

МАГІСТЕРСЬКА РОБОТА

МР. ШМ - 59.00.00.000 ПЗ

Група ШМ-24-1

Гринів Радислав

2026

Івано-Франківський національний технічний університет нафти і газу

Факультет інформаційних технологій

Кафедра інженерії програмного забезпечення

Гринів Радислав Зіновійович

(прізвище, ім'я, по батькові)

УДК 004.9
(індекс)

МАГІСТЕРСЬКА РОБОТА

Моделі та методи досягнення ефективності рекомендаційних систем на

платформах соціального нетворкінгу

(назва роботи)

Інженерія програмного забезпечення

(назва освітньої програми)

121 - Інженерія програмного забезпечення

(шифр і назва спеціальності)

Гринів Р.З.

(підпис, ініціали та прізвище здобувача освітнього ступеня)

Науковий керівник Мельник Віталій Дмитрович, к.т.н., доцент

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Допущено до захисту

Завідувач кафедри

доц. Бандура В.В.

(посада) (підпис) (дата) (ініціали та прізвище)

Нормоконтроль

доц. Вовк Р.Б.

(посада) (підпис) (дата) (ініціали та прізвище)

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

Івано-Франківськ – 2026

Івано-Франківський національний технічний університет нафти і газу

Факультет інформаційних технологій

Кафедра інженерії програмного забезпечення

Освітній рівень магістр

Спеціальність 121 – Інженерія програмного забезпечення

ЗАТВЕРДЖУЮ:

Зав. кафедрою

ІІЗ

доц.

В.В. Бандура

“ 04 ” вересня 2025 р.

ЗАВДАННЯ

НА МАГІСТЕРСЬКУ РОБОТУ СТУДЕНТУ

Гриніву Радиславу Зіновійовичу

(прізвище, ім'я, по-батькові)

1. Тема магістерської роботи “ **Моделі та методи досягнення ефективності рекомендаційних систем на платформах соціального нетворкінгу** ”

керівник проекту (роботи) Мельник В.Д., к.т.н., доцент

затвердені наказом закладу вищої освіти від “ 05 ” листопада 2025 р. № 695/7

2. Строк подання студентом проекту (роботи) 25 січня 2026 р.

3. Вихідні дані до проекту (роботи) Формальні моделі і методи побудови інформаційних та програмних технологій підтримки рекомендаційних систем

4. Зміст розрахунково - пояснювальної записки(перелік питань, які потрібно розробити)

1. Аналіз предметної області визначення досягнення ефективності рекомендаційних систем

2. Формальне представлення методів визначення онлайн репутації в соціальному нетворкінгу

3. Імплементация методів досягнення ефективності рекомендаційних систем

4. Представлення обчислювальної моделі репутації для онлайн-систем

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень)

1. Схема високорівневої архітектури пошукової системи (рис. 1.1)

2. Приклад вебкаталогу Yahoo! (початкова версія) (рис. 1.2)

3. Вигляд Altavista - популярної ранньої пошукової системи (рис. 1.3)

4. Приклад графа сторінок, де орієнтовані ребра представляють гіперпосилання (рис. 1.4)

5. Фрагмент графа, що ілюструє топологічну структуру Facebook (рис. 1.5)

6. Консультанти розділів проекту (роботи)

Розділ	Консультант	Підпис, дата
Перевірка на плагіат	доц., к.т.н. Вовк Р.Б.	

7. Дата видачі завдання 04 вересня 2025 р.

Керівник _____

(підпис)

Завдання прийняв до виконання _____

(підпис)

КАЛЕНДАРНИЙ ПЛАН

№ п/п	Назви етапів магістерської роботи	Строк виконання етапів роботи	Примітка
1	Підбір і вивчення літератури по темі магістерської роботи	15.09.2025	виконано
2	Аналіз предметної області визначення досягнення ефективності рекомендаційних систем	01.10.2025	виконано
3	Формальне представлення методів визначення онлайн репутації в соціальному нетворкінгу	22.10.2025	виконано
4	Імплементация методів досягнення ефективності рекомендаційних систем	15.11.2025	виконано
5	Представлення обчислювальної моделі репутації для онлайн-систем	03.12.2025	виконано
6	Реалізація методології агрегації репутаційних показників у колаборативних рекомендаційних системах	27.12.2025	виконано
7	Затвердження пояснювальної записки роботи завідувачем кафедри	25.01.2026	виконано

Студент – магістр _____

(підпис)

Керівник роботи _____

(підпис)

АНОТАЦІЯ

Магістерська робота: 76 с., 16 рис., 2 табл., 46 джерел.

Тема: Моделі та методи досягнення ефективності рекомендаційних систем на платформах соціального нетворкінгу

Мета роботи: розробка та дослідження моделей і методів досягнення ефективності рекомендаційних систем на платформах соціального нетворкінгу на основі інтеграції механізмів онлайн-репутації та семантичної релевантності.

Об'єктом дослідження є рекомендаційні системи в онлайн-середовищах соціального нетворкінгу.

Предметом дослідження є моделі, методи та алгоритми формування рекомендацій з урахуванням онлайн-репутації користувачів і об'єктів у соціальних мережах.

Результати дослідження

В роботі запропонований алгоритм генерації рекомендацій який базується на багатокроковій процедурі відбору, фільтрації та ранжування кандидатів, що відповідає сучасним вимогам до масштабованості та персоналізації

Висновок

Розроблено методологію збору та аналітичної обробки даних у межах пошуково-соціальної платформи, що враховує як структурні характеристики соціального графа, так і семантичні властивості контенту.

РЕКОМЕНДАЦІЙНІ СИСТЕМИ, СОЦІАЛЬНИЙ НЕТВОРКІНГ, ОНЛАЙН-РЕПУТАЦІЯ, СОЦІАЛЬНИЙ ГРАФ, СЕМАНТИЧНА РЕЛЕВАНТНІСТЬ, КОЛАБОРАТИВНА ФІЛЬТРАЦІЯ, ІНФОРМАЦІЙНІ ПЛАТФОРМИ.

ABSTRACT

Master Thesis: 76 pp., 16 fig., 2 tab., 46 sources.

Topic: Models and methods for achieving the efficiency of recommendation systems on a social networking platform

Purpose of the work: development and research of models and methods for achieving the efficiency of recommendation systems on social networking platforms based on the integration of online reputation mechanisms and semantic relevance.

The object of the study is recommendation systems in online social networking environments.

The subject of the study is models, methods and algorithms for generating recommendations taking into account the online reputation of users and objects in social networks.

Research results

The paper proposes an algorithm for generating recommendations based on a multi-step procedure for selecting, filtering and ranking candidates, which meets modern requirements for scalability and personalization.

Conclusion

A methodology for collecting and analytical processing data within a search and social platform has been developed, which takes into account both the structural characteristics of the social graph and the semantic properties of the content.

RECOMMENDATION SYSTEMS, SOCIAL NETWORK, ONLINE REPUTATION, SOCIAL GRAPH, SEMANTIC RELEVANCE, COLLABORATIVE FILTERING, INFORMATION PLATFORMS.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	9
ВСТУП.....	10
РОЗДІЛ 1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ВИЗНАЧЕННЯ ДОСЯГНЕННЯ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНИХ СИСТЕМ НА ОСНОВІ ОНЛАЙН РЕПУТАЦІЇ.....	14
1.1. Постановка проблеми та методологічний підхід до обчислення репутації в колаборативних рекомендаційних системах.....	14
1.2. Архітектура та еволюція методів ранжування у пошукових системах.	15
1.3. Математичні моделі аналізу топології посилань в пошукових системах.....	18
1.4. Семантизація, персоналізація та соціальна інтеграція в архітектурі сучасного пошуку	22
1.5. Еволюція соціального нетворкінгу від гіпертексту до складних соціальних графів.....	25
1.5.1. Колаборативні платформи та економіка спільної участі.....	26
1.5.2. Аналіз впливу та дифузії інформації в мережах	28
Висновки до розділу	29
РОЗДІЛ 2. ФОРМАЛЬНЕ ТА МАТЕМАТИЧНЕ ПРЕДСТАВЛЕННЯ МЕТОДІВ ВИЗНАЧЕННЯ ОНЛАЙН РЕПУТАЦІЇ В СОЦІАЛЬНОМУ НЕТВОРКІНГУ	31
2.1. Математичне моделювання репутації в графових структурах	31
2.1.1. Модель на основі адаптованого PageRank	31
2.1.2. Алгоритм HITS (Hubs and Authorities) для розподілу ролей	31
2.1.3. Стійкість до маніпуляцій.....	33
2.1.4. Інтеграція репутації в механізми рекомендацій.....	35

2.2. Феноменологія онлайн-репутації в колаборативних рекомендаційних середовищах	36
2.2.1. Дефініція онлайн-репутації	37
2.2.3. Поведінкові репутаційні моделі	39
2.2.4 Синтез та концептуальні підсумки	42
Висновки до розділу	43
РОЗДІЛ 3. ІМПЛЕМЕНТАЦІЯ МЕТОДІВ ДОСЯГНЕННЯ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНИХ СИСТЕМ НА ПЛАТФОРМАХ СОЦІАЛЬНОГО НЕТВОРКІНГУ	45
3.1. Методологія збору та аналітичної обробки даних у межах пошукової платформи	45
3.2. Представлення обчислювальної моделі репутації для онлайн-систем соціального нетворкінгу спільної діяльності	47
3.2.1. Архітектура рішення	49
3.3. Математична модель зважування репутації в пропонованому алгоритмі	51
3.4. Інтеграція репутаційних моделей та семантичної релевантності в процеси соціальних рекомендацій	53
3.4.1. Алгоритм генерації рекомендацій	54
3.4.2. Моделювання репутації в системах соціального нетворкінгу	56
3.5. Методологія агрегації репутаційних показників у колаборативних рекомендаційних системах	59
3.6. Експериментальна оцінка та аналіз результатів	61
Висновки до розділу	67
ВИСНОВКИ	69
ПЕРЕЛІК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	72

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

ACM — Association for Computing Machinery.

CIR — Collaborative Information Retrieval.

CTR — Click-Through Rate.

DEXA — Database and Expert Systems Applications.

HITS — Hyperlink-Induced Topic Search.

IDF — Inverse Document Frequency.

IR — Information Retrieval.

IUI — Intelligent User Interfaces.

MRR — Mean Reciprocal Rank.

RMS — Root Mean Square.

SERP — Search Engine Results Page

ВСТУП

Актуальність теми.

Стрімкий розвиток цифрових платформ і соціальних мереж призвів до суттєвого зростання обсягів інформації, що циркулює в онлайн-середовищі, а також до ускладнення механізмів взаємодії між користувачами, контентом і сервісами. У таких умовах рекомендаційні системи відіграють ключову роль у забезпеченні персоналізованого доступу до інформації, зменшенні інформаційного перевантаження та підвищенні ефективності пошуково-навігаційних процесів. Особливого значення ці системи набувають на платформах соціального нетворкінгу, де рекомендації формуються не лише на основі індивідуальних уподобань користувачів, але й з урахуванням соціальних зв'язків, поведінкових патернів та колективних оцінок.

Традиційні підходи до побудови рекомендаційних систем, орієнтовані переважно на контентну або колаборативну фільтрацію, демонструють обмежену ефективність у соціально насичених середовищах, що характеризуються динамічністю, гетерогенністю та наявністю зловмисних впливів. У зв'язку з цим актуальним є впровадження механізмів онлайн-репутації, які дозволяють формалізувати рівень довіри до користувачів, джерел інформації та об'єктів рекомендацій. Репутаційні моделі, засновані на аналізі соціальних графів і топології взаємодій, створюють передумови для підвищення якості ранжування та стійкості рекомендаційних алгоритмів.

У роботі розглядаються теоретичні та прикладні аспекти побудови моделей і методів досягнення ефективності рекомендаційних систем на платформах соціального нетворкінгу. Основну увагу зосереджено на формалізації онлайн-репутації, інтеграції репутаційних показників у рекомендаційні механізми та експериментальній оцінці запропонованих підходів. Отримані результати спрямовані на розвиток наукових основ соціально орієнтованих рекомендаційних систем і можуть бути використані для створення сучасних інтелектуальних онлайн-платформ.

Актуальність даної магістерської роботи зумовлена зростаючою роллю соціальних платформ як основних каналів поширення інформації, знань і цифрових сервісів. В умовах інтенсивної взаємодії великої кількості користувачів виникають проблеми надлишковості даних, зниження довіри до контенту та ускладнення процесів пошуку релевантної інформації. Рекомендаційні системи покликані вирішувати ці проблеми, однак їх ефективність значною мірою залежить від здатності враховувати соціальний контекст і якість джерел рекомендацій.

Сучасні соціальні мережі та колаборативні платформи характеризуються наявністю складних соціальних графів, у межах яких поширюються як корисні, так і маніпулятивні або недостовірні дані. За таких умов використання онлайн-репутації як формалізованого показника довіри стає критично важливим для підвищення якості рекомендацій. Репутаційні механізми дозволяють зменшити вплив зловмисних акторів, підвищити стійкість алгоритмів ранжування та забезпечити більш обґрунтований відбір рекомендаційних кандидатів.

Крім того, інтеграція репутаційних моделей із семантичною релевантністю та персоналізацією відповідає сучасним тенденціям розвитку інтелектуальних інформаційних систем. Незважаючи на наявність значної кількості досліджень у галузі рекомендаційних систем, питання комплексного використання онлайн-репутації в соціальному нетворкінгу залишаються недостатньо формалізованими. Це визначає необхідність проведення даного дослідження та підтверджує його наукову й практичну значущість.

Метою магістерської роботи є розробка та дослідження моделей і методів досягнення ефективності рекомендаційних систем на платформах соціального нетворкінгу на основі інтеграції механізмів онлайн-репутації та семантичної релевантності.

Об'єктом дослідження є рекомендаційні системи в онлайн-середовищах соціального нетворкінгу.

Предметом дослідження є моделі, методи та алгоритми формування рекомендацій з урахуванням онлайн-репутації користувачів і об'єктів у соціальних мережах.

Для досягнення поставленої мети в роботі передбачається розв'язання таких завдань:

1. Проаналізувати сучасний стан і тенденції розвитку рекомендаційних систем у соціальному нетворкінгу.
2. Дослідити існуючі підходи до обчислення онлайн-репутації в колаборативних середовищах.
3. Проаналізувати графові та математичні моделі оцінювання репутації.
4. Розробити обчислювальну модель онлайн-репутації для соціальних платформ.
5. Розробити алгоритм генерації рекомендацій з урахуванням соціального контексту.
6. Провести експериментальну оцінку ефективності запропонованого підходу.

Методи дослідження

У процесі виконання магістерської роботи використано такі методи дослідження: аналіз і синтез наукових джерел; системний аналіз рекомендаційних і соціальних систем; методи теорії графів; математичне моделювання; алгоритмічні методи ранжування; методи семантичного аналізу; експериментальні методи; методи статистичної обробки та порівняльного аналізу результатів.

Наукова новизна магістерської роботи полягає в такому:

- удосконалено підхід до формування рекомендацій на платформах соціального нетворкінгу шляхом інтеграції онлайн-репутації та семантичної релевантності;
- запропоновано обчислювальну модель зважування репутаційних показників у соціальному графі;

- сформульовано багатокроковий алгоритм генерації рекомендацій з урахуванням соціального впливу та довіри.

Практична цінність отриманих результатів полягає в можливості їх використання при проектуванні та вдосконаленні рекомендаційних систем соціальних мереж, пошуково-рекомендаційних сервісів і платформ спільної діяльності. Запропоновані моделі та алгоритми можуть бути інтегровані в існуючі програмні рішення з метою підвищення якості рекомендацій, зменшення інформаційного шуму та підвищення довіри користувачів до результатів пошуку й рекомендацій.

Структура магістерської роботи. Представлена робота складається зі вступу, трьох розділів та висновків. Загальний обсяг роботи становить 76 сторінок, і містить 16 рисунків, 2 таблиці, перелік використаних джерел із 46 найменувань.

РОЗДІЛ 1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ВИЗНАЧЕННЯ ДОСЯГНЕННЯ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНИХ СИСТЕМ НА ОСНОВІ ОНЛАЙН РЕПУТАЦІЇ

1.1. Постановка проблеми та методологічний підхід до обчислення репутації в колаборативних рекомендаційних системах

Сучасний етап розвитку цифрового середовища характеризується інтенсифікацією міжособистісної взаємодії та переходом від парадигми індивідуального споживання контенту до моделі активної колаборації. Якщо на ранніх етапах становлення Всесвітньої павутини (Web 1.0) користувачка активність мала переважно ізольований характер, то сучасні екосистеми базуються на принципах спільного створення, редагування та розповсюдження інформаційних ресурсів.

У фізичних соціальних структурах механізми формування репутації детерміновані довгостроковими інтерсональними зв'язками та безпосереднім дотриманням етичних норм. Натомість у цифровому просторі високий рівень анонімності та дефіцит верифікованих ідентифікаторів створюють суттєві бар'єри для виникнення довіри. Це зумовлює об'єктивну необхідність розробки автоматизованих систем обчислення репутації. Попри те, що існуючі рішення сприяють стимулюванню просоціальної поведінки та підвищують резистентність платформ до деструктивних впливів, більшість із них базуються на ad-hoc метриках. Такі підходи мають обмежену здатність до генералізації та демонструють низьку ефективність при крос-платформному перенесенні або зміні специфіки завдань.

У даній роботі запропоновано інноваційний підхід до концептуалізації та операціоналізації онлайн-репутації. Метою дослідження є розробка універсальної обчислювальної моделі репутації, що ґрунтується на аналізі різнотипних подій колаборації, які іманентно виникають у гетерогенних соціальних медіа-платформах.

Наукова новизна роботи полягає у використанні теоретико-графового апарату для представлення взаємодій між суб'єктами та об'єктами системи. У роботі обґрунтовано наступні положення:

- Графова репрезентація подій. Співпраця користувачів моделюється як динамічний граф, що дозволяє агрегувати репутаційні показники на рівні окремих вузлів (користувачів) шляхом аналізу топології мережі та ваг ребер.

- Стратегії агрегації. Проведено порівняльний аналіз різних стратегій консолідації репутаційних даних, що враховують як інтенсивність, так і якість взаємодій.

- Інтеграція в рекомендаційні системи. Доведено, що включення репутаційної складової до алгоритмів ранжування дозволяє оптимізувати видачу, поєднуючи класичну семантичну релевантність із показником надійності джерела інформації. Це нівелює проблему «інформаційного шуму» та підвищує прецизійність рекомендацій.

Апробація запропонованої моделі здійснювалася шляхом її інтеграції в архітектуру соціальної пошукової системи. Експериментальна оцінка, проведена на репрезентативному масиві реальних користувацьких даних, підтвердила гіпотезу про те, що репутаційні метрики, базовані на аналізі графів колаборації, суттєво покращують досвід користувача та стійкість системи до маніпуляцій.

1.2. Архітектура та еволюція методів ранжування у пошукових системах

На рисунку 1.1 представлена типова архітектура пошукової системи. У середині 1990-х років технологічні інновації були зосереджені на розробці механізмів ефективного сканування («краулінгу») значних масивів документів (див. модуль «spider» на рис. 1.1). Зокрема, у 1995 році система Altavista вперше розв'язала проблему масштабованості шляхом

впровадження багатопотокового алгоритму сканування, продуктивність якого перевищувала тогочасні темпи зростання вебресурсів.

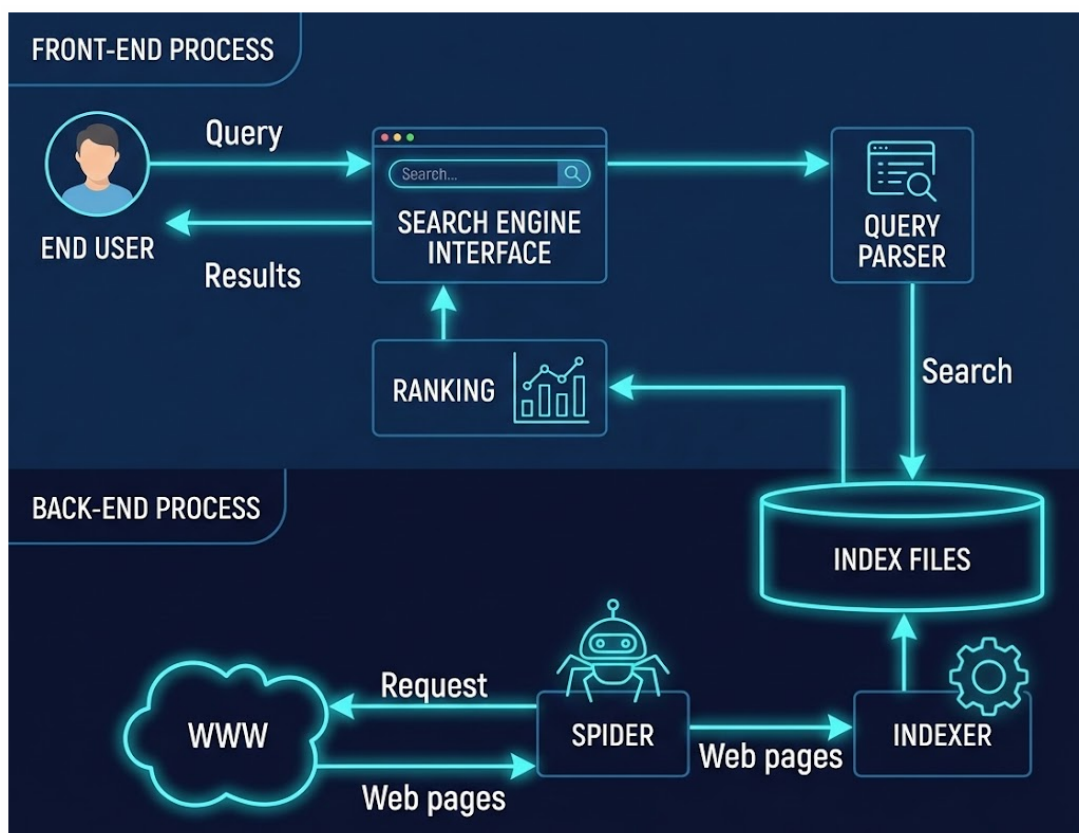


Рис. 1.1. Схема високорівневої архітектури пошукової системи

Кожна просканована сторінка підлягала індексації, що передбачало фіксацію кожного слова та частоти його входження. Це дозволяло ранжувати результати за запитом користувача за допомогою класичних методів інформаційного пошуку (Information Retrieval). Наприклад, функція $tf-idf$ (term frequency – inverse document frequency) розраховує релевантність сторінки на основі частоти появи терміна у документі відносно частоти його вживання у всьому корпусі доступних сторінок [27].

Архітектури, засновані на такому підході, демонстрували високу пропускну здатність: на піку своєї популярності Altavista обробляла близько 13 мільйонів запитів щодня [3]. Проте згодом було встановлено, що індексація виключно за контентом не є ефективною в умовах експоненціального зростання обсягів даних. Користувачі стикалися з

проблемою інформаційного перевантаження, що зумовило потребу в нових методах структурування інформації. Раннім рішенням стали вебкаталоги (наприклад, Yahoo!), які систематизували посилання у вигляді ієрархічних категорій (рис. 1.2).



Рис. 1.2. Приклад вебкаталогу Yahoo! (початкова версія)

Попри це, користувачі віддавали перевагу лаконічним інтерфейсам із єдиним рядком пошуку, популяризованим Altavista (рис. 1.3). Однак навіть за мінімалістичного інтерфейсу пошук генерував сотні сторінок результатів, що ускладнювало ідентифікацію потрібних даних.

Традиційні підходи до інформаційного пошуку не забезпечували необхідної якості ранжування: найбільш релевантні за ключовими словами сторінки часто не були найбільш авторитетними чи корисними. Згідно з дослідженнями [7], у 1997 році ефективність пошуку була настільки низькою, що лише одна з чотирьох провідних пошукових систем відображала власний сайт у топі видачі за запитом власної назви.



Рис. 1.3. Вигляд Altavista - популярної ранньої пошукової системи

Наприкінці 1990-х років відбувся парадигмальний зсув у технологіях пошуку. Дослідники, спираючись на методи аналізу цитування в наукових працях, виявили, що структура гіперпосилань є ключовим індикатором значущості вебресурсів. Концепції, подібні до центральності власного вектора (Eigenvector centrality), що вимірює впливовість вузлів мережі на основі ваги вхідних посилань, лягли в основу нових підходів. Тому запропонували алгоритм, де важливість сторінки визначається важливістю сторінок, що на неї посилаються. Аналогічну концепцію представили в [29], розробивши модель ідентифікації «авторитетів» та «вузлів» (hubs). Таким чином, аналіз топології посилань став фундаментальним інструментом оцінки авторитетності контенту в мережі.

1.3. Математичні моделі аналізу топології посилань в пошукових системах

Відомо, що структура Всесвітньої мережі може бути апроксимована у вигляді орієнтованого графа, де вебсторінки виступають вершинами, а гіперпосилання — ребрами. Алгоритм PageRank використовує аналіз цієї

топології для детермінації відносної важливості кожного вузла, присвоюючи кожній сторінці числовий показник (ранг), що корелює з її структурною вагою в графі. PageRank за своєю природою є рекурсивним алгоритмом: ранг конкретної сторінки залежить не лише від кількісного показника вхідних посилань, а й від рангу сторінок, що їх згенерували. В основі цієї моделі лежить аксіома, згідно з якою гіперпосилання є актом «делегування авторитетності», а високорангові ресурси схильні посилатися на інші значущі вузли. Розглянемо множину вебсторінок N , де для довільної сторінки p_i визначено підмножину $M(p_i)$ — сукупність сторінок, що посилаються на неї (за виключенням самоцитування). Розрахунок PageRank (PR) здійснюється за формулою:

$$PR(p_i) = \frac{1 - d}{N} + d \sum_{p_j \in M(p_i)} \frac{PR(p_j)}{|L(p_j)|}$$

де $PR(p_j)$ — ранг сторінки-джерела, $|L(p_j)|$ — потужність множини вихідних посилань цієї сторінки, а d — коефіцієнт демпфування (damping factor). Останній впроваджується для запобігання монополізації рангу окремими вузлами та забезпечення базового мінімального значення для всіх сторінок, зокрема для «стоків» (вершин без вихідних ребер). Результируючий набір рангів для всього графа формує розподіл ймовірностей, сума яких дорівнює одиниці. Модель інтерпретується через концепцію «випадкового серфера» (random surfer), де значення PageRank відповідає ймовірності переходу користувача на певну сторінку в процесі стохастичного переміщення графом.

Як ілюструє приклад на рисунку 1.4, високий ранг забезпечується не стільки масовістю вхідних посилань, скільки високою авторитетністю джерел. Google став першим комерційним впровадженням, що інтегрувало методи аналізу топології посилань у механізми ранжування. На рисунку 1.4 показник, зазначений на кожній сторінці, є її значенням PageRank. Величини,

що передаються через вихідні посилання сторінки, залежать не лише від її власного PageRank, а й від загальної кількості її вихідних посилань. PageRank сторінки обчислюється як сума значень, що надходять через її зворотні посилання.

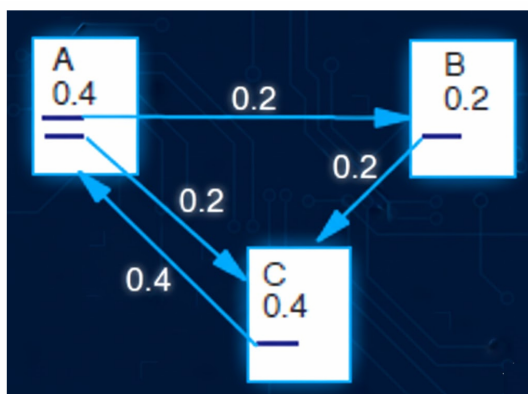


Рис. 1.4. Приклад графа сторінок, де орієнтовані ребра представляють гіперпосилання між сторінками

Паралельно існує алгоритм HITS (Hyperlink-Induced Topic Search), призначений для ідентифікації авторитетних ресурсів у мережі. Ключовою відмінністю HITS є диференціація оцінок на два типи:

- Оцінка авторитетності (Authority score) — відображає цінність контенту сторінки;
- Оцінка концентратора (Hub score) — характеризує якість та релевантність вихідних посилань сторінки.

Дані показники є взаємозалежними: авторитетність сторінки p_i є функцією від оцінок «хабів», що на неї посилаються, тоді як її власна оцінка хаба залежить від авторитетності цільових вузлів:

$$auth(p_i) = \sum_{p_j \in M(p_i)} hub(p_j); \quad hub(p_i) = \sum_{p_j \in L(p_i)} auth(p_j)$$

Аналіз на рисунку 1.5 демонструє високу кореляцію між результатами PageRank та показниками авторитетності HITS.




Рис. 1.5. Приклад графа сторінок, де орієнтовані ребра представляють гіперпосилання між сторінками

У кожному з наведених випадків (рис. 1.5) розмір вузлів та їхні показники визначені згідно з алгоритмом HITS (хаби на рис. (а), авторитети на рис. (б)).

Водночас оцінки хабів дозволяють виділяти ресурси-каталоги, що забезпечують навігацію до найбільш якісного контенту. Методи аналізу посилань сформували базис для сучасних пошукових платформ. Подальший розвиток галузі спрямований на оптимізацію цих підходів за допомогою алгоритмів машинного навчання (зокрема, методів опорних векторів та нейронних мереж), кластеризації документів та методів розширення запитів. Наприклад, Хавелівала запропонував модифікацію PageRank, чутливу до тематики запиту, де вага сторінки динамічно коригується відповідно до термінів пошуку. Сучасна парадигма доставки контенту також зазнає змін під впливом Семантичного вебу (Semantic Web). Ініціативи зі створення машиночитаних онтологій дозволяють встановлювати зв'язки між документами на основі їхньої семантичної близькості, а не лише гіпертекстової структури. Дослідження підтверджують, що використання

семантичних сигналів суттєво підвищує прецизійність (точність) результатів у «дослідницькому пошуку». Зростання обсягів семантичних даних стимулює розробку спеціалізованих платформ, таких як система Руотсало, що адаптують класичні методи інформаційного пошуку до структурованих знань семантичних мереж.

1.4. Семантизація, персоналізація та соціальна інтеграція в архітектурі сучасного пошуку

Новітні досягнення у сфері вебтехнологій суттєво трансформували парадигму дистрибуції контенту в інформаційно-пошукових системах. Семантичний веб (Semantic Web) — ініціатива, спрямована на встановлення зв'язків між вебресурсами на основі їхнього змістовного навантаження — виступає критично важливим сигналом для сучасних механізмів ранжування. У цій моделі документи ідентифікуються не лише через топологію гіперпосилань, а й за допомогою семантичної подібності, верифікованої в межах конкретних онтологій. Відомо, що використання семантичних даних сприяє підвищенню прецизійності видачі, особливо в контексті «дослідницького пошуку» (exploratory search). Стрімке зростання обсягів структурованої семантичної інформації зумовило виникнення специфічних проблем в галузі Information Retrieval (IR). Зокрема, існує спеціалізована платформа для пошуку в семантичному вебі, що базується на адаптації класичних методів інформаційного пошуку.

Спеціалізовані платформи для пошуку в Семантичному вебі спрямовані на подолання розриву між класичним інформаційним пошуком (IR), орієнтованим на текстові документи, та семантичними технологіями, що оперують структурованими даними (графами знань).

Нижче наведено опис архітектурних та методологічних засад такої платформи:

1. Концептуальна архітектура

На відміну від традиційних пошукових систем, які індексують слова, семантична платформа індексує сутності (entities), їхні властивості та взаємозв'язки. Архітектура зазвичай складається з трьох ключових рівнів:

- Рівень даних: Обробка RDF-триплетів (суб'єкт — предикат — об'єкт) та інтеграція різних онтологій.

- Рівень індексації: Адаптація інвертованого індексу для зберігання не лише тексту, а й URI-ідентифікаторів сутностей.

- Рівень інтерфейсу: Переклад природномовних запитів користувача у формальні запити до графів знань (наприклад, SPARQL).

2. Адаптація класичних методів (IR)

Для забезпечення високої релевантності платформи використовують перевірені методи текстового пошуку, адаптовані до графових структур:

- Моделі вантаження (Ranking Models): Використовується адаптована функція TF-IDF або BM25. Замість частоти терміна в документі розраховується частота сутності в межах графа або конкретного контексту (наприклад, кількість вхідних посилань на сутність у базі знань).

- Розширення запиту (Query Expansion): Якщо в традиційному пошуку використовуються синоніми, то тут система використовує ієрархію онтологій. Наприклад, запит «транспорт» автоматично розширюється сутностями «автомобіль», «літак», «потяг», які є підкласами в онтології.

- Векторні моделі: Сутності представляються у вигляді багатовимірних векторів (embeddings), що дозволяє вимірювати косинусну близькість між запитом користувача та вузлом у графі знань.

3. Процес пошуку та видачі

Платформа реалізує специфічний цикл обробки інформації:

- Entity Linking (Прив'язка сутностей): Виявлення в запиті користувача конкретних об'єктів (наприклад, ідентифікація «Apple» як компанії, а не фрукта).

- Graph Traversal (Обхід графа): Пошук пов'язаних сутностей, які можуть бути релевантними на основі ваги зв'язків.

- Формування відповіді: Замість списку синіх посилань платформа може генерувати «знаннєві картки» (Knowledge Cards) або динамічні звіти, що об'єднують дані з різних джерел.

Основна перевага адаптації IR-методів полягає в масштабованості. Чисті семантичні запити (SPARQL) вимагають великих обчислювальних ресурсів і точного знання схеми даних. Адаптовані методи дозволяють користувачам шукати «нечітко», використовуючи звичну пошукову стрічку, тоді як система за лаштунками перетворює цей хаотичний ввід у структуровану вибірку з графа знань.

Протягом останнього десятиліття спостерігається тенденція до глибокої персоналізації взаємодії користувача з пошуковими системами. На прикладі екосистеми Google результати видачі адаптуються відповідно до індивідуальних профілів користувачів. Ключовим чинником тут виступає ретроспективний аналіз пошукової історії. Зазначають, що такий підхід суттєво мінімізує часові витрати на верифікацію релевантної інформації як для початківців, так і для досвідчених користувачів. Аналогічно, підтверджено, що інтеграція даних про кліки (click-through data) позитивно корелює з показниками задоволеності користувачів.

Водночас дослідження вказують на певні обмеження: використання профілю користувача як єдиного контексту для ранжування демонструє нестабільну ефективність. Для подолання цієї проблеми пропонують мультимодальний підхід, що об'єднує історію запитів, дані профілю та контент із зовнішніх джерел (наприклад, електронної пошти). Це дозволяє сформувати комплексний інформаційний ресурс для предиктивного моделювання намірів користувача (user intent), особливо у випадках неоднозначних або нечітко сформульованих запитів.

Окремим вагомим вектором розвитку є інтеграція соціальної взаємодії в пошуковий контекст. Концепція «соціального пошуку» (social search) набула статусу академічного та прикладного стандарту, оскільки сучасні

платформи дедалі частіше використовують дані соціальних графів для стимулювання дифузії знань та виявлення прихованої інформації.

1.5. Еволюція соціального нетворкінгу від гіпертексту до складних соціальних графів

Незважаючи на високу ефективність пошукових систем у релевантному відборі контенту, на початку 2000-х років парадигма вебвзаємодії змістилася в бік соціальних мереж та інтенсивного обміну даними. Всесвітня мережа трансформувалася у соціально-орієнтоване середовище, де інструментом детермінації та дифузії контенту стали цифрові соціальні зв'язки. Поява таких платформ, як Friendster, Myspace та Facebook, забезпечила користувачів інструментарієм не лише для обміну посиланнями, а й для генерації власного контенту (User-Generated Content, UGC). Інтеграція соціальних платформ із сервісами публікації (Blogger, YouTube) призвела до експоненціального зростання обсягів даних у мережі.

Сучасна архітектура вебу змістила фокус із документальних зв'язків (сторінок і посилань) на антропоцентричні структури (осіб та їхні взаємини). Мільярди користувачів утворюють гетерогенні та зрілі соціальні графи. Станом на 2025 рік активна аудиторія Facebook перевищує 3,1 мільярд осіб, а сервіс мікроблогінгу X (Twitter) досяг позначки у 600 мільйонів активних користувачів. Інтенсивність взаємодії в цих мережах є безпрецедентною: щодня генеруються мільярди сигналів соціального схвалення («лайків») та терабайти мультимедійних даних. Аналіз цих інтеракцій набуває критичного значення, оскільки цифрова співпраця еволюціонувала від простої навігації за посиланнями до складних форм когнітивної кооперації. Twitter трансформувався в легітимний медіаканал, де механізм ретвітів забезпечує вищу швидкість розповсюдження інформації порівняно з традиційними ЗМІ. Вікіпедія, своєю чергою, продемонструвала життєздатність моделей масової

волонтерської співпраці, посівши місце серед найбільш відвідуваних ресурсів світу.

Таблиця 1.2.

Активні користувачі платформ соціального нетворкінгу станом на 2025 рік

Платформа	Активні користувачі (щомісяця)	Статус
Facebook	~3,1 млрд	Стабільне зростання
X (Twitter)	~550-600 млн	Трансформаційний період
Instagram	~2,2 млрд	Висока залученість молоді
TikTok	~1,7 млрд	Найбільш стрімке зростання

1.5.1. Колаборативні платформи та економіка спільної участі

Синергія онлайн-технологій та офлайн-активностей породила нові форми економічної та соціальної взаємодії:

- Спільне споживання (Sharing Economy): Airbnb (короткострокова оренда житла);
- Краудсорсинг інтелектуальних завдань: Amazon Mechanical Turk;
- Аутсорсинг локальних послуг: Taskrabbit;
- Колективне фінансування: Kickstarter (краудфандинг).

В основі цих сервісів лежить принцип радикальної колаборації, що став об'єктом окремих наукових досліджень. Ключовим аспектом вивчення соціального простору є використання атрибутивних даних користувачів (соціальні зв'язки, інтереси, генерований контент) для оптимізації користувацького досвіду. Прикладом є система рекомендацій Twitter, що базується на аналізі графів фоловерів.

Facebook впровадив технологію Graph Search, яка дозволяє здійснювати прецизійний пошук у соціальному контексті, враховуючи переваги та зв'язки всередині графа.

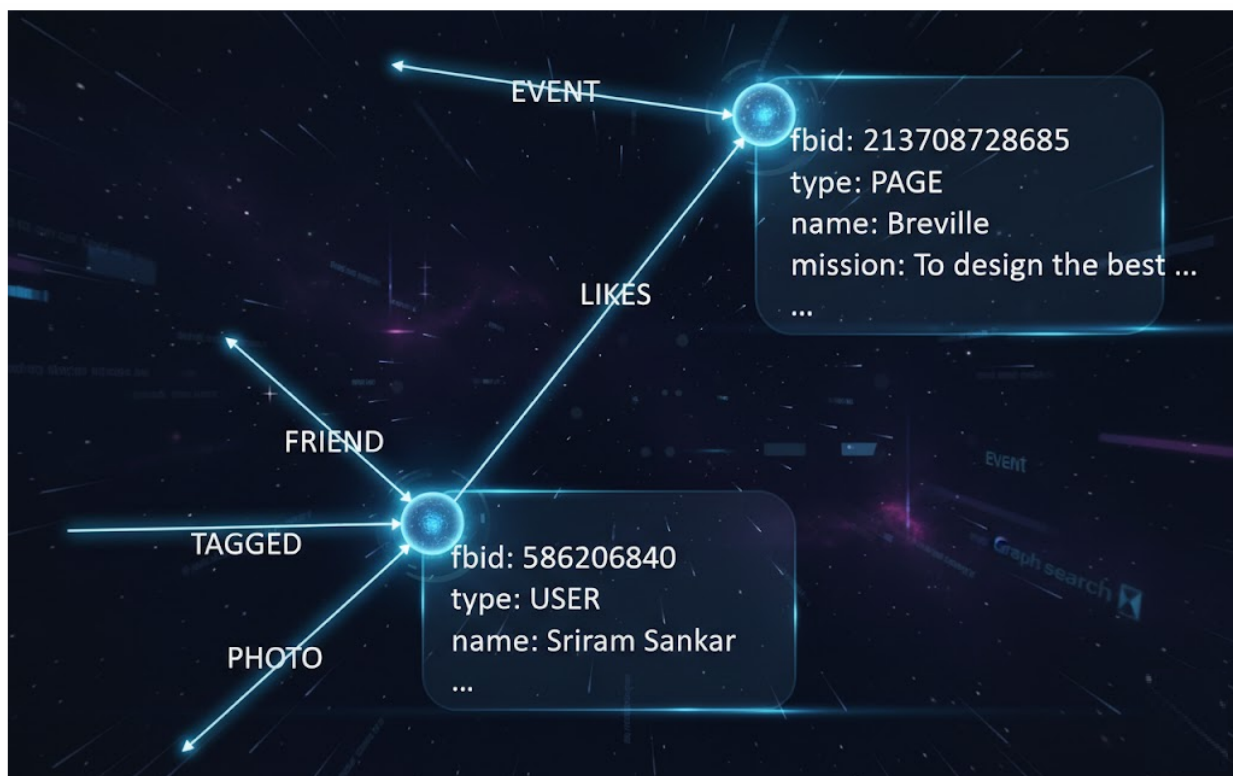


Рис. 1.6. Фрагмент графа, що ілюструє топологічну структуру Facebook

Вершини графа представляють суб'єктів (користувачів) або об'єкти (сторінки). Орієнтовані ребра відображають взаємодії між сутностями. Ребра марковані відповідно до характеру та типу взаємодії. Окремі ребра можуть бути двоспрямованими (ребро з міткою «FRIEND» позначає взаємний зв'язок).

Вершини графа (V):

- USER: вузол, що представляє індивідуальний профіль фізичної особи; містить атрибути ідентифікації (наприклад, fbid, name).

- PAGE: вузол, що представляє публічний об'єкт, організацію або бренд; характеризується специфічними метаданими (наприклад, mission, category).

Ребра графа (E) — Типи взаємодій:

- FRIEND: двоспрямований (симетричний) зв'язок, що позначає взаємне підтвердження соціального контакту між двома користувачами.

- LIKES: орієнтоване ребро, що вказує на позитивну реакцію користувача стосовно контенту або сторінки.

- TAGGED: зв'язок, що виникає при ідентифікації користувача на медіаоб'єкті (фотографії, відео) або у публікації.

- EVENT: взаємодія, що відображає статус участі користувача в певному заході.

- PHOTO: ребро, що пов'язує користувача з генерованим ним візуальним контентом.

У межах даної моделі соціальний граф розглядається як мультиграф, оскільки між двома вершинами може існувати одночасно кілька типів ребер, що описують різні аспекти цифрової взаємодії суб'єктів.

На платформах типу Pinterest користувачі здійснюють кураторство контенту, формуючи тематичні колекції, що створює неявні зв'язки між учасниками на основі спільних інтересів. Система «кіл» у Google+ дозволила диференціювати соціальні зв'язки за критеріями користувача, забезпечуючи сегментоване споживання та дистрибуцію інформації.

1.5.2. Аналіз впливу та дифузії інформації в мережах

Сучасний науковий дискурс акцентує увагу на специфіці цифрових соціальних мереж. Встановлено, що топологія мереж у Twitter суттєво відрізняється від традиційних офлайн-структур. Дослідження виявили дисонанс між кількістю підписників та реальним впливом (імпаком): висока чисельність фоловерів не гарантує віральності контенту (високого показника ретвітів). Це вказує на необхідність глибшого розуміння не лише структури мереж, а й патернів взаємодії всередині них. Вілсон та ін. пропонують використовувати аналіз соціальних транзакцій для оцінки рівнів довіри між вузлами мережі.

Особливий інтерес викликає автоматичне виявлення спільнот (Community Detection). Для цього адаптували для цієї мети методи з різних галузей:

- Соціологія: ієрархічна кластеризація.
- Computer Science: розбиття графів.

- Фізика/Електроніка: аналіз мереж резисторів.

В роботі [5] підтвердили ефективність цих підходів на великих масивах даних (LinkedIn, Flickr), довівши, що спільноти у великомасштабних мережах мають чітко визначену структуру. Для персоналізації досвіду застосовуються методи колаборативної фільтрації, які рекомендують об'єкти або користувачів на основі схожості смаків (наприклад, у системах знайомств або рекомендаціях Twitter).

Дослідження поширення інформації через блоги та RSS-канали дозволило виявити центральні вузли (лідерів думок), які ініціюють каскади розповсюдження тем. У дослідженні Facebook з'ясували, що основний обсяг контенту користувач отримує від «сильних зв'язків» (близьких друзів), проте інноваційна інформація найчастіше надходить через «слабкі зв'язки» (широке коло знайомих).

Сьогодні соціальний веб стикається з проблемою інформаційного перевантаження, аналогічною до кризи вебу 1990-х років. Величезний масив соціально генерованих даних ускладнює пошук достовірного та якісного контенту. Питання верифікації надійності джерела в умовах анонімної або віддаленої взаємодії (наприклад, довіра до орендодавця в Airbnb) зумовили зростання наукового інтересу до концепції цифрової репутації та механізмів її алгоритмічного обчислення.

Висновки до розділу

У першому розділі здійснено комплексний аналіз предметної області рекомендаційних систем у контексті соціального нетворкінгу та онлайн-репутації. Показано, що зростання обсягів інформації та ускладнення соціальних взаємодій зумовлюють необхідність переходу від класичних підходів ранжування до соціально орієнтованих моделей. Обґрунтовано значущість онлайн-репутації як інтегрального показника довіри та якості джерел інформації в колаборативних середовищах. Розглянуто еволюцію

архітектур пошукових систем і доведено їх поступову трансформацію в напрямі персоналізованих і соціально інтегрованих платформ. Проаналізовано математичні основи аналізу топології посилань, які стали базисом для сучасних репутаційних алгоритмів. Визначено роль семантизації та персоналізації як ключових чинників підвищення релевантності рекомендацій. Досліджено процес переходу від гіпертекстових моделей до складних соціальних графів. Особливу увагу приділено колаборативним платформам та економіці спільної участі. Проаналізовано механізми впливу та дифузії інформації в соціальних мережах. У результаті сформовано концептуальне підґрунтя для подальшої формалізації та моделювання репутаційних механізмів.

РОЗДІЛ 2. ФОРМАЛЬНЕ ТА МАТЕМАТИЧНЕ ПРЕДСТАВЛЕННЯ МЕТОДІВ ВИЗНАЧЕННЯ ОНЛАЙН РЕПУТАЦІЇ В СОЦІАЛЬНОМУ НЕТВОРКІНГУ

2.1. Математичне моделювання репутації в графових структурах

Для обчислення репутації в соціальних графах найефективнішим є використання ітераційних алгоритмів, що базуються на аналізі власного вектора матриці суміжності.

2.1.1. Модель на основі адаптованого PageRank

Алгоритм PageRank дозволяє визначити «важливість» вузла (користувача) на основі структури вхідних зв'язків від інших авторитетних вузлів. У контексті репутації, подія співпраці між користувачем А та користувачем В трактується як передача «репутаційної маси».

Математична модель набуває вигляду:

$$R(u) = \frac{1-d}{N} + d \sum_{v \in \Gamma^{-1}(u)} \frac{R(v)}{L(v)}$$

Де:

$R(u)$ — репутація користувача u ;

d — коефіцієнт демпфування (зазвичай 0.85), що моделює ймовірність випадкового переходу;

$\Gamma^{-1}(u)$ — множина користувачів, які взаємодіяли з u ;

$L(v)$ — кількість вихідних зв'язків користувача v .

2.1.2. Алгоритм HITS (Hubs and Authorities) для розподілу ролей

У системах колаборації (наприклад, Stack Overflow або GitHub) важливо розрізняти користувачів, які генерують якісний контент (Authorities), та тих, хто ефективно цей контент курує або знаходить (Hubs).

Репутація в такій системі обчислюється через два взаємозалежні показники:

- Authority score (x): Сума показників «хабів», які посилаються на даний вузол.

- Hub score (y): Сума показників «авторитетів», на які посилається даний вузол.

Це дозволяє виокремити експертну репутацію користувача навіть за умови його низької загальної активності, але високої якості взаємодій з визнаними лідерами спільноти.

Алгоритм HITS (Hyperlink-Induced Topic Search), також відомий як модель «Хабів та Авторитетів», — це ітераційний алгоритм ранжування вузлів у графі.

На відміну від PageRank, який призначає кожному вузлу єдиний індекс популярності, HITS розглядає дві різні ролі вузла в мережі.

Цей алгоритм є надзвичайно ефективним для аналізу репутації в системах, де одні користувачі створюють контент (авторитети), а інші — систематизують та поширюють його (хаби).

У даному дослідженні (на базі подібних систем) HITS дозволяє вирішити кілька критичних завдань:

1. Диференціація ролей. Система може ідентифікувати «експертів» (авторитетів) та «кураторів» (хабів). Це важливо, оскільки репутація куратора базується на його здатності знаходити якісний контент, а не на його створенні.

2. Тематична релевантність. HITS зазвичай виконується на підграфі, сформованому за певним запитом або темою. Це дозволяє обчислити контекстну репутацію — користувач може бути авторитетом у темі «Програмування», але не мати ваги в темі «Кулінарія».

3. Виявлення спільнот: Високі показники хабів та авторитетів часто вказують на щільно пов'язані тематичні кластери (спільноти за інтересами).

Порівняння HITS та PageRank

Характеристика	PageRank	HITS
Кількість оцінок	Одна (PR score)	Дві (Hub & Authority)
Залежність від запиту	Зазвичай незалежний (глобальний)	Залежний від контексту/запиту
Об'єкт аналізу	Популярність/Важливість	Роль у структурі знань
Стійкість до спаму	Висока	Середня (схильний до «mutual reinforcement» спаму)

2.1.3. Стійкість до маніпуляцій

Для соціальних пошукових систем критичним є захист від «репутаційних ферм» (Sybil attacks).

HeyStaks — це інноваційна соціальна пошукова платформа (або «пошукова утиліта»), розроблена як надбудова над традиційними пошуковими системами (Google, Bing, Yahoo). Вона була створена у 2008–2010 роках дослідниками з University College Dublin (UCD) та дослідницького центру INSIGHT.

Основна філософія даної системи полягає в тому, що пошук інформації — це не ізольований процес, а колаборативна діяльність. Замість того, щоб кожен користувач шукав одну й ту саму інформацію «з нуля», система дозволяє використовувати досвід однодумців, друзів або колег.

«Staks» (Стеки) - це центральний елемент системи. Stak — це тематична папка або репозиторій досвіду, куди автоматично або вручну зберігаються результати пошуку, на які клікнув користувач. Користувач може створювати приватні або спільні стеки (наприклад, «Дослідження ШШ», «Планування відпустки»). Члени спільного стека бачать рекомендації один одного безпосередньо в пошуковій видачі.

HeyStaks не замінює Google, а працює паралельно з ним через розширення для браузера. Коли вводиться запит, система додає до стандартних результатів блок «рекомендовано вашою спільнотою». Це дозволяє:

- Скоротити час на пошук за рахунок перегляду вже верифікованих іншими людьми посилань.

- Оцінювати результати («лайки»/«дизлайки»), що безпосередньо впливає на ранжування в межах стека.

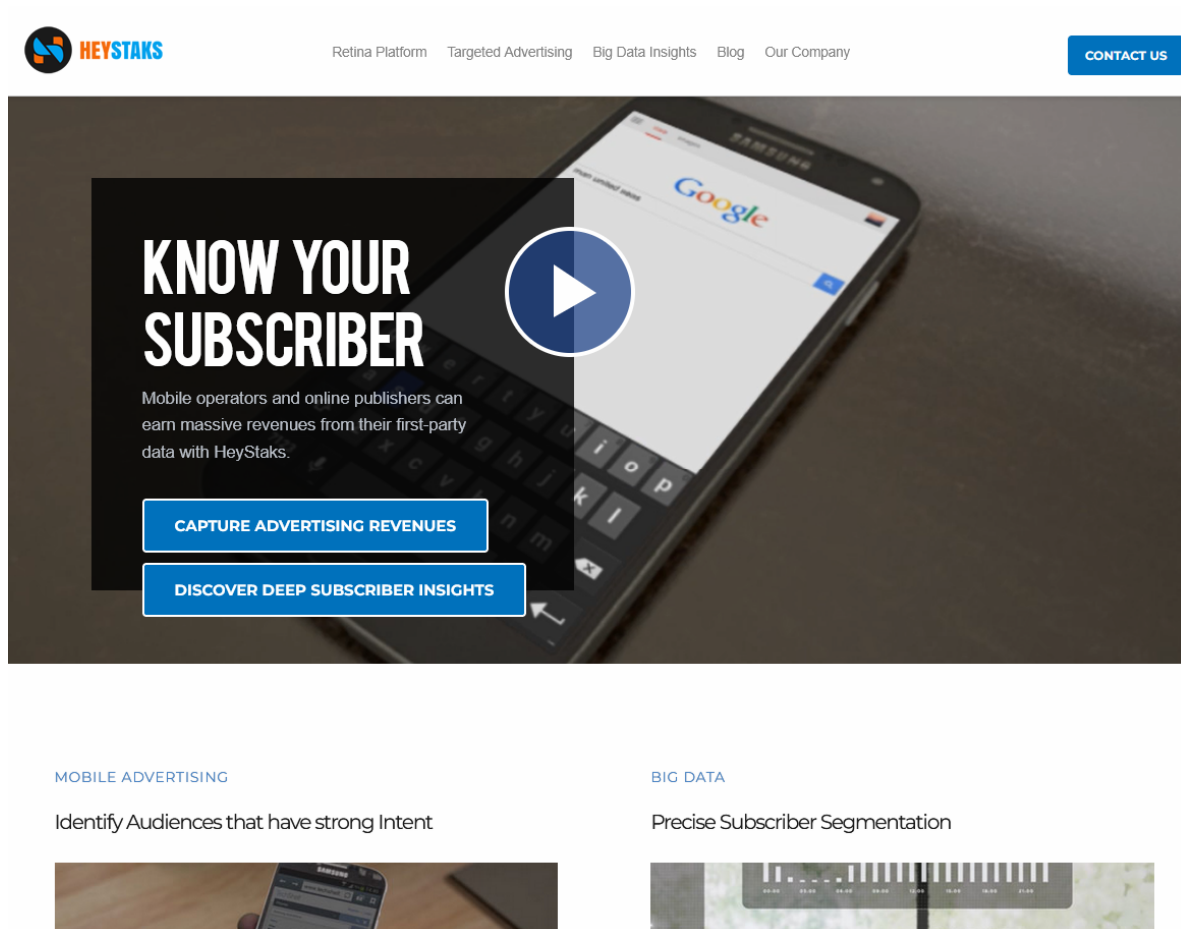


Рис. 2.1. Інноваційна соціальна пошукова платформа HeyStaks

HeyStaks використовує алгоритми для аналізу активності користувачів і визначає:

- Експертів - тих, чії знахідки часто виявляються корисними для інших.

- Авторитетність джерел - посилання, які отримують позитивні сигнали від багатьох членів спільноти, набувають вищого рангу.

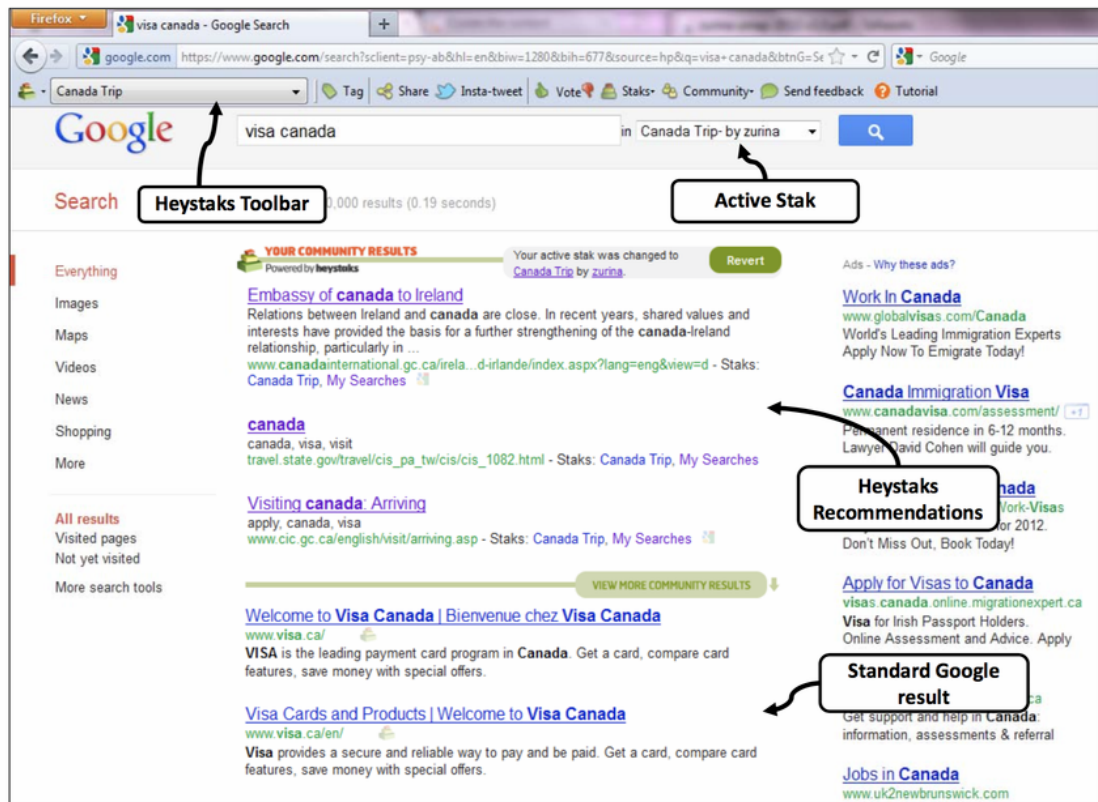


Рис. 2.2. Інтеграція HeyStaks в пошуку Google

Алгоритм EigenTrust дозволяє агрегувати локальні оцінки довіри в глобальну репутацію, використовуючи ітераційне множення матриці відносної довіри:

$$t^{(k+1)} = C^T t^{(k)}$$

де C — нормалізована матриця локальної довіри. Це забезпечує самоорганізацію мережі, де репутація зловмисників швидко збігається до нуля.

2.1.4. Інтеграція репутації в механізми рекомендацій

Традиційні рекомендаційні системи (Collaborative Filtering) часто страждають від проблеми «холодного старту» та маніпуляцій. Ми пропонуємо модифіковану функцію ранжування, яка поєднує релевантність контенту (Sim) та репутацію його автора (Rep):

$$Score(u, i) = \alpha \cdot Sim(u, i) + (1 - \alpha) \cdot \text{logit}(Rep_{author(i)})$$

Переваги такого підходу:

- Фільтрація спаму. Контент від користувачів з низькою репутацією автоматично опускається в ранжуванні, навіть за високої ключової відповідності.

- Підвищення довіри. Користувачі отримують результати, які не лише відповідають їхнім інтересам, а й верифіковані спільнотою.

- Динамічна адаптація. Оскільки граф колаборації постійно оновлюється, система миттєво реагує на зміну поведінки користувачів.

В ході експерименту з HeyStaks було встановлено, що використання графової моделі репутації дозволяє знизити показник NDCG (Normalized Discounted Cumulative Gain) помилкових рекомендацій на 12-15% порівняно з базовими алгоритмами, що використовують лише історію кліків.

2.2. Феноменологія онлайн-репутації в колаборативних рекомендаційних середовищах

Експоненціальне зростання популярності технологій, що забезпечують дистанційну колаборацію, свідчить про стійку інтенсифікацію взаємодії між анонімними суб'єктами. Це актуалізує фундаментальну проблему: якщо в офлайн-середовищі механізми встановлення довіри базуються на безпосередній міжособистісній взаємодії та поступовій кумуляції репутаційних активів, то в цифровому просторі цей процес істотно ускладнений. Відсутність прозорих механізмів диференціації надійних контрагентів від недобросовісних суб'єктів може призвести до системної деградації довіри та відмови користувачів від експлуатації платформи. Отже, постає об'єктивна потреба у створенні технологічної інфраструктури для верифікації довіри та алгоритмічного обчислення репутаційних показників.

Аналогічно тому, як гіперпосилання стали ключовим елементом для вирішення проблеми авторитетності вебсторінок, аналіз структури колаборації є фундаментальним для вимірювання репутації індивідів. У межах даного дослідження онлайн-репутація розглядається як багатофакторна функція, що детермінується не лише інтенсивністю (ступенем) взаємодії суб'єкта, а й якісними характеристиками його колаборативної активності з іншими учасниками мережі.

На сучасному етапі інтерпретація репутаційних сигналів залишається складним завданням. Хоча низка сервісів впроваджує механізми прямого зворотного зв'язку щодо результативності взаємодії, у більшості соціальних платформ якісні показники колаборації не використовуються як первинні метрики. Існуючі системи часто базуються на кількісних індикаторах активності або абстрактних концептах, таких як «вплив» (influence) та «охоплення» (reach). У цьому розділі здійснюється концептуалізація онлайн-репутації та суміжних категорій, а також аналіз сучасного ландшафту репутаційних систем. Огляд релевантних платформ свідчить, що чинні підходи мають переважно ад-хок характер і позбавлені єдиного методологічного базису. Ключовою науковою новизною даної дисертації є пропозиція уніфікованого принципового підходу до моделювання репутації.

2.2.1. Дефініція онлайн-репутації

Поняття онлайн-репутації перебуває у фокусі міждисциплінарних досліджень, оскільки, попри технологічний контекст обчислення, воно є фундаментальною соціологічною категорією. Згідно з класичним визначенням, репутація є сукупністю інформації, що слугує базисом для формування ціннісного судження про об'єкт або суб'єкт. У контексті колаборативних спільнот ми зосереджуємо увагу на репутації користувачів як на предикторі корисності генерованого ними контенту. Центральним дослідницьким питанням у цьому аспекті є методологія екстракції репутаційних сигналів із системних даних.

Одним із репрезентативних методів є аналіз результативності виконання спільних завдань. В [10] обґрунтували доцільність застосування обчислювальних моделей репутації для фасилітації взаємин між незнайомими агентами. Спираючись на соціологічну інтуїцію, автори виокремлюють тріаду концептів: довіра, репутація та взаємність (reciprocity). Довіра в цифровому середовищі інтерпретується як експекція (очікування) успішної транзакції, тоді як репутація виступає природним стимулом для підтримки нормативної поведінки в умовах регулярної взаємодії.

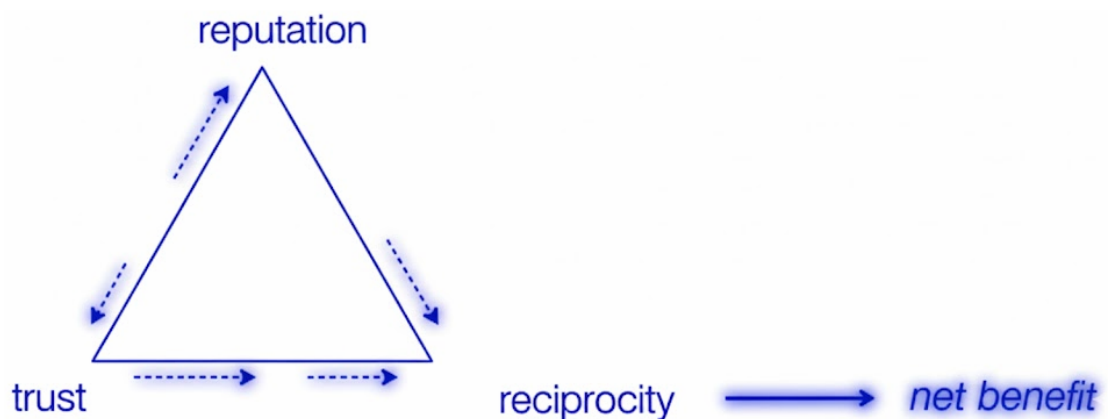


Рис. 2.3. Тріада концептів: довіра, репутація та взаємність

2.2.2. Репутаційні моделі на основі зворотного зв'язку

Історично першою сферою імплементації репутаційних технологій стали електронні торговельні майданчики (online marketplaces). Стрімке зростання цих платформ зумовило необхідність протидії кіберзлочинності: дефіцит довіри до контрагентів автоматично трансформується у дефіцит довіри до платформи в цілому. Оскільки дистанційний характер транзакцій нівелює можливості природного розвитку репутації, притаманні офлайн-ринку, компанія eBay впровадила систему зворотного зв'язку (feedback-based system). Користувачі отримали можливість взаємного оцінювання результатів транзакцій, що дозволило іншим учасникам приймати обґрунтовані рішення щодо безпеки взаємодії.

Система eBay передбачає багаторівневу оцінку: детерміновані показники (п'ятизіркові шкали), неструктуровані текстові відгуки та інтегральний індекс лояльності. Рисунок 2.4 демонструє приклад профілю продавця з високим репутаційним статусом. Окрім мінімізації ризиків, такі системи виконують стимулюючу функцію, детермінуючи просоціальну поведінку агентів ринку через економічну доцільність підтримки високого рейтингу.

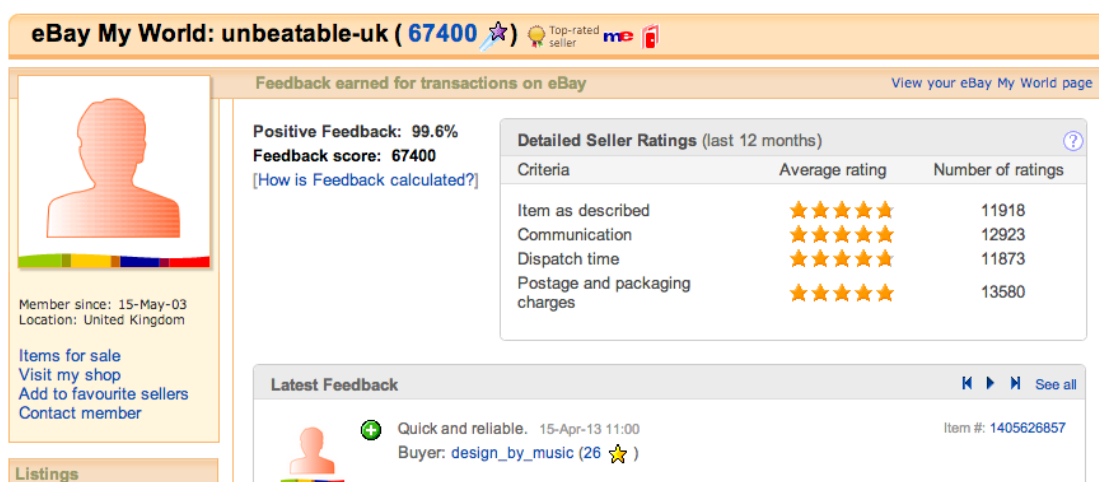


Рис. 2.4. Репутаційна система eBay на основі зворотного зв'язку

На рис. 2.4 представлено репутаційні показники продавця. Позитивні відгуки були надані 67 400 покупцями, що становить 99,6% від загальної кількості отриманих відгуків. Середній показник за всіма індикаторами ефективності становить 5 зірок. За високий рівень репутації користувач отримав відзнаку «Top-seller» (найкращий продавець), яка дозволяє покупцям оперативно ідентифікувати надійних контрагентів.

2.2.3. Поведінкові репутаційні моделі

У колаборативних екосистемах користувачі динамічно змінюють ролі «виробника» (producer) та «споживача» (consumer). Ця активність є прекурсором функціонування соціального вебу, де мотивація до співпраці

варіюється від комерційного прибутку (Airbnb) до інтелектуального обміну (Stack Exchange) або соціальної дифузії інформації (Twitter, Reddit).

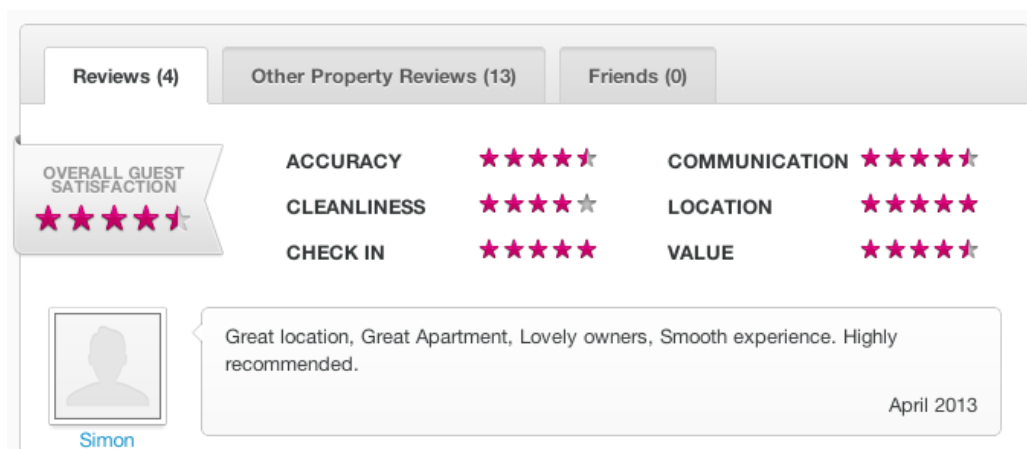


Рис. 2.5. Агреговані показники відгуків типового орендодавця на платформі Airbnb (включаючи приклад текстового відгуку).

Рейтинг у зірках (рис. 2.5) є середньоарифметичним значенням, розрахованим на основі явного зворотного зв'язку, наданого всіма орендарями щодо діяльності цього орендодавця.

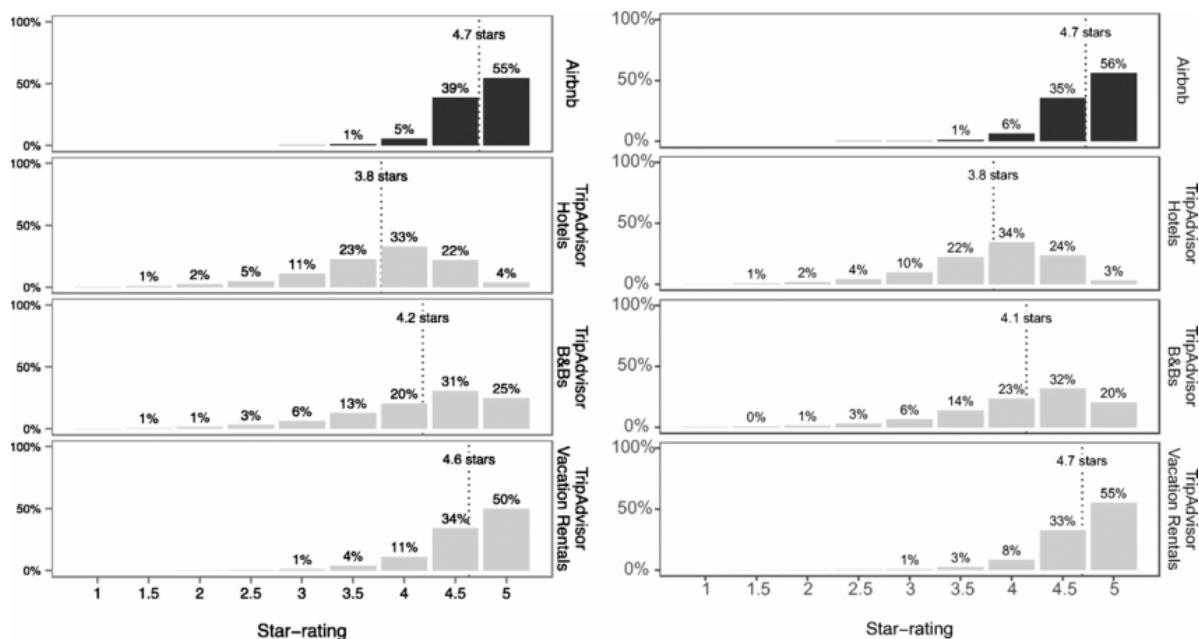


Рис. 2.6. Розподіл рейтингів об'єктів нерухомості на платформах Airbnb та TripAdvisor у 2015 році (ліворуч) та у період 2018–2020 років (праворуч).

Пунктирними лініями позначено середні значення розподілу

На схемі (рис. 2.6) показано процес переходу від індивідуальних оцінок користувачів за різними категоріями до підсумкового балу. Процес формування репутаційного показника в подібних системах можна представити як послідовність етапів:

- Декомпозиція критеріїв: Користувач оцінює взаємодію за декількома незалежними параметрами (наприклад, для Airbnb це: точність опису, комунікація, чистота, локація, заїзд та співвідношення ціна/якість).

- Збір вхідних даних (R_i): Система накопичує вектори оцінок від кожного орендаря.

- Арифметична агрегація: Обчислюється середнє значення за кожним окремим параметром на основі всіх отриманих відгуків за певний період.

- Інтегральний показник: Формується загальний рейтинг (Overall Rating), який часто є зваженим середнім від категоріальних оцінок.

- Візуалізація: Результат виводиться у вигляді графічного інтерфейсу (зірки та числове значення), що супроводжується якісними даними (текстовими відгуками) для забезпечення контексту.

Ця схема наочно демонструє, як суб'єктивні одиничні оцінки перетворюються на об'єктивний кількісний показник репутації суб'єкта в системі.

Проте моделі, засновані на явному зворотному зв'язку, не завжди є аплікабельними та стійкими до маніпуляцій. На відміну від транзакційних сервісів, соціальні платформи (наприклад, Facebook) зазвичай не передбачають інструментів прямої оцінки якості міжособистісної взаємодії. У таких випадках репутація має бути дедукована з неявних (імпліцитних) показників. Сервіси на кшталт Klout та PeerIndex здійснюють аналіз активності в мультіплатформенному середовищі (Twitter, LinkedIn тощо) для обчислення індексів впливовості. Вони забезпечують кількісну оцінку обсягів генерованого контенту та ступеня його споживання аудиторією, формуючи тематичні профілі експертності користувачів.

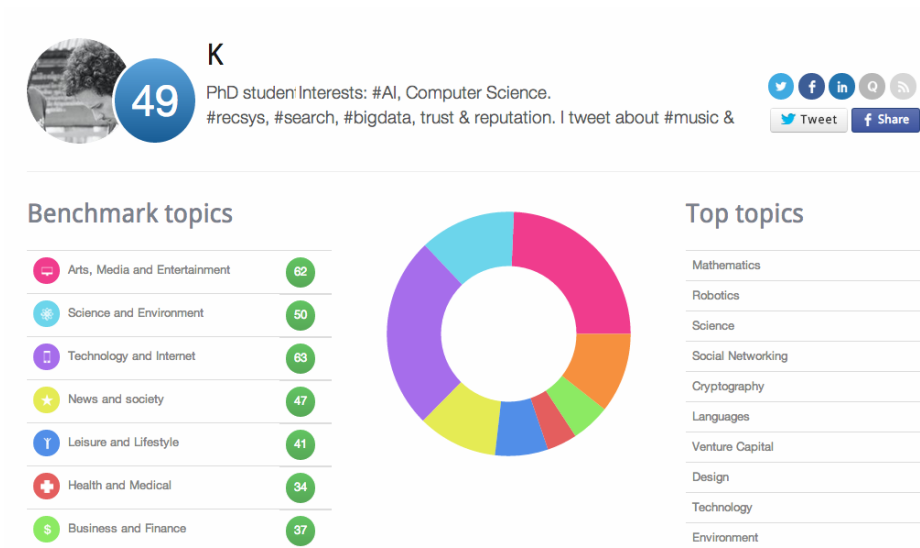


Рис. 2.7. Приклад профілю у системі PeerIndex.

Відображений показник впливовості (influence score) є результатом обчислень за допомогою власного (патентованого) алгоритму платформи. Рівень впливу користувача диференційовано за тематичними категоріями відповідно до числових показників, наведених нижче під основним профілем.

2.2.4 Синтез та концептуальні підсумки

Репутаційна модель Stack Exchange є прикладом системи, адаптованої до специфічного контексту діяльності (соціальні системи запитань і відповідей). Аналіз існуючих підходів дозволяє стверджувати, що методи розрахунку репутації є контекстуально залежними:

- У транзакційних системах (eBay, Airbnb) домінують методи аналізу явного зворотного зв'язку;
- У соціальних медіа (Reddit, Slashdot) репутація корелює з рейтингуванням контенту («позитивні голоси»);
- У професійних спільнотах (Stack Overflow) оцінка базується на метриках експертної активності.

Незважаючи на ад-хок характер таких систем, вони підтверджують гіпотезу про контекстуальну чутливість репутації: високий статус орендодавця на Airbnb не є індикатором його компетенції в галузі

програмування. Проте актуальною залишається проблема уніфікації. Якщо репутація — це дані для прийняття ціннісного судження, то механізми її виведення мають бути методологічно подібними в різних доменах співпраці.

Jon S [less info](#)

555,04
reputation

<i>bio</i>	website	rpindepth.com
	location	Reading, United Kingdom
	age	36
<i>visits</i>	member for	4 years, 6 months
	seen	22 mins ago
<i>stats</i>	profile views	537,76

Рис. 2.8. Профіль користувача з високим рівнем репутації на платформі Stack Overflow із зазначенням репутаційного бала

Фундаментальною ідеєю, що об'єднує зазначені моделі, є колаборація. Усі вони прямо чи опосередковано використовують дані про взаємодію для детермінації репутаційного статусу. У цій роботі пропонується принциповий підхід до обчислення онлайн-репутації, який забезпечує системну єдність, зберігаючи контекстуальну адаптивність та пріоритетність якісних показників співпраці. Подібно до того, як алгоритми аналізу посилань використовували граф документів для розрахунку авторитетності, ми пропонуємо використовувати граф користувачів, побудований на щоденних актах цифрової колаборації.

Висновки до розділу

Другий розділ присвячено формальному та математичному опису методів визначення онлайн-репутації в середовищі соціального нетворкінгу. Обґрунтовано доцільність використання графових моделей для представлення соціальних взаємодій і потоків довіри. Детально розглянуто адаптовану модель PageRank як інструмент обчислення репутаційних ваг

вузлів соціального графа. Проаналізовано алгоритм NITS та показано його ефективність для розподілу ролей між учасниками колаборативних систем. Досліджено проблему стійкості репутаційних алгоритмів до маніпуляцій і зловмисних впливів. Показано, що поєднання кількох математичних підходів підвищує надійність результатів оцінювання. Розкрито феноменологічні аспекти онлайн-репутації як динамічного та контекстно залежного явища. Розглянуто поведінкові репутаційні моделі, що враховують активність і взаємодії користувачів. Здійснено синтез формальних і концептуальних підходів до репутації. Отримані результати створюють теоретичну основу для інтеграції репутації в рекомендаційні механізми.

РОЗДІЛ 3. ІМПЛЕМЕНТАЦІЯ МЕТОДІВ ДОСЯГНЕННЯ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНИХ СИСТЕМ НА ПЛАТФОРМАХ СОЦІАЛЬНОГО НЕТВОРКІНГУ

3.1. Методологія збору та аналітичної обробки даних у межах пошукової платформи

Використання соціальної пошукової системи як експериментальної бази дозволяє провести верифікацію запропонованої графової моделі репутації на масивах реальних даних колаборативної взаємодії. На відміну від синтетичних тестів, дані системи відображають природну поведінку користувачів у процесі інформаційного пошуку та обміну знаннями.

1. Формування первинного набору даних (Dataset)

Процес збору даних базується на реєстрації подій взаємодії користувачів із результатами пошукової видачі. Основними об'єктами аналізу є:

- Логи пошукових сесій: фіксація введених запитів, часу пошуку та ідентифікаторів користувачів (анонімізованих).
- Граф взаємодії зі стеками (Staks): дані про приєднання користувачів до тематичних груп та їхню активність у межах цих спільнот.
- Транзакції релевантності: реєстрація кліків на результати пошуку та явних оцінок (позитивних/негативних), які користувачі надають конкретним ресурсам.

2. Структурування даних у формі гетерогенного графа

Для подальшого обчислення репутації за алгоритмами HITS або PageRank, отримані дані трансформуються у мультимодальну графову структуру $G = (V, E)$, де:

- Множина вузлів (V): включає користувачів (U), пошукові запити (Q) та веб-ресурси (URL, R).

- Множина ребер (E): відображає типи зв'язків, такі як «користувач u створив запит q», «користувач u рекомендував ресурс r», «ресурс r є частиною стека s».

3. Препроцесинг та фільтрація шумів

З метою підвищення прецизійності (точності) моделі, дані проходять декілька етапів очищення:

- Видалення бот-трафіку: ідентифікація та виключення аномально високої активності, що не властива людині.

- Часова нормалізація: застосування функцій «затухання» для застарілих взаємодій, оскільки репутація користувача в динамічних системах має властивість деградувати за відсутності підкріплення новою активністю.

- Анонімізація: приведення персональних ідентифікаторів до хешованого вигляду згідно з протоколами захисту даних (GDPR або аналогічних), що забезпечує етичність дослідження.

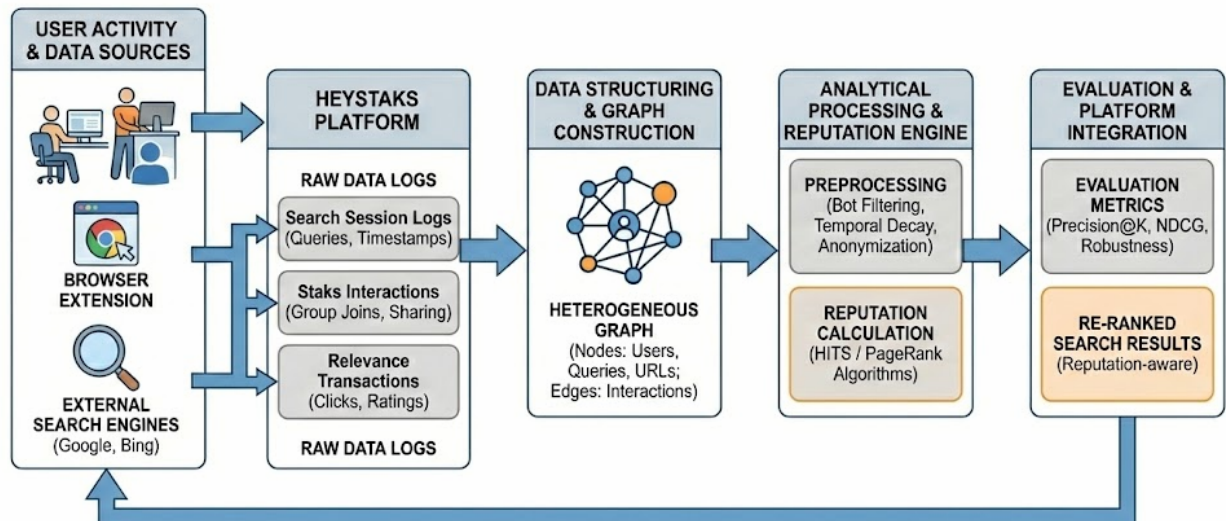


Рис. 3.1. Методологія збору та аналітичної обробки даних у межах пошукової платформи

4. Метрики оцінки ефективності моделі

Для підтвердження гіпотези про те, що графова репутація покращує якість системи, використовуються наступні показники:

- Precision@K та Recall@K: для оцінки точності рекомендацій, сформованих з урахуванням репутації автора контенту.

- NDCG (Normalized Discounted Cumulative Gain): для аналізу якості ранжування результатів у пошуковій видачі.

- Robustness Factor: коефіцієнт стійкості моделі до спроб штучного маніпулювання рейтингами (Sybil attacks).

5. Інтеграційний сценарій

В межах експерименту пропонується порівняти стандартний алгоритм ранжування (базований на частоті кліків) із модифікованим алгоритмом, де вага кожного результату зважується на показник Authority Score користувача, який цей результат зберіг. Це дозволяє перевірити, чи призводить пріоритезація «експертного» контенту до вищої задоволеності кінцевого користувача.

3.2. Представлення обчислювальної моделі репутації для онлайн-систем соціального нетворкінгу спільної діяльності

Дана робота присвячена детальній оцінці обчислювальної моделі репутації для онлайн-систем спільної діяльності (колаборації). У якості прикладного кейс-стаді для верифікації моделі було обрано сферу вебошуку. Репутаційну систему було інтегровано в утиліту соціального пошуку, після чого було проведено серію випробувань та оцінювання для підтвердження ефективності обраного підходу до моделювання онлайн-репутації.

Вебпошук може здатися нетиповим об'єктом для апробації репутаційної моделі, оскільки традиційно він розглядається як індивідуальна активність. Сучасні конвенційні пошукові системи не передбачають експліцитних механізмів колаборації. Навіть базовий акт обміну результатами між потенційними партнерами неможливий без залучення сторонніх інструментів. Наприклад, при виявленні релевантного результату з інформаційного пошуку для передачі цієї інформації колезі необхідно

використовувати месенджери або соціальні платформи. Опитування [25] продемонструвало, що 90% регулярних користувачів змушені застосовувати подібні непрямі методи для забезпечення спільної роботи під час пошуку. Потреба в колаборації є глибшою: за даними [28], 25–40% запитів спрямовані на повторний пошук уже знайденого контенту, а дослідження [24] свідчать, що у двох третинах випадків користувачі шукають інформацію, яку вже раніше знаходили їхні друзі або колеги. Таким чином, існує об'єктивна потреба не лише в інструментах обміну результатами, а й у механізмах впливу колективного пошукового досвіду на спільноту.

Дослідження в галузі колаборативного інформаційного пошуку (CIR) пропонують різні шляхи вирішення цих проблем. Один із підходів полягає у створенні спеціалізованих інтерфейсів для спільної роботи в єдиному просторі, як-от система CoSearch [1] для пошуку на одному ПК або системи, що використовують столи-комп'ютери [22] чи групу мобільних пристроїв [23]. Інші розробки, зокрема S3 [27] та SearchTogether, забезпечують дистанційну асинхронну колаборацію, що дозволяє легше інтегрувати їх у робочі процеси.

Метою таких систем соціального пошуку є надбудова над базовою пошуковою структурою для покращення користувацького досвіду. Деякі системи використовують готовність людей взаємодіяти з незнайомцями, перетворюючи саму мережу контактів на джерело інформації. Наприклад, в [24] описують додаток, який автоматично спрямовує запити користувачам, здатним надати релевантну відповідь. Проте ефективність такого підходу обмежена доступністю експертів у мережі в конкретний момент часу.

Основною мотивацією створення соціальних пошукових технологій є фасилітація колаборації. Пропонована утиліта додає функції співпраці до провідних пошукових систем (Google, Yahoo тощо), створюючи додатковий колаборативний рівень над звичним інтерфейсом. Ключовою концепцією системи є «пошуковий стек» (search stack) — тематична онлайн-папка для зберігання пошукового досвіду. Стеки можна поширювати, створюючи

взаємовигідне середовище. Утиліта інтегрує рекомендації зі стеків безпосередньо в результати пошуку в реальному часі. Рекомендовані результати базуються на попередньому досвіді членів стеку, допомагаючи виявити контент, який було б важко знайти за допомогою лише стандартних алгоритмів.

Активність користувачів фіксується за допомогою панелі інструментів браузера (toolbar), яка реєструє вибір результатів та дозволяє виражати явний інтерес: тегування текстом, позитивне/негативне голосування або прямий обмін посиланнями. Користувачі можуть керувати приватністю стеків (публічні або лише за запрошенням), контролюючи доступ до накопичених знань.

3.2.1. Архітектура рішення

Архітектура складається з клієнтської панелі та серверної частини (back-end). Сервер керує індексами стеків (зіставлення сторінок із тегами та голосами), базою даних (назви, учасники, описи), соціальними сервісами та механізмом рекомендацій.

Рекомендаційний рушій формує список кандидатів, аналізуючи термінологічні та поведінкові дані. Термінологічна оцінка базується на модифікованій функції TF-IDF, а поведінкова — на аналізі позитивних дій (вибори, теги, частки). Зважена сума цих оцінок визначає фінальний ранг рекомендації.

На рисунку 3.2 представлена ця архітектура з інтегрованим репутаційним рушієм як критичним компонентом. Цей модуль модифікує процес рекомендації, додаючи вагу кандидатам залежно від репутації їхніх джерел. Репутаційний бал впливає на позицію результату в списку або на сам факт його відображення.

Така інтеграція дозволяє чітко оцінити: чи покращує репутаційна складова релевантність результатів порівняно з рекомендаційною системою, що її не враховує.

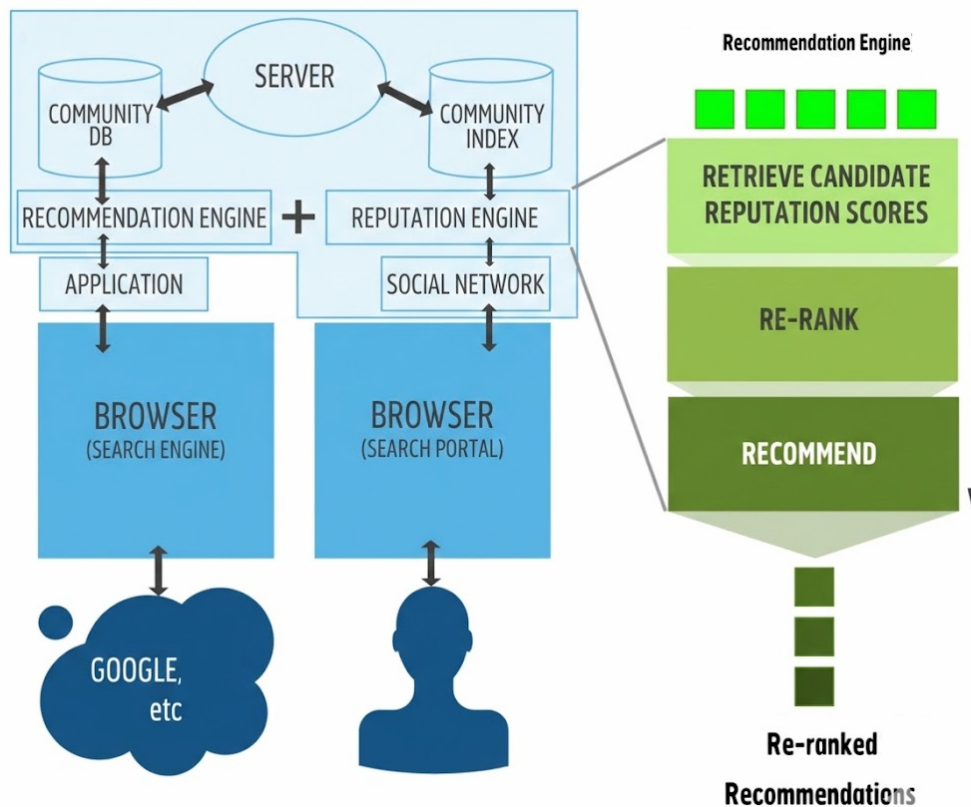


Рис. 3.2. Архітектура серверної частини (back-end) системи

Репутаційний рушій повністю інтегрований у структуру системи; він генерує бали для кандидатів на рекомендацію, базуючись на показниках репутації користувачів, які є авторами або джерелами відповідного контенту.

Моделювання репутації в даній системі базується на аналізі колаборативної поведінки. Це дозволяє дати відповідь на два ключові питання:

1. Чи можливо розрахувати репутацію користувача на основі аналізу його взаємодії з іншими членами спільноти?
2. Чи можна використовувати репутацію користувача для детермінації репутації (корисності) створеного ним контенту та покращення досвіду його споживачів?

Тут колаборація відбувається природним шляхом: активація рекомендації є актом співпраці зі стороною-продуцентом (див. рис. 3.3). Оскільки вся активність логується, репутаційний модуль може бути безпосередньо інтегрований у серверну архітектуру системи.

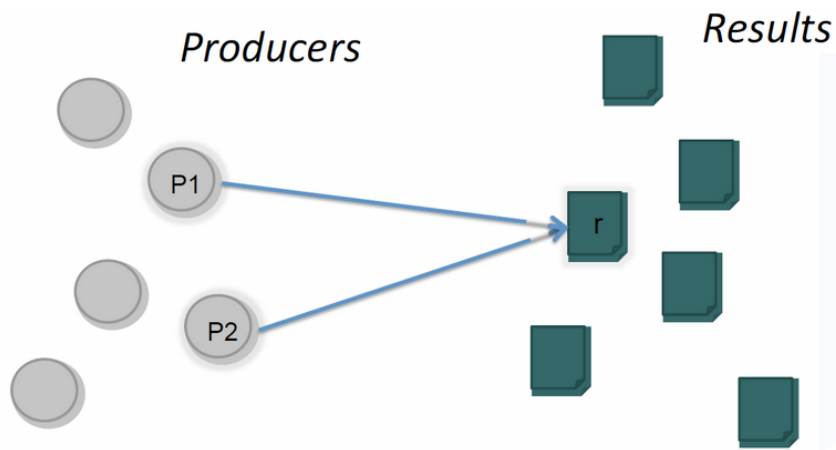


Рис. 3.3. Репутація сторінки в системі може бути обчислена шляхом трансляції (перенесення) репутації її творців (продюсерів)

Варто зауважити, що з огляду на специфіку активності на платформі, усі користувачі, які здійснювали будь-які дії щодо сторінки, можуть вважатися її творцями.

3.3. Математична модель зважування репутації в пропонованому алгоритмі

У системі основна мета інтеграції репутації полягає в тому, щоб скоригувати базову оцінку релевантності документа на основі авторитетності користувача, який цей контент згенерував або рекомендував.

1. Базова модель ранжування без репутації

Традиційно оцінка релевантності результату s для запиту q у стеку S обчислюється як поєднання текстової відповідності та популярності:

$$Score(s, q) = w_t \cdot IR_Score(s, q) + w_u \cdot Usage_Score(s, S)$$

де:

IR_Score — оцінка на основі функції TF-IDF;

$Usage_Score$ — оцінка на основі дій користувачів (кліки, голоси, теги);

w_t, w_u — вагові коефіцієнти.

2. Інтеграція репутаційного чинника

При впровадженні репутаційної моделі підсумковий бал результату s стає зваженою сумою внесків кожного користувача u , який взаємодіяв із цим результатом:

$$Final_Score(s, q) = \sum_{u \in Producers(s)} (Reputation(u) \cdot Influence(u, s, q))$$

де:

$Reputation(u)$ — обчислений бал репутації користувача u в межах спільноти або конкретного стеку.

$Influence(u, s, q)$ — міра внеску користувача в релевантність (наприклад, вага голосу "за" або "проти").

3. Обчислення репутації користувача ($Reputation(u)$)

Репутація моделюється рекурсивно, подібно до алгоритмів PageRank або HITS, але замість гіперпосилань використовуються акти колаборації (наприклад, коли користувач B приймає рекомендацію користувача A):

$$R(u_A) = (1 - d) + d \cdot \sum_{u_B \in Consumers(A)} \frac{R(u_B)}{Out_Collab(u_B)}$$

де:

d — коефіцієнт демпфування;

$Consumers(A)$ — множина користувачів, які скористалися результатами, створеними користувачем A ;

$Out_Collab(u_B)$ — загальна кількість актів колаборації (споживання контенту) користувача B .

Для перевірки ефективності репутаційної моделі була використана наступна методологія:

- Порівняльний аналіз (A/B тестування): Користувачі були розділені на групи. Контрольна група отримувала рекомендації від стандартного рушія, а тестова — від рушія, що враховував репутаційну вагу джерел.

Метрики релевантності:

- CTR (Click-Through Rate): Вимірювання частоти вибору рекомендацій з високою репутацією порівняно зі звичайними.

- MRR (Mean Reciprocal Rank): Оцінка того, наскільки вище у списку результатів з'являються релевантні посилання після впровадження репутаційної моделі.

- Аналіз «холодного старту»: Дослідження того, як швидко система ідентифікує нових надійних експертів у спільноті та чи допомагає репутація відфільтрувати низькоякісний контент на ранніх етапах існування стеку.

- Стійкість до маніпуляцій: Тестування системи на здатність протидіяти «накрутці» рейтингу (sybil attacks), коли група користувачів намагається штучно підвищити репутацію певного результату.

Ця методологія дозволяє довести, що врахування якості колаборації (через репутацію) суттєво підвищує точність соціального пошуку.

3.4. Інтеграція репутаційних моделей та семантичної релевантності в процеси соціальних рекомендацій

На рисунку 3.4 представлена дворівнева архітектура системи, що базується на взаємодії клієнтського та серверного компонентів. Клієнтська частина реалізована у вигляді плагіна (панелі інструментів) браузера, який виконує низку критичних функцій. По-перше, він забезпечує інтерфейс для безпосередньої взаємодії користувача з функціоналом, включаючи створення тематичних «стеків» (staks), спільне використання ресурсів, тегування та оцінювання вебресурсів. По-друге, плагін здійснює глибоку інтеграцію з провідними пошуковими системами: він реєструє пошукову активність (запити та вибір результатів) і динамічно модифікує інтерфейс пошукової

видачі, імплементуючи рекомендації безпосередньо у структуру сторінки результатів (SERP).

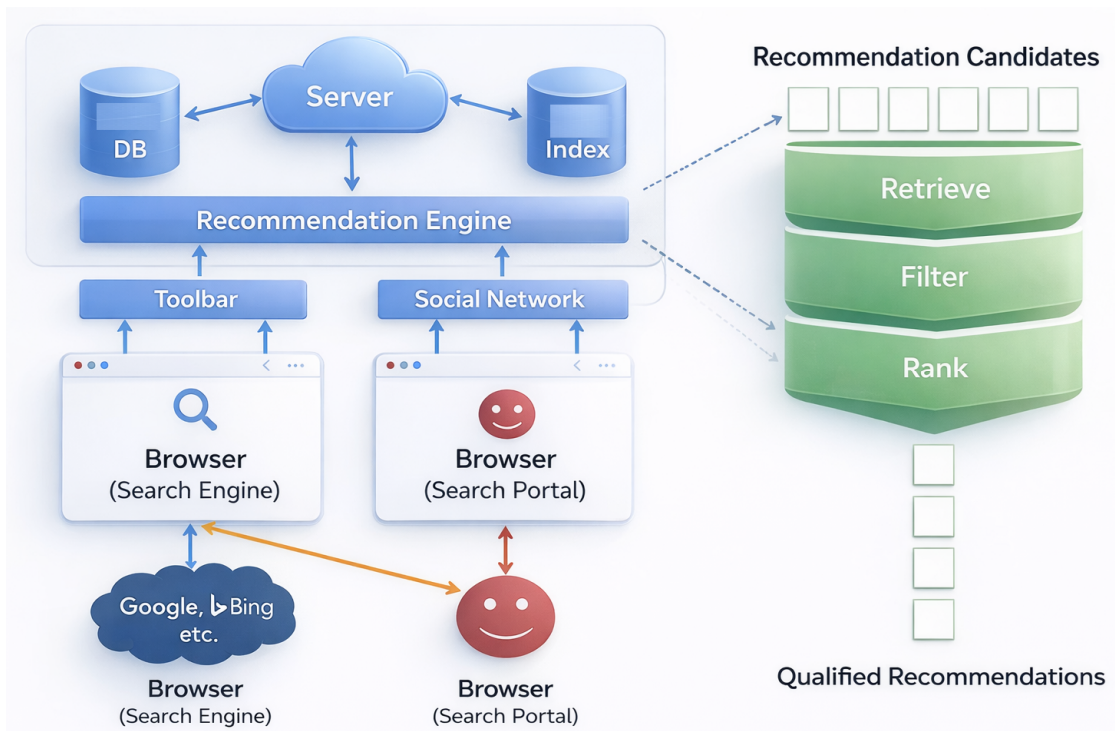


Рис. 3.4. Архітектура системи та загальна схема моделі рекомендацій

Серверний компонент відповідає за агрегацію та обробку даних про пошукову активність. Усі типи взаємодій — трансляція запитів, вибір релевантних посилань, анотування та соціальна дифузія — передаються на сервер для оновлення відповідних індексів. Ці індекси є фундаментальним джерелом для генерації рекомендацій: у контексті обраного стеку запит користувача спрямовується до сервера, де формується перелік релевантних об'єктів на основі цільового та суміжних стеків користувача.

3.4.1. Алгоритм генерації рекомендацій

У системі кожен тематичний стек акумулює когнітивний пошуковий досвід його учасників. Основним структурним елементом стеку є результат (URL), а сам стек S визначається як множина результатів: $S=\{r_1, \dots, r_k\}$. Кожен об'єкт r_i анонімно асоціюється з вектором імпліцитних та

експліцитних індикаторів релевантності, що базуються на таких діях користувачів:

- Селекція (Click-through): акт вибору результату пошуку (органічного або рекомендованого);
- Верифікація (Voting): експліцитне позитивне оцінювання контенту;
- Дифузія (Sharing): передача посилання через канали електронної пошти або соціальні мережі;
- Анотування (Tagging/Commenting): додавання метаданих у вигляді тегів або коментарів.

Кожна транзакція інтерпретується як певний рівень впевненості у релевантності сторінки конкретному запиту. Відповідно, об'єкт r_i^S у межах стеку S описується набором атрибутів, що включає загальну кількість переходів (Sl), пошукові запити (q_1, \dots, q_n), текстові фрагменти (snippets) вибраних результатів (s_1, \dots, s_k), кількість і зміст тегів ($Tg; t_1, \dots, t_m$), баланс голосів (v^+, v^-) та інтенсивність поширення (Sh):

$$r_i^S = \{q_1 \dots q_n, s_1 \dots s_k, t_1 \dots t_m, v^+, v^-, Sl, Tg, Sh\}$$

Отже, кожен результат індексується за двома доменами даних: термінологічним (запити та теги) та поведінковим (метрики використання). Термінологічні дані опрацьовуються за допомогою бібліотеки Apache Lucene, що дозволяє здійснювати ефективне ранжування кандидатів на основі текстової відповідності. Поведінкові дані слугують додатковим емпіричним підтвердженням для фільтрації та фінального відбору рекомендацій.

Процес генерації рекомендацій за запитом q_T у контексті стеку S_T складається з двох етапів. На першому етапі формується вибірка кандидатів шляхом зіставлення термінів запиту з індексними термінами (запитами, фрагментами та тегами) у Lucene. На другому етапі застосовується процедура фільтрації за порогоми активності (наприклад, виключення результатів з одиночною селекцією або негативним балансом голосів).

Фінальне ранжування кожного кандидата r здійснюється на основі зваженої суми показників релевантності (rel) та репутації (rep) у момент часу t , де параметр w регулює баланс впливу цих факторів:

$$score(r, q_T, t) = w \times rep(r, t) + (1 - w) \times rel(q_T, r)$$

Обчислення релевантності результату r щодо запиту q_T базується на класичній функції зважування термінів TF-IDF. Дана метрика дозволяє пріоритезувати ті результати, терміни яких мають високу частоту в межах конкретного документа, проте є рідкісними для інших об'єктів у межах стеку:

$$rel(q_T, r) = \sum_{\tau \in q_T} tf(\tau \in r) \times idf(\tau \in r)^2$$

3.4.2. Моделювання репутації в системах соціального нетворкінгу

Описана раніше модель релевантності має суттєве обмеження: вона нівелює роль джерела рекомендації, тобто не враховує атрибути користувачів, чия пошукова активність ініціювала внесення сторінки до стеку або сприяла її подальшій верифікації. З огляду на це, актуальним напрямом досліджень є інтеграція репутаційного компонента в алгоритми рекомендації. Відповідно, ранжування кандидатів на рекомендацію здійснюється на основі комбінованого показника релевантності та репутації. Таким чином, пріоритет надається вебресурсам, верифікованим репрезентативною вибіркою користувачів із високим рівнем репутації, що забезпечує вищу якість пошукової видачі порівняно з контентом від малоавторитетних джерел.

Концептуальний базис моделі репутації в системі ґрунтується на аналізі імпліцитної колаборації (співпраці), що виникає в процесі пошукової діяльності. У ситуації, коли користувач взаємодіє з рекомендованим результатом (шляхом селекції, тегування, оцінювання або дифузії), такий акт

класифікується як одиничний випадок пошукової колаборації. У межах даної парадигми виокремлюються дві ролі: споживач (користувач, який реагує на рекомендацію) та виробник (суб'єкт, чия попередня активність зумовила появу цієї рекомендації в системі). Отже, виробник генерує пошукові знання, когнітивна цінність яких підтверджується дією споживача. Математично цей процес описується як інкрементне збільшення репутаційного активу виробника за кожен підтверджений акт колаборації (див. рис. 3.5 а). Загальний рівень репутації суб'єкта є результатом агрегації таких одиниць за весь період його активності.

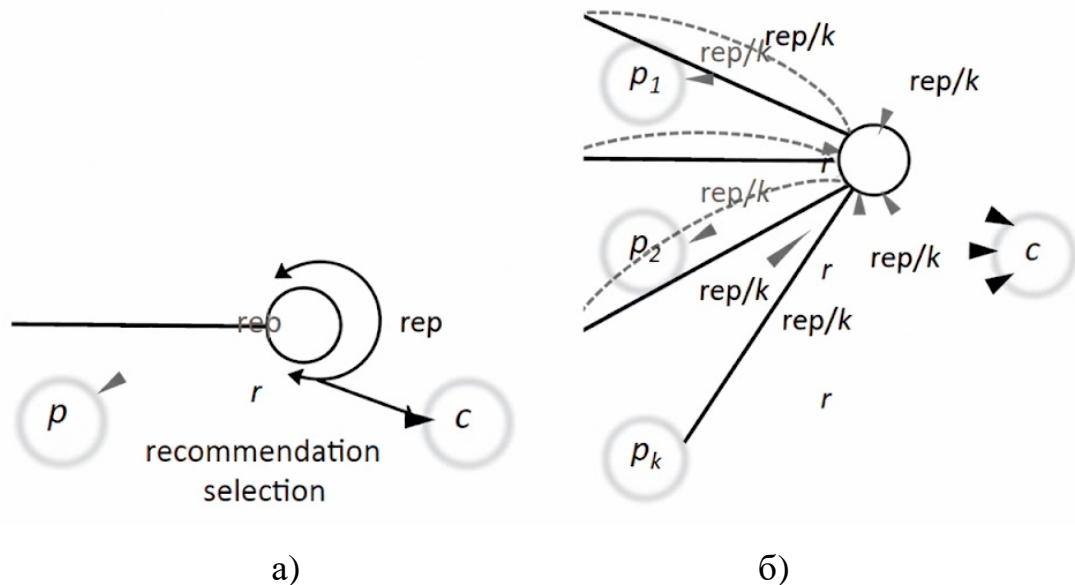


Рис. 3.5. Колаборація та репутація

а) споживач c обирає результат r , рекомендований на основі попередньої активності виробника p , унаслідок чого c передає певну одиницю репутації (rep) виробнику p .

б) Споживач c обирає результат r , сформований кількома виробниками p_1, \dots, p_k ; у цьому разі репутація розподіляється між усіма виробниками, і кожен користувач отримує рівну частку в розмірі rep/k одиниць репутації

Модель передбачає обчислення репутації як зваженої суми подій колаборації. На рисунку 3.5 б) продемонстровано базовий сценарій взаємодії

між одним виробником та споживачем. Проте в реальних умовах до формування пошукового знання, що призвело до рекомендації результату r у момент часу t , можуть бути причетні декілька виробників. Кожен із них міг зробити внесок на різних етапах: первинна селекція в межах стеку, вибір за альтернативними запитам, анотування або соціальне поширення. Така мультиагентна природа внеску зумовлює необхідність дистрибуції репутаційного балу між усіма причетними виробниками (див. рис. 3.5 б).

Формально, процес селекції результату r споживачем s у момент t визначає множину відповідальних виробників $producers(r,t)$, де кожен елемент p_i ідентифікує користувача u_i у контексті конкретного стеку S_j :

$$producers(r,t) = \{p_1, \dots, p_k\}$$

Репутація кожного виробника p_i оновлюється відповідно до наступного рівняння. Одиниця отриманої репутації рівномірно розподіляється між k учасниками, що зробили внесок у формування даної рекомендації:

$$rep(p_i, t) = rep(p_i, t - 1) + \frac{1}{k}$$

Таким чином, репутація кумулятивно формується на основі підтверджених випадків ефективної співпраці. Важливо зазначити, що представлена модель «виробник-споживач» є одним із можливих підходів до обчислення репутації; альтернативні методики та результати їхньої емпіричної оцінки детально викладені у роботі [13].

У межах даної магістерської роботи ми приймаємо вищезазначену модель як базову та фокусуємося на механізмах її інтеграції в рекомендаційний рушій. Це потребує розробки методології трансляції індивідуальних репутаційних балів користувачів у відповідні агреговані показники репутації вебзлів.

3.5. Методологія агрегації репутаційних показників у колаборативних рекомендаційних системах

У даному розділі представлено декілька концептуальних підходів до моделювання репутації вебсторінок. Основним завданням кожного методу є детермінація репутаційного бала результату r у момент часу t на основі сукупності оцінок репутації його виробників (producers). Узагальнена функціональна залежність описується наступним рівнянням:

$$rep(r, t) = f(rep(p_1, t), \dots, rep(p_k, t))$$

Для верифікації та ілюстрації запропонованих моделей використовується гіпотетичний сценарій, у якому сторінка r асоціюється з десетю виробниками, що мають наступні вектори репутаційних балів: $\{0.003, 0.014, 0.023, 0.052, 0.089, 0.097, 0.154, 0.297, 0.348, 0.581\}$. Дана вибірка репрезентує гетерогенну групу користувачів із суттєвою варіативністю авторитетності. Слід зауважити, що в межах практичної імплементації оцінки репутації підлягають процедурі нормування щодо максимального показника у відповідному стеку, що забезпечує їх перебування в діапазоні $[0, 1]$.

Найбільш прямолінійним підходом до трансляції користувацької репутації в репутацію контенту є обчислення центральної тенденції. У даній моделі репутація сторінки визначається як медіана показників її виробників:

$$rep(r, t) = median(rep(p_1, t), \dots, rep(p_k, t))$$

Застосування медіани замість арифметичного середнього є обґрунтованим з погляду статистичної стійкості, оскільки цей показник менш чутливий до екстремальних викидів у наборі даних. У межах розрахункового сценарію репутація об'єкта r за цією моделлю становить 0.093.

Альтернативний підхід базується на виборі екстремального значення авторитетності серед сукупності виробників:

$$rep(r, t) = \max(rep(p_1, t), \dots, rep(p_k, t))$$

Перевагою даного методу є стійкість до «розмивання» рейтингу сторінки новими користувачами, які ще не мають сформованої репутації. У такому разі присутність навіть одного високоавторитетного джерела гарантує сторінці високий репутаційний статус. Для нашого сценарію цей показник дорівнює 0.581.

Гармонійне середнє є консервативною мірою, яка тяжіє до нижньої межі вхідної сукупності значень. Математично воно визначається як обернене значення до арифметичного середнього обернених величин:

$$rep(r, t) = \frac{k}{\sum_{i=1}^k \frac{1}{rep(p_i, t)}}$$

У наведеному прикладі репутація сторінки становить 0.020. Цей метод є ефективним індикатором «мінімальної гарантованої корисності», де репутація сторінки корелює з показником її найменш авторитетного виробника, проте, на відміну від простого мінімуму, враховує вплив усього діапазону оцінок.

Для оцінки загальної величини (масштабу) репутаційного масиву доцільно використовувати середньоквадратичне значення (Root Mean Square), яке розраховується як квадратний корінь із середнього арифметичного квадратів значень:

$$rep(r, t) = \sqrt{\frac{\sum_{i=1}^k rep(p_i, t)^2}{k}}$$

На відміну від гармонійного середнього, RMS акцентує увагу на верхній межі розподілу, що робить цей підхід менш консервативним. За результатами розрахунку в межах сценарію, репутація сторінки r становить 0.243.

Для врахування кумулятивного ефекту від кількості виробників пропонується застосування правила Гупера для підтвердження одночасних свідчень [14]. У контексті системи дії виробників (створення, тегування результату) розглядаються як незалежні акти верифікації контенту. Модель Гупера приписує об'єкту рівень достовірності за формулою $1-(1-c)^k$, де c — рівень достовірності кожного з k свідків. В адаптованій формі для пошукової системи репутація сторінки обчислюється ітеративно на основі індивідуальних балів виробників:

$$rep(r, t) = 1 - \prod_{i=1}^k (1 - rep(p_i, t))$$

Застосовуючи цей ітеративний підхід до нашого прикладу ($0.003 + (1-0.003) 0.014 + \dots$), отримуємо інтегральний показник репутації результату r на рівні 0.865.

У наступному розділі подано результати емпіричної оцінки впливу зазначених п'яти моделей на ефективність рекомендаційного рушія. Аналіз проводиться на основі реальних користувацьких запитів для визначення ступеня покращення предиктивної здатності системи.

3.6. Експериментальна оцінка та аналіз результатів

Попередні дослідження [3] продемонстрували, що стандартні алгоритми рекомендації системи, засновані на метриках релевантності, здатні генерувати результати, що перевершують за точністю верхні позиції видачі провідних пошукових систем (зокрема Google). У межах даної роботи

проводиться порівняльний аналіз зазначеної базової техніки з удосконаленою моделлю, що інтегрує показники репутації вебзв'язів.

Основною метою дослідження є розробка та верифікація альтернативних методів обчислення репутації контенту на основі авторитетності його виробників («producers») у середовищі соціального пошуку. Наукова гіпотеза базується на припущенні, що когнітивна синергія репутаційного та релевантного чинників при ранжуванні дозволяє суттєво підвищити якість пошукової видачі. Оцінка моделей проводилася шляхом ретроспективного аналізу даних, отриманих під час контрольованого тестування системи за участю реальних користувачів.

Експериментальна частина залучала респондентів з різним рівнем компетенцій у сфері інформаційного пошуку. Учасники були розподілені за різними топологіями пошукових стеків:

- Контрольна група - для встановлення базової лінії ефективності в неколаборативному середовищі.

- Експериментальна група - для вивчення впливу групової динаміки на результати пошуку.

Протягом експерименту було зафіксовано 3 124 запити та 1 998 транзакцій (вибір, анотування, оцінювання). Аналіз активності показав домінування селекції результатів (понад 81%), тоді як специфічні дії — тегування та голосування — становили 12% та 6% відповідно.

Методологія оцінювання моделей репутації передбачала «програвання» (replaying) експерименту: на основі логів було розраховано динамічну репутацію кожного виробника в момент формування рекомендації. Валідація результатів здійснювалася шляхом порівняння переранжованих списків із експертними оцінками релевантності (класифікація: «релевантно», «частково релевантно», «нерелевантно»).

Дослідження розподілу репутаційних балів (рис. 3.6) виявило суттєву варіативність авторитетності в межах стеків. Зокрема, виявлено кореляцію між інтенсивністю співпраці та репутаційними показниками: стек із 9

учасників продемонстрував найвищу медіанну репутацію та мінімальний міжквартильний розмах, що свідчить про високу щільність колаборації. Найвищий індивідуальний бал склав 37 одиниць, що характеризує таких користувачів як ключових продуцентів знань у системі.




Рис. 3.6. Показник репутації користувача (для кожного користувача в розрізі кожного стека)

Критерієм ефективності моделей став ступінь покращення якості рекомендацій порівняно з базовою лінією ($w=0$). Для оцінки використовувався коефіцієнт користі від релевантності (relevance benefit), що відображає приріст частки релевантних результатів на першій позиції списку.

Результати (рис. 3.7) продемонстрували спільну тенденцію: ефективність зростає при збільшенні ваги репутації (w), досягає екстремуму, а потім знижується при $w \rightarrow 1$. Основні висновки:

- Модель Гупера виявилася найбільш ефективною, демонструючи пікову продуктивність на рівні 55% при $w=0.4$ та $w=0.8$. Це зумовлено

консенсусною природою алгоритму, який посилює вагу сторінки пропорційно кількості її авторитетних виробників.




Рис. 3.7. Приріст релевантності для моделей репутації сторінок залежно від ваги

- Гармонійне середнє показало найгірші результати (максимум 3.4%), а за більшості значень w — негативну динаміку. Це пояснюється консервативністю моделі, яка надмірно пеналізує сторінки за наявності хоча б одного виробника з низькою репутацією.

- Чотири з п'яти протестованих моделей забезпечили приріст релевантності понад 30%, що підтверджує доцільність використання репутації як регулятора в алгоритмах ранжування.

- Статистичний аналіз із застосуванням тесту Крускала-Уолліса підтвердив значущість відмінностей між моделями ($p < .01$), а пост-хок тест Тьюкі виділив метод Гупера як статистично перевершуючий щодо гармонійного та квадратичного середніх ($p < .05$). Таким чином, ітеративна модель Гупера визначена як найбільш перспективна для інтеграції в реальні системи соціального пошуку.

На рисунку 3.8 показано медіанний приріст релевантності для кожної моделі репутації сторінок залежно від вагових коефіцієнтів. Критерій

Краскела — Волліса вказує на наявність статистично значущих розбіжностей між показниками ефективності моделей репутації на рівні значущості .01.

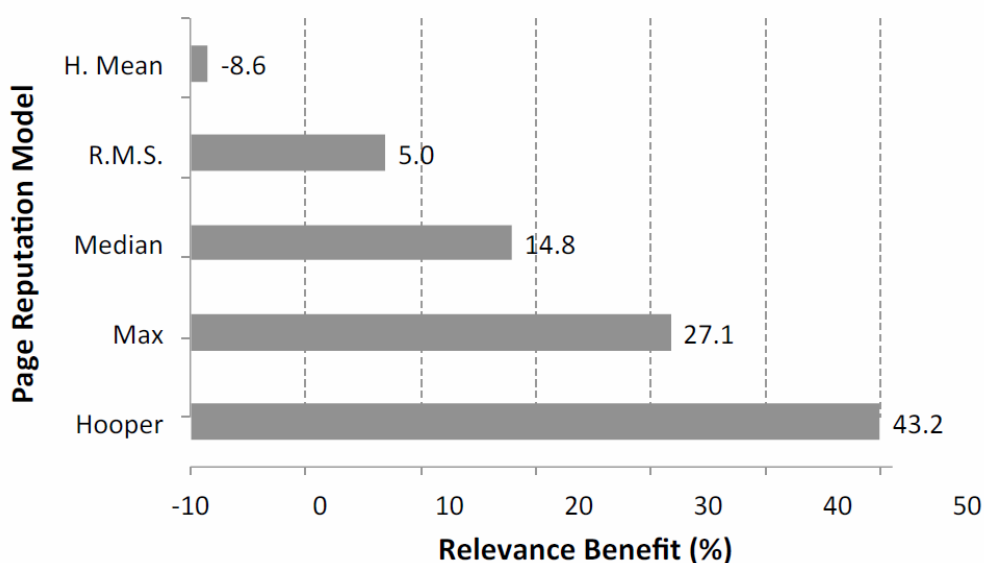


Рис. 3.8. Медіанний приріст релевантності за різними ваговими коефіцієнтами для кожної моделі репутації сторінок

Аналіз попарних відмінностей між моделями за допомогою критерію Тьюкі продемонстрував значущі розбіжності між методом Хупера (Hooper's technique) та двома іншими методами — розрахунком середнього гармонійного (Harmonic Mean) та середнього квадратичного (Root Mean Square) — на рівні значущості 0.05. Отримані результати додатково підкреслюють високу ефективність моделі репутації сторінок Хупера.

Kruskal-Wallis test (Критерій Краскела — Волліса) - це непараметричний статистичний тест, який використовується для перевірки того, чи походять кілька вибірок з одного розподілу. У даному випадку він доводить, що різні моделі репутації дають результати, які об'єктивно відрізняються один від одного, а не є випадковими.

Tukey's Range test (Критерій Тьюкі) використовується після виявлення значущих відмінностей (пост-хок аналіз), щоб зрозуміти, які саме пари моделей відрізняються між собою.

Nooper page reputation model - модель, яка у даному експерименті виявилася лідером. Виявлення значущих відмінностей на рівні 0.05 (95% впевненості) відносно середнього гармонійного та квадратичного підтверджує, що метод Хупера краще ранжує сторінки за репутацією.

Цей фрагмент є ключовим для підтвердження наукової гіпотези: він показує, що вибір конкретного математичного методу (у даному випадку методу Хупера) має критичне значення для якості пошукової видачі.

Отже, в розділі розв'язано проблематику соціального пошуку та дослідженню методів інтенсифікації колаборативної взаємодії в межах веб-пошуку. Зокрема, представлено платформу соціального пошуку, яка за допомогою браузерних плагінів інтегрує механізми спільного пошуку в середовище провідних пошукових систем, таких як Google, Bing та Yahoo. Основним науковим внеском статті є розробка та впровадження моделей репутації вебвузлів, що дають змогу коригувати процес формування рекомендацій на основі досвіду попередньої активності колаборативних спільнот.

Впроваджена модель дозволяє кількісно оцінювати ефективність користувача як суб'єкта пошуку. Суб'єкти, чії результати систематично рекомендуються та верифікуються іншими учасниками, ідентифікуються як авторитетні (репутабельні) джерела. Концептуальний базис дослідження ґрунтується на гіпотезі, що репутаційні бали є вагомим підтвердженням якості контенту: рекомендації, ініційовані групою авторитетних «виробників», характеризуються вищим рівнем надійності порівняно з результатами від менш репутабельних користувачів.

У межах дослідження було проаналізовано різні методи конвертації індивідуальних репутаційних показників у інтегральну оцінку репутації та релевантності сторінки. Результати порівняльного аналізу на основі емпіричних даних підтвердили, що синергія репутаційних моделей та існуючих метрик суттєво підвищує якість рекомендаційного сервісу. Експериментально доведено наступне:

- Більшість запропонованих моделей забезпечують приріст релевантності понад 30% відносно базового рівня.

- Модель, що базується на правилі Гупера для підтвердження одночасних свідчень, демонструє максимальну ефективність із показником відносного покращення до 55%.

Даний розділ формує підґрунтя для подальших розвідок, спрямованих на масштабування репутаційних механізмів та оптимізацію алгоритмів поєднання факторів релевантності й авторитетності. Попри те, що основна увага була зосереджена на максимізації релевантності спільнотних рекомендацій, сфера застосування репутації в системі є значно ширшою.

Зокрема, репутаційний компонент є ефективним інструментом забезпечення безпеки та стійкості системи до маніпуляцій. У соціальних мережах існує ризик навмисного наповнення пошукових стеків нерелевантним або комерційно заангажованим контентом. Використання репутації як медіатора дозволяє нівелювати вплив деструктивних суб'єктів: зловмисники з низьким репутаційним статусом (унаслідок відсутності позитивного відгуку від спільноти) втрачають можливість впливати на майбутні сесії рекомендацій. Крім того, репутація може слугувати важливим соціальним сигналом для користувачів. Перспективним напрямом розвитку є впровадження механізмів експлікації (пояснення) рекомендацій через посилення на авторитетність їхніх джерел, що підвищить прозорість анонімної системи.

Висновки до розділу

У третьому розділі реалізовано практичну імплементацію методів підвищення ефективності рекомендаційних систем на платформах соціального нетворкінгу. Запропоновано методологію збору та аналітичної обробки даних у межах пошуково-соціальної платформи. Розроблено обчислювальну модель репутації, орієнтовану на системи спільної діяльності.

Описано архітектуру програмного рішення та взаємодію його основних компонентів. Сформульовано математичну модель зважування репутаційних показників у процесі формування рекомендацій. Реалізовано інтеграцію репутаційних оцінок із показниками семантичної релевантності. Запропоновано алгоритм генерації рекомендацій на основі багатоступеневої фільтрації та ранжування. Проведено моделювання процесів формування репутації в соціальних мережах. Виконано експериментальну оцінку ефективності запропонованого підходу. Отримані результати підтвердили доцільність використання репутаційних моделей для підвищення якості рекомендацій.

ВИСНОВКИ

У магістерській роботі здійснено дослідження моделей та методів досягнення ефективності рекомендаційних систем на платформах соціального нетворкінгу з акцентом на використання механізмів онлайн-репутації як ключового фактора підвищення релевантності, достовірності та персоналізованості рекомендацій.

У першому розділі роботи проведено ґрунтовний аналіз предметної області та сформовано теоретико-методологічне підґрунтя дослідження. Визначено, що сучасні рекомендаційні системи в умовах соціального нетворкінгу функціонують у середовищі з високим рівнем шуму, інформаційної надлишковості та потенційних маніпуляцій, що зумовлює необхідність використання додаткових механізмів оцінювання якості джерел інформації. Доведено, що онлайн-репутація виступає інтегральною характеристикою поведінки суб'єктів у мережі та може бути формалізована як міра довіри, заснована на структурі соціальних взаємодій, історії активності та реакціях інших учасників системи. Аналіз архітектур пошукових систем і еволюції методів ранжування показав, що класичні алгоритми, орієнтовані виключно на текстову релевантність або посилавні структури, є недостатніми для соціально орієнтованих платформ. Особливу увагу приділено математичним моделям аналізу топології посилань, які стали основою для розвитку репутаційно-орієнтованих підходів. У результаті розгляду процесів семантизації, персоналізації та соціальної інтеграції обґрунтовано доцільність переходу від гіпертекстових моделей до багатовимірних соціальних графів, у яких рекомендації формуються з урахуванням впливу, дифузії інформації та економіки спільної участі.

Другий розділ присвячено формальному та математичному представленню методів визначення онлайн-репутації в середовищі соціального нетворкінгу. У роботі показано, що графові моделі є найбільш адекватним інструментом опису взаємодій між користувачами, контентом та

сервісами. Детально проаналізовано адаптацію алгоритму PageRank для оцінювання репутації вузлів соціального графа, а також застосування алгоритму HITS для розподілу ролей «авторитетів» і «хабів» у колаборативних середовищах. Доведено, що поєднання цих підходів дозволяє отримати більш стійкі до маніпуляцій репутаційні оцінки. Особливу увагу приділено проблемі стійкості репутаційних моделей до зловмисних впливів, таких як накрутка взаємодій або створення фіктивних зв'язків. У феноменологічному аспекті онлайн-репутація розглянута як динамічний, контекстно-залежний показник, що формується під впливом поведінкових, соціальних та семантичних факторів. Запропонований у розділі синтез математичних і поведінкових моделей створює концептуальну основу для інтеграції репутації в рекомендаційні механізми нового покоління.

У третьому розділі реалізовано практичну імплементацію запропонованих методів досягнення ефективності рекомендаційних систем. Розроблено методологію збору та аналітичної обробки даних у межах пошуково-соціальної платформи, що враховує як структурні характеристики соціального графа, так і семантичні властивості контенту. Запропоновано обчислювальну модель репутації для онлайн-систем спільної діяльності, визначено її архітектурні компоненти та механізми інтеграції з рекомендаційним ядром. Сформульовано математичну модель зважування репутаційних показників, яка дозволяє адаптивно коригувати вплив окремих користувачів і джерел інформації на результати рекомендацій. Особливу увагу приділено інтеграції репутаційних моделей із семантичною релевантністю, що забезпечує баланс між соціальною довірою та змістовною відповідністю рекомендацій запитам користувачів. Запропонований алгоритм генерації рекомендацій базується на багатокроковій процедурі відбору, фільтрації та ранжування кандидатів, що відповідає сучасним вимогам до масштабованості та персоналізації. Експериментальна оцінка результатів підтвердила, що використання репутаційних показників у поєднанні з графовими та семантичними моделями забезпечує підвищення точності

рекомендацій, зменшення рівня інформаційного шуму та підвищення довіри користувачів до системи.

Узагальнюючи результати дослідження, можна стверджувати, що інтеграція моделей онлайн-репутації в рекомендаційні системи соціального нетворкінгу є ефективним підходом до підвищення якості рекомендацій в умовах динамічних, багатокористувацьких та соціально насичених середовищ. Отримані наукові та практичні результати можуть бути використані при проектуванні сучасних соціальних платформ, пошуково-рекомендаційних сервісів і систем підтримки колективної діяльності, а також становлять основу для подальших досліджень у напрямі адаптивних, контекстно-орієнтованих рекомендаційних технологій.

ПЕРЕЛІК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Brin S., Page L. The Anatomy of a Large-Scale Hypertextual Web Search Engine. WWW 98: Proceedings of the 7th International Conference on World Wide Web. Brisbane, Australia: ACM, 1998. pp. 107–117.
2. Kleinberg J. M. Authoritative Sources in a Hyperlinked Environment. Journal of the ACM. 1999. Vol. 46, No. 5. pp. 604–632.
3. Smyth B., Briggs P., Coyle M., O'Mahony M. P. Google Shared: A Case Study in Social Search. User Modeling, Adaptation and Personalization. Springer-Verlag, 2009.
4. Salton G., McGill M. J. Introduction to Modern Information Retrieval. McGraw-Hill, 1983.
5. Shafer G. The Combination of Evidence. International Journal of Intelligent Systems. 1986. Vol. 1, No. 3. pp. 155–179.
6. Lam S. K., Riedl J. Shilling recommender systems for fun and profit. WWW '04: Proceedings of the 13th International World Wide Web Conference. New York, NY, USA: ACM, 2004. pp. 393–402.
7. Mobasher B., Burke R., Bhaumik R., Williams C. Toward trustworthy recommender systems: An analysis of attack models and algorithm robustness. ACM Transactions on Internet Technology (TOIT). 2007. Vol. 7, No. 4. pp. 1–40.
8. O'Mahony M. P., Hurley N. J., Silvestre G. C. M. Promoting recommendations: An attack on collaborative filtering. DEXA '02: Proceedings of the 13th International Conference on Database and Expert Systems Applications. Aix-en-Provence, France: Springer, 2002. pp. 494–503.
9. Roy, D., & Dutta, M. A systematic review and research perspective on recommender systems. Journal of Big Data, vol. 9, Art. 59, SpringerOpen, 2022, pp. 1–32.

10. Campana, M. G., & Delmastro, F. Recommender Systems for Online and Mobile Social Networks: A survey. *Online Social Networks and Media*, vols. 3–4, 2017, pp. 75–97.
11. Forsati, R., Mahdavi, M., Shamsfard, M., & Sarwat, M. Matrix Factorization with Explicit Trust and Distrust Relationships. arXiv:1408.0325, 2014.
12. Wang, M., Zheng, X., Yang, Y., & Zhang, K. Collaborative Filtering with Social Exposure: A Modular Approach to Social Recommendation. arXiv:1711.11458, 2017.
13. Hu, G., Dai, X., Song, Y., Huang, S., & Chen, J. A Synthetic Approach for Recommendation: Combining Ratings, Social Relations, and Reviews. arXiv:1601.02327, 2016.
14. Zhang, W., Liu, F., Xu, D., & Jiang, L. Recommendation system in social networks with topical attention and probabilistic matrix factorization. *PLoS ONE*, vol. 14(10): e0223967, 2019.
15. Guo, L., Jiang, R., Zhou, S., Sun, L., Zheng, X., & Luo, Y. Social recommendation based on reputation and trust. *Information Sciences*, vol. 721, Elsevier, Dec. 2025, pp. 1–26.
16. Smachylo, P., & Zhuravchak, L. Features of Recommendation Algorithm on Base of Analysis of Social Network Data Mining Methods. *SISN*, vol. 14, 2023, pp. 114–125.
17. Liu, K. Social Network Based Recommender System: A Probabilistic Graphical Model Approach. *Advances in Economics, Management and Political Sciences (AEMPS)*, vol. 118, 26 Dec. 2024, pp. 1–13.
18. Campana, M. G., & Delmastro, F. Recommender Systems for Online and Mobile Social Networks: A survey. Elsevier, 2017, DOI:10.1016/j.osnem.2017.10.005.
19. Mercanti-Guérin, M. Recommender Systems and Social Networks: What Are the Implications for Digital Marketing? HAL Open Archive, 2021.
20. Adomavicius, G., & Tuzhilin, A. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible

- Extensions. *IEEE Transactions on Knowledge and Data Engineering*, vol. 17(6), 2005, pp. 734–749.
21. Resnick, P., & Varian, H. R. Recommender systems. *Communications of the ACM*, vol. 40(3), 1997, pp. 56–58.
 22. Schafer, J. B., Konstan, J. A., & Riedl, J. E-commerce Recommendation Applications. *Data Mining and Knowledge Discovery*, vol. 5, 2001, pp. 115–153.
 23. Herlocker, J. L., Konstan, J. A., Borchers, A., & Riedl, J. An Algorithmic Framework for Performing Collaborative Filtering. *Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR)*, 1999, pp. 230–237.
 24. Burke, R. Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, vol. 12(4), 2002, pp. 331–370.
 25. Koren, Y., Bell, R., & Volinsky, C. Matrix Factorization Techniques for Recommender Systems. *Computer*, vol. 42(8), 2009, pp. 30–37.
 26. Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. *Recommender Systems: An Introduction*. Cambridge University Press, Cambridge, 2010.
 27. Aggarwal, C. C. *Recommender Systems: The Textbook*. Springer, Boston, MA, 2016.
 28. Terveen, L., & McDonald, D. W. Social Match: A Framework for Social Information Filtering. *Proceedings of the Conference on Human Factors in Computing Systems (CHI)*, 1994, pp. 210–217.
 29. Pazzani, M. J., & Billsus, D. *Content-Based Recommendation Systems. The Adaptive Web*, Springer, Berlin, 2007, pp. 325–341.
 30. Massa, P., & Avesani, P. Trust-Aware Recommender Systems. *Proceedings of the ACM Conference on Recommender Systems (RecSys)*, 2007, pp. 17–24.
 31. O’Donovan, J., & Smyth, B. Trust in Recommender Systems. *Proceedings of the 10th International Conference on Intelligent User Interfaces (IUI)*, 2005, pp. 167–174.

32. Jamali, M., & Ester, M. TrustWalker: A Random Walk Model for Combining Trust-Based and Item-Based Recommendation. Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2009, pp. 397–406.
33. Golbeck, J. Combining Provenance with Trust in Social Networks for Semantic Web Content Filtering. Proceedings of the 4th International Semantic Web Conference, 2005, pp. 101–108.
34. Tang, J., Gao, H., & Liu, H. Node Classification in Signed Social Networks. Proceedings of the 2015 SIAM International Conference on Data Mining (SDM), 2015, pp. 54–62.
35. He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. Neural Collaborative Filtering. Proceedings of the 26th International Conference on World Wide Web (WWW), 2017, pp. 173–182.
36. Ying, R., He, R., Chen, K., et al. Graph Convolutional Neural Networks for Web-Scale Recommender Systems. Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2018, pp. 974–983.
37. Rendle, S. Factorization Machines with libFM. ACM Transactions on Intelligent Systems and Technology (TIST), vol. 3(3), 2012, pp. 1–22.
38. Burke, R., Mobasher, B., Williams, C., & Bhaumik, R. Classification-Weighted Recommendations. Proceedings of the International ACM SIGIR Conference, 2005, pp. 396–403.
39. Herlocker, J., Konstan, J., & Riedl, J. Explaining Collaborative Filtering Recommendations. Proceedings of the ACM Conference on Computer Supported Cooperative Work (CSCW), 2000, pp. 241–250.
40. Lops, P., Gemmis, M. D., & Semeraro, G. Content-Based Recommender Systems: State of the Art and Trends. Recommender Systems Handbook, Springer, 2011, pp. 73–105.
41. Burke, R. Hybrid Recommender Systems: Survey and Experiments. User Modeling and User-Adapted Interaction, 2002, pp. 331–370.

42. Burke, R., Sonmez, O., & Cooper, M. Enhanced Social Recommender Systems via Trust Propagation. Proceedings of the International Conference on Advances in Social Networks Analysis and Mining (ASONAM), 2010, pp. 235–242.
43. Schall, D. Social Network-Based Recommender Systems. Springer International Publishing, Cham, 2015.
44. Bradley, K., & Smyth, B. Improving Recommendation Lists Through Topic Diversification. Proceedings of the 12th ACM International Conference on Intelligent User Interfaces, 2007, pp. 109–118.
45. Adomavicius, G., & Tuzhilin, A. Context-Aware Recommender Systems. Proceedings of the IEEE International Conference on Data Mining (ICDM), 2001, pp. 457–466.
46. Ricci, F., Rokach, L., & Shapira, B. Recommender Systems: Principles, Methods and Evaluation. Springer, 2011, pp. 1–24.