

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 можливих моделей пояснень в рекомендаційних системах
(тема)

Виконав:
здобувач 2 року навчання,
групи ІУСТМ-23-1
Суліма Володимир Сергійович
(прізвище, ім'я, по батькові)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)


Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)

Освітня програма Інформаційні
управляючі системи та технології
(повна назва освітньої програми)

Керівник проф. Оксана ЧАЛА
(посада, власне ім'я, ПРІЗВИЩЕ)

Допускається до захисту

Зав. кафедри


(підпис)

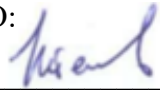
Костянтин ПЕТРОВ
(Власне ім'я, ПРІЗВИЩЕ)

2025 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наукКафедра Інформаційних управляючих системРівень вищої освіти другий (магістерський)Спеціальність 122 Комп'ютерні науки
(код і повна назва)Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)Освітня програма Інформаційні управляючі системи та технології
(повна назва)

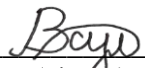
ЗАТВЕРДЖУЮ:

Зав. кафедри 
(підпис)« 09 » грудня 2024 р.**ЗАВДАННЯ**
НА КВАЛІФІКАЦІЙНУ РОБОТУздобувачеві Сулімі Володимиру Сергійовичу
(прізвище, ім'я, по батькові)1. Тема роботи Дослідження можливісних моделей пояснень в рекомендаційних системахзатверджена наказом університету від 27 листопада 2024 р. № 1249Ст2. Термін подання здобувачем роботи до екзаменаційної комісії 19 січня 2025 р.3. Вихідні дані до роботи Науково-технічні публікації та інтернет-джерела з тематики дослідження можливісних моделей пояснень в рекомендаційних системах.4. Перелік питань, що потрібно опрацювати в роботі аналіз бізнес-процесів рекомендаційних систем, загальна функціональна класифікація бізнес-процесів рекомендаційних систем, детальна характеристика процесів рекомендаційних систем, аналіз підходів до управління рекомендаціями, загальна характеристика можливісних моделей пояснень, характеристика методів генерації можливісних моделей, постановка задачі дослідження, аналіз контентного підходу для генерації пояснень у рекомендаційних системах.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів	Примітка
1	Аналіз предметної області	09.12.2024 - 13.12.2024	Виконано
2	Постановка задачі	13.12.2024 - 15.12.2024	Виконано
3	Обробка матеріалу	15.12.2024 - 20.12.2024	Виконано
4	Дослідження рекомендаційних систем	20.12.2024 - 25.12.2024	Виконано
5	Дослідження методів генерації пояснень	25.12.2024 - 30.12.2024	Виконано
6	Експериментальна перевірка	30.12.2024 - 04.01.2025	Виконано
7	Аналіз результатів дослідження	04.01.2025 - 07.01.2025	Виконано
8	Написання пояснювальної записки	07.01.2025 - 12.01.2025	Виконано
9	Підготовка презентації	12.01.2025 - 14.01.2025	Виконано
10	Перевірка на плагіат	14.01.2025 - 16.01.2025	Виконано
11	Нормконтроль	16.01.2025 - 19.01.2025	Виконано
12	Захист	22.01.2025	Виконано

Дата видачі завдання 09 грудня 2024 р.

Здобувач 
(підпис)

Керівник роботи  проф.каф. ІУС Оксана ЧАЛІА
(підпис) (посада, власне ім'я, ПРИЗВИЩЕ)

РЕФЕРАТ

Пояснювальна записка до кваліфікаційної роботи: 81 стор., 4 табл., 8 рис., 28 джерел.

ЕЛЕКТРОННА КОМЕРЦІЯ, ІНТЕРПРЕТАЦІЯ РЕКОМЕНДАЦІЙ, МЕТОДИ ГЕНЕРАЦІЇ ПОЯСНЕНЬ, ПЕРСОНАЛІЗОВАНІ ПРОПОЗИЦІЇ, РЕКОМЕНДАЦІЙНІ СИСТЕМИ, ХОЛОДНИЙ СТАРТ.

Об'єктом дослідження є процес побудови пояснень у рекомендаційних системах, зокрема в контексті електронної комерції, для створення зрозумілих і прозорих рекомендацій. Це включає розробку методів, що дозволяють новим користувачам отримувати персоналізовані пропозиції та допомагають вирішити проблему "холодного старту". Предметом дослідження є методи генерації пояснень, які дають змогу користувачам інтерпретувати і оцінювати рекомендації.

Метою роботи є створення рекомендаційної системи, що використовує ефективні методи побудови персоналізованих пропозицій для нових користувачів, інтегруючи функціонал пояснень для підвищення довіри та прозорості, а також аналіз впливу таких методів на задоволеність і активність користувачів.

ABSTRACT

Explanatory note to the qualification work: 81 pages, 4 tables, 8 figures, 28 sources.

ELECTRONIC COMMERCE, RECOMMENDATION INTERPRETATION, EXPLANATION GENERATION METHODS, PERSONALIZED PROPOSALS, RECOMMENDATION SYSTEMS, COLD START.

The object of the research is the process of building explanations in recommender systems, in particular in the context of e-commerce, to create understandable and transparent recommendations. This includes the development of methods that allow new users to receive personalized offers and help solve the problem of "cold start". The subject of the research is the methods of generating explanations that allow users to interpret and evaluate recommendations.

The goal of the work is to create a recommender system that uses effective methods of building personalized offers for new users, integrating the functionality of explanations to increase trust and transparency, as well as analyzing the impact of such methods on user satisfaction and activity.

ЗМІСТ

С.

Вступ.....	7
1 Аналіз предметної області дослідження	9
1.1 Аналіз властивостей рекомендаційних систем	9
1.2 Аналіз підходів до побудови рекомендацій	20
1.3 Аналіз моделей пояснень в інтелектуальних системах.....	27
1.4 Постановка задачі дослідження.....	39
2 Можливісна модель пояснень в рекомендаційній системі	40
2.1 Розробка можливісного підходу до побудови пояснень в рекомендаційних системах.....	40
2.2 Удосконалена можливісна модель пояснень	42
3 Розробка інформаційної технології побудови пояснень на основі можливісної моделі	51
4 Програмна реалізація та експериментальна перевірка отриманих результатів.....	55
4.1 Реалізація модулю генерації можливісних моделей пояснень.....	55
4.2 Експериментальна перевірка отриманих теоретичних результатів.....	60
Висновки	69
Перелік джерел посилання	71
Додаток А Графічний матеріал кваліфікаційної роботи.....	74

ВСТУП

Сучасний світ характеризується стрімким розвитком інформаційних технологій, що докорінно змінюють способи взаємодії людини з інформацією. Системи рекомендацій (RS) займають важливе місце серед цих технологій, забезпечуючи персоналізовані пропозиції, які допомагають користувачам орієнтуватися у великому обсязі доступних даних. Від фільмів і музики до товарів у сфері електронної комерції — рекомендаційні системи значно спрощують прийняття рішень, заощаджуючи час і підвищуючи якість обслуговування. Проте їхня ефективність часто залежить не лише від точності пропозицій, а й від здатності пояснювати ці рекомендації.

Однією з основних проблем сучасних рекомендаційних систем є відсутність прозорості, що перетворює їх у так звані «чорні скриньки». Без належного пояснення користувачі можуть сумніватися в обґрунтованості пропозицій, що знижує рівень довіри до системи та задоволення від її використання. Дослідження можливих моделей пояснень стає актуальним завданням, адже воно спрямоване на підвищення зрозумілості, зручності та ефективності рекомендаційних систем у різних сферах людської діяльності.

Об'єктом даного дослідження є рекомендаційні системи та їхні механізми надання пояснень. Зокрема, увага зосереджена на різноманітних підходах до побудови моделей пояснень, що забезпечують прозорість і зрозумілість процесу рекомендацій.

Метою даної роботи є аналіз і розробка можливих моделей пояснень у рекомендаційних системах, які підвищують довіру користувачів, покращують взаємодію з системою та сприяють ефективнішому прийняттю рішень.

Для досягнення поставленої мети необхідно виконати такі задачі:

– проаналізувати сучасний стан досліджень у сфері рекомендаційних систем та моделей пояснень;

- вивчити основні критерії оцінки якості пояснень, такі як прозорість, довіра, ефективність і задоволення користувачів;
- розробити підходи до побудови можливісних моделей пояснень, які враховують особливості різних рекомендаційних систем;
- провести емпіричну оцінку запропонованих моделей пояснень у реальних умовах;
- надати практичні рекомендації щодо впровадження моделей пояснень у комерційні рекомендаційні системи.

Наукова новизна роботи полягає у розробці та систематизації підходів до побудови можливісних моделей пояснень у рекомендаційних системах. У роботі вперше запропоновано методики, які враховують багатокритеріальну оцінку пояснень, їхній вплив на користувацький досвід і довіру до системи. Особлива увага приділяється інтеграції пояснень у різні типи рекомендаційних платформ, що сприяє їхній універсальності.

Результати даного дослідження можуть бути застосовані для вдосконалення існуючих і розробки нових рекомендаційних систем у сферах електронної комерції, онлайн-навчання, розважального контенту тощо. Запропоновані моделі пояснень дозволяють підвищити задоволеність користувачів, зменшити кількість відмов від рекомендацій і покращити загальну продуктивність систем. Це, у свою чергу, сприяє підвищенню конкурентоспроможності компаній, які використовують рекомендаційні системи в своїй діяльності.

Отже, дослідження можливісних моделей пояснень у рекомендаційних системах є надзвичайно актуальним завданням, результати якого сприятимуть розвитку цієї сфери та розширенню можливостей застосування таких систем у різних галузях. Робота побудована таким чином, щоб забезпечити комплексне розуміння проблеми, запропонувати нові підходи до її вирішення та оцінити їхню ефективність у реальних умовах.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ДОСЛІДЖЕННЯ

1.1 Аналіз властивостей рекомендаційних систем

Рекомендаційні системи є важливим компонентом сучасних інтелектуальних інформаційних систем, що використовуються в різних галузях, таких як електронна комерція, освіта, медицина, соціальні мережі та інші. Їх основна мета полягає у формуванні індивідуальних рекомендацій для користувачів на основі аналізу їхніх уподобань, поведінки чи інших параметрів. Рекомендаційні системи базуються на різних підходах, серед яких можна виділити фільтрацію на основі контенту, колаборативну фільтрацію та гібридні методи. Вони використовують алгоритми машинного навчання та аналіз великих обсягів даних для виявлення прихованих залежностей і забезпечення релевантних результатів.

Для оцінки ефективності рекомендаційних систем використовуються різноманітні критерії, такі як точність, повнота, диверсифікація, стабільність та чутливість до змін у вхідних даних. Точність визначає, наскільки запропоновані рекомендації відповідають потребам користувача, а повнота вказує на здатність системи знаходити всі релевантні об'єкти. Диверсифікація характеризує різноманітність запропонованих варіантів, що особливо важливо для уникнення одноманітності рекомендацій. Стабільність показує, наскільки результати системи залишаються сталими за умов змін у її параметрах, а чутливість вказує на здатність адаптуватися до нових даних. Якість роботи рекомендаційної системи залежить від якості даних, які використовуються. Упередженість, шум чи пропуски у даних можуть значно знижувати продуктивність системи та впливати на її точність і релевантність.

Незважаючи на досягнення в розробці рекомендаційних систем, існує низка викликів, які обмежують їх ефективність. Наприклад, проблема "холодного старту" виникає у випадках, коли для нових користувачів чи об'єктів бракує достатніх даних. Упередженість у даних може призводити до

надання рекомендацій, які не відповідають реальним потребам користувачів, а це знижує ефективність системи. Відсутність прозорості роботи алгоритмів також впливає на довіру користувачів до системи, особливо якщо рекомендації здаються незрозумілими чи нелогічними. Юридичні та етичні аспекти також є значущими викликами, оскільки використання персональних даних користувачів потребує відповідності до законодавчих норм і забезпечення конфіденційності.

Особливу увагу привертає проблема пояснюваності рекомендаційних систем. Пояснення надають можливість користувачам зрозуміти, чому була обрана конкретна рекомендація, що підвищує рівень довіри до системи та сприяє її більш ефективному використанню. Розробка пояснень базується на врахуванні психологічних аспектів сприйняття інформації. Наприклад, пояснення повинні бути простими, зрозумілими та релевантними для конкретного користувача. Існують різні методи забезпечення пояснюваності, серед яких текстові обґрунтування, графічна візуалізація та інтерактивні засоби, які дозволяють користувачам надавати зворотний зв'язок і уточнювати свої запити.

Алгоритми машинного навчання є основою сучасних рекомендаційних систем. Серед них можна виділити нейронні мережі, які здатні обробляти великі обсяги даних і виявляти складні залежності, методи глибокого навчання, які застосовуються для розпізнавання шаблонів у мультимедійних даних, а також методи кластеризації, які дозволяють визначати схожі групи користувачів чи об'єктів. Використання цих методів дозволяє значно підвищити точність і адаптивність рекомендацій. Однак впровадження інноваційних алгоритмів створює нові виклики, пов'язані з їхньою етичністю, прозорістю та забезпеченням прав користувачів.

Вплив рекомендаційних систем на користувачів є значним. Вони здатні формувати переваги, впливати на вибір товарів чи послуг, а також змінювати поведінку людей у різних контекстах. Однак зловживання можливостями таких систем може призводити до маніпуляцій, коли рекомендації спрямовані

не на задоволення потреб користувачів, а на досягнення комерційних чи інших цілей розробників. Це підкреслює важливість етичного підходу до розробки рекомендаційних систем та забезпечення їхньої прозорості.

Таким чином, аналіз властивостей рекомендаційних систем дозволяє визначити основні аспекти, які впливають на їхню ефективність, а також виявити ключові виклики та перспективи їхнього розвитку. Рекомендаційні системи залишаються важливим інструментом у сучасному інформаційному просторі, однак їхнє впровадження потребує уважного підходу з урахуванням інтересів користувачів, юридичних норм та етичних принципів.

Моделювання рекомендацій також включає активне використання машинного навчання та глибоких нейронних мереж. Наприклад, моделі на основі алгоритмів глибокого навчання можуть виявляти складні зв'язки між різними параметрами, прогнозувати майбутні дії користувачів та адаптувати рекомендації до їхніх змінюваних інтересів. Крім того, сучасні рекомендаційні системи часто навчаються в реальному часі, використовуючи потокові дані про взаємодії користувачів. Це дозволяє системам бути більш гнучкими та швидко реагувати на зміни в поведінці користувачів. Таким чином, рекомендаційні системи можуть надавати більш точні та актуальні рекомендації, що сприяє підвищенню задоволеності користувачів.

Завершальний етап бізнес-процесів — це подання рекомендацій користувачам. На цьому етапі рекомендації персоналізуються відповідно до уподобань і контексту кожного користувача. Наприклад, електронні платформи можуть враховувати географічне розташування користувача для пропозиції локальних товарів, а стримінгові сервіси можуть адаптувати рекомендації до часу доби чи дня тижня. Особлива увага приділяється зручності візуалізації рекомендацій, яка має бути інтуїтивно зрозумілою та привабливою. Це дозволяє користувачам легко знаходити потрібний контент і робить взаємодію з системою більш приємною та ефективною.

Пояснення рекомендацій є ще одним важливим аспектом. Користувачі охочіше взаємодіють із системами, які надають зрозумілі причини своїх

рекомендацій. Наприклад, платформи можуть зазначати: "Ми рекомендуємо цей товар, тому що ви переглядали подібні" або "Цей фільм обрано на основі ваших уподобань у жанрі". Такі пояснення підвищують довіру до системи та покращують її ефективність. Це також дозволяє користувачам краще розуміти, чому їм пропонуються ті чи інші варіанти, що робить взаємодію з системою більш прозорою.

Важливість пояснень у рекомендаційних системах виходить за рамки простого покращення користувацького досвіду. Вони також сприяють підвищенню загальної довіри до системи, оскільки користувачі відчують, що їхні інтереси враховані і що система працює прозоро. Наприклад, в електронній комерції пояснення причин вибору певного товару може призвести до збільшення продажів, оскільки користувачі будуть більш схильні довіряти рекомендаціям і купувати запропоновані товари. У стримінгових сервісах пояснення, чому рекомендується певний фільм або серіал, можуть допомогти користувачам знайти контент, який їм справді сподобається, тим самим підвищуючи їхню задоволеність сервісом.

З іншого боку, пояснення також допомагають уникнути можливих конфліктів або непорозумінь. Якщо користувач розуміє, чому йому пропонується певний товар або послуга, він менш схильний до негативних реакцій, навіть якщо рекомендація не зовсім відповідає його очікуванням. Наприклад, платформа може пояснити: "Ми рекомендуємо цей товар на основі ваших попередніх покупок і поточних трендів", що може переконати користувача у вагомості рекомендації, навіть якщо вона спочатку виглядала не дуже релевантною.

На додаток, надання пояснень користувачам допомагає системам зібрати цінний зворотний зв'язок. Користувачі можуть залишати відгуки або оцінки рекомендацій, що дозволяє системі постійно вдосконалювати свої алгоритми і моделі. Це створює позитивний цикл, де пояснення рекомендацій сприяють зростанню задоволеності користувачів, а отримані відгуки допомагають системі ставати ще точнішою і кориснішою.

Інтеграція пояснень у рекомендаційні системи також підвищує їхню етичність та відповідальність. Наприклад, у сфері медичних послуг рекомендації можуть стосуватися критично важливих рішень, тому пояснення причин вибору певного лікування або діагностичного тесту є надзвичайно важливими для забезпечення довіри пацієнтів до медичних систем. Користувачі очікують, що системи будуть працювати чесно і прозоро, особливо коли мова йде про їхнє здоров'я або особисті дані.

Таким чином, пояснення рекомендацій є ключовим елементом успішних рекомендаційних систем. Вони не тільки підвищують задоволеність і довіру користувачів, але й сприяють загальному вдосконаленню систем, роблячи їх більш ефективними, адаптивними та етичними. У сучасному світі, де рекомендаційні системи відіграють важливу роль у багатьох аспектах життя, від електронної комерції до медичних послуг, важливість надання чітких і зрозумілих пояснень неможливо переоцінити.

Аналіз бізнес-процесів рекомендаційних систем дозволяє виявити ключові вузькі місця, такі як складність обробки великих даних, недостатня персоналізація чи відсутність пояснень рекомендацій.

Це відкриває можливості для їх вдосконалення, зокрема через автоматизацію обробки даних, інтеграцію сучасних технологій машинного навчання та впровадження адаптивних моделей, які враховують зміни в поведінці користувачів у реальному часі. Крім того, забезпечення етичності та конфіденційності є невід'ємною складовою цих процесів. Наприклад, системи повинні гарантувати, що особисті дані користувачів використовуються відповідно до законодавства та не передаються третім сторонам без згоди користувачів.

Зрештою, оптимізація бізнес-процесів рекомендаційних систем є необхідною умовою для досягнення високого рівня задоволення користувачів і реалізації бізнес-цілей. Вона включає вдосконалення всіх етапів роботи системи — від збору даних до презентації рекомендацій, підвищуючи її ефективність, точність і адаптивність до змін. Це дозволяє системам бути

більш конкурентоспроможними та забезпечувати користувачам найкращий можливий досвід. Таким чином, рекомендаційні системи можуть краще задовольняти потреби користувачів та сприяти розвитку бізнесу.

Бізнес-процеси рекомендаційних систем охоплюють широкий комплекс дій, спрямованих на збір, аналіз, обробку та трансформацію даних у персоналізовані рекомендації, які відповідають конкретним потребам користувачів.

Ці процеси базуються на багаторівневій взаємодії між користувачем, системою та зовнішніми джерелами даних, і включають різноманітні методи, алгоритми й інструменти для забезпечення максимальної точності, релевантності та ефективності запропонованих рішень. Розглянемо детально основні компоненти та етапи цих бізнес-процесів.

На цьому етапі система отримує дані, які слугують основою для створення рекомендацій. Джерела даних можуть включати:

- взаємодії користувачів із системою (перегляди, покупки, оцінки, кліки);
- контекстуальні фактори (час, місце, пристрій, з якого здійснюється доступ);
- демографічна інформація (вік, стать, місце проживання);
- зовнішні джерела (відгуки з соціальних мереж, трендові дані).

Система може застосовувати пасивне або активне збирання даних, наприклад, через опитування або інтеграцію API сторонніх сервісів.

Обробка даних включає кілька ключових етапів:

- очистка даних: видалення шуму, дублювань, неповної та некоректної інформації;
- агрегація: об'єднання даних для формування єдиної бази знань;
- формування профілів користувачів: створення структурованих описів інтересів, уподобань і поведінки кожного користувача.

Цей етап визначає якість рекомендацій, адже неточності у вхідних даних можуть суттєво вплинути на результати.

Проблема "холодного старту" в рекомендаційних системах залежить від специфіки конкретної системи і її підходів до аналізу даних. Одним із ключових завдань таких систем в онлайн-магазинах є встановлення зв'язків між товарами, які часто купуються разом. Аналізуючи ці дані, можна визначити групи користувачів із подібними покупками, що дозволяє створювати персоналізовані пропозиції. Наприклад, якщо два покупці здійснювали схожі покупки, їм можна рекомендувати однакові товари, що потенційно їх зацікавлять.

Основними компонентами рекомендаційної системи є користувачі, товари та події. Подія визначається як взаємодія користувача з товаром, наприклад, позитивна чи негативна оцінка. Для більш точного опису можна використовувати метрику оцінювання, яка визначає ступінь задоволення користувача конкретним товаром. Таким чином, кожна подія може бути описана як факт того, що користувач оцінив товар певним чином. Цей базовий принцип є фундаментом функціонування рекомендаційних систем.

Основне завдання таких систем полягає у прогнозуванні оцінок, які користувачі можуть дати товарам, використовуючи доступну інформацію. Знаючи передбачувані оцінки, система може формувати рекомендації. Наприклад, якщо для певного товару система прогнозує високу оцінку від користувача, варто надати цьому товару пріоритет у рекомендаціях. Для цього система ранжує товари за прогнозованими оцінками та пропонує користувачеві найкращі варіанти, наприклад, п'ять найрелевантніших товарів.

Дані в рекомендаційних системах зазвичай організуються у вигляді матриці, де рядки представляють користувачів, стовпці – товари, а на перетинах зберігаються оцінки або інша інформація про взаємодію. На основі такої структури система рекомендує товари, які подібні до тих, що вже були придбані або оцінені користувачем. Схожість визначається за характеристиками товарів, такими як категорія, бренд або ціна. При цьому рекомендації залежать від конкретної предметної області: системи для товарів

і для медіаконтенту (наприклад, фільмів) будуть функціонувати по-різному через різні критерії оцінювання.

Колаборативна фільтрація є одним із найпоширеніших підходів у рекомендаційних системах. Її популярність пояснюється простотою реалізації та ефективністю, особливо з огляду на можливість інтеграції з алгоритмами машинного навчання. Цей метод базується на аналізі історії оцінок користувачів. Користувачів групують за схожістю вподобань, і вважається, що люди в одній групі мають подібні інтереси.

Одним із ключових аспектів цього методу є групування користувачів за схожістю їхніх вподобань. Для цього система аналізує попередні дії користувачів, такі як перегляди, оцінки, покупки або інші форми взаємодії. Знайшовши схожість між діями різних людей, система формує групи, які складаються з користувачів із подібними інтересами. У такому разі вважається, що члени однієї групи мають спільні уподобання і з високою ймовірністю зацікавляться схожими товарами чи контентом.

Важливою перевагою цього підходу є можливість використовувати інформацію про дії одного користувача для покращення рекомендацій іншим членам його групи. На основі цього алгоритм формує рекомендації, адаптовані до передбачуваних вподобань кожного окремого користувача.

Колаборативна фільтрація також дозволяє враховувати динамічні зміни в уподобаннях користувачів. Наприклад, якщо користувач починає взаємодіяти з новим типом контенту чи товарами, система адаптується, вносячи відповідні коригування в рекомендації. Це підвищує гнучкість алгоритму та дозволяє системі залишатися актуальною навіть у випадках змін поведінки користувачів або появи нових трендів.

Далі доцільно детальніше розглянути, як архітектура рекомендаційної системи може бути оптимізована для потреб онлайн-магазинів, зокрема у контексті підвищення продуктивності, зниження затримок і забезпечення точності рекомендацій. Більшість цих онлайн сервісів мають у собі РС. Архітектура типової РС зображена на рисунку 1.1.

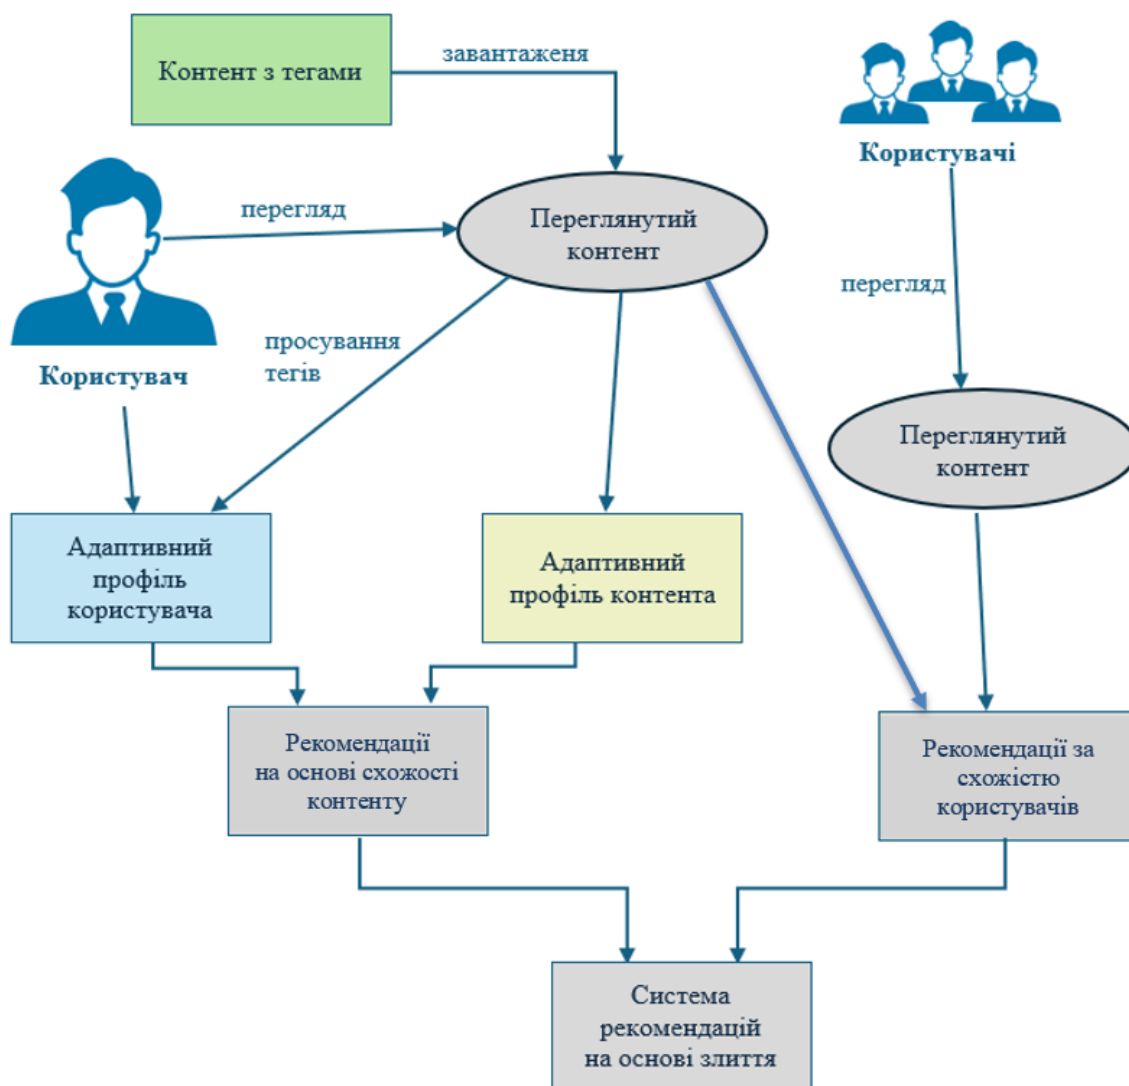


Рисунок 1.1 – Схема архітектури рекомендаційної системи

Система рекомендацій взаємодіє з кількома основними елементами: користувачами, об'єктами та подіями. Для якісного функціонування системи потрібно зібрати якомога більше інформації про кожен із цих компонентів. На першому етапі формується база даних про користувачів, яка включає інформацію з анкет, відгуків чи оцінок. Дані про об'єкти, як-от товари, зазвичай вже зберігаються в інформаційній базі підприємства. Ця інформація структурована і легко доступна за допомогою традиційних баз даних.

Однак дані про взаємодії користувачів із системою, такі як додавання товарів до кошика, оцінки чи перегляди, можуть займати значні обсяги пам'яті. Обсяг таких даних для великого онлайн-магазину може досягати

десять гігабайт щоденно, оскільки фіксується близько сотні подій за секунду. Для зберігання такого обсягу інформації звичайні реляційні бази даних не підходять, тому використовується технологія зберігання великих даних у розподілених файлових системах. Ці події фіксуються за допомогою систем трекінгу активності, які встановлені на сайтах і збирають детальну інформацію про взаємодію користувачів.

Дані про дії користувачів надсилаються в черги повідомлень, організовані за допомогою спеціальних інструментів, таких як системи чергування повідомлень і збору логів. Після цього інформація потрапляє до розподіленої файлової системи для обробки. Для роботи з великими обсягами даних використовується механізм, який дозволяє виконувати запити до розподіленої файлової системи за допомогою SQL-подібного синтаксису. Це значно спрощує отримання вибірок із великих масивів даних. Додатково, дані про користувачів і товари можуть завантажуватися в систему через спеціалізовані інструменти, які забезпечують інтеграцію даних із зовнішніх джерел.

Обробка цих даних для формування рекомендацій відбувається в спеціальних обчислювальних кластерах. Така архітектура дозволяє розподілити навантаження між багатьма серверами і значно підвищити швидкість обробки даних. Кластери не обов'язково розташовані в інфраструктурі компанії; вони можуть бути хмарними, проте деякі організації надають перевагу локальним рішенням через міркування безпеки і продуктивності.

Одним із ключових викликів у рекомендаційних системах є ідентифікація користувача. Для цього можуть використовуватися різні методи, наприклад, карти лояльності чи унікальні ідентифікатори. Проте цей процес залишається складним завданням, яке нерідко потребує більше ресурсів, ніж безпосереднє створення рекомендацій.

Обробка даних у кластері може бути реалізована за допомогою платформи для розподіленого обчислення, яка використовує парадигму

обробки великих даних. Ця платформа підтримує розподілене зберігання та обробку інформації, однак базові механізми, такі як обробка через API, мають обмеження, що можуть ускладнювати роботу. Через це для ітеративних алгоритмів, які використовуються в машинному навчанні, оптимальним рішенням є інструменти, здатні працювати безпосередньо в оперативній пам'яті. Це дозволяє уникати тривалих операцій вводу/виводу, які виникають під час зчитування даних із диска та їхнього повторного запису.

Сучасні обчислювальні фреймворки оптимізують процес обробки, завантажуючи дані до оперативної пам'яті. У результаті основна обробка відбувається безпосередньо в пам'яті, а записи на диск виконуються лише для збереження остаточних результатів. Такий підхід суттєво зменшує витрати на операції вводу/виводу, що є критично важливим для роботи з великими обсягами даних.

Окрім цього, система для рекомендацій інтегрується з інструментами обробки SQL-запитів, що дозволяє виконувати прості вибірки з великих масивів даних. Для більш складних операцій, які не можуть бути описані SQL-запитами, розробляються користувацькі функції. Це дозволяє гнучко налаштовувати систему під специфічні потреби і виконувати складні аналітичні розрахунки.

Під час створення рекомендаційної системи значна частина часу витрачається на підготовку даних. Це включає екстракцію, трансформацію та завантаження даних до необхідного формату. Після завершення підготовки даних алгоритми машинного навчання можуть застосовуватися для аналізу взаємозв'язків між користувачами, товарами та їхньою взаємодією. У результаті формується матриця взаємодій, яка використовується для генерації персоналізованих рекомендацій.

Такий підхід до побудови рекомендаційних систем дозволяє ефективно обробляти великі обсяги даних, адаптувати рекомендації до потреб користувачів і швидко інтегрувати зміни.

1.2 Аналіз підходів до побудови рекомендацій

Управління рекомендаціями є одним із ключових завдань сучасних систем, що прагнуть надати користувачам максимально персоналізовані пропозиції. Цей процес охоплює весь цикл від збору та аналізу даних до розробки моделей рекомендацій та їх інтеграції в реальне середовище. Основною метою такого управління є оптимізація взаємодії між системою та користувачем, що сприяє не лише підвищенню задоволеності, але й досягненню важливих бізнес-результатів.

Традиційні підходи до управління рекомендаціями базуються на кількох основних методах, кожен із яких має свої особливості, переваги й обмеження. Контентна фільтрація ґрунтується на аналізі характеристик об'єктів, які система може порівнювати з уподобаннями користувача. Наприклад, якщо користувач надає перевагу товарам певного бренду чи жанру, система підбирає подібні варіанти, враховуючи ці параметри. Такий підхід є зручним для роботи з чітко структурованими даними, але має обмеження у вигляді складності врахування поведінкових особливостей чи контексту.

Колаборативна фільтрація зосереджена на взаємодії користувачів і пошуку схожих патернів у їх поведінці. Вона не залежить від конкретних характеристик об'єктів, а натомість аналізує зв'язки між користувачами, що допомагає виявляти неочевидні рекомендації. Наприклад, якщо двоє користувачів мають схожі вподобання в певній категорії, система може запропонувати одному з них товари, які обрав інший. Проте цей метод вимагає великої бази даних про поведінку, а також є вразливим до проблеми "холодного старту" для нових користувачів.

Гібридні підходи поєднують елементи контентної та колаборативної фільтрації, що дозволяє враховувати як характеристики об'єктів, так і поведінкові взаємодії. Такі методи забезпечують більшу гнучкість і точність у побудові рекомендацій. Наприклад, вони дозволяють долати обмеження, які характерні для окремих підходів, і є універсальними для роботи з різними

типами даних. Гібридні методи особливо актуальні для великих систем, де важливо враховувати різноманітність користувацьких потреб і широкий спектр об'єктів.

Сучасні підходи до управління рекомендаціями все частіше інтегрують передові технології, такі як машинне навчання, глибокі нейронні мережі та алгоритми штучного інтелекту. Ці інструменти дозволяють системам аналізувати великі обсяги даних і знаходити складні зв'язки між різними змінними. Наприклад, алгоритми глибокого навчання можуть враховувати не лише поточну поведінку користувача, але й передбачати його майбутні вподобання, адаптуючись до змін у режимі реального часу.

Крім того, такі сучасні методи забезпечують високу точність і персоналізацію, завдяки чому рекомендації стають більш релевантними. Алгоритми штучного інтелекту дозволяють враховувати не лише явні дані, а й латентні зв'язки, що робить систему більш адаптивною. Це особливо важливо в умовах динамічного середовища, де вподобання користувачів постійно змінюються, а системи мають бути готовими швидко реагувати на ці зміни.

Розвиток технологій також дозволяє інтегрувати механізми пояснення рекомендацій, які сприяють підвищенню довіри користувачів до системи. Такі пояснення допомагають зрозуміти, чому були запропоновані певні варіанти, що робить взаємодію з системою прозорішою та зручнішою. Наприклад, система може пояснити, що певний товар був рекомендований через схожість із раніше вибраними об'єктами або через популярність серед користувачів із подібними вподобаннями.

Отже, управління рекомендаціями – це складний багаторівневий процес, який охоплює різні підходи та методи, що постійно вдосконалюються. Інтеграція сучасних технологій, зокрема алгоритмів машинного навчання та штучного інтелекту, відкриває нові можливості для створення більш ефективних та персоналізованих рекомендацій, які відповідають динамічним

потребам користувачів і бізнесу. У таблиці 1.1 наведено коротку порівняльну характеристику описаних вище підходів.

Таблиця 1.1 – Підходи до побудови рекомендацій

Підхід	Концептуальна мета	Вхідні дані
Коллаборативний	Надати рекомендації на основі спільного підходу, який враховує оцінки та дії як мої, так і моїх однодумців.	Оцінки користувачів, оцінки спільноти
Контентний	Надати рекомендації на основі характеристик контенту, які я віддавав перевагу у своїх попередніх оцінках та діях.	Оцінки користувачів, атрибути елементів
Знання-орієнтований	Надати рекомендації на основі чітко зазначених мною характеристик контенту, який мене цікавить.	Вказівки користувача, атрибути елементів, знання домену

Управління контекстуальними рекомендаціями займає особливе місце в сучасних системах, оскільки врахування додаткової інформації, такої як місце перебування користувача, час доби, тип пристрою або навіть поточна активність, дозволяє значно підвищити якість і релевантність запропонованих рекомендацій. Наприклад, система може запропонувати теплі напої в ранкові години або найближчі ресторани на основі геолокації. Такий підхід забезпечує більш гнучку та персоналізовану взаємодію, що підвищує задоволення користувачів і сприяє їхній лояльності.

Контекстуальні рекомендації також можуть враховувати сезонність, святкові події чи навіть зміну поведінки користувачів у певний період. Це

особливо важливо для електронної комерції та сфери послуг, де пропозиція може змінюватися залежно від зовнішніх чинників. Наприклад, під час новорічних свят рекомендації можуть зосереджуватися на подарунках або святковому меню. Інтеграція контекстуальних факторів дозволяє не лише поліпшити точність рекомендацій, але й формувати довгострокову стратегію взаємодії з користувачем, орієнтуючись на його поточні та майбутні потреби.

Важливим аспектом є також впровадження пояснювальних моделей у рекомендаційні системи. Такі моделі допомагають користувачам зрозуміти, чому певні рекомендації були запропоновані. Наприклад, система може вказати: "Ми рекомендуємо цей товар, тому що інші користувачі з подібними вподобаннями також обрали його" або "Цей фільм обраний на основі ваших попередніх переглядів". Такі пояснення не лише підвищують прозорість системи, але й створюють відчуття контролю у користувача, що значно зміцнює довіру до системи.

Пояснювальні моделі особливо актуальні в сферах, де вибір користувача має важливе значення, наприклад, в освіті, охороні здоров'я або фінансових послугах. У таких випадках користувачі хочуть чітко розуміти логіку прийняття рішення, оскільки це може впливати на їхнє життя або фінансове становище. Наприклад, у системах рекомендацій медичних послуг пояснення, що певний лікар був запропонований на основі його спеціалізації та відгуків інших пацієнтів, робить вибір більш обґрунтованим і прийнятним.

Аналіз підходів до управління рекомендаціями показує, що ефективне рішення рідко базується на використанні лише одного методу. Комбінування кількох підходів, таких як контентна фільтрація, колаборативна фільтрація та врахування контексту, дозволяє створювати більш комплексні та адаптивні системи. Наприклад, гібридні моделі, які поєднують контекстуальні та поведінкові дані, здатні одночасно забезпечити високу точність рекомендацій і зручність для користувачів.

Важливо також враховувати специфіку сфери застосування рекомендаційної системи. Наприклад, в електронній комерції основна увага

може приділятися збільшенню конверсії та середнього чека, тоді як у сфері охорони здоров'я пріоритетом буде надання безпечних і точних рекомендацій, що відповідають медичним стандартам. Такий підхід дозволяє не лише досягати бізнес-цілей, але й забезпечувати високий рівень задоволення потреб користувачів.

Загалом, сучасні рекомендаційні системи мають великий потенціал для адаптації до змінюваних потреб користувачів і динаміки ринку. Використання контекстуальних факторів, пояснювальних моделей та гібридних підходів створює можливість для побудови інноваційних і гнучких систем, що сприяють досягненню як бізнес-цілей, так і підвищенню якості користувацького досвіду.

Системи рекомендацій класифікуються за підходами, що застосовуються для відбору релевантних даних, необхідних користувачам. Серед найбільш поширених методів виділяють два основні: спільно-орієнтовану фільтрацію (Collaborative Filtering, CF) і контентно-орієнтовану фільтрацію (Content-Based Filtering, CBF). Окрім цього, використовується гібридний підхід, який об'єднує обидва зазначені методи, забезпечуючи більшу ефективність.

Спільно-орієнтована фільтрація створює рекомендації, базуючись на аналізі історії дій користувачів або груп із подібною поведінкою. У випадку аналізу групової взаємодії система враховує спільні інтереси, застосовуючи методи аналізу даних, такі як алгоритми кластеризації. Ці алгоритми дозволяють створювати профілі користувачів і групувати їх на основі схожих характеристик. Сильна сторона цього підходу полягає у високій точності рекомендацій, але є і суттєві недоліки, зокрема складність формування рекомендацій для індивідуальних користувачів без відповідних даних.

CF підрозділяється на два основних типи: орієнтовану на користувача (user-based) і орієнтовану на об'єкт (item-based). У першому випадку користувачі з подібними інтересами групуються за допомогою методів пошуку сусідів або інших алгоритмів, які аналізують спільні риси. Основна

проблема такого підходу – це відсутність інформації для нових користувачів або об'єктів (так звана проблема "холодного старту"). У другому випадку система знаходить об'єкти, схожі за характеристиками, що дозволяє уникнути залежності від активності інших користувачів. Проте й тут можуть виникати труднощі з формуванням рекомендацій для нових елементів або повторенням очевидних варіантів.

Контентно-орієнтовані системи формують рекомендації, аналізуючи властивості об'єктів і їхню схожість із тими, що вже зацікавили користувача. Наприклад, якщо користувач переглядає фільми одного жанру чи читає книги одного автора, система визначає схожі елементи на основі цих характеристик. Такий підхід спирається на індивідуальний контент, а не на аналіз дій інших користувачів. Він є зручним для нових користувачів, які ще не встигли взаємодіяти із системою, оскільки дозволяє формувати рекомендації без необхідності накопичення великого обсягу даних.

Гібридна фільтрація комбінує переваги спільно- та контентно-орієнтованих методів. Вона дозволяє підвищити точність рекомендацій і частково вирішити проблему недостатності даних. Такий підхід надає можливість використовувати вагові коефіцієнти для об'єднання результатів різних методів, що забезпечує більш збалансовані рекомендації. Проте гібридні системи є складними у розробці й потребують значних обчислювальних ресурсів.

Системи, засновані на знаннях, працюють з інформацією про користувача та об'єкти, орієнтуючись на специфічні вимоги. Вони часто використовуються там, де потрібна індивідуальна настройка, наприклад, при виборі техніки або складних послуг. Знання предметної області дозволяє системі враховувати такі фактори, як уподобання, цінові межі або конкретні технічні характеристики, що дає змогу формувати точні рекомендації.

Розвиток сучасних алгоритмів, таких як методи кластеризації, байєсові мережі, ланцюги Маркова та факторизаційні підходи, відкриває широкі перспективи для вдосконалення рекомендаційних систем. Зокрема, методи

факторизації даних дозволяють спрощувати та узагальнювати моделі користувачів, що значно знижує складність системи, забезпечуючи при цьому високу точність навіть при роботі з великими обсягами інформації. Використання алгоритмів типу SVD (сингулярного розкладу) дозволяє ефективно аналізувати матриці уподобань, виокремлювати найважливіші фактори, які безпосередньо впливають на вибір користувачів, та оптимізувати рекомендації на основі отриманих даних.

На додачу до цих складних методів, у практиці побудови рекомендаційних систем застосовуються й простіші підходи, такі як базовий аналіз популярності чи використання основних статистичних методик. Ці підходи надають можливість швидко визначати найбільш затребувані товари, послуги або контент, що користуються популярністю серед широкої аудиторії. Проте слід зауважити, що такі методи не враховують індивідуальних переваг окремих користувачів, а тому їх ефективність обмежена в умовах потреби в персоналізації.

Сучасні інноваційні підходи, зокрема засновані на використанні нечіткої логіки, дають змогу гнучко враховувати різні типи невизначеності та будувати рекомендації з урахуванням численних факторів. Наприклад, нечітка логіка дозволяє працювати із ситуаціями, де точні дані відсутні або є неповними, шляхом формування загальних правил і припущень, що наближують процес рекомендації до реальних умов використання. Такий підхід особливо цінний для складних систем, які мають справу з великими масивами даних різного характеру.

Таким чином, сучасні рекомендаційні системи являють собою складні та багатофункціональні механізми, здатні обробляти величезні обсяги даних та використовувати різноманітні методи аналізу. Вони поєднують як прості алгоритми, що забезпечують базові функції, так і складні математичні моделі, які дозволяють адаптуватися до потреб окремих користувачів. Вибір конкретного методу або алгоритму залежить від багатьох чинників, серед яких можна виділити специфічні цілі системи, доступні дані, ресурси для обробки

інформації та технічні обмеження, які можуть впливати на реалізацію. Рекомендаційні системи постійно еволюціонують, адаптуючись до змінних потреб ринку та зростаючого обсягу даних, що робить їх ключовим елементом сучасних цифрових сервісів.

1.3 Аналіз моделей пояснень в інтелектуальних системах

Концепція пояснюваності знаходить застосування в різних наукових дисциплінах, таких як комп'ютерні науки, математика, фізика, інженерія та психологія. Важливо розуміти різницю між поняттями "пояснюваність" та "інтерпретованість". Інтерпретованість — це властивість алгоритму прогнозування в інтелектуальній системі, яка робить цей алгоритм безпосередньо зрозумілим для користувача. Пояснюваність, на відміну від інтерпретованості, є набутою властивістю процесу прийняття рішень, яка зазвичай реалізується зовнішніми засобами. Інтерпретованість розкриває внутрішню структуру моделі машинного навчання і вимагає глибоких знань у галузі штучного інтелекту. Пояснюваність ж фокусується на зовнішніх користувачах системи штучного інтелекту, надаючи їм можливість зрозуміти, які фактори мали найбільший вплив на прийняте рішення. Ці фактори можуть стосуватися як вхідних даних, так і дій, які призводять до формування рішення в інтелектуальній системі. Таким чином, система стає зрозумілою для користувача.

Пояснюваний штучний інтелект (xAI) — це динамічна та швидко розвиваюча галузь досліджень, яка зосереджена на створенні інтелектуальних систем, що є прозорими та зручними для користувачів. Основна мета xAI полягає у вирішенні так званої проблеми "чорної скриньки", яка виникає при використанні моделей машинного навчання. Ця проблема пов'язана з тим, що процес прийняття рішень у таких моделях часто є непрозорим і важким для інтерпретації користувачами. xAI надає користувачам можливість зрозуміти алгоритми прийняття рішень на певному

рівні деталізації та досягнути причини цих рішень, що значно підвищує довіру до результатів інтелектуальних систем.

Довіра є ключовим елементом для збільшення впевненості користувачів у рішеннях системи та забезпечення їх ефективного використання. Формування причинно-наслідкових зв'язків для пояснення рішення системи спрощує сприйняття системи штучного інтелекту, роблячи її більш антропоморфною. Пояснення роблять причинно-наслідкові зв'язки між вхідними даними та рішенням моделі явними, представляючи ці зв'язки у формі, зрозумілій кінцевим користувачам.

Дослідження в галузі пояснюваного штучного інтелекту проводилися в останні роки за програмою DARPA. Ця програма була спрямована на вирішення викликів, пов'язаних з розумінням психології пояснень, розробки методів для конструювання пояснень та розробки методів для оцінки пояснень.

Існуючі підходи до оцінки пояснень недостатньо уваги приділяють різним вимогам користувачів інтелектуальних систем. Розроблені підходи в основному зосереджені на визначенні впливу вхідних даних на рішення, коли інтелектуальна система представлена як "чорна скринька", та на оцінці сприйняття пояснень користувачами. Однак довіра користувачів до процесу прийняття рішень та результатів системи штучного інтелекту залежить від правильності прийнятих рішень, які повинні бути представлені у вигляді бінарної оцінки. Розроблені підходи для оцінки правильності рішень (числова оцінка) визначають відхилення результату у випадку значних відхилень у вхідних даних.

Однак ці підходи в основному зосереджені на обробці зображень і не враховують різниці у вхідних даних, наприклад, для рекомендаційних систем. Тим не менш, така оцінка може бути узагальнена за допомогою Теорії Можливостей, яка дозволяє описувати вхідні дані в імовірнісній формі, незалежно від типу даних. Це вказує на актуальність завдання розробки

можливої оцінки правильності пояснення для користувача системи штучного інтелекту.

Метою роботи є розробка методу формування можливої оцінки правильності пояснень для кінцевого користувача в системі штучного інтелекту. Оцінка правильності пояснень дозволяє підвищити довіру користувача до рішення системи штучного інтелекту та, як наслідок, створити умови для ефективного використання цього рішення. Для досягнення цієї мети вирішуються наступні завдання: структурування пояснень відповідно до потреб користувачів, розробка показника правильності пояснень за допомогою Теорії Можливостей та розробка методу оцінки правильності пояснень за допомогою підходу можливостей.

Пояснюваний штучний інтелект на сьогоднішній день є одним з ключових концептів у розвитку інтелектуальних систем, оскільки наступні фактори є важливими для оцінки пояснень: необхідність обґрунтування рішення системи штучного інтелекту, важливість представлення моделі рішення в "прозорій" формі, покращення точності рішень систем штучного інтелекту та виявлення нових знань про процес прийняття рішень. Обґрунтування рішення поясненням робить модель, що лежить в основі системи штучного інтелекту, зрозумілою та прозорою. Це дозволяє внутрішнім користувачам системи (наприклад, дата-саєнтистам або розробникам) виявляти потенційні недоліки. Система може бути відлагоджена та оптимізована на основі виявлених проблем та можливостей, що покращує точність її рішень.

Ці фактори відображають вплив пояснень на внутрішній механізм системи штучного інтелекту. Такі пояснення є важливими для користувачів, залучених до розробки та покращення інтелектуальної системи. Зовнішні користувачі, які використовують систему для вирішення практичних завдань, повинні отримувати пояснення, щоб отримати нові знання про причини формування рішення та особливості його використання.

Враховуючи різні потреби внутрішніх та зовнішніх користувачів, пояснення повинні розкривати причини дій у процесі прийняття рішень та причини отриманого результату (або простежуваність та реконструктивні пояснення). Пояснення процесу прийняття рішень призначені для спеціалістів у розробці системи штучного інтелекту. Такі пояснення відображають результати, реалізовані в моделі, на якій базується система штучного інтелекту. Пояснення результату призначені для користувачів, які безпосередньо використовують систему. Такі пояснення зазвичай показують вплив вхідних характеристик на отриманий прогноз.

Наприклад, пояснення, яке виділяє характеристики бігуна на зображенні, що обґрунтовує класифікацію цього зображення як "людина біжить". У цьому прикладі різниця між поясненням розробника та поясненням користувача полягає в тому, що модель змогла проаналізувати інші характеристики, які не були суттєвими для класифікації та не вплинули на результат. Інформація про етапи аналізу додаткових характеристик включається в пояснення процесу прийняття рішень в інтелектуальній системі. Іншими словами, різниця між поясненнями типу "Що сталося в системі штучного інтелекту?" та "Чому система штучного інтелекту отримала цей результат?" полягає в використанні різних моделей. У першому випадку пояснення повинно використовувати модель рішення (або ту, що близька до неї за точністю). У другому випадку використовується спрощена модель системи штучного інтелекту, яка відображає лише ключові фактори, що впливають на рішення системи. Наприклад, дерева рішень, правила виводу тощо.

Пояснення для розробників та користувачів мають різні вимоги до точності та обґрунтування рішення. Пояснення для розробників повинні бути більш деталізованими та враховувати вплив як важливих, так і неважливих факторів. Іншими словами, ці пояснення повинні забезпечувати більшу точність та представляти систему штучного інтелекту як "білу" або "сіру" скриньку. Пояснення для користувачів повинні відображати основні причини

рішення та забезпечувати виявлення нових знань для практичного застосування цих рішень.

Користувачі пояснень в системах штучного інтелекту — це зовнішні та внутрішні спеціалісти, які розробляють та використовують ці системи. Ціх користувачів можна поділити на дві групи: спеціалісти в системах штучного інтелекту та спеціалісти в галузі, в якій використовується така система.

До першої групи входять власники систем штучного інтелекту, розробники систем та розробники моделей рішень. До другої групи входять експерти в галузі, кінцеві користувачі інтелектуальної системи та представники регулюючих органів.

Користувачі першої групи повинні отримувати пояснення того, як система працює на різних рівнях деталізації. Власники визначають можливості та режими роботи системи штучного інтелекту.

Користувачам штучного інтелекту необхідно надавати інформацію на високому рівні, яка пояснює основи роботи системи та принципи прийняття рішень.

Це включає опис підходів, які використовуються для забезпечення підтримки в ухваленні рішень, управління розвитком системи, а також фінансовими витратами. Розробники, які працюють над створенням та вдосконаленням системи, охоплюють такі аспекти, як інтерфейс, бази даних чи знань та інтелектуальний модуль. Їм часто не потрібна глибока експертиза у предметній галузі, адже вони використовують пояснення, щоб знаходити та виправляти помилки, аналізуючи всі етапи обробки даних.

Створення та вдосконалення моделей прийняття рішень — це завдання спеціалістів, які працюють над ядром системи. Їхня робота полягає у створенні, навчанні та тестуванні моделі, яка забезпечує класифікацію чи прогнозування. Вони визначають тип моделі, проводять навчання, але не завжди володіють спеціальними знаннями у сфері застосування.

Інша категорія користувачів — це експерти у відповідній галузі, які використовують систему для перевірки її відповідності практичним вимогам.

Їхня мета — переконатися, що система працює належним чином, але вони зазвичай не мають навичок створення моделей машинного навчання. Кінцеві користувачі використовують систему для вирішення прикладних задач, маючи лише базове уявлення про її роботу. Їм важливо розуміти, як саме система приходить до певних рішень, щоб довіряти її результатам.

Регулятори аналізують роботу штучного інтелекту для відповідності нормативним вимогам. Наприклад, якщо навчання системи базувалося на упереджених даних, її рішення можуть бути дискримінаційними, як у випадку автоматизованого відбору персоналу, де враховуються фактори, що не впливають на продуктивність, наприклад вік чи стать.

Пояснення системи повинні відображати два аспекти: системний і користувацький. Системні пояснення розкривають причинно-наслідкові зв'язки на різних етапах прийняття рішень. Вони орієнтовані на розробників, які прагнуть впливати на функціонування системи. Користувацькі пояснення фокусуються на роз'ясненні, чому система ухвалила те чи інше рішення, його відповідності практичним потребам і стандартам галузі. Такі пояснення повинні бути простими, точними та зрозумілими для людей, які не мають технічних знань.

Для внутрішніх користувачів пояснення є детальними, з акцентом на точність та прозорість моделі. Для зовнішніх — акцент робиться на зрозумілості результату та його відповідності контексту. Це дозволяє покращити довіру до системи та її рішень, враховуючи нормативні обмеження та потреби конкретної галузі.

Під час оцінки пояснень у системах штучного інтелекту важливо враховувати різницю між системним і користувацьким підходами. Системний підхід дозволяє розкрити внутрішній механізм роботи інтелектуальної системи, що може сприяти уточненню її чутливості та точності. У користувацькому аспекті основний акцент робиться на коректності пояснень, які мають бути зрозумілими та відповідати запитам користувачів.

Запропонований метод оцінки коректності враховує використання альтернативних вхідних даних для отримання пояснень. Наприклад, у випадку рекомендаційної системи, яка пропонує ноутбук із певними характеристиками (процесор, пам'ять, жорсткий диск), пояснення може вказувати на модель процесора як основну причину вибору. Ця модель процесора є частиною певного набору можливих варіантів, і вибір залежить від ймовірності її обрання порівняно з іншими моделями, представленими у системі.

Ймовірність вибору конкретного процесора враховує популярність моделей інших виробників, представлених у системі. Якщо якась інша модель є дуже популярною, потреба у виборі рекомендованого процесора знижується. Для того щоб пояснення було коректним, ймовірність вибору альтернативного процесора має бути меншою за 0,5. У такому разі пояснення вважається обґрунтованим.

Метод оцінки коректності пояснення включає кілька етапів. Обчислення ймовірності використання вхідних значень. Розрахунок ймовірності вибору альтернативних значень. Визначення необхідності вибору конкретного значення та перевірка умов його правильності.

Результати показують, що розробникам інтелектуальних систем важливо забезпечити повний або частковий ланцюжок пояснень рішень. Для кінцевих користувачів акцент робиться на поясненнях, що демонструють зв'язок між вхідними даними та кінцевим результатом.

Важливо відзначити, що для внутрішніх користувачів, які займаються розробкою та вдосконаленням системи, слід застосовувати оцінку точності пояснень, тоді як для зовнішніх користувачів доцільно використовувати оцінку коректності. Запропонований метод дозволяє порівняти значення вхідних змінних, що використовуються в поясненні, з ймовірністю вибору альтернативних значень.

Це забезпечує перевірку необхідності використання конкретного значення та гарантує правильність пояснень.

У таблиці 1.2 наведено приклади методів побудови моделей пояснень у рекомендаційних системах.

Таблиця 1.2 – Моделі пояснень у xAi

Модель	Особливості
Каузальна	Застосовуються причинно-наслідкові зв'язки. (Каузальні залежності). Забезпечується можливість пояснити як отриманий результат роботи інтелектуальної системи, так і сам процес його досягнення.
Статистична	Застосовуються шаблони та залежності, виявлені через аналіз даних інтелектуальною системою. Основний акцент зроблено на поясненні рішень системи штучного інтелекту.
Семантична	Застосовуються знання з предметної області, включаючи часові аспекти, для пояснення процесу прийняття рішень і результатів роботи інтелектуальної системи. Передбачена можливість адаптації до рівня обізнаності користувача.
Концептуальна	Застосовуються знання про загальні принципи, моделі, технології та процеси прийняття рішень у певній предметній області. Забезпечується можливість створення узагальненого високорівневого пояснення, яке підходить для різних контекстів цієї області. Також підтримується деталізація пояснень із використанням причинно-наслідкового, статистичного та семантичного підходів.

Можливі моделі пояснень можуть бути класифіковані за різними критеріями, зокрема, за типами даних, на яких базується пояснення, і за рівнем деталізації пояснень. Одним з типів моделей пояснень є пояснення на основі контенту, коли основна увага приділяється характеристикам об'єкта, який рекомендується. Наприклад, якщо користувач отримує рекомендацію фільму, пояснення може містити інформацію про жанр, акторів, режисера або подібні фільми, які він раніше переглядав.

Ще одним типом є колаборативні пояснення, в яких інформація генерується на основі поведінки інших користувачів з подібними вподобаннями. Наприклад, пояснення може бути таким: "Цей товар рекомендовано, оскільки його також придбали інші користувачі з подібними інтересами".

Гібридні пояснення — це комбінація різних підходів, що використовують як контентні, так і колаборативні фактори. Вони можуть надавати більш точне уявлення про причини рекомендації, поєднуючи інформацію про характеристики об'єкта та поведінку інших користувачів.

Також існують пояснення за допомогою моделей інтерпретації, які використовуються в складних алгоритмах машинного навчання чи глибоких нейронних мережах. Наприклад, методи, такі як LIME (Local Interpretable Model-agnostic Explanations), дозволяють пояснити результати складних моделей у вигляді зрозумілих для користувача причин.

Останнім типом є пояснення на основі контексту, коли враховуються додаткові фактори, такі як час, місце або пристрій, з якого користувач звертається до системи. Це дозволяє надавати пояснення, що враховують змінні обставини, в яких користувач взаємодіє з платформою.

Ці моделі пояснень важливі для підвищення прозорості системи, створення довіри користувачів і забезпечення оптимальної взаємодії з платформою. Вибір моделі пояснення залежить від складності системи, обсягу даних та типу взаємодії, яку вона підтримує.

Методи генерації можливісних моделей пояснень в рекомендаційних системах можуть значно варіюватися залежно від обраної стратегії та інструментів, що використовуються для їх побудови. Основним завданням цих методів є створення таких пояснень, які були б зрозумілі та корисні для користувачів, дозволяючи їм краще розуміти, чому система запропонувала ту чи іншу рекомендацію.

Один із найбільш популярних методів — це контентний підхід, де пояснення ґрунтуються на характеристиках об'єкта, який рекомендується. Такий метод зазвичай використовується в системах, де є велика кількість структурованих даних про продукти або послуги. Для фільмів це можуть бути жанри, актори, режисери або рік випуску, для товарів — характеристики, типи та категорії.

Інший метод — колаборативний підхід, де пояснення базуються на поведінці інших користувачів. Наприклад, якщо інші користувачі з подібними вподобаннями купили або переглянули цей продукт, система може пояснити це таким чином: "Цей товар був рекомендований через схожість ваших вподобань з іншими покупцями."

Методи машинного навчання та глибоких нейронних мереж використовуються для складних, адаптивних рекомендацій, де можуть застосовуватися більш складні алгоритми для створення пояснень. Алгоритми, такі як LIME (Local Interpretable Model-agnostic Explanations), допомагають забезпечити інтерпретованість навіть для складних моделей. Ці методи можуть формувати пояснення на основі змін, які впливають на результат рекомендації.

Також популярним є використання гібридних підходів, які комбінують кілька методів пояснень, щоб забезпечити більш точне і комплексне розуміння причин рекомендацій. Наприклад, система може одночасно враховувати як контентні характеристики, так і взаємодії інших користувачів, забезпечуючи більш багатогранне пояснення рекомендаційної системи, доступних даних, цілей розробника та очікувань користувачів. Наприклад, у системах для

електронної комерції, де важлива швидкість рекомендацій і їхня пояснюваність, можуть використовуватися простіші методи, доповнені базовими характеристиками контенту. Водночас у системах для освітніх платформ або медичних застосунків перевага надається більш складним алгоритмам, які забезпечують глибоке і точне пояснення.

Таким чином, сучасні рекомендаційні системи прагнуть досягти балансу між точністю, адаптивністю та прозорістю. Застосування гібридних підходів та таких алгоритмів, як LIME, дозволяє не тільки формувати релевантні рекомендації, але й надавати зрозумілі пояснення, які підвищують довіру користувачів. Це робить рекомендаційні системи не лише корисним, але й комфортним інструментом для користувачів, адаптованим до їхніх очікувань і потреб.

Контентний підхід до генерації пояснень у рекомендаційних системах базується на використанні характеристик самого об'єкта, який рекомендується. У цьому методі пояснення будуються на основі вивчення контенту товару, послуги чи іншого предмета рекомендацій, що дозволяє створити більш прозорі й зрозумілі пояснення для кінцевих користувачів.

Основна ідея контентного підходу полягає в тому, що система використовує характеристику самих об'єктів для того, щоб пояснити, чому вони були рекомендовані користувачу. Для цього система звертається до вхідних даних про об'єкти (товари, фільми, музичні треки і т.д.) і здійснює їх порівняння з попередніми вподобаннями користувача або іншими даними про його поведінку. Наприклад, для фільмів це можуть бути жанри, актори, режисери або рік випуску; для товарів — категорії, характеристики та бренди. Якщо користувач раніше вибирав або оцінював фільми з подібними характеристиками, система може пояснити рекомендацію через ці спільні риси.

Переваги контентного підходу включають простоту та зрозумілість. Пояснення базуються на характеристиках об'єктів, які зазвичай є доступними і зрозумілими для користувачів, що робить метод інтуїтивно зрозумілим. Крім

того, цей підхід дозволяє створювати персоналізовані рекомендації, враховуючи інтереси та вподобання користувача, що безпосередньо відображаються в поясненнях. Метод також є гнучким, оскільки його можна застосовувати до різних типів даних — від текстових до числових характеристик, що робить його універсальним.

Однак контентний підхід має і свої недоліки. Він не враховує контекстуальних факторів або взаємодії між різними користувачами, що може обмежувати його ефективність у складних рекомендаційних системах. Крім того, цей метод залежить від характеристик об'єктів, і якщо ці характеристики недостатньо детальні або неоднозначні, це може знизити точність рекомендацій і пояснень. Іншим недоліком є те, що метод не враховує нових вподобань користувачів, що може бути проблемою для тих, хто не має великої історії взаємодії з системою (так звана проблема "холодного старту").

Контентний підхід є одним із ключових інструментів, що активно застосовується у рекомендаційних системах для фільмів, книг, товарів на онлайн-платформах та інших об'єктів. Він базується на аналізі конкретних характеристик об'єктів і використовується для формування зрозумілих та прозорих рекомендацій. Наприклад, в електронній комерції контентний підхід дозволяє пропонувати товари, схожі за категорією, брендом чи іншими параметрами до тих, які користувач вже придбав, пояснюючи вибір через спільні ознаки.

Цей підхід є ефективним для створення простих і зрозумілих рекомендацій, особливо коли необхідно швидко обґрунтувати вибір. Він дозволяє користувачам краще зрозуміти логіку роботи системи та довіряти її рішенням. Однак у випадках, коли об'єкти складніші або взаємодії між ними неочевидні, контентний підхід може бути недостатнім. Для підвищення точності та релевантності рекомендацій його часто комбінують з іншими методами, такими як колаборативне фільтрування, що враховує поведінку інших користувачів, або алгоритми глибокого навчання, які здатні виявляти приховані зв'язки та складні патерни в даних.

1.4 Постановка задачі дослідження

Існуючі методи генерації можливісних моделей пояснень у рекомендаційних системах базуються на повному аналізі даних, що використовуються для створення рекомендацій. У процесі цього аналізу застосовуються різноманітні алгоритми, які можуть працювати як з великими наборами структурованих даних, так і з більш складними, неструктурованими даними, що базуються на поведінці користувачів. Це дозволяє не лише надавати персоналізовані рекомендації, але й забезпечувати їх пояснення для кінцевих користувачів.

Проте існуючі методи генерації пояснень не завжди враховують потреби користувачів у зрозумілості та прозорості, особливо в складних системах, де може бути велика кількість взаємодій між різними факторами. У такому випадку методи генерації пояснень можуть бути адаптовані для врахування попередньо визначених правил або моделей, що дозволяють зменшити складність обробки даних і забезпечити більш ефективне пояснення рекомендацій.

Об'єктом дослідження є процес побудови пояснень.

Предметом роботи є можливісні моделі пояснень.

Метою даної роботи є удосконалення методів генерації пояснень у рекомендаційних системах з метою забезпечення їх зрозумілості для користувачів, зменшення складності алгоритмів пояснень та поліпшення точності рекомендацій за рахунок використання попередньо визначених моделей та стратегій пояснень.

2 МОЖЛИВІСНА МОДЕЛЬ ПОЯСНЕНЬ В РЕКОМЕНДАЦІЙНІЙ СИСТЕМІ

2.1 Розробка можливісного підходу до побудови пояснень в рекомендаційних системах

Теоретико-ймовірнісні методи широко застосовуються для моделювання багатьох аспектів невизначеності та нечіткості, що виникають через обмеженість або недостовірність знань. Однак їх ефективність значно знижується для процесів, в яких основну роль відіграють саме нечіткість і невизначеність. Це особливо актуально для моделювання складних фізичних, соціальних та економічних систем, де неможливо проводити статистичні випробування. Відомо, що у теорії ймовірностей подія та її протилежність характеризуються однією мірою ймовірності, що виражається рівністю що зображена на формулі 2.1:

$$P(A) + P(\neg A) = 1 \quad (2.1)$$

Натомість, у теорії можливостей для взаємопротилежних подій має місце нерівність

$$\Pi(A) + \Pi(\neg A) \geq 1, \quad (2.2)$$

де Π — міра можливості. Це означає, що теорія можливостей дозволяє більш гнучко описувати невизначеність, що виникає внаслідок нечітких або суб'єктивних даних.

Важливо зазначити, що одна лише міра можливості не є достатньою для адекватного опису експериментів, пов'язаних із суб'єктивними судженнями, тому було запропоновано використовувати також міру необхідності. Міра необхідності вводиться як додатковий елемент для точнішого опису явищ,

дозволяючи створювати більш коректну структуру для знань про досліджувані системи.

Оскільки в класичній ймовірності події та їх заперечення мають єдину ймовірність, у теорії можливостей ці поняття характеризуються двома різними мірами — можливості та необхідності. Для цього було розроблено математичне обґрунтування, згідно з яким міра можливості $\Pi(x)$ для події x визначається як

$$\Pi(x) = \sup_{\omega \in F(x)} \mu(\omega), \quad (2.3)$$

де μ — функція належності нечіткої множини. Міра необхідності $N(x)$ визначається через міру можливості як

$$N(x) = 1 - \Pi(\neg x) \quad (2.4)$$

що забезпечує необхідну структуру для подій з нечіткими або неповними даними.

Завдяки цьому підходу можна побудувати узагальнену модель, яка включає як міру можливості, так і міру необхідності. Ця модель дозволяє коректно моделювати складні системи з нечіткими або суб'єктивними характеристиками, що є важливим для створення пояснень у рекомендаційних системах.

Такий підхід дозволяє враховувати не лише ймовірності подій, а й їх потенційну необхідність у контексті конкретних ситуацій. Модель здатна забезпечити більш точне і багатогранне представлення невизначеності, що виникає під час прийняття рішень у рекомендаційних системах, підвищуючи якість пояснень для кінцевих користувачів. Це дозволяє створювати більш адаптивні та інтуїтивно зрозумілі пояснення, які не лише відображають ймовірні сценарії, але й демонструють важливість кожної рекомендації у конкретному контексті, що підвищує довіру користувачів до системи.

2.2 Удосконалена можливісна модель пояснень

Сучасні інтелектуальні системи активно використовуються для підтримки прийняття рішень у різноманітних сферах, таких як пошук інформації, страхування, медицина, банківські та військові операції. Використання складних непрозорих алгоритмів, що базуються на методах машинного навчання, дозволяє отримувати складні результати, які можуть бути не зовсім зрозумілими для користувачів цих систем. Непрозорість результатів може викликати сумніви та недовіру до рішень, що приймаються такими системами, що в свою чергу обмежує їх практичне застосування. Тому важливою умовою широкого використання інтелектуальних систем є прозорість та зрозумілість їх рішень.

Для забезпечення зрозумілості рішень, які приймаються штучними інтелектами, використовуються пояснення. Пояснення можуть бути розглянуті в двох контекстах: як кінцевий продукт та як процес. Пояснення як кінцевий продукт надає користувачеві інформацію, яка допомагає йому зрозуміти, як була прийнята конкретна рішення інтелектуальною системою. Це пояснення встановлює зв'язки між вхідною інформацією та виходом системи, при цьому внутрішні стани системи можуть бути неповними або відсутніми. Завдання побудови пояснення як кінцевого продукту полягає в ідентифікації каузальних зв'язків між вхідними параметрами і результатом, що був отриманий. Це завдання вирішується в умовах невизначеності щодо конкретної реалізації процесу прийняття рішення в інтелектуальній системі.

Пояснення як процес містить послідовність кроків, що обґрунтовують шлях, яким система прийшла до своєї поточної рішення. Цей підхід передбачає наявність інформації про внутрішні стани інтелектуальної системи, що дозволяє детально описати, як рішення було прийнято. У загальному випадку, пояснення як процес не завжди орієнтоване на просто обґрунтування кінцевого результату, а зосереджується на з'ясуванні залежностей між діями, що призвели до прийняття рішення.

Таким чином, пояснення повинні встановлювати каузальні зв'язки між вхідними даними та виходом системи, а також представити ці залежності навіть в умовах неповної інформації щодо внутрішнього стану системи в процесі прийняття рішення. Сучасні підходи до побудови пояснень розроблені в рамках програми Explainable Artificial Intelligence, яка зосереджена на вирішенні двох основних завдань: моделювання сприйняття пояснень людиною та побудова самих пояснень.

Розв'язання першої задачі передбачає дослідження особливостей та принципів побудови пояснень, які використовуються людиною у процесі пізнання навколишнього світу. В рамках другої задачі, на основі раніше визначених принципів, розробляються методи побудови пояснень. Пояснення можуть базуватися на безпосередньому інтерпретуванні процесу прийняття рішення або на представленні темпоральних та каузальних залежностей, що встановлюють зв'язок між вхідними даними та результатом, а також забезпечують порівняння з альтернативними варіантами. Однак існуючі підходи часто не приділяють достатньої уваги побудові каузальних залежностей за умов невизначеності та багатоваріантності можливих рішень, що може призводити до складності пояснення отриманих результатів.

Особливо важливим є вирішення задачі побудови каузальних зв'язків, які враховують вплив кожної вхідної змінної на результат, при представленні інтелектуальної системи як чорного ящика, де відсутня повна інформація про внутрішні стани системи. Це дозволяє краще зрозуміти, як кожна змінна може вплинути на кінцевий результат, і таким чином зробити пояснення більш точним і доступним для користувача.

Метою статті є побудова моделі каузальних зв'язків для пояснень в умовах невизначеності щодо станів інтелектуальної системи, яка представлена як чорний ящик. Для досягнення цієї мети необхідно вирішити ряд задач: створити структуру пояснення, враховуючи особливості когнітивної діяльності людини, сформулювати умови для каузальної залежності,

використовуючи теорію можливостей, а також розробити модель каузальної залежності для однієї вхідної змінної, яка враховує невизначеність.

Моделювання пояснень у контексті невизначеності ґрунтується на виділенні їх властивостей як елементу когнітивної діяльності людини. Пояснення є невід'ємною частиною процесу пізнання, який включає три основні фази: отримання та сприйняття інформації, обробка та зберігання знань, а також використання знань для прийняття рішень. Пояснення допомагають людині зрозуміти та організувати отриману інформацію, зв'язати її з попереднім досвідом і знаннями, що є важливим для формування нових знань і прийняття обґрунтованих рішень.

Пояснення, як частина пізнавального процесу, створює умови для осмислення навколишнього світу, формує знання та поведінку людини. Вони є ключовим інструментом для відкриття нових знань і розуміння об'єктів чи явищ у певній предметній області. Дослідження в когнітивній психології виявляють зв'язок між пізнанням і поясненнями в двох основних аспектах: концептуальному та тлумачному. У концептуальному аспекті пояснення функціонують як зв'язок між вхідними даними та базовими знаннями людини про предметну область, в той час як тлумачний аспект включає порівняння властивостей об'єктів і їх категоризацію, що дозволяє вибирати найбільш відповідні пояснення.

Пояснення в когнітивному процесі відіграють важливу роль в навчанні та міркуваннях, створюючи основу для побудови концепцій і подальшого розуміння поточної предметної області.

Розглядаючи сприйняття концепцій людьми, можна стверджувати, що для повного розуміння предметів і явищ важливою умовою є відповідність концепцій базовим знанням, які люди мають про навколишній світ. Така відповідність дозволяє обґрунтувати кожен концепцію за допомогою одного з можливих пояснень, що створюються на основі фонових знань. Розвиток цих концепцій неможливий без створення та зміни системи знань людини. У цьому

контексті важливо відзначити, що розширення та реконструкція знань потребують постійного уточнення базових елементів знань.

Другий аспект пізнання, пов'язаний із "тлумачним" мисленням, фокусується на побудові каузальних зв'язків під час порівняння властивостей вхідних об'єктів для категоризації знань. Це дозволяє більш ефективно групувати і класифікувати об'єкти відповідно до їх характерних ознак, що допомагає створювати загальні концепції, з урахуванням причинно-наслідкових зв'язків. Пояснення, побудоване на основі причинно-наслідкових зв'язків, допомагає з'ясувати типові, різноманітні й схожі властивості різних категорій.

У цьому контексті можна зробити висновок, що пояснення, яке включає причинно-наслідкові зв'язки, надає можливість встановити залежності між елементами знань, навіть якщо частина інформації про предметну область залишається невизначеною. У таких випадках пояснення дозволяє знайти причини результатів, що стають об'єктами аналізу людиною. Це дозволяє відповісти на питання типу «як?» чи «чому?» для обґрунтування отриманого результату. Причинно-наслідкові зв'язки можуть бути представлені в вигляді логічних схем або через аналіз детальних суджень.

Крім того, пояснення можна розглядати як результат когнітивної діяльності, який можна оцінити людиною, або як сам процес цієї діяльності. Пояснення як результат — це формулювання причин для отриманого рішення, що має практичну цінність для людини, яка оцінює його достовірність. Пояснення як процес передбачає послідовність кроків у когнітивній діяльності, яка веде до формулювання результату. В цьому випадку одне або кілька пояснень можуть бути отримані на основі когнітивних процесів.

Задача формулювання пояснень полягає в створенні каузальної залежності між вхідною інформацією, знанням людини та прийнятим рішенням. Це дозволяє створити основи для тлумачення результатів. В умовах невизначеності важливо визначити необхідні й достатні умови для побудови

таких зв'язків. Моделювання пояснень в умовах невизначеності полягає в інтеграції різних аспектів когнітивного процесу.

Пояснення, що стосується результатів роботи інтелектуальних систем, є узагальненням послідовності причинно-наслідкових зв'язків, які описують процес отримання рішення. Воно зв'язує властивості вхідних даних із результатами, отриманими в інтелектуальній системі. Пояснення визначає, в якій мірі кожне значення вхідної змінної впливає на отримане рішення.

Нехай $X = \{x_1, x_2, \dots, x_i\}$ — множина можливих значень вхідної змінної. Оскільки в умовах чорного ящика інтелектуальної системи немає доступу до внутрішніх станів, вплив кожного з можливих значень на результат можна представити через оцінку ймовірності $\pi(x_i)$, що характеризує ймовірність вибору певного значення змінної x_i для отримання відповідного результату.

$$0 \leq \pi(x_i) \leq 1, \quad \sum_{i=1}^n \pi(x_i) = 1, \quad (2.4)$$

де X – типи та покоління процесорів;

$\pi(x_i)$ – буде ймовірністю того, що система вибере ноутбук із визначеним процесором x_i .

Ця оцінка $\pi(x_i)$ відображає ймовірність того, що інтелектуальна система вибере значення x_i для подальшого використання, в залежності від його впливу на результат. Зокрема, у випадку рекомендаційної системи для вибору ноутбука.

Якщо в системі спостерігається повторюваність певного процесора серед тих, що вже були обрані в інших ноутбуках, то пояснення може орієнтуватися на модель процесора, що є найпоширенішим у виборах інших користувачів.

Пояснення, як механізм когнітивної діяльності, може спиратися на відмінності у властивостях елементів певної категорії, наприклад, категорії "процесори". В контексті рекомендаційної системи, пояснення ґрунтується на аналізі відмінностей між

процесорами, які використовувалися у раніше придбаних комп'ютерах, і цьому процесу може бути надано форму через множину змінних X_i , яка містить покоління та моделі процесорів.

У разі, коли користувач має додаткові структуровані знання про елементи комп'ютерної техніки, пояснення може враховувати концептуальний аспект. Наприклад, якщо в рекомендованому списку з'являється комп'ютер з процесором i7 11 покоління, і користувач знає, що цей процесор має високу потужність та є доступним за помірною ціною, тоді пояснення можна побудувати на основі концепції прагматичного вибору: "потужний комп'ютер за розумну ціну".

Цей підхід передбачає використання множини значень $\{x_i\}$ для формування пояснень і забезпечує багатогранний погляд на можливості, які визначаються залежностями між вхідними змінними та результатами, отриманими системою.

Множина вхідних змінних складається з підмножин X_j , які визначають можливі значення змінних на різних інтервалах часу T_j :

$$X = \{X_j : X_j \subseteq X, \exists t_j \in T_j, \forall j\}, \quad (2.5)$$

де T_j — інтервали часу для кожної підмножини X_j .

Інтервали часу можуть перекриватися, і для одного значення змінної x_i можуть існувати кілька можливих інтервалів часу.

Оцінка можливості для кожної підмножини. Для кожної підмножини X_j визначається можливість Π_j , яка є верхньою гранню для значень $\pi(x_i)$ в межах цієї підмножини:

$$\Pi_j = \sup\{\pi(x_i) : x_i \in X_j\} \quad (2.6)$$

Можливісна оцінка Π для множини X визначається як відображення всіх підмножин X_j на інтервал $[0,1]$:

$$\Pi : X_j \rightarrow [0, 1] \quad (2.7)$$

Для наявності каузальної залежності між значенням x_j і отриманим результатом, достатня умова полягає в тому, щоб значення $\pi(x_j)$ на поточному інтервалі часу T_j було максимальним:

$$\pi(x_j) = \max_i \{\pi(x_i)\}, \quad x_j \in X_j \quad (2.8)$$

Необхідна умова для каузальної залежності включає оцінку довіри до того, як часто певне значення змінної використовувалося для отримання результату. Це можна виміряти за допомогою оцінки необхідності N , яка визначає, наскільки важливою є певна змінна для результату. Оцінка N для множини можливих підмножин X_j має вигляд:

$$N : X_j \rightarrow [0, 1] \quad (2.9)$$

Ця оцінка відображає частоту використання значень змінної для отримання відповідного результату, і на її основі можна визначити, чи є ця змінна значущою для результату. Розроблений підхід до генерації можливісних моделей пояснень у рекомендаційних системах спрямований на інтеграцію міри можливості та необхідності для формулювання більш точних і надійних пояснень результатів. Використовуючи принципи каузальної залежності, цей підхід дозволяє створювати обґрунтовані висновки про зв'язки між вхідними змінними та результатами в інтелектуальних системах. За допомогою необхідної умови визначається рівень довіри до вхідної змінної, що є критично важливим для отримання результату. У той же час, достатня умова визначає найімовірніший варіант значення змінної, яке, ймовірно, спричинить отриманий результат. Це дозволяє не тільки точно оцінювати вплив окремих факторів, але й формувати більш стійкі та обґрунтовані пояснення в системах. Схема розробленого підходу зображена на рисунку 2.1.

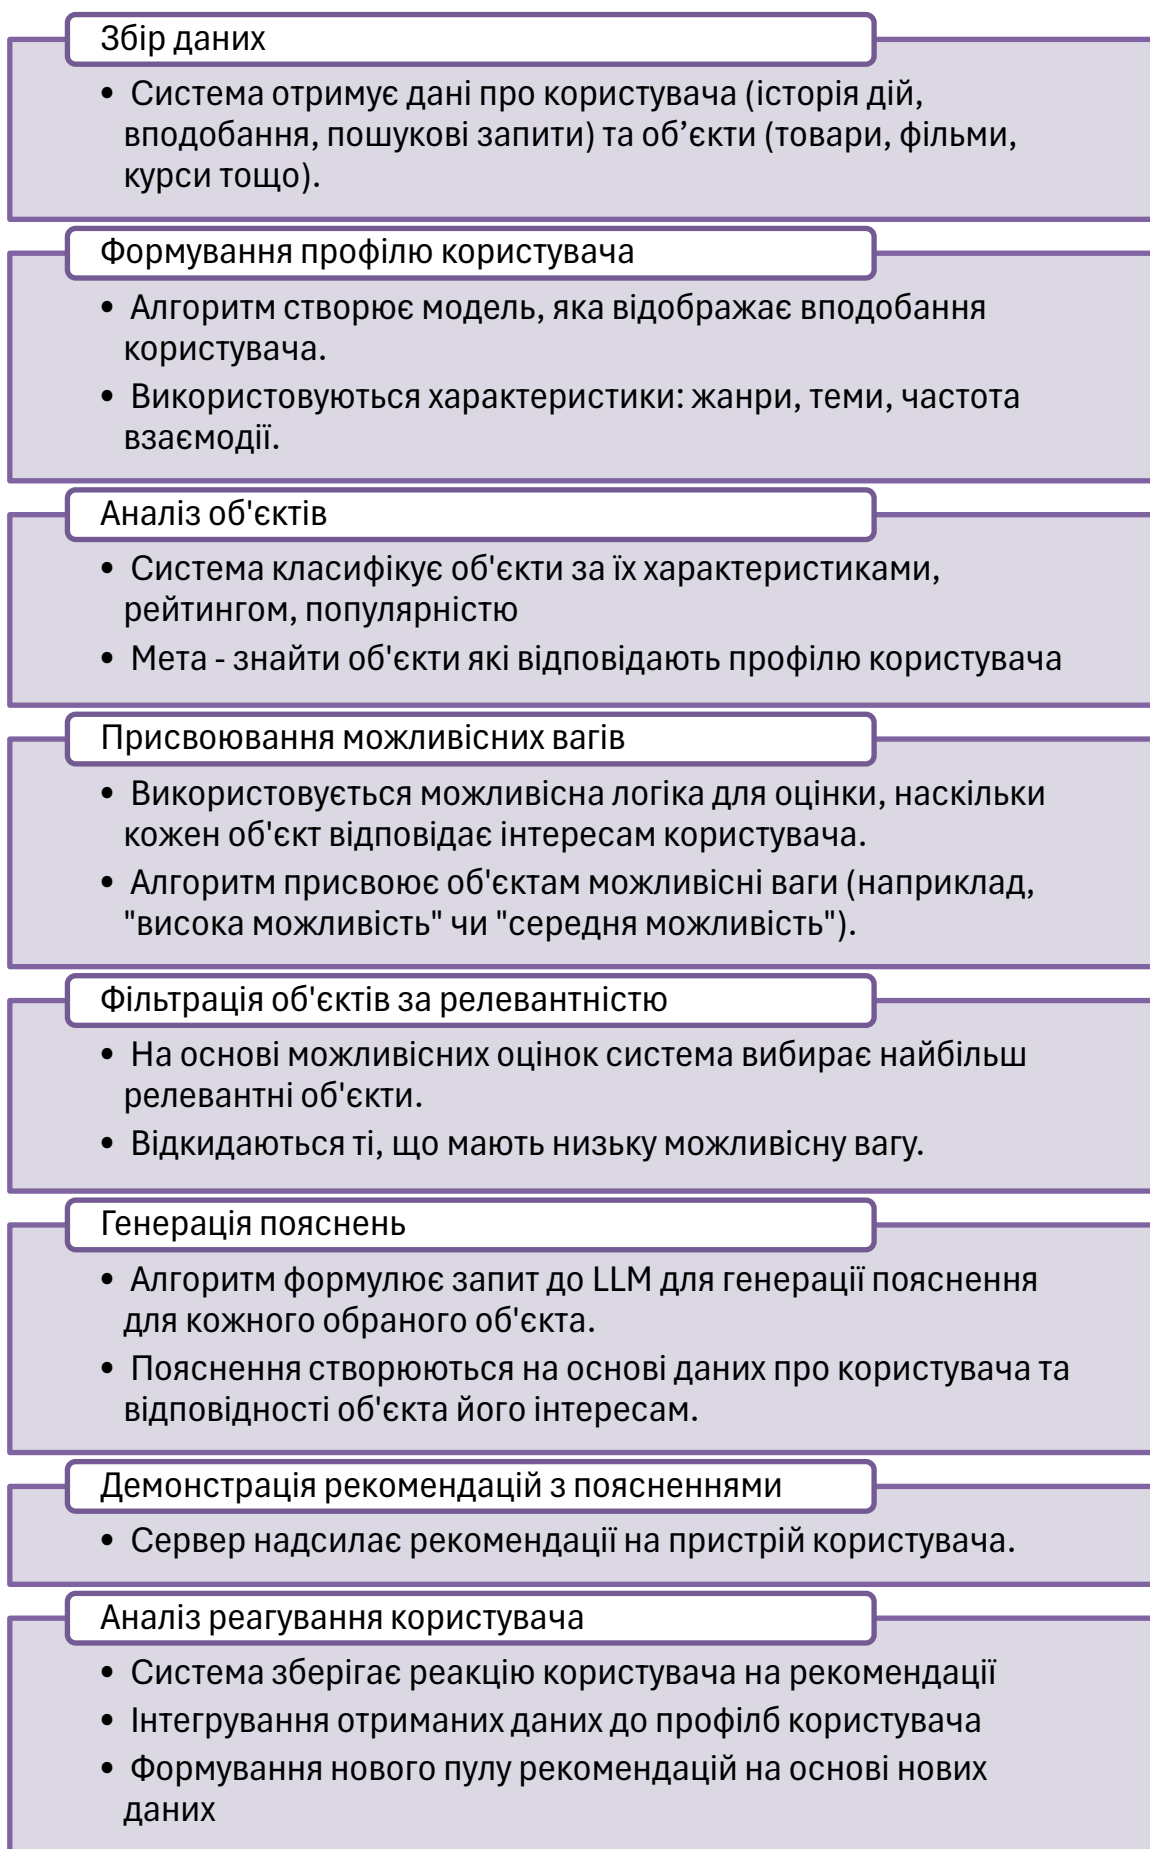


Рисунок 2.1 – Схема моделі генерації можливісної пояснень

Завдяки цьому підходу досягнуто можливості побудови більш комплексних каузальних моделей, що дозволяє враховувати різні аспекти та параметри, які можуть впливати на результат. Особливо важливою є здатність моделі працювати з неповними або нечіткими знаннями про систему, що дає їй можливість адаптуватися до різних сценаріїв. Це забезпечує кращу точність у формулюванні рекомендацій та пояснень, дозволяючи користувачам отримувати більш точні й зрозумілі висновки навіть в умовах складної та нестабільної інформації. Подальша розробка цього підходу включає можливість визначення каузальних зв'язків для декількох вхідних змінних одночасно, що дозволить створювати більш багатовимірні та детальні моделі пояснень.

У майбутньому цей підхід можна адаптувати для більш складних рекомендаційних систем, що працюють з великими обсягами даних і багатьма змінними. Інтеграція багатьох вхідних змінних в модель дозволить створити більш детальну картину взаємозв'язків між різними факторами, що впливають на результат. Це також відкриває можливості для використання в системах, де користувачі надають різні типи даних, наприклад, особисті уподобання або поведінкові патерни. Подальший розвиток може включати врахування динамічних змін у системі, що дозволить моделі адаптуватися до змінюваних умов і пропонувати пояснення в реальному часі, з урахуванням останніх даних. Це забезпечить більш гнучкий підхід до рекомендацій і пояснень, який зможе краще відповідати потребам користувачів, забезпечуючи їм більш точні та зрозумілі інтерпретації результатів.

3 РОЗРОБКА ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ПОБУДОВИ ПОЯСНЕНЬ НА ОСНОВІ МОЖЛИВИСНОЇ МОДЕЛІ

Опис процесної моделі IDEF0, розробленої для можливісної моделі пояснень у рекомендаційних системах, допомагає зрозуміти ключові етапи створення пояснень, структуровано організувати всі необхідні процеси, а також визначити ресурси, які знадобляться на кожному етапі. Такий підхід дозволяє отримати чітке бачення як для розробників, так і для дослідників, що займаються цим проектом. Модель зображена на рисунку 3.1 не тільки описує етапи побудови пояснень, але й дозволяє спроектувати програмне рішення на її основі.

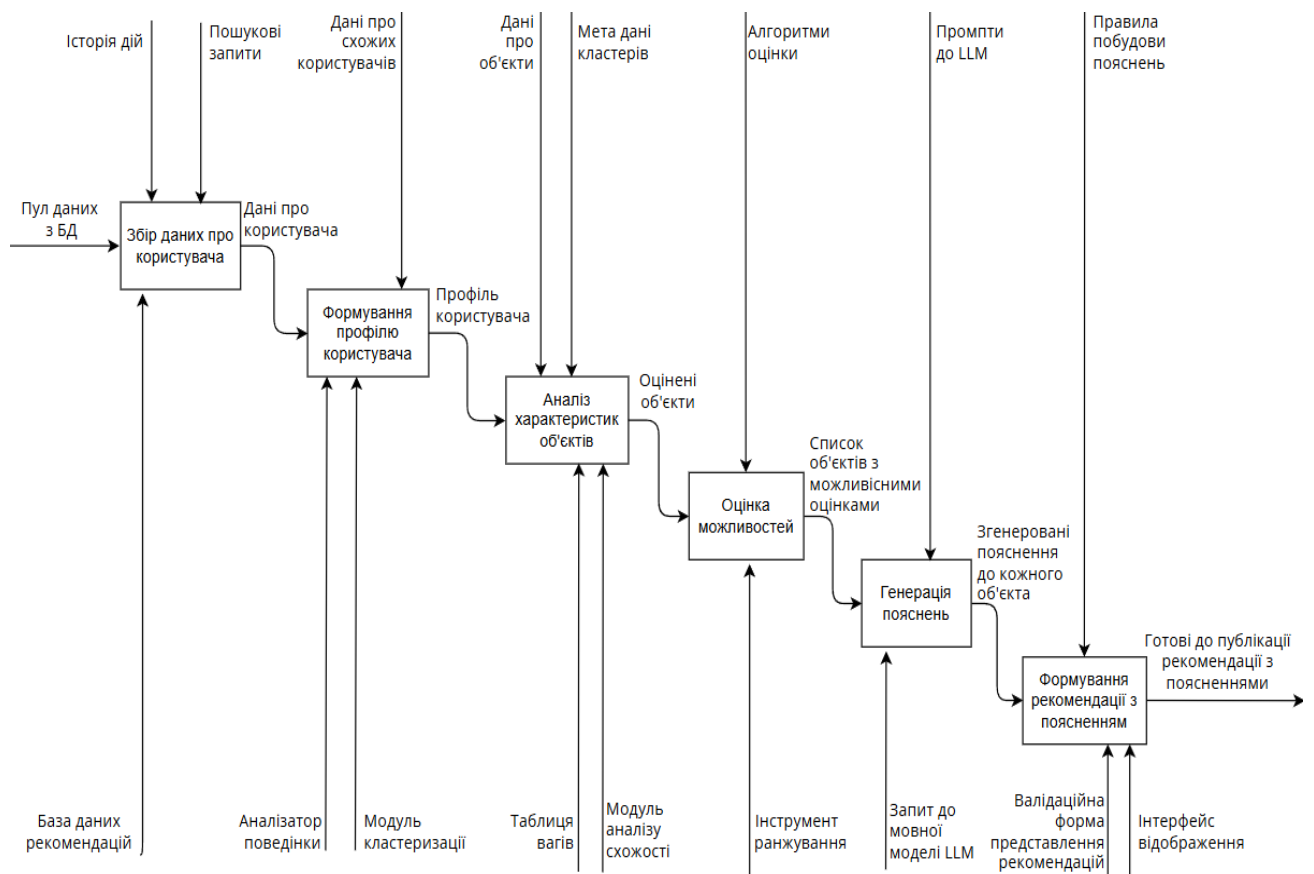


Рисунок 3.1 – Декомпована процесна модель генерації можливісних пояснень у нотатції IDEF0

На верхньому рівні (A0) процесної моделі описується загальна мета – створення можливісної моделі пояснень для рекомендаційної системи. Система має забезпечити зрозуміле пояснення для користувача, чому саме ці об'єкти були рекомендовані. Інтеграція даних користувача, об'єктів і алгоритмічних моделей дозволяє формувати точні та релевантні пояснення. Завдяки чіткій структурі процесів, модель може бути легко адаптована для різних платформ, будь то рекомендації у сфері електронної комерції, відеосервісів чи освітніх платформ.

Контекст моделі передбачає, що її основна мета – це забезпечення користувача зрозумілим і прозорим поясненням, яке підвищить довіру до системи. Кінцевий результат – сформоване пояснення, яке базується на аналізі профілю користувача, характеристик об'єктів та застосуванні можливісної логіки.

На першому етапі збираються дані про користувача, які включають історію взаємодій, інтереси, поведінкові патерни та вподобання. На основі цих даних створюється персоналізований профіль користувача. Важливість цього етапу полягає в тому, що без точного розуміння уподобань користувача неможливо запропонувати релевантні рекомендації.

Формування профілю користувача передбачає використання алгоритмів кластеризації, які групують схожі за поведінкою чи інтересами профілі. Це дозволяє отримати ключові характеристики, які будуть використовуватись на наступних етапах для аналізу об'єктів. У майбутньому цей етап допоможе інтегрувати в програмне рішення модулі збору даних, аналізу поведінки та кластеризації.

Другий етап полягає в детальному аналізі об'єктів, доступних для рекомендацій. Кожен об'єкт оцінюється за ключовими характеристиками: категорія, популярність, рейтинг, метадані тощо. Аналіз об'єктів важливий для того, щоб визначити, які з них найбільш релевантні для користувача.

На цьому етапі використовуються алгоритми порівняння, що дозволяють зіставити об'єкти з профілем користувача. Наприклад, якщо

користувач цікавиться книгами на тему штучного інтелекту, система визначає релевантність кожної книги за заданими параметрами. Цей етап стане основою для розробки програмного модуля оцінки об'єктів, який у реальному часі може проводити фільтрацію та оцінку.

Третій етап полягає у визначенні можливісної оцінки кожного об'єкта з урахуванням профілю користувача. Тут використовується можливісна логіка для того, щоб оцінити, наскільки ймовірно об'єкт відповідає інтересам користувача.

Можливісна логіка є особливо корисною, оскільки дозволяє працювати з нечіткими даними. Наприклад, якщо в профілі користувача недостатньо інформації, система все одно зможе надати рекомендацію, вказуючи, що цей об'єкт "можливо" підходить. Це підвищує гнучкість системи та дозволяє працювати з неповними або неточними даними.

У програмному рішенні цей етап буде реалізований у вигляді алгоритму, який враховує можливісну міру для кожного об'єкта. Алгоритм має інтегруватися з базою даних, щоб автоматично оновлювати оцінки при зміні даних про користувача чи об'єкти.

На цьому етапі створюються пояснення для кожної рекомендації. Система використовує каузальний зв'язок між характеристиками об'єкта і профілем користувача, щоб сформулювати чітке пояснення. Наприклад, "Ця книга рекомендована, оскільки вона схожа на ті, які ви переглядали раніше, і має високий рейтинг".

Генерація пояснень є ключовим моментом, адже саме цей етап формує зрозумілий текст для користувача. У програмному рішенні цей процес буде інтегровано з мовними моделями (LLM), які допоможуть створити природні пояснення. Це дозволить зменшити розрив між складними алгоритмами і користувацьким інтерфейсом.

Заключний етап передбачає об'єднання всіх отриманих даних – оцінок об'єктів, пояснень і вибору найбільш релевантних рекомендацій. Система

оптимізує порядок рекомендацій, відображає їх у зручному вигляді та забезпечує можливість зворотного зв'язку.

Цей етап також дозволяє інтегрувати інтерфейс відображення для користувача. У програмному рішенні результат формуватиметься у вигляді списку рекомендацій із поясненнями, доступного через API або інший зручний механізм.

Процесна модель IDEF0 забезпечує структуровану основу для розробки програмного рішення. Завдяки чіткій декомпозиції процесів розробники можуть зрозуміти, які етапи потрібно автоматизувати, які дані потрібні на кожному етапі, та які інструменти й алгоритми необхідні.

Ця модель дозволяє створити модульне програмне рішення, де кожен етап (формування профілю, аналіз об'єктів, оцінка можливостей, генерація пояснень) є окремим модулем. Модульність спрощує тестування, налагодження і розширення системи.

Крім того, використання можливої логіки в поєднанні з мовними моделями (LLM) забезпечує створення гнучкої системи, яка може працювати з неточними або обмеженими даними. У перспективі така система може бути адаптована для різних доменів, включаючи електронну комерцію, освіту, розваги тощо.

Процесна модель IDEF0 для розробки можливої моделі пояснень – це структурований підхід, який не тільки полегшує розробку програмного рішення, але й робить його гнучким, масштабованим і зрозумілим для кінцевого користувача.

4 ПРОГРАМНА РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНА ПЕРЕВІРКА ОТРИМАНИХ РЕЗУЛЬТАТІВ

4.1 Реалізація модулю генерації можливісних моделей пояснень

Даний програмний код використовує графовий підхід для моделювання причинно-наслідкових зв'язків, що реалізовано через бібліотеку NetworkX. Основна ідея полягає у створенні орієнтованого графа, де вузли представляють окремі події або змінні, а спрямовані ребра – причинно-наслідкові зв'язки між ними. Це дозволяє моделювати систему, в якій одна подія може впливати на іншу, і надавати текстові пояснення, як саме це відбувається. У граф додаються зв'язки, що відповідають логіці «причина → наслідок».

Наприклад, якщо подія А впливає на подію В, створюється відповідне ребро. Далі для аналізу використовується алгоритм, який перевіряє наявність шляху між заданими вузлами. Якщо шлях існує, визначаються всі можливі маршрути, які з'єднують початкову та кінцеву події. Це дозволяє сформулювати пояснення у вигляді тексту, в якому перераховуються всі можливі варіанти впливу однієї події на іншу. Даний метод зображено на рисунку 4.1.

```

1 import networkx as nx
2
3 class CausalExplanation:
4     def __init__(self):
5         self.graph = nx.DiGraph()
6
7     def add_causal_link(self, cause, effect):
8         self.graph.add_edge(cause, effect)
9
10    def generate_explanation(self, cause, effect):
11        if nx.has_path(self.graph, cause, effect):
12            paths = list(nx.all_simple_paths(self.graph, cause, effect))
13            explanation = f"Зміна в {cause} може призвести до зміни в {effect} через такі
                шляхи:\n"
14            for path in paths:
15                explanation += " -> ".join(path) + "\n"
16            return explanation
17        else:
18            return f"Між {cause} та {effect} немає прямого зв'язку."

```

Рисунок 4.1 – Реалізація модулю орієнтовного графа

Наприклад, якщо між подіями А і С існують два шляхи, одразу прямий і через іншу подію В, у поясненні це буде чітко вказано з наведенням кожного шляху. Крім цього, код дозволяє візуалізувати граф, що дає змогу користувачеві краще зрозуміти структуру взаємозв'язків у системі.

Візуалізація відображає вузли як події та зв'язки між ними у вигляді стрілок, що ілюструють напрямок впливу. Такий підхід дає змогу наочно уявити, як події взаємодіють, та спрощує аналіз складних систем. Робота коду зображеного на рисунку 4.2 зводиться до того, щоб надавати інструменти для аналізу, пояснення та візуалізації причинно-наслідкових зв'язків, що є особливо корисним у задачах, де важлива прозорість і зрозумілість для кінцевого користувача.

```

19
20     def visualize_graph(self):
21         import matplotlib.pyplot as plt
22         pos = nx.spring_layout(self.graph)
23         nx.draw(self.graph, pos, with_labels=True, node_size=2000, node_color='lightblue',
24               font_size=12)
25         plt.show()
26
27 causal_system = CausalExplanation()
28 causal_system.add_causal_link("A", "B")
29 causal_system.add_causal_link("B", "C")
30 causal_system.add_causal_link("A", "C")
31
32 explanation = causal_system.generate_explanation("A", "C")
33 print(explanation)

```

Рисунок 4.2 – Реалізація каузального методу

Розроблений метод реалізує систему зважування для оцінки елементів за заданими критеріями. Використовується метод агрегування вагових коефіцієнтів, який є поширеним у багатокритеріальному аналізі рішень. Система базується на ідеї, що кожен критерій, важливий для оцінки, має певну вагу, яка відображає його значимість у загальній оцінці.

Метод роботи коду побудований у кілька етапів. Спочатку задаються ваги критеріїв, які представляють, наскільки кожен з них впливає на підсумкову оцінку. Наприклад, у наведеному прикладі критеріям «ціна»,

«якість» та «популярність» призначено ваги 0.3, 0.5 та 0.2 відповідно. Це означає, що якість є найбільш значущим фактором, тоді як популярність впливає найменше.

Далі код дозволяє оцінювати конкретні елементи, використовуючи метод агрегування. Для цього оцінки елемента за кожним критерієм перемножуються на відповідні ваги, після чого їх сума визначає загальний результат. Наприклад, для елемента, оціненого як «8» за критерієм «ціна», «7» за критерієм «якість» і «9» за критерієм «популярність», підсумкова оцінка обчислюється шляхом підсумовування добутків оцінок на ваги.

Код також включає функцію оновлення ваг, що дозволяє змінювати пріоритетність критеріїв залежно від зовнішніх факторів або нових вимог. Наприклад, якщо критерію «ціна» потрібно надати більше значення, його вага може бути збільшена, а вага інших критеріїв відповідно зменшена.

Ще одна важлива функція – нормалізація ваг. Вона забезпечує, що всі ваги разом складають одиницю, що є необхідною умовою для коректного підсумовування. Це корисно, коли ваги змінюються, оскільки дозволяє зберігати пропорційність між ними.

Загалом цей підхід застосовується для створення гнучких моделей оцінки, які можна використовувати в різних сферах: від аналізу споживчих товарів до складних бізнес-рішень. Код дозволяє швидко адаптувати систему до нових умов, що робить її зручною для інтерактивного використання та прийняття рішень.

Описана система зважування зображена на рисунку 4.3 зводиться також демонструє свою ефективність у контексті персоналізованого підходу до прийняття рішень. Завдяки можливості налаштування ваг для критеріїв вона дозволяє враховувати індивідуальні уподобання користувачів або специфічні вимоги до аналізованих елементів. Наприклад, у разі оцінки товарів для різних категорій споживачів можна динамічно змінювати ваги залежно від їхніх пріоритетів, таких як ціна для бюджетно орієнтованих покупців

```

1 import numpy as np
2
3 class WeightingSystem:
4     def __init__(self, criteria_weights):
5         self.criteria_weights = criteria_weights
6
7     def evaluate_element(self, element_scores):
8         total_score = 0
9         for criterion, weight in self.criteria_weights.items():
10            total_score += element_scores.get(criterion, 0) * weight
11        return total_score
12
13    def update_weights(self, new_weights):
14        self.criteria_weights.update(new_weights)
15
16    def normalize_weights(self):
17        total_weight = sum(self.criteria_weights.values())
18        for key in self.criteria_weights:
19            self.criteria_weights[key] /= total_weight
20
21 criteria_weights = {"price": 0.3, "quality": 0.5, "popularity": 0.2}
22 element_scores = {"price": 8, "quality": 7, "popularity": 9}
23
24 system = WeightingSystem(criteria_weights)
25 score = system.evaluate_element(element_scores)
26 print("Оцінка елемента:", score)
27
28 new_weights = {"price": 0.4, "quality": 0.4, "popularity": 0.2}
29 system.update_weights(new_weights)
30 system.normalize_weights()
31
32 score_updated = system.evaluate_element(element_scores)
33 print("Оновлена оцінка елемента:", score_updated)

```

Рисунок 4.3 – Інтеграція LLM від OpenAI

Цей програмний код реалізує метод інтеграції мовної моделі OpenAI для автоматичної генерації пояснень до рекомендацій, спираючись на вказаний контекст. У основі роботи лежить використання API OpenAI, яке забезпечує доступ до мовної моделі для створення текстових відповідей на основі заданого запиту. Код спочатку налаштовує з'єднання з API, використовуючи ключ доступу. Далі реалізовані функції, які працюють з мовною моделлю: одна для обробки окремого запиту і генерації пояснення, а друга — для пакетної обробки списку рекомендацій.

Цей запит передається в API OpenAI, яке обробляє його за допомогою нейронної моделі та повертає текстову відповідь, що описує причини чи обґрунтування для даної рекомендації. Це дозволяє автоматизувати створення інформативних пояснень, які допомагають користувачам краще зрозуміти, чому була зроблена саме така рекомендація. Функція обмежує кількість tokenів у відповіді для забезпечення лаконічності та уникнення надлишкової інформації.

Друга функція зображена на рисунку 4.4 зводиться відповідає за обробку кількох рекомендацій одночасно. Вона послідовно викликає першу функцію для кожної рекомендації зі списку, забезпечуючи уніфіковане пояснення для кожного пункту.

```

1 import openai
2
3 openai.api_key = "fmgixzcb-44jks-mlasz"
4
5 def query_llm_explanation(recommendation, context):
6     prompt = f"На основі наступного контексту надай пояснення до цієї рекомендації:
7         {recommendation}\nКонтекст: {context}"
8     response = openai.Completion.create(
9         engine="text-davinci-003",
10        prompt=prompt,
11        max_tokens=200
12    )
13    return response.choices[0].text.strip()
14
15 def query_batch_llm_explanations(recommendations, context):
16     explanations = []
17     for recommendation in recommendations:
18         explanation = query_llm_explanation(recommendation, context)
19         explanations.append(explanation)
20     return explanations
21
22 recommendation = "Рекомендуємо купити товар X через його високу якість."
23 context = "Товар X має високий рейтинг за відгуками, а також визнаний експертами у цій
24 категорії."
25
26 explanation = query_llm_explanation(recommendation, context)
27 print("Пояснення до рекомендації:", explanation)
28
29 batch_recommendations = [
30     "Рекомендуємо вибрати послугу Y, оскільки вона найвигідніша.",
31     "Спробуйте товар Z, він має найкращу ефективність за відгуками."
32 ]
33 batch_explanations = query_batch_llm_explanations(batch_recommendations, context)
34 for idx, exp in enumerate(batch_explanations):
35     print(f"Пояснення до запиту {idx + 1}: {exp}")

```

Рисунок 4.4 – Генерація пояснення для рекомендації

Код демонструє приклади використання обох функцій. У першому випадку створюється пояснення до однієї рекомендації, що заснована на якості товару та визнанні експертами. У другому — пояснення генеруються для кількох рекомендацій, кожна з яких ґрунтується на різних аспектах, таких як вигідність чи ефективність. Це особливо корисно в системах, що потребують пояснення до великого обсягу рекомендацій, наприклад, у випадках роботи з інтернет-магазинами або платформами, які пропонують персоналізовані рішення.

Загалом, цей метод забезпечує автоматизацію процесу створення пояснень, дозволяючи значно спростити комунікацію між системою рекомендацій та кінцевим користувачем. Він враховує контекстні дані для побудови логічних та переконливих текстів, що сприяє підвищенню довіри до рекомендаційної системи. Технологія базується на потужній нейронній моделі, яка здатна генерувати тексти, що імітують людську мову, роблячи їх зрозумілими для користувачів різних рівнів підготовки.

4.2 Експериментальна перевірка отриманих теоретичних результатів

Перевірка розробленого методу є одним із ключових етапів дослідження, оскільки вона дозволяє підтвердити його ефективність, надійність і відповідність поставленим цілям. У рамках даної роботи було розроблено методичку, що базується на можливісній моделі пояснень, яка забезпечує створення персоналізованих рекомендацій для користувачів із супровідними поясненнями, що підвищують довіру до рекомендаційної системи. Однак теоретична модель, якою б досконалою вона не здавалася, потребує перевірки у реальних умовах для того, щоб забезпечити її коректну роботу на практиці.

Експериментальна перевірка має велике значення, адже вона дозволяє впевнитися у правильності функціонування розробленого додатка. Перш за

все, проводиться тестування, щоб пересвідчитися, що система працює відповідно до закладеної теоретичної моделі. Це включає перевірку всіх ключових етапів – від обробки даних користувача до формування рекомендацій і пояснень. Крім того, здійснюється аналіз релевантності рекомендацій, що забезпечує відповідність результатів реальним інтересам користувача. Рекомендації не лише повинні відповідати вподобанням, але й демонструвати чіткий зв'язок між профілем користувача та характеристиками запропонованих об'єктів.

Окрему увагу приділяють перевірці пояснень. Ця частина надзвичайно важлива, оскільки пояснення підвищують прозорість роботи рекомендаційної системи, що позитивно впливає на довіру користувачів. Перевіряється, чи пояснення є достатньо зрозумілими, логічними та пов'язаними з інтересами користувача. У разі, якщо пояснення не відповідають цим критеріям, виявляються слабкі місця алгоритму та вносяться відповідні корективи.

Експеримент також дозволяє виявити потенційні недоліки розробленої методики. Наприклад, у ході тестування можуть бути знайдені аспекти, які раніше не були враховані у теоретичній моделі, або ж проявляються складнощі в обробці даних, які потребують доопрацювання. Цей процес є невід'ємною частиною розробки, адже саме через виявлення і виправлення недоліків створюється система, яка відповідає вимогам користувачів і реальних умов експлуатації.

Для проведення експерименту була створена база даних, яка відповідає описаній у процесній моделі, побудованій у стандарті IDEF0. Ця база містить дані про користувачів, їхні вподобання та історію дій, а також інформацію про об'єкти, що можуть бути рекомендовані, включаючи їхні характеристики. До бази також додані можливісні пояснення, які використовуються для формування зв'язку між рекомендаціями та профілем користувача.

У межах експерименту було вибрано сферу книжкових рекомендацій, що дозволяє проілюструвати роботу системи у конкретній тематиці. Основна задача системи полягає у формуванні списку книжок, які відповідають

інтересам користувача, із супровідними поясненнями, які пояснюють логіку вибору.

Під час експерименту виконувалися кілька основних кроків. Спочатку формувався профіль користувача, який включав його інтереси, історію взаємодій із системою та оцінки попередніх рекомендацій. Цей профіль використовувався як основа для аналізу. На наступному етапі система аналізувала характеристики книжок, доступних у базі даних, серед яких були жанр, популярність, рейтинг та інші метадані. Цей аналіз дозволив виявити книжки, які найбільш точно відповідали профілю користувача.

Далі застосовувалася можливісна логіка, яка дозволила оцінити, наскільки кожна книжка відповідає інтересам користувача. Ця логіка враховувала рівень невизначеності у даних, дозволяючи зробити рекомендації навіть у випадках, коли про користувача було мало інформації. На основі оцінок релевантності формувався список рекомендованих книжок. Кожна рекомендація супроводжувалася поясненням, яке базувалося на зв'язках між профілем користувача та характеристиками книжки.

Наприклад, для користувача, який цікавиться психологією, класичною літературою та науково-популярними виданнями, система згенерувала наступний список рекомендацій. Серед рекомендованих книг були "Думай, як монах", "1984", "Сила звички" та "Коротка історія часу". Пояснення до цих рекомендацій пояснювали, що книжки вибрані через інтереси користувача до саморозвитку, психології чи значущих творів класичної літератури. Наприклад, книга "Думай, як монах" була рекомендована через її тематичну близькість до саморозвитку, а "1984" – як класика, що відображає глибокі філософські теми, які резонують із вподобаннями користувача.

Ці результати підтвердили, що методика працює відповідно до очікувань. Модель змогла сформувані релевантні рекомендації та пояснення, які були зрозумілими і відповідали інтересам користувача. Крім того, пояснення сприяли підвищенню довіри до системи, оскільки користувач міг побачити логіку формування рекомендацій.

Розгорнута база даних зображена на рисунку 4.5 зводиться дозволяє зберігати та керувати інформацією про користувачів, елементи, рекомендації та відгуки. Вона забезпечує можливість створення персоналізованих рекомендацій на основі історії взаємодій користувачів та їхніх уподобань. Пояснення рекомендацій допомагають користувачам краще розуміти, чому саме ці елементи були рекомендовані.

```

CREATE TABLE Users (
  UserID INT PRIMARY KEY AUTO_INCREMENT,
  UserName VARCHAR(100) NOT NULL,
  Email VARCHAR(100) UNIQUE NOT NULL,
  RegistrationDate DATE DEFAULT CURRENT_DATE
);

CREATE TABLE Items (
  ItemID INT PRIMARY KEY AUTO_INCREMENT,
  ItemName VARCHAR(100) NOT NULL,
  Category VARCHAR(50),
  Description TEXT
);

CREATE TABLE Explanations (
  ExplanationID INT PRIMARY KEY AUTO_INCREMENT,
  ExplanationText TEXT NOT NULL,
  ModelType VARCHAR(50) NOT NULL,
  CreatedAt TIMESTAMP DEFAULT CURRENT_TIMESTAMP
);

CREATE TABLE Recommendations (
  RecommendationID INT PRIMARY KEY AUTO_INCREMENT,
  UserID INT NOT NULL,
  ItemID INT NOT NULL,
  ExplanationID INT,
  Rating DECIMAL(2,1),
  RecommendationDate TIMESTAMP DEFAULT CURRENT_TIMESTAMP,
  FOREIGN KEY (UserID) REFERENCES Users(UserID) ON DELETE CASCADE,
  FOREIGN KEY (ItemID) REFERENCES Items(ItemID) ON DELETE CASCADE,
  FOREIGN KEY (ExplanationID) REFERENCES Explanations(ExplanationID) ON DELETE SET NULL
);

CREATE TABLE Feedback (
  FeedbackID INT PRIMARY KEY AUTO_INCREMENT,
  RecommendationID INT NOT NULL,
  UserFeedback TEXT,
  FeedbackDate TIMESTAMP DEFAULT CURRENT_TIMESTAMP,
  FOREIGN KEY (RecommendationID) REFERENCES Recommendations(RecommendationID) ON DELETE CASCADE
);

```

Рисю 4.5 – Створення бази даних РС

Розглянемо приклад використання цієї бази даних для створення рекомендації та пояснення. Збір даних: Система збирає дані про взаємодії користувачів, такі як перегляди елементів та їхні оцінки. Це дозволяє системі розуміти, які елементи користувач переглядав та як він їх оцінив.

Обробка даних: Дані проходять очистку, нормалізацію та агрегацію. Наприклад, видаляються дублікати, заповнюються відсутні значення та усуваються аномалії. Це дозволяє системі отримати чисті та структуровані дані для подальшого аналізу.

Створення моделі: На основі оброблених даних створюється модель рекомендацій. Наприклад, модель може використовувати колаборативну фільтрацію для аналізу поведінки схожих користувачів або контентний підхід для аналізу властивостей елементів. Це дозволяє системі створити модель, яка може генерувати рекомендації на основі даних.

Генерування рекомендації: Модель генерує рекомендацію для користувача. Наприклад, якщо користувач позитивно оцінив фільми жанру драми, система може рекомендувати інші фільми цього жанру. Це дозволяє системі надавати користувачеві рекомендації, які відповідають його уподобанням.

Створення пояснення: На основі генерування рекомендації створюється пояснення. Наприклад, "Цей фільм рекомендується, тому що ви позитивно оцінили інші фільми жанру драми". Це дозволяє системі надавати користувачеві пояснення, чому саме цей елемент був рекомендований.

Збереження інформації: Інформація про рекомендацію та пояснення зберігається у відповідних таблицях бази даних. Це дозволяє системі зберігати деталі про кожну рекомендацію та пояснення для подальшого використання.

Подання рекомендації: Рекомендація та пояснення подаються користувачеві. Наприклад, користувачеві показується рекомендований фільм та пояснення, чому саме цей фільм був обраний. Це дозволяє користувачеві отримати рекомендацію та пояснення, чому саме цей елемент був рекомендований.

Збір відгуків: Користувач може залишити відгук про рекомендацію, який зберігається у таблиці відгуків. Це дозволяє системі зберігати деталі про кожен відгук, який може бути наданий користувачам.

Ця база даних зображена на рисунку 4.6 дозволяє створювати персоналізовані рекомендації та пояснення, які допомагають користувачам краще розуміти логіку системи та приймати більш обґрунтовані рішення. Вона забезпечує можливість зберігання та управління інформацією про користувачів, елементи, рекомендації та відгуки, що підвищує ефективність та точність рекомендаційних систем.

Таблиця 4.1 – Сутності бази даних

Таблиця	Опис
Users	Таблиця містить інформацію про користувачів системи рекомендацій. Зберігає інформацію про користувачів системи рекомендацій. Кожен користувач має унікальний ідентифікатор, ім'я, адресу електронної пошти та дату реєстрації.
Items	Таблиця зберігає інформацію про товари або предмети, які можуть бути рекомендовані користувачам. Зберігає інформацію про товари, які рекомендуються. Кожен товар має ідентифікатор, назву, категорію та опис.
Explanations	Зберігає пояснення до рекомендацій. Кожне пояснення має унікальний ідентифікатор, текст пояснення, тип моделі, що використовувалася для його генерації
Recommendations	Зберігає інформацію про рекомендації, надані користувачам. Кожна рекомендація має унікальний ідентифікатор, зв'язок з користувачем та товаром, може містити пояснення, рейтинг і дату рекомендації.
Feedback	Таблиця зберігає відгуки користувачів про надані рекомендації. Зберігає відгуки користувачів про рекомендації. Кожен відгук має унікальний ідентифікатор, зв'язок з рекомендацією, текст відгуку та дату подачі відгуку.



Рисунок 4.6 – Схема БД рекомендаційної системи

"Users" містить інформацію про користувачів, включаючи унікальні ідентифікатори, імена, електронні пошти та дати реєстрації, що дозволяє ідентифікувати кожного з них.

Дані про елементи для рекомендацій, такі як назва, категорія й опис, зберігаються у таблиці "Items".

Для управління поясненнями використовується "Explanations", де зберігаються тексти, моделі створення та час формування. Ця структура додає прозорості до процесу рекомендацій.

"Recommendations" об'єднує користувачів, елементи та пояснення через їхні ідентифікатори, зберігаючи також рейтинг і час пропозиції, що забезпечує зручний облік рекомендацій.

Таблиця 4.2 – Сгенеровані пояснення до рекомендацій

Рекомендація	Пояснення	Можли- вість	Необхід- ність
"Думай, як монах"	Рекомендовано вам тому, що стосується тем саморозвитку, які вас цікавлять.	0.32	0.72
"Атлант розправив плечі"	Ця книга рекомендована вам тому, що вона є класичним твором з філософським змістом, що відповідає вашим вподобанням.	0.45	0.91
"Коротка історія часу"	Ви переглядали популярні наукові роботи схожі на дану.	0.28	0.87
"Підсвідомість може все"	Дана робота довподоби фанатам психології, схожим на вас.	0.41	0.95
"1984"	Рекомендовано вам, оскільки цей класичний твір відображає ваші вподобання до важливих літературних текстів.	0.18	0.76
"Сила звички"	Книга обрана для вас, оскільки вона актуальна в контексті теми поведінкових змін, що вас цікавить.	0.40	0.84
"Феномен моди"	Рекомендовано вам через її відповідність до вашої зацікавленості в розборі соціальних явищ.	0.26	0.67
"Злочин і кара"	Цей твір підійде вам завдяки поєднанню класичного сюжету та психологічних аспектів, що співпадають з вашими інтересами.	0.34	0.80

У ході експерименту також були виявлені аспекти, які потребують подальшого доопрацювання. Наприклад, у випадках, коли у профілі користувача було мало даних, пояснення іноді виглядали недостатньо детально. Це свідчить про необхідність подальшого удосконалення алгоритмів генерації пояснень, зокрема, за допомогою більш складних мовних моделей.

Отже, експериментальна перевірка розробленого методу підтвердила його працездатність і ефективність у реальних умовах. Можлива модель пояснень виявилася корисною для створення прозорих та зрозумілих рекомендацій, що підвищує довіру до системи та покращує взаємодію користувачів із нею. Завдяки експерименту вдалося не лише продемонструвати переваги розробленої методики, але й виявити напрями для подальшого розвитку, що робить цей етап важливим внеском у загальну структуру дослідження.

ВИСНОВКИ

У рамках цього дослідження було проведено всебічний аналіз проблематики побудови пояснень у рекомендаційних системах, з особливим акцентом на електронну комерцію, де важливими аспектами є персоналізація рекомендацій, проблема "холодного старту" та забезпечення прозорості для користувачів. Зокрема, було проаналізовано існуючі підходи до інтеграції пояснень у рекомендаційні системи, що допомагають підвищити рівень довіри користувачів до платформи, збільшити їхню задоволеність та полегшити взаємодію з системою. Особлива увага приділялася вибору методів побудови пояснень, які враховують якості, такі як прозорість, достовірність та релевантність рекомендацій.

Актуальність роботи полягає у вирішенні однієї з основних проблем сучасних рекомендаційних систем — недостатньої прозорості їхніх рішень для кінцевих користувачів. Зокрема, виявлено, що існуючі підходи не завжди задовольняють вимоги до зручності та зрозумілості пояснень, що може призвести до зниження довіри до системи. Розроблена в рамках роботи модель побудови пояснень на основі можливісного підходу враховує ці потреби, сприяючи підвищенню ефективності взаємодії користувачів з системою та полегшенню сприйняття складних рекомендацій.

Завдання, що були вирішені в рамках дослідження, включають розробку теоретичної основи для побудови пояснень у рекомендаційних системах, створення удосконаленої моделі, що враховує багатокритеріальну оцінку, і реалізацію цієї моделі в інформаційній технології для автоматизованої генерації пояснень. Окрім того, дослідження охоплює тестування та експериментальну перевірку ефективності розробленого підходу.

Розроблена модель базується на можливісному підході, що дозволяє забезпечити прозорість і надійність рекомендацій. Вона враховує потреби як нових, так і постійних користувачів, що допомагає адаптувати систему до

різних умов використання. В результаті, створена система пояснень забезпечує підвищення довіри до платформ, сприяючи покращенню точності рекомендацій, зменшенню відмов від запропонованих рішень та збільшенню загальної задоволеності користувачів.

Наукова новизна роботи полягає в розробці нової можливісної моделі пояснень, яка ефективно інтегрується в рекомендаційні системи та вирішує проблему "холодного старту", а також забезпечує більш прозорі та зрозумілі пояснення. Практичне значення отриманих результатів полягає в можливості впровадження цієї моделі в комерційні платформи для покращення персоналізованих пропозицій та збільшення конкурентоспроможності системи.

Таким чином, результати дослідження мають великий потенціал для впровадження в різні галузі, такі як електронна комерція, онлайн-освіта та розважальний контент, сприяючи вдосконаленню існуючих рекомендаційних систем. У майбутньому дослідження можуть бути зосереджені на адаптації моделей до нових технологічних викликів і інтеграції їх у багатофункціональні платформи для підвищення їхньої універсальності та ефективності.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Чалий С. Ф., Лещинський В., Лещинська І. Реляційно-тимчасова модель множини сутностей предметної області для процесу формування рішень в інтелектуальних інформаційних системах. Вісник Національного технічного університету "ХПІ". Серія: Системний аналіз, управління та інформаційні технології. 2022. Т. 1(7). С. 84–89.
2. Голдштейн М., Учїда С. Порівняльна оцінка алгоритмів для виявлення аномалій без нагляду для багатовимірних даних. PLOS ONE. 2016. Т. 11(4). С. 31.
3. Чалий С. Ф., Лещинський В. О. Побудова локальних пояснень щодо обмежень процесу формування рішення в інтелектуальній системі. Information Technologies and Automation–2024. 2024. С. 693.
4. Лю Ф. Т., Тінг К. М., Чжоу З.-Х. Виявлення аномалій на основі ізоляції. ACM Transactions on Knowledge Discovery From Data. 2012. Т. 6. С. 39.
5. Чалий С. Ф., Лещинська І. О. Принципи побудови ментальних моделей рішення для зовнішнього користувача в задачі формування пояснень в інтелектуальній системі. АСУ та прилади автоматики. 2024. Т. 82-90.
6. Чалий С. Ф., Лещинський В. О. Побудова пояснень в інтелектуальних системах на основі формування каузальних залежностей. АСУ та прилади автоматики. 2024. Т. 4-15.
7. Бальдан Лозано Ф. Дж., Гарсія-Гіль Д. Бенчмаркінг методів виявлення аномалій: погляди з архіву аномалій UCR Time Series. Expert Systems. 2024. С. 11.
8. Чалий С. Ф., Лещинська І. О. Уточнення ментальної моделі рішення на основі доповнення вхідних даних в задачі формування пояснень в інтелектуальній системі. АСУ та прилади автоматики. 2024. Т. 66-72.
9. Чалий С. Ф., Бганцев М. В. Розробка методів оцінювання ІТ-компаній з використанням анонімних відгуків. The 8th International scientific and practical conference “Innovative ...”. 2024.

10. Певни Т. Loda: Легкий онлайн-детектор аномалій. *Machine Learning*. Т. 102. С. 275–304.
11. Ленц Р., Рейхерт М. IT-підтримка для медичних процесів – передумови, виклики, перспективи. *Data & Knowledge Engineering*. 2007. Т. 61(1). С. 39–58.
12. Чалий С. Ф., Лещинська І. О. Екстерналізація неявних знань в ментальній моделі користувача системи штучного інтелекту. Національний технічний університет "Харківський політехнічний інститут". 2024.
13. Чалий С. Ф., Лещинський В. О. Темпорально-каузальні методи побудови пояснень в системах штучного інтелекту. АСУ та прилади автоматизації. 2024. Т. 91-99.
14. Чалий С. Ф., Лещинський В. О. Побудова процесно-орієнтованих пояснень в інтелектуальних інформаційних системах на основі можливісних каузальних залежностей. АСУ та прилади автоматизації. 2024. Т. 25-33.
15. Lof: Identifying Density-Based Local Outliers / Breunig M. M. et al. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*. 2000. С. 93–104.
16. Чалий С. Ф., Богатов І. О. Технологія автоматизованого побудови прототипу моделі бізнес-процесу на основі попередньої обробки подій. Вісник Національного технічного університету "ХПІ". Серія: Системний аналіз, управління та інформаційні технології. 2020. Т. 2(4). С. 57–63.
17. Лю Ю. та ін. Генеративне суперечливе активне навчання для виявлення аномалій без нагляду. *IEEE Transactions on Knowledge and Data Engineering*. 2019. Т. 32. С. 1517–1528.
18. Estimating the Support of a High-Dimensional Distribution / Schölkopf B. et al. *Neural Computation*. 2001. Т. 13. С. 1443–1471.
19. Copod: Copula-Based Outlier Detection / Li Z. et al. *IEEE International Conference on Data Mining (ICDM)*. 2020. С. 1118–1123.
20. Чалий С. Ф., Полозов М. О. Виявлення бізнес-правил на основі темпоральних залежностей з використанням технології інтелектуального

аналізу процесів. Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління: тези доп. дванадцятої міжнародної науково-технічної конференції. 2022. Т. 2. С. 84.

21. Ecod: Unsupervised Outlier Detection Using Empirical Cumulative Distribution Functions / Li Z. et al. IEEE Transactions on Knowledge and Data Engineering. 2022. Т. 35. С. 12181–12193.

22. Чалий С. Ф., Лещинська І. О. Принцип доповнення вхідних даних у ментальній моделі користувача інтелектуальної системи. Information Technologies and Automation–2024. 2024. С. 691.

23. Чалий С. Ф., Лещинський В. О. Побудова пояснень на локальному рівні представлення процесу формування рішень для внутрішніх користувачів інтелектуальної системи. Біоніка інтелекту. 2024. Т. 1(100). С. 58-64.

24. Чалий С. Ф., Єрохін Д. О. Оцінка пояснень користувачами з використанням інтелектуального аналізу процесів. Застосування інформаційних технологій у підготовці та діяльності сил охорони ... 2024.

25. Пуліменопулоу М., Маламатеніу Ф., Василагопулос Г. Специфікація вимог до процесів робочих потоків для служби екстреної медичної допомоги. Journal of medical systems. 2003. Т. 27(4). С. 325–335.

26. Фернандес А., Фернандес Д., Гарсія Й. Управління бізнес-процесами для оптимізації клінічних процесів: систематичний огляд літератури. Health Informatics Journal. 2020. Т. 26(2). С. 1305–1320.

27. Чалий С. Ф., Мацейко Т. М. Представлення аномальних послідовностей робіт у бізнес-процесах з використанням темпоральних правил. ТОВ «Друкарня Мадрид». 2024. С. 113–114.

28. Буттіг'єг С., Дей П., Гаучі Д. Управління бізнес-процесами в охороні здоров'я: поточні виклики та майбутні перспективи. Innovation and Entrepreneurship in Health. 2016. Т. 3. С. 1–13.