapira (2018). Evaluation of recommender systems. C. 556-589.
8. Jorge Barbosa, Geert-Jan Houben, and Daniel Oliveira (2018). Context-aware recommender systems: a literature review and classification. C. 15-19.
9. Francesco Ricci, Lior Rokach, Bracha Shapira, and Paul Kantor (2018). Recommender Systems Handbook. C. 678-702.
10. Michael Walker (2018). Applied Data Science: Building Recommender Systems. C. 245-286.
11. Christoph Trattner and Denis Parra (2018). Recommender Systems for Social Tagging Systems. C. 89-101.
12. Andrew Ng (2020). Machine Learning Yearning. C. 75-100.

13. Michael P. O'Mahony, Dietmar Jannach and James C. Lester (2018). Collaborative Filtering Recommender Systems. C. 56-98.
14. Alexandros Karatzoglou, Xavier Amatriain, Linas Baltrunas and Nuria Oliver (2020). Modern Recommender Systems: Collaborative Filtering and Beyond. C. 110-165.
15. Giovanni Felici and Alessandro Farinelli (2019). Hybrid Approaches to Machine Learning and Data Mining: Methodologies, Challenges, and Applications. C. 120-178.
16. Guo G., Zhang J. and Yorke-Smith N. (2015), "TrustSVD: Collaborative Filtering with Both the Explicit and Implicit Influence of User Trust and of Item Ratings" AAAI. C. 67–112.
17. Ruining He and Julian McAuley. Fusing similarity models with markov chains for sparse sequential recommendation. In 2016 IEEE 16th International Conference on Data Mining (ICDM), 2016. C. 191–200.
18. Lei Mei, Pengjie Ren, Zhumin Chen, Liqiang Nie, Jun Ma, and Jian-Yun Nie. An attentive interaction network for context-aware recommendations. In Proceedings of the 27th ACM international conference on information and knowledge management, 2018. C. 157–166.
19. Nur Baiti Afini Normadhi, Liyana Shuib, Hairul Nizam Md Nasir, Andrew Bimba, Norisma Idris, and Vimala Balakrishnan. Identification of personal traits in adaptive learning environment: Systematic literature review. Computers & Education, 2019. C. 168–190p.
20. Gina George and Anisha M Lal. Review of ontology-based recommender systems in e-learning. Computers & Education, 2019. C. 120-145.
21. Mozhgan Karimi, Dietmar Jannach, and Michael Jugovac. News recommender systems—survey and roads ahead. Information Processing & Management, 2018. C. 89-143.

22. R Logesh, V Subramaniaswamy, V Vijayakumar, and Xiong Li. Efficient user profiling based intelligent travel recommender system for individual and group of users. *Mobile Networks and Applications*, 2019. C. 134-167.
23. Norha M Villegas, Cristian S´anchez, Javier D´iaz-Cely, and Gabriel Tamura. Characterizing context-aware recommender systems: A systematic literature review. *Knowledge-Based Systems*, 2018. C. 89-123.
24. Li Chen, Guanliang Chen, and Feng Wang. Recommender systems based on user reviews: the state of the art. *User Modeling and User-Adapted Interaction*, 2015. C. 99–154.
25. Jure Leskovec, Anand Rajaraman, and Jeffrey David Ullman. *Mining of massive data sets*. Cambridge university press, 2020. C. 22-34.
26. Alejandro Bellog´ın, Pablo Castells, and Iv´an Cantador. Neighbor selection and weighting in user-based collaborative filtering: a performance prediction approach. *ACM Transactions on the Web (TWEB)*, 2014. C. 1-30.
27. Dong Qin, Xiangmin Zhou, Lei Chen, Guangyan Huang, and Yanchun Zhang. Dynamic connection-based social group recommendation. 2020. C. 453–467.
28. Lakshmanan Rakkappan and Vaibhav Rajan. Context-aware sequential recommendations with stacked recurrent neural networks. In *The World Wide Web Conference*, 2019. C. 134-156.
29. Weihua Yuan, Hong Wang, Xiaomei Yu, Nan Liu, and Zhenghao Li. Attention-based context-aware sequential recommendation model. *Information Sciences*, 2020. C. 122–134p.
30. The Deloitte Consumer Review. Made-to-order: The rise of mass personalisation. URL: <https://www2.deloitte.com/ch/en/pages/consumerbusiness/articles/made-to-order-the-rise-of-mass-personalisation.html>.
31. Методичні вказівки щодо розробки та оформлення магістерської кваліфікаційної роботи за спеціальністю 122 Комп’ютерні науки (освітня програма «Управління проектами в галузі інформаційних технологій»)

освітньо-кваліфікаційного рівня «магістр» / Упоряд.: Петров К.Е., Левикін В.М., Чалий С.Ф., Євланов М.В., Саєнко В.І., Міхнов Д.К., Міхнова А.В., Чала О.В. – Харків: ХНУРЕ, 2021. – 28 с

32. ДСТУ 3008:2015. Інформація та документація. Звіти у сфері науки і техніки. Структура і правила оформлювання. – Чинний від 22.06.2015. – Київ: ДП «УкрНДНЦ», 2016. – 31

33. ДСТУ 8302:2015. Інформація та документація. Бібліографічні посилання. Загальні положення та правила складання. – Чинний від 04.03.2016. – Київ: ДП «УкрНДНЦ», 2016. – 20 с.