

Глибовець М. М., Сидорова Є. О.

## ЗАСТОСУВАННЯ ГРАФОВИХ БАЗ ДАНИХ І EXPLAINABLE AI У СТВОРЕННІ РЕКОМЕНДАЦІЙНОЇ СИСТЕМИ З ГІБРИДНИМ СПОСОБОМ ФІЛЬТРАЦІЇ

*У дослідженні описано побудову рекомендаційної системи з гібридним способом фільтрації, що використовує гетерогенні графові структури, нейронні мережі та Explainable AI заради підвищення персоналізації та прозорості рішень. Базова методологія оптимізації рекомендацій ґрунтується на сучасних методах машинного навчання, які здатні ефективно моделювати залежності між об'єктами. Предметна область задачі охоплює мультимедійні рекомендації, зосереджені на персоналізованому підході. Представлена архітектура системи дає можливість ефективно обробляти множину вузлів різних типів і зв'язків (набір взаємодій, належність елементів до жанру, подібність), що відображають комплексні ознаки поведінкових і контекстуальних даних.*

*Результати експериментального тестування підтвердили ефективність запропонованого підходу: система демонструє високі показники персоналізації, новизни рекомендацій та здатності виявляти подібних користувачів.*

**Ключові слова:** рекомендаційна система; графова нейронна мережа; гетерогенний граф; гібридна фільтрація; мультимодальні дані; персоналізація; Explainable AI; Neo4j; Python.

### Вступ

У сучасному інформаційному просторі обсяг цифрового контенту постійно зростає, що одночасно і спрощує, і ускладнює для користувачів процес пошуку цікавої та корисної інформації, зокрема у вигляді книжок, ігор, фільмів і безлічі інших мультимедійних об'єктів. З огляду на це рекомендаційні системи (далі — РС) мають неабияке значення для отримання релевантного контенту в процесі взаємодії з інформаційними платформами. Це дослідження спрямоване на створення РС із гібридним способом фільтрації, залученням гетерогенних графових структур і підходів Explainable AI для покращення персоналізації наданих порад.

Зазвичай подібні системи стикаються з низкою обмежень, зокрема пов'язаних із класичними підходами у формі колаборативної і контентної фільтрації, відсутністю прозорості у прийнятих рішеннях і вузьким спектром мультимодальних ознак.

Отже, основною метою цієї роботи є побудова такої архітектури, яка б надавала можливість застосовувати ефективний і більш розширений підхід для досягнення персоналізації і прозорості рекомендацій. Запропоноване у цій статті програмне рішення враховує мультимодальні ознаки, об'єднує атрибутивну та поведінкову інформацію, а також обґрунтовує причинові зв'язки обраних рекомендацій, орієнтуючись на реальні патерни користувача.

### Аналіз сучасних підходів

Найпоширенішими парадигмами РС є колаборативна фільтрація (CF) і контентна фільтрація (CBF), однак їхнє впровадження дуже залежить від структури і типів даних для контенту [2]. Для першого типу значною вразливістю є проблема «холодного старту» за наявності вузького спектра початкових даних; для другого ж значним викликом є складність даних у формі мультимодальності та різноманітності типів контенту, тоді як інтеграція гібридного способу дає можливість використовувати обидва підходи одночасно [12].

Також слід зазначити, що запровадження такої гібридної архітектури часто підкріплено використанням графових структур і нейронних мереж для моделювання зв'язків між об'єктами різних типів. Таким чином, побудована програмна реалізація відображає комплексні ознаки поведінкових і кон-

текстуальних даних. Також слід сказати, що впровадження й застосування таких моделей, як GraphSAGE, забезпечує індуктивне навчання з високою здатністю до узагальнення [5].

Крім того, зі стрімким розвитком технологій усе більшої актуальності набувають інтеграції компонентів Explainable AI (XAI) до такого роду моделей. Через архітектуру «чорної скриньки» взаємозв'язок між результатом і системою часто потребує пояснень, тому рішення з їхнім використанням дають змогу зрозуміти, які елементи стали найбільш вагомими [4].

Порівняно з наявними рішеннями, які використовують лише текстові чи табличні ознаки, у цій роботі система враховує інтегровані векторні ознаки з різних медіамодалностей — текстові, візуальні та жанрові ознаки; забезпечує крос-типову подібність (наприклад, книжки, подібні до фільмів за жанровим профілем); об'єднує поведінкові взаємодії, доповнені атрибутами об'єктів; використовує пояснення XAI для підвищення довіри до рекомендацій.

### Архітектура графової системи

В основі архітектури лежить гетерогенний граф  $G=(V, E)$ , у якому вузли й ребра мають різні типи й категорії. Така структура дає змогу одночасно моделювати поєднання різнорідних об'єктів і їхніх відношень, що є основною складовою для рекомендаційних задач у складному медіасередовищі [4]. Предметна область персоналізованих рекомендацій мультимедійного контенту охоплює такі типи ресурсів, як книжки, фільми та відеоігри. Вона характеризується високою різнорідністю об'єктів, множинним вибором взаємодій і потребою в глибокій персоналізації результатів.

Множина вузлів  $V$  для цього дослідження охоплює користувачів (User), книжки (Book), фільми (Movie), ігри (Game) та жанри (Genre). Множина ребр  $E$  описує такі зв'язки: належність медіаелементу до певного жанру, взаємодія користувачів з об'єктами (перегляд, оцінка, ігнорування, купівля), а також залежності подібності.

Отже, кожен тип вузла та зв'язку має окрему семантику у формі типізованих ознак, відповідно до моделі гетерогенних графів.

### Набір даних

Було сформовано синтетичний набір даних, проте з реалістичними показниками, який містить об'єкти трьох доменів, а також штучно згенеровану популяцію користувачів із симульованою поведінкою. Дані для книжок було отримано за допомогою API Google Books [3], де для кожного жанру вказано конфігурації належності саме до типу книжок, оскільки категоризація відповідає саме початковому типу об'єкта. Для ігор було використано API RAWG [9], яке надає доступ до великої бази даних ігровою класифікацією, а для фільмів — сервіс RapidAPI з API Advanced Search [1], за допомогою яких аналогічно до попередніх відбувався процес класифікації за жанровою належністю. Кожному типу об'єкта ми зберегли набір атрибутів, який складається з унікального ідентифікатора, назви, жанру, короткого опису та посилання до відповідного зображення.

Користувачів було створено як незалежних агентних сутностей із відповідними атрибутами віку (15–65 років), статі, розташування, дати реєстрації на визначеному проміжку й рівня активності, який обраховується як відношення кількості прикладів взаємодії з моменту реєстрації дотепер (нормований коефіцієнт). Усі 1000 сутностей були відмічені унікальними ідентифікаторами для імітації гетерогенної популяції з різними стилями споживання контенту. За поведінкові зв'язки відповідають ребра, типізовані за типами взаємодій, згаданих до цього. Кількість таких взаємодій було згенеровано пропорційно до рівня активності кожного користувача.

Усі зібрані дані нормалізувалися для використання єдиного класу жанру та відповідного універсального зв'язку. Збережені об'єкти інтегрувалися до графової бази даних Neo4j.

### Векторні репрезентації та матриці подібності

Для представлення об'єктів використано мультимодальні ембедінги, які формуються шляхом поєднання текстових, візуальних і жанрових ознак. Для побудови векторних подань словесних матеріалів медіаоб'єктів було використано модель Sentence-BERT, що відображає текстові описи у векторний простір сталої розмірності [10]. За жанровими мітками було збудовано one-hot репре-

зентації, які дозволяють створювати належність до конкретного набору жанрів. Для візуальних прив'язок було використано попередньо навчену модель ResNet-50 з обробленням фотоданих у контексті масштабування і нормалізації. Оброблення виконується для кожного типу медіа окремо. Формування векторів для користувачів ґрунтується на метаданих, тому для числових змінних застосовано стандартизацію, а для категоріальних — one-hot.

На цій основі обчислюються матриці косинусної подібності з подальшим формуванням симетричних графових відношень. Тоді для кожного з типів медіа розраховується top-k (у цьому випадку 5) найбільш подібних об'єктів за косинусною відстанню між ембедінгами. Оцінюється міжтипова жанрова подібність за one-hot репрезентаціями жанрів, де схожість вище, ніж заданий поріг. На основі інформації про користувачів будується top-k (у цьому випадку 5) найближчих користувачів для колаборативних рекомендацій. Усі обчислені відношення імпортуються до графової бази даних Neo4j з відповідними ваговими коефіцієнтами. Приклади запитів для наочної демонстрації зв'язків у графовій структурі подано на рис. 1 і 2.




Рис. 1. Приклад зв'язків схожості користувачів у графовій системі



Рис. 2. Приклад зв'язків міжтипової схожості у графовій системі

Таким чином було сформовано систему з 4150 вузлів, які описують об'єкти різних типів і 122 862 ребра для відображення стосунків між ними.

### Надання рекомендацій

Для побудови персоналізованих рекомендацій ми застосували графові нейронні мережі, що дає можливість досить просто навчити спільний простір представлень для різноманітних сутностей і їхніх взаємодій [6].

Розроблений гетерогенний граф слугує початком для створення одиничної ознаки, всі зв'язки серіалізуються та оброблюються за допомогою фреймворку PyTorch Geometric. Архітектура запропонованої моделі передбачає агрегацію інформації, використання двох рівнів конвулюційних шарів і оброблення лінійними шарами для обчислення функції подібності. Навчання триває 50 епох, містить метод negative sampling і створює ітеративний процес оновлення ваг шарів.

Для процесу пояснення рекомендацій до використання цієї моделі використовується кілька важливих етапів. По-перше, для прозорості результатів пошуку подібних користувачів використовується градієнт косинусної подібності між векторами схожості користувачів і ідентифікація перетину їхніх взаємодій. Генерація інтерпретованих пояснень передбачає обраховану градієнтну оцінку, спільні демографічні атрибути та дії користувачів. Приклад продемонстровано на рис. 3.

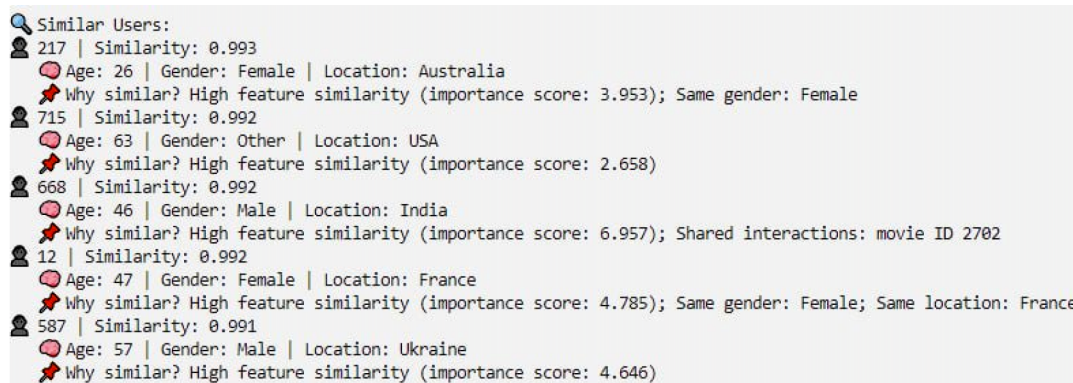


Рис. 3. Приклад рекомендації схожих користувачів

По-друге, процес обґрунтування рекомендацій об'єктів відбувається шляхом градієнтної оцінки важливості за сумністю пари «користувач — елемент». Таким чином для кожного типу вузлів обираються найбільш впливові, що дозволяє сформувати список представників, які відіграли значущу роль у формуванні рекомендації. Приклад продемонстровано на рис. 4.




Рис. 4. Приклад рекомендації медіаелементів

### Програмна реалізація

Для програмної реалізації (далі — ПР) було використано мову програмування Python із залученням таких основних бібліотек: PyTorch Geometric (для побудови графових нейронних мереж), scikit-learn, pandas (для кодування й попереднього оброблення даних) і matplotlib (для візуалізації).

РС реалізовано у формі модульного застосунку з окремими компонентами для побудови графа, тренування моделі, генерації рекомендацій, ХАІ-компонентами (пояснення схожості користувачів і важливості вузлів за градієнтними характеристиками), а також тестування.

### Експериментальне тестування

У межах експериментального тестування було обрано набір нееталонних метрик (reference-free, без ground-truth) для оцінки, оскільки система не оперує завчасно готовими правильними відповідями для рекомендацій. Вони містять Intra-List Similarity і Novelty для оцінки рекомендованих елементів; User Similarity, Shared Interaction Overlap, Attribute Alignment, User Diversity для оцінки схожості користувачів; а також Coverage для аналізу спектра доступних релевантних елементів і Personalization для оцінки унікальності рекомендацій [7; 8; 11].

Загалом результати експериментального дослідження засвідчили якісну здатність знаходити схожих користувачів і пропонувати нові унікальні медіаоб'єкти. Це підтверджується високими показниками новизни рекомендацій і внутрішньої різноманітності списків. Нормалізоване отримане значення спільних об'єктів взаємодії між цільовими й подібними користувачами, а також рівень різноманітності схожих користувачів не завжди були оптимальними, що зумовлено великим каталогом медіапродуктів порівняно з кількістю користувачів та обсягом їхньої активності. Помірна відповідність атрибутивної схожості між користувачами найімовірніше пов'язана з вузьким наповненням метаданих профілів, аналогічно до показників персоналізації.

Слід зазначити, що результати тестування, показані на рис. 5, окреслюють ключові напрями подальшого вдосконалення, зокрема збагачення атрибутивної моделі користувачів.




Рис. 5. Результати роботи системи

### Висновок

У статті описано процес розроблення гібридної архітектури РС і продемонстровано підхід до її побудови із залученням графових нейронних мереж і Explainable AI. Програмна реалізація РС представлена у формі застосунку. Запропонована архітектура програмної системи включає модульну структуру, яка позначає свої результати роботи на відповідних запитах.

Тестування показало здатність системи знаходити нові релевантні рекомендації з високим рівнем різноманітності й персоналізації, а також формувати логічні пояснення на основі обґрунтованих порад.

Варто зазначити, що під час розроблення було враховано низку технічних викликів, зокрема обчислювальну складність, вплив шуму у даних, складність масштабування графових моделей та необхідність зрозумілості ХАІ-рішень.

У результаті запропонована архітектура РС дає можливість реалізувати розширений підхід до рекомендацій, здатний адаптуватися до різних сценаріїв використання, який можна удосконалювати згідно з проведеним аналізом.



### Список літератури

1. Advanced Movie Search API [Electronic resource]. — Mode of access: <https://rapidapi.com/rapidapi/api/advanced-movie-search>.
2. Darban Z. Z. GHRS: Graph-based Hybrid Recommendation System with Application to Movie Recommendation [Electronic resource] / Z. Z. Darban, M. H. Valipour // Faculty of Information Technology, Monash University, Melbourne, Australia, Department of Engineering and Product, Ostadkar Company, Tehran, Iran. — 2021. — Mode of access: <https://arxiv.org/pdf/2111.11293>.
3. Google Books API [Electronic resource]. — Mode of access: <https://developers.google.com/books>.
4. Gupta S. K. Multimodal Graph-based Recommendation System using Hybrid Filtering Approach [Electronic resource] / S. K. Gupta, A. Kumar, D. Prasad // International Journal of Computing and Digital Systems. — 2025. — Mode of access: <https://doi.org/10.12785/ijcds/1571047857>.
5. Hamilton W. Inductive representation learning on large graphs [Electronic resource] / W. Hamilton, Z. Ying, J. Leskovec // NIPS. — 2017. — Mode of access: <https://arxiv.org/pdf/1706.02216>.
6. Hu W. Open Graph Benchmark: Datasets for Machine Learning on Graphs [Electronic resource] / W. Hu et al. NeurIPS, 2020. — Mode of access: <https://arxiv.org/pdf/2005.00687>.
7. Jesse M. W. Intra-list similarity and human diversity perceptions of recommendations: the details matter [Electronic resource] / M. W. Jesse, C. Bauer, D. Jannach // User Modeling and User-Adapted Interaction. — 2022. — Vol. 33 (5). — Mode of access: <https://doi.org/10.1007/s11257-022-09351-w>.
8. Liu H. A new user similarity model to improve the accuracy of collaborative filtering [Electronic resource] / H. Liu, Z. Hu, A. U. Mian // Knowledge-Based Systems. — 2014. — Vol. 56 (6). — Pp. 156–166. — Mode of access: <https://doi.org/10.1016/j.knsys.2013.11.006>.
9. RAWG Video Games Database API [Electronic resource]. — Mode of access: <https://rawg.io/apidocs>.
10. Reimers N. Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks [Electronic resource] / N. Reimers, I. Gurevych // Proceedings of EMNLP-IJCNLP. — 2019. — Mode of access: <https://aclanthology.org/D19-1410/>.
11. Vargas S. Rank and Relevance in Novelty and Diversity Metrics for Recommender Systems [Electronic resource] / S. Vargas, P. Castells // Proceedings of the 2011 ACM Conference on Recommender Systems (RecSys 2011), Chicago, IL, USA, October 23–27, 2011. — Mode of access: <https://doi.org/10.1145/2043932.2043955>.
12. Wu L. A survey on neural recommendation: From collaborative filtering to content and knowledge enhanced recommendation [Electronic resource] / L. Wu, P. Sun, Y. Fu, R. Hong // IEEE Transactions on Knowledge and Data Engineering. — 2020 — Mode of access: [https://www.researchgate.net/publication/351120123\\_A\\_Survey\\_on\\_Neural\\_Recommendation\\_From\\_Collaborative\\_Filtering\\_to\\_Content\\_and\\_Context\\_Enriched\\_Recommendation](https://www.researchgate.net/publication/351120123_A_Survey_on_Neural_Recommendation_From_Collaborative_Filtering_to_Content_and_Context_Enriched_Recommendation).

### References

- Advanced Movie Search API. <https://rapidapi.com/rapidapi/api/advanced-movie-search>.
- Darban, Z. Z., & Valipour, M. H. (2021). *GHRS: Graph-based Hybrid Recommendation System with Application to Movie Recommendation*. Faculty of Information Technology, Monash University, Melbourne, Australia, Department of Engineering and Product, Ostadkar Company, Tehran, Iran. <https://arxiv.org/pdf/2111.11293>.
- Google Books API. <https://developers.google.com/books>.
- Gupta, S. K., Kumar, A., & Prasad, D. (2025). Multimodal Graph-based Recommendation System using Hybrid Filtering Approach. *International Journal of Computing and Digital Systems*. <https://doi.org/10.12785/ijcds/1571047857>.
- Hamilton, W., Ying, Z., & Leskovec, J. (2017). Inductive representation learning on large graphs. In *Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS)*. <https://arxiv.org/pdf/1706.02216>.
- Hu, W., Fey, M., Zitnik, M., Dong, Y., Ren, H., Liu, B., Catasta, M., & Leskovec, J. (2020). Open Graph Benchmark: Datasets for Machine Learning on Graphs. In *Proceedings of NeurIPS*. <https://arxiv.org/pdf/2005.00687>.
- Jesse, M. W., Bauer, C., & Jannach, D. (2022). Intra-list similarity and human diversity perceptions of recommendations: the details matter. *User Modeling and User-Adapted Interaction*, 33 (5). <https://doi.org/10.1007/s11257-022-09351-w>.
- Liu, H., Hu, Z., & Mian, A. U. (2014). A new user similarity model to improve the accuracy of collaborative filtering. *Knowledge-Based Systems*, 56(6), 156–166. <https://doi.org/10.1016/j.knsys.2013.11.006>.
- RAWG Video Games Database API. <https://rawg.io/apidocs>.
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks. In *Proceedings of EMNLP-IJCNLP*. <https://aclanthology.org/D19-1410/>.
- Vargas, S., & Castells, P. (2011). Rank and Relevance in Novelty and Diversity Metrics for Recommender Systems. In *Proceedings of the 2011 ACM Conference on Recommender Systems (RecSys 2011)*. Chicago, IL, USA, October 23–27, 2011. <https://doi.org/10.1145/2043932.2043955>.
- Wu, L., Sun, P., Fu, Y., & Hong, R. (2020). A survey on neural recommendation: From collaborative filtering to content and knowledge enhanced recommendation. *IEEE Transactions on Knowledge and Data Engineering*. [https://www.researchgate.net/publication/351120123\\_A\\_Survey\\_on\\_Neural\\_Recommendation\\_From\\_Collaborative\\_Filtering\\_to\\_Content\\_and\\_Context\\_Enriched\\_Recommendation](https://www.researchgate.net/publication/351120123_A_Survey_on_Neural_Recommendation_From_Collaborative_Filtering_to_Content_and_Context_Enriched_Recommendation).

M. Hlybovets, Y. Sydorova

## GRAPH-BASED MULTIMODAL RECOMMENDATION SYSTEM WITH EXPLAINABLE AI

*The article presents the development process of a hybrid recommendation system (RS) based on heterogeneous graph data structures and graph neural networks (GNN), incorporating Explainable AI (XAI) approaches. The target domain is personalized multimedia recommendations, encompassing books,*

*movies, and games, characterized by diverse item modalities and high demand for personalization.*

*The system architecture is produced upon a heterogeneous graph  $G=(V, E)$ , where nodes and edges represent different entity types (users, items, genres) and relationships (interactions, similarity, genre associations). Multimodal embeddings are defined by using textual features (via Sentence-BERT), visual data (via ResNet-50), and categorical labels (via one-hot genre encoding). These embeddings are used to generate similarity-based connections across item types and users.*

*For recommendations, a neural model based on the PyTorch Geometric framework is trained with negative sampling. The model predicts user-item relevance and generates recommendations. To support clarity, XAI modules provide explanations via gradient-based influence analysis, shared interactions, and demographic attribute comparison.*

*A set of reference-free evaluation metrics is used, including Intra-List Similarity, Novelty, User Similarity, Attribute Alignment, and Coverage. Experimental results demonstrate the model's capability to generate novel, diverse, and personalized recommendations while offering interpretable justifications.*

*The implementation is based on Python with modular components for data preprocessing, training, evaluation, and explanation outcomes, and leverages the Neo4j graph database for storage and analysis.*

**Keywords:** recommendation system, graph neural network, heterogeneous graph, hybrid filtering, explainable AI, personalization, multimodal embeddings, Neo4j, Python.

*Матеріал надійшов 25.06.2025*



Creative Commons Attribution 4.0 International License (CC BY 4.0)