

СМАЧИЛО ПЕТРО

Національний університет "Львівська політехніка"

<https://orcid.org/0009-0008-1285-4181>email: petro.i.smachylo@lpnu.ua

ЖУРАВЧАК ЛЮБОВ

Національний університет "Львівська політехніка"

<http://orcid.org/0000-0002-1444-5882>email: liubov.m.zhuravchak@lpnu.ua

ПОКРАЩЕННЯ СИСТЕМ РЕКОМЕНДАЦІЙ: ГІБРИДНИЙ ПІДХІД З ВИКОРИСТАННЯМ АНАЛІЗУ ТОНАЛЬНОСТІ ТЕКСТУ ТА КОЛАБОРАТИВНОЇ ФІЛЬТРАЦІЇ

У цій роботі розглядаються обмеження традиційних систем рекомендацій шляхом включення аналізу настроїв у спільну фільтрацію для підвищення точності рекомендацій. Звичайні системи часто ігнорують емоційний контекст у відгуках користувачів, покладаючись переважно на минулу поведінку чи явні вподобання. Запропонований підхід аналізує настрої — позитивні, нейтральні чи негативні — в онлайн-оглядах, щоб зафіксувати емоційну реакцію користувачів на продукти, таким чином покращуючи персоналізацію. За допомогою семантичного аналізу та спільного використання функцій алгоритм визначає та класифікує характеристики продукту та думки користувачів. Експерименти показують, що цей метод з урахуванням емоцій забезпечує більш точні, повні та задовільні рекомендації, особливо для подібних продуктів, шляхом узгодження пропозицій із функціональними та емоційними вподобаннями користувача.

Ключові слова: рекомендації щодо продуктів на основі емоцій, персоналізовані рекомендації, вплив настрою відгуків на рекомендації, онлайн-відгуки.

SMACHYLO PETRO, ZHURAVCHAK LIUBOV

Lviv Polytechnic National University

ENHANCING RECOMMENDER SYSTEMS: A HYBRID APPROACH USING SENTIMENT ANALYSIS AND COLLABORATIVE FILTERING

With the development of the Internet and e-commerce, the number of online reviews has increased, creating a large array of data for user decision-making. However, traditional recommender systems often do not take into account the emotional preferences of users, and collaborative filtering methods face the problems of data sparsity and cold start. Conventional recommendation systems primarily rely on user preferences or purchase history, often neglecting the emotional context present in customer feedback. The approach improves these systems by analyzing the sentiment expressed in user reviews—positive, neutral, or negative—to create more relevant and personalized recommendations for products in similar or mixed categories. For example, two products may be equally functional, but a user's emotional attachment or aversion expressed in feedback can significantly change the recommendation. By integrating sentiment data, a deeper understanding of user preferences is created, revealing the connection between emotions and purchasing decisions. This paper proposes a recommendation algorithm that combines emotional color analysis of online reviews with collaborative filtering to improve recommendation accuracy. The algorithm analyzes the emotions in user feedback, determines their preferences, and uses this information to generate personalized recommendations. In our experiments, we performed a comprehensive analysis of online reviews, employing several preprocessing steps to ensure accurate sentiment extraction. Reviews were segmented using specific punctuation marks, and stop words were removed to enhance clarity. We utilized semantic similarity analysis to identify and categorize relevant product features and user opinions, employing techniques such as cosine similarity on word vectors obtained from pre-trained models. Additionally, we examined product feature co-occurrence to uncover relationships between features in user reviews. To calculate user preference similarities, we identified similar users based on shared product ratings, effectively predicting new product interests for users based on their preferences and the emotional sentiment present in reviews. Experiments have shown that the proposed approach improves the accuracy, completeness, and coverage of recommendations compared to traditional methods, especially in the category of similar product recommendations. Findings show that combining collaborative filtering with sentiment analysis leads to deeper insights and more satisfying product suggestions.

Keywords: emotion-based product recommendations, personalized recommendations, sentiment impact on recommendations, online review.

Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями

Аналіз тональності тексту став невід'ємною частиною сучасних систем рекомендацій, оскільки він дозволяє глибше розуміти емоційні реакції користувачів на різні продукти та послуги [1]. У поєднанні з колаборативною фільтрацією, яка вже зарекомендувала себе в системах рекомендацій, аналіз тональності тексту забезпечує новий рівень точності та персоналізації. Колаборативна фільтрація є поширеною технологією рекомендацій, але вона також має певні проблеми, такі як розрідженість даних і проблеми холодного старту [2]. Колаборативна фільтрація на основі вподобань схожих користувачів дозволяє виявляти закономірності у виборі продуктів. Водночас аналіз тональності тексту дає змогу враховувати емоційний контекст, що дозволяє краще розуміти та прогнозувати поведінку користувачів. У цій статті ми розглянемо, як поєднання аналізу тональності тексту і колаборативної фільтрації допомагає покращити системи рекомендацій.

Аналіз досліджень та публікацій

Дослідження аналізу емоційного забарвлення онлайн-відгуків. Аналіз емоційного забарвлення – це техніка, що використовує методи текстової аналітики для аналізу емоцій, виражених в онлайн-відгуках: позитивне або негативне ставлення користувача до продукту. Аналіз емоційного забарвлення є важливою частиною дослідження думок, що ідентифікує та виділяє суб'єктивні думки, емоції та почуття, виражені в тексті.

Аналіз емоційного забарвлення зазвичай проводять на рівні слів та на рівні документів. Аналіз на рівні документів поділяють на методи, що базуються на зниженні розмірності (SVM, метод опорних векторів), та методи, засновані на лексиконах емоцій (MSA-COSR, LTR, PREM і SO-LSA). Ці методи застосовують у різних галузях, включаючи огляди фільмів, відгуки про продукти та аналіз соціальних мереж. Інша гілка досліджень аналізу емоційного забарвлення фокусується на класифікації емоцій, де мета полягає в тому, щоб віднести текст до задалегідь визначених категорій емоцій. Серед викликів класифікації емоцій є різні способи їх вираження у різних галузях, розпізнавання сарказму або іронії та обробка заперечень у тексті.

Дослідження колаборативної фільтрації. Системи рекомендацій на основі колаборативної фільтрації здобули широке поширення в електронній комерції. Вони ґрунтуються на поведінці користувачів, тобто на їхній історії покупок, для рекомендації продуктів. Однак традиційна колаборативна фільтрація має обмеження (розрідженість даних і проблема холодного старту), коли нові користувачі або товари не мають достатньо даних для формування точних рекомендацій.

Щоб вирішити ці проблеми, дослідники запропонували кілька удосконалень колаборативної фільтрації, включаючи гібридні моделі, які поєднують колаборативну фільтрацію з контентною фільтрацією або аналізом емоційного забарвлення. Один з підходів полягає у використанні технік PCA (аналіз головних компонент) або SOM (самоорганізаційна картка) для кластеризації уподобань користувачів, що можуть бути поєднані з колаборативною фільтрацією.

Застосування аналізу емоційного забарвлення в системах рекомендацій. Аналіз емоційного забарвлення інтегрували у системи рекомендацій для підвищення їхньої точності. Дослідження показали, що такий аналіз може відігравати важливу роль у розумінні вподобань користувачів та прогнозуванні їхньої поведінки [3]. Наприклад, деякі дослідники зосередилися на аналізі відгуків користувачів для вилучення тональності та використання її разом із рекомендаціями товарів для підвищення ефективності рекомендацій [4].

Холодні та гарячі продукти є поширеним явищем у системах рекомендацій. Холодні продукти – це ті, про які користувачі мало знають. Щоб допомогти користувачам їх зрозуміти ці продукти, система рекомендацій активно надає їм відповідну інформацію. Навпаки, гарячі продукти добре відомі, і користувачі можуть уже бути з ними знайомі. Дослідники класифікують відгуки користувачів на холодні та гарячі категорії, щоб відрізнити думки користувачів про ці продукти. Поширений підхід полягає в аналізі історії переглядів користувачів та даних про кліки.

Відгуки користувачів зазвичай містять детальні оцінки, зокрема, про ефективність продукту, і можуть бути важливим орієнтиром для інших користувачів. Однак коли відгук не містить достатньо деталей, його цінність значно знижується. Наприклад, відгук на кшталт "хороший продукт" не подає багато корисної інформації. Крім того, надто деталізовані відгуки можуть бути недостатньо лаконічними, що впливає на ефективність системи рекомендацій. Тому виникає потреба аналізувати характеристики відгуків на основі статусу продуктів як гарячих або холодних. Експерименти, що використовували аналіз тональності у системі рекомендацій, показали, що оцінки продуктів користувачами не завжди корелюють з сентиментами відгуків, написаних для тих самих продуктів [5].

Рекомендації щодо гарячих продуктів зазвичай ґрунтуються на задалегідь визначеному пороговому значенні для визначення, чи вважати продукт "гарячим". Система відстежує поведінку покупців і визначає продукт як "гарячий", якщо він перевищує порогове значення. З іншого боку, холодні продукти – це ті, що ще не досягли порогу, але мають потенціал для майбутніх покупок. Дослідники пропонують використовувати відгуки користувачів про гарячі продукти для доповнення бази знань про холодні продукти, підвищуючи так ефективність системи рекомендацій.

Формулювання цілей статті

Об'єкт дослідження: рекомендаційний алгоритм, що інтегрує аналіз тональності тексту онлайн-відгуків із техніками колаборативної фільтрації.

Предмет дослідження: інтеграція аналізу тональності тексту та методологій колаборативної фільтрації з акцентуванням на аналізі онлайн-відгуків користувачів для вилучення вподобань.

Мета роботи: підвищити ефективність рекомендаційних систем, долаючи обмеження традиційної колаборативної фільтрації, зокрема, проблеми, пов'язані з розрідженістю даних і холодним стартом, та інтегруючи з нею аналіз тональності тексту.

Виклад основного матеріалу

Попередня обробка онлайн-відгуків. На основі розділових знаків, використаних у відгуках, текст відгуків сегментують. На жаль, користувачі не завжди дотримуються послідовного використання розділових

рейтингами користувачів u та v для функції f_i у цій категорії. Система порівнює схожість між користувачами u та v на основі таких двох критеріїв:

1) якщо середній рейтинг, наданий користувачем u для функції f_i , вищий за $G_i(v)$, система обчислює різницю від середнього рейтингу, і середній рейтинг відгуку користувача позначається як $R_i(u) \geq R_i(v)$.

Система фіксує це як надання позитивної переваги користувачем u щодо функції f_i ;

2) якщо середній рейтинг, наданий користувачем u для функції f_i , нижчий за $G_i(v)$, система обчислює різницю від середнього рейтингу, і середній рейтинг відгуку користувача позначається як $R_i(u) \leq R_i(v)$.

Система фіксує це як надання негативної переваги користувачем u щодо функції f_i .

Оцінку переваги користувача для функції f_i обчислюють за формулою:

$$Concern(u, f_i) = \frac{count(u_1 + \dots + u_n)}{N} \times count(f_i),$$

де $Concern(u, f_i)$ вказує на ступінь зацікавленості користувача u щодо функції f_i ; $count(u)$, $count(f_i)$ – загальні кількості відгуків користувача u та для функції f_i .

Другий метод оцінки, $Ntipick(u, f_i)$, подає рівень вибірковості користувача u щодо функції f_i і обчислюється за такою формулою:

$$Ntipick(u, f_i) = \frac{G_i - G_i(u)}{G_i(u) + 1} \times \frac{N}{G_i + 1}.$$

Якщо $G_i > G_i(u)$ або $G_i < G_i(u)$, то загальний рейтинг для функції f_i є вищим або нижчим за середній рейтинг користувача u , тобто $Ntipick(u, f_i)$ є позитивним або негативним відповідно. Якщо $G_i = G_i(u)$, то загальний рейтинг для функції f_i відповідає середньому рейтингу користувача u , що призводить до нейтрального $Ntipick(u, f_i)$.

Результат множення $Ntipick(u, f_i)$ та $Concern(u, f_i)$ відображає те, наскільки користувачу u важлива функція f_i ($Concern$) у поєднанні з його вибірковістю або відносною перевагою ($Ntipick$):

$$Preference(u, f_i) = Concern(u, f_i) \times Ntipick(u, f_i).$$

Якщо $Preference(u, f_i) = 0$, то це означає, що користувач u байдужий до функції f_i . Якщо $Preference(u, f_i) > 0$ або $Preference(u, f_i) < 0$, то це означає, що користувач u надає позитивну або негативну перевагу щодо функції f_i .

Вагові оцінки переваг обчислюють так:

$$W_{uv} = \frac{\sum_{i=1}^n |p_{ui} \cdot p_{vi}|}{\sum_{i=1}^n |p_{ui} - p_{vi}| + 1}$$

де p_{ui} , p_{vi} – оцінки переваги користувачів u , v для функції f_i .

Обробка "гарячих" продуктів. Рекомендаційна система вважає продукти з високою кількістю натискань і високим (або ж низьким) рівнем конверсії "гарячими" товарами. Система припускає, що ці "гарячі" продукти викликають значний інтерес, але їх не купують, що може вказувати на проблеми з їхнім маркетингом або поданням. Це може призвести до подальшого аналізу характеристик цих продуктів. Якщо продукт має велику кількість покупок, рекомендаційна система частіше вважає його "гарячим". "Гарячі" продукти часто купують разом з іншими товарами. Якщо історія переглядів користувача показує схильність до "гарячого" продукту, система може збільшити кількість рекомендацій для пов'язаних продуктів. Навпаки, продукти, що не отримують багато уваги, з меншою ймовірністю будуть часто рекомендувати. Такий метод рекомендацій може бути корисним, коли база користувачів велика. Якщо рекомендації можна контролювати, система може використовувати відповідні алгоритми для збалансування цих "гарячих" рекомендацій, запобігаючи їх повному домінуванню у списку рекомендацій і уникаючи надмірного впливу популярних продуктів на користувача.

Крім того, людей, які купують подібні продукти, система часто класифікує як користувачів з "подібними інтересами". Хоча ці користувачі мають схожу поведінку покупок, це не обов'язково означає, що вони мають схожі потреби чи пов'язані атрибути. Рекомендовані продукти, отримані від таких користувачів, можуть не завжди відповідати інтересам інших користувачів. Крім того, багато систем рекомендацій мають великі бази даних. Якщо двох користувачів ідентифікують як таких, що мають подібні інтереси на основі статистичного аналізу (наприклад, обидва купують науково-фантастичні книги), це не обов'язково означає, що вони мають подібні уподобання, оскільки їхній спільний інтерес може бути просто наслідком популярності певних книг. Таким чином, якщо користувачі оцінюють "гарячі" продукти, це не обов'язково означає, що вони хочуть, щоб система рекомендувала їм інші схожі продукти; можливо, вони просто шукають рекомендації на основі своїх поточних уподобань чи конкретних потреб. Щоб врахувати ці складнощі, система може змінювати силу рекомендацій на основі оцінок або відгуків користувачів про "гарячі" продукти.

Якщо розглядають продукти з різних категорій, система рекомендацій використовує рекурсивний підхід для обчислення схожості та коригує ваги рекомендацій відповідно.

Для продуктів у межах однієї категорії система рекомендацій використовує оцінки користувачем різних характеристик. Метод можна поділити на двовимірний масив із характеристиками f_1 , f_2 і т.п. і категоріями [позитивна, негативна, нейтральна]. Кожна характеристика в масиві подає думку користувача про конкретну характеристику продукту. Якщо користувач оцінив характеристику позитивно або негативно, цю

оцінку використовують як уподобання користувача. Якщо жодної оцінки не надано, припускають нейтральну думку.

Припустимо, що користувач А оцінює характеристики 1, 2 та 3 як позитивну, нейтральну та негативну. Користувач В оцінює характеристики 1, 2 та 3 як позитивну, негативну та нейтральну. Користувач С оцінює характеристики 1, 2 та 3 як позитивну, негативну та позитивну. Оцінки кожного користувача враховують під час обчислення індексу схожості, який можна виразити так:

$$D_{ji} = ((\text{позитивна}, 1), (\text{нейтральна}, 0), (\text{негативна}, -1)), j \in \{A, B, C\}.$$

Результати використовують для коригування сили рекомендацій на основі оцінок і уподобань користувача.

Обчислення інтересу користувача до продуктів. Для обчислення схожості між користувачами u і v на основі інтересів до продуктів [8] беруть K найбільш схожих користувачів, які придбали ті самі продукти, що й користувач u . Формулу для обчислення інтересу користувача u до продукту i задають так:

$$Interest(u, i) = \sum_{v \in S(u, K) \cap N(i)} W_{uv} \cdot r_{vi},$$

де $S(u, K)$ – множина з K користувачів, які найбільш схожі на користувача u на основі їхніх історій покупок; $N(i)$ – множина користувачів, які купили продукт i ; W_{uv} – схожість між користувачами u і v ; r_{vi} – рейтинг, наданий продукту i користувачем v . Оцінка інтересу $Interest(u, i)$ має один параметр K , що контролює кількість схожих користувачів, яких враховують в обчисленні.

Приклад обчислень: користувач u – користувач А; продукт i – "книгал"; множина схожих користувачів $S(u, K) = \{\text{користувач В, користувач С}\}$; множина користувачів, які придбали "книгу1", $N(i) = \{\text{користувач В, користувач С}\}$; оцінки схожості W_{uv} , зокрема, $W_{AB} = 0.75$ (схожість між користувачами А і В), $W_{AC} = 0.6$ (схожість між користувачами А і С); рейтинги, надані "книзі1" користувачами В та С r_{vi} , $r_{Bi} = 4$, $r_{Ci} = 5$. Обчислюємо зважену суму за формулою:

$$Interest(\text{UserA}, \text{Book1}) = W_{AB} \cdot r_{Bi} + W_{AC} \cdot r_{Ci},$$

тобто

$$Interest(\text{UserA}, \text{Book1}) = 0.75 \cdot 4 + 0.6 \cdot 5 = 3 + 3 = 6.$$

Отже, оцінка інтересу користувача А до "книги1" складає 6.

Оцінка рекомендацій схожих продуктів. Для аналізу використано набір даних із рецензій (відгуків) на книги з платформи Amazon [9]. Книги обрано як категорію для рекомендацій схожих продуктів, оскільки вони є товарами з безперервною моделлю покупок і частими придбаннями. Хоча дослідження зосереджено на книгах, алгоритм можна адаптувати для інших сфер: музика, кіно та роздрібна торгівля.

Спочатку протестовано різні алгоритми з різними значеннями параметра K для індикаторів ефективності (табл. 1). Можна побачити, що при значенні $K=120$ точність і коефіцієнт відгуку є найвищими, а охоплення та популярність перебувають у прийнятних межах. Отже, для рекомендацій продуктів було обрано саме це значення K .

У табл. 2 порівняно ефективність базового алгоритму рекомендацій і запропонованого та реалізованого алгоритму рекомендацій. Базовий алгоритм колаборативної фільтрації – це основний алгоритм рекомендацій, який використовує дані про взаємодію користувачів з товарами для прогнозування їхніх уподобань. Алгоритм базується на схожості поведінки користувачів або на схожості товарів, що дозволяє пропонувати нові товари користувачам на основі оцінок і виборів інших користувачів. Метод, запропонований у цьому дослідженні, демонструє значно вищі показники точності, коефіцієнта відгуку та охоплення, тоді як популярність продукту дещо зменшилася порівняно з базовим алгоритмом [10].

Таблиця 1

Ефективність рекомендацій схожих продуктів при різних значеннях параметра K

K	Точність	Повнота	Охоплення	Різноманітність
10	9.42%	5.78%	26.56%	20.65
20	10.34%	6.14%	27.80%	37.81
50	12.68%	6.87%	28.77%	32.45
80	14.07%	7.32%	29.90%	30.92
100	15.10%	7.91%	27.05%	39.17
120	15.87%	8.26%	19.25%	35.32
200	14.76%	8.02%	18.76%	38.62

Таблиця 2

Порівняння ефективності різних алгоритмів рекомендацій продуктів

Algorithm	Влучність	Повнота	Охоплення	Популярність
Baseline Method	13.21%	7.43%	13.97%	50.23
Proposed Method	15.87%	8.26%	19.25%	35.32

Оцінка рекомендацій змішаних продуктів. Змішані рекомендації стосуються комбінації різних категорій книг. Експеримент показує, що при $K=100$ точність, повнота, охоплення та різноманітність змішаної системи рекомендацій кращі, ніж при $K=120$, що було оптимальним значенням для рекомендацій схожих книг (табл. 3). Це демонструє, що ефективність змішаних рекомендацій краща (табл. 4), і необхідно використовувати кілька зразків із різних категорій продуктів.

Таблиця 3

Ефективність змішаних рекомендацій продуктів при різних значеннях K

K	Точність	Повнота	Охоплення	Різнманітність
10	8.16%	5.03%	32.37%	30.21
20	9.14%	5.27%	33.24%	31.00
50	11.32%	5.65%	31.64%	37.10
80	13.19%	6.12%	28.64%	34.89
100	15.21%	6.77%	27.09%	34.37
120	15.21%	6.77%	27.09%	34.37

Таблиця 4

Порівняння ефективності різних алгоритмів рекомендацій змішаних продуктів

Algorithm	Влучність	Повнота	Охоплення	Популярність
Baseline Method	12.71%	6.42%	18.80%	45.38
Proposed Method	13.82%	7.02%	21.79%	33.72

Точність і повнота змішаних рекомендацій продуктів не такі високі, як у рекомендацій схожих продуктів, оскільки цей алгоритм призначений для різних середовищ і варіантів використання. Однак, детальніша структура даних з відгуків дозволяє системі досягти кращої загальної ефективності рекомендацій.

Висновки з даного дослідження**і перспективи подальших розвідок у даному напрямі**

Онлайн-відгуки використовують для оптимізації ефективності системи рекомендацій. Відповідно до інформації про відгуки користувача метод відображає ступінь уподобання користувача щодо кожної характеристики продукту та популярність самого продукту.

Для рекомендацій схожих продуктів система враховує уподобання користувачів щодо кожної характеристики продукту на основі історичних даних. Вона обчислює увагу користувачів до кожної характеристики продукту та порівнює ступінь інтересу між різними користувачами до однієї і тієї ж характеристики продукту. Це призводить до персоналізованіших рекомендацій. Запропонований алгоритм демонструє поліпшену ефективність порівняно з традиційними методами, особливо в аспектах точності, відгуку та охоплення, про що свідчать експериментальні результати.

Наукова новизна отриманих результатів дослідження полягає у вдосконаленні методу колаборативної фільтрації через його інтеграцію з аналізом тональності тексту. Запропонований підхід підвищує ефективність системи, зокрема за показниками точності, відгуку та охоплення, що підтверджено експериментальними результатами.

Практична значущість результатів дослідження – результати цього дослідження мають практичну цінність для галузей, які покладаються на персоналізовані рекомендації, зокрема, в електронній комерції та медіаплатформах. Включаючи аналіз тональності в системи рекомендацій, компанії можуть надавати точніші та орієнтованіші на користувачів пропозиції, потенційно підвищуючи їхню задоволеність і залученість. Цей підхід можна реалізовувати на різних цифрових платформах для покращення взаємодії з клієнтами та процесів ухвалення рішень.

Подальші дослідження будуть зосереджені на удосконаленні методів аналізу емоційного забарвлення, зокрема, аналізі складніших моделей обробки природної мови для кращого розуміння емоційних відтінків текстів. Також буде розглянуто застосування інших методів обробки текстових даних (тематичне моделювання) для автоматичного виявлення прихованих тем у відгуках користувачів.

Література

1. Петро Смачило, Любов Журавчак. Особливості рекомендаційного алгоритму на основі аналізу методів добування даних з соціальних мереж // Вісник Національного університету „Львівська політехніка”. Серія "Інформаційні системи та мережі". – 2023. – № 14. – С. 114–125. – DOI: <https://doi.org/10.23939/sisn2023.14.114>
2. Yuan H., Hernandez A. A. User cold start problem in Recommendation Systems: A Systematic review // IEEE Access. – 2023. – № 11. – P. 136958–136977. – DOI: <https://doi.org/10.1109/access.2023.3338705>
3. Chen J., Song N., Su Y., Zhao S., Zhang Y. Learning user sentiment orientation in social networks for sentiment analysis // Information Sciences. – 2022. – № 616. – P. 526–538. – DOI: <https://doi.org/10.1016/j.ins.2022.10.135>
4. Zhang K., Qian H., Liu Q., Zhang Z., Zhou J., Ma J., Chen E. SIFN: A sentiment-aware interactive fusion network for review-based item recommendation // Proceedings of the 30th ACM International Conference on Information & Knowledge Management (CIKM '21). – 2021. – P. 3627–3631. – DOI: <https://doi.org/10.1145/3459637.3482181>
5. Elahi M., Kholgh D. K., Kiarostami M. S., Oussalah M., Saghari S. Hybrid recommendation by incorporating the sentiment of product reviews // Information Sciences. – 2023. – № 625. – P. 738–756. – DOI: <https://doi.org/10.1016/j.ins.2023.01.051>
6. Cao W., Liu Y., Cao G., He Z. Implicit user relationships across sessions enhanced graph for session-based recommendation // Information Sciences. – 2022. – № 609. – P. 1–14. – DOI: <https://doi.org/10.1016/j.ins.2022.07.062>
7. Nawangsari R. P., Kusumaningrum R., Wibowo A. Word2Vec for Indonesian Sentiment Analysis towards Hotel Reviews: An Evaluation Study // Procedia Computer Science. – 2019. – № 157. – P. 360–366. – DOI: <https://doi.org/10.1016/j.procs.2019.08.178>
8. Suhaim A. B., Berri J. Directional user similarity model for personalized recommendation in online social networks // Journal of King Saud University - Computer and Information Sciences. – 2022. – № 34(10). – P. 10205–10216. – DOI: <https://doi.org/10.1016/j.jksuci.2022.10.017>
9. Seo S., Huang J., Yang H., Liu Y. Interpretable convolutional neural networks with dual local and global attention for review rating prediction // Proceedings of the Eleventh ACM Conference on Recommender Systems (RecSys '17). – 2017. – P. 297–305. – DOI: <https://doi.org/10.1145/3109859.3109890>
10. Fareed A., Hassan S., Belhaouari S. B., Halim Z. A collaborative filtering recommendation framework utilizing social networks // Machine Learning With Applications. – 2023. – № 14. – P. 100495. – DOI: <https://doi.org/10.1016/j.mlwa.2023.100495>

References

1. Petro Smachylo, Liubov Zhuravchak. Features of recommendation algorithm on base of analysis of social network data mining methods // Visnyk of the Lviv Polytechnic National University. Series Information Systems and Networks. – 2023. – № 14. – P. 114–125. – DOI: <https://doi.org/10.23939/sisn2023.14.114>
2. Yuan H., Hernandez A. A. User cold start problem in Recommendation Systems: A Systematic review // IEEE Access. – 2023. – № 11. – P. 136958–136977. – DOI: <https://doi.org/10.1109/access.2023.3338705>
3. Chen J., Song N., Su Y., Zhao S., Zhang Y. Learning user sentiment orientation in social networks for sentiment analysis // Information Sciences. – 2022. – № 616. – P. 526–538. – DOI: <https://doi.org/10.1016/j.ins.2022.10.135>
4. Zhang K., Qian H., Liu Q., Zhang Z., Zhou J., Ma J., Chen E. SIFN: A sentiment-aware interactive fusion network for review-based item recommendation // Proceedings of the 30th ACM International Conference on Information & Knowledge Management (CIKM '21). – 2021. – P. 3627–3631. – DOI: <https://doi.org/10.1145/3459637.3482181>
5. Elahi M., Kholgh D. K., Kiarostami M. S., Oussalah M., Saghari S. Hybrid recommendation by incorporating the sentiment of product reviews // Information Sciences. – 2023. – № 625. – P. 738–756. – DOI: <https://doi.org/10.1016/j.ins.2023.01.051>
6. Cao W., Liu Y., Cao G., He Z. Implicit user relationships across sessions enhanced graph for session-based recommendation // Information Sciences. – 2022. – № 609. – P. 1–14. – DOI: <https://doi.org/10.1016/j.ins.2022.07.062>
7. Nawangsari R. P., Kusumaningrum R., Wibowo A. Word2Vec for Indonesian Sentiment Analysis towards Hotel Reviews: An Evaluation Study // Procedia Computer Science. – 2019. – № 157. – P. 360–366. – DOI: <https://doi.org/10.1016/j.procs.2019.08.178>
8. Suhaim A. B., Berri J. Directional user similarity model for personalized recommendation in online social networks // Journal of King Saud University - Computer and Information Sciences. – 2022. – № 34(10). – P. 10205–10216. – DOI: <https://doi.org/10.1016/j.jksuci.2022.10.017>
9. Seo S., Huang J., Yang H., Liu Y. Interpretable convolutional neural networks with dual local and global attention for review rating prediction // Proceedings of the Eleventh ACM Conference on Recommender Systems (RecSys '17). – 2017. – P. 297–305. – DOI: <https://doi.org/10.1145/3109859.3109890>
10. Fareed A., Hassan S., Belhaouari S. B., Halim Z. A collaborative filtering recommendation framework utilizing social networks // Machine Learning With Applications. – 2023. – № 14. – P. 100495. – DOI: <https://doi.org/10.1016/j.mlwa.2023.100495>