

**ГЕРУС ОЛЕГ**

Національний лісотехнічний університет України

<https://orcid.org/0009-0004-5337-883X>e-mail: [oleh.herus@nltu.edu.ua](mailto:oleh.herus@nltu.edu.ua)**ШАБАТУРА ЮРІЙ**

Національна академія сухопутних військ імені гетьмана П. Сагайдачного

<https://orcid.org/0000-0002-9961-1244>e-mail: [shabaturayuriy@gmail.com](mailto:shabaturayuriy@gmail.com)

## ІНТЕГРОВАНІЙ МЕТОД СИНТЕЗУ РЕКОМЕНДАЦІЙ НА ОСНОВІ БАГАТОКРИТЕРІАЛЬНОГО АНАЛІЗУ ТА КОЛАБОРАТИВНОЇ ФІЛЬТРАЦІЇ

*У статті представлено метод синтезу рекомендацій, який базується на поєднанні багатокритеріального аналізу, динамічного визначення ваг критеріїв, оцінки втрат і здобутків та колаборативної фільтрації. Методика забезпечує персоналізацію рекомендацій шляхом врахування індивідуальних уподобань користувачів та об'єктивних характеристик альтернатив. Практична реалізація запропонованого методу виконана на прикладі вибору квартири. Вона об'єктивно демонструє ефективність запропонованого підходу для розв'язання задач із суперечливими критеріями.*

*Ключові слова: багатокритеріальний аналіз, рекомендаційна система, колаборативна фільтрація, персоналізація.*

**GERUS OLEH**

The National Forestry University of Ukraine

**SHABATURA YURIY**

Hetman Petro Sahaidachnyi National Army Academy

## INTEGRATED METHOD FOR SYNTHESIS OF RECOMMENDATIONS BASED ON MULTI-CRITERION ANALYSIS AND COLLABORATIVE FILTRATION

*The article examines a novel approach to personalized recommendations based on a combination of multi-criteria analysis, dynamic weighting, loss-gain estimation, and collaborative filtering. This method addresses the problem of optimizing decisions in scenarios with conflicting criteria by balancing objective factors such as price or quality with the subjective preferences of users. By dynamically adjusting the weights of criteria using behavioral data, this approach adapts to changing user priorities and contexts, providing relevant and accurate recommendations.*

*The main innovation is the integration of Pareto analysis to narrow down the optimal options, quantify trade-offs using gain-loss estimation, and refine the results using collaborative filtering that uses feedback from users with similar preferences. These components are combined into a single framework to provide a comprehensive and adaptive decision-making system. The practical application of the method is demonstrated on the example of residential real estate selection, where it effectively combines criteria such as price per square meter, developer rating, and location preference.*

*The proposed system not only improves recommendation personalization, but also offers scalability for various domains, including e-commerce, real estate, and asset management. Its adaptability is achieved by incorporating both quantitative assessments and qualitative insights derived from user behavior.*

*Future research directions include extending the method to handle larger datasets with higher dimensional criteria, integrating advanced machine learning models for dynamic parameter optimization, and improving computational efficiency for real-time implementation. This framework has significant potential for solving complex decision-making tasks in both individual and organizational contexts, facilitating the development of more sophisticated and user-centric recommendation systems.*

*Keywords: multi-criteria analysis, recommendation systems, collaborative filtering, personalization.*

### Постановка проблеми у загальному вигляді

#### та її зв'язок із важливими науковими чи практичними завданнями

Однією з яскравих та відмінних рис сучасного суспільства є активне використання систем синтезу рекомендацій у багатьох аспектах повсякденного життя. Вони спрощують та неабияк пришвидшують процес прийняття тих чи інших рішень людиною. Проте, такі інформаційні системи часто стикаються з задачами, в яких критерії оцінки можуть бути суперечливими, а їхня вага варіюється залежно від контексту. Ще складнішим завданням є вибір альтернативи у випадках коли, одні й ті ж критерії мають різну важливість для різних користувачів, а вподобання самих користувачів можуть змінюватися з часом. Ця проблема часто постає у таких сферах як електронна комерція, медицина, логістика, туризм та розробка програмного забезпечення.

Одним із варіантів вирішення даної проблеми є розгляд такої системи синтезу рекомендацій, у якій комбінуються методи багатокритеріальної оптимізації [1] з підходами персоналізації. Така модель дозволила б враховувати динамічні зміни у процесі роботи, що в свою чергу, сприяло б кращій точності рекомендацій.

### Аналіз досліджень та публікацій

Проблеми багатокритеріальної оптимізації широко розглядаються у наукових роботах. Зокрема, відомі методи, такі як аналіз ієрархій Саати [2] та Парето-оптимізація [3], знаходять застосування у різних галузях. Наприклад, метод Саати дозволяє формувати ваги критеріїв на основі експертних оцінок, тоді як Парето-оптимізація використовується для побудови множини оптимальних рішень без прямих

конфліктів між критеріями.

У роботі [4] запропоновано розробку алгоритму рекомендацій на основі колаборативної фільтрації, який враховує переваги користувачів, кластеризуючи їх за типами уподобань. Такий підхід дав можливість підвищити точність і персоналізацію рекомендацій. Дослідження [5] представило новий підхід до рекомендаційних систем, який поєднує колаборативну фільтрацію з нейронними мережами. Запропонована модель дозволяє ефективно враховувати як динамічні особливості користувачів і об'єктів, так і їхні взаємозв'язки, що суттєво підвищує якість отриманих порад. Отримані результати демонструють переваги нейронної архітектури над традиційними методами в задачах персоналізації. Робота [6] описує метод рекомендаційних систем на основі графових нейронних мереж, механізмів уваги та модифікованого алгоритму Gated Recurrent Unit (GRU) [7].

У статті [8] представлено методологію багатокритеріального аналізу для задач пріоритетного вибору, що базується на трьох основних стратегіях: методи послідовних поступок, методи головного критерію та методи згортки критеріїв. Автор пропонує формалізований підхід до вирішення проблеми вибору найбільш прийняттого варіанту в умовах множинності критеріїв та їх можливої суперечливості. Особливу увагу приділено практичним аспектам застосування запропонованих методів, зокрема процедурам нормалізації критеріїв та визначення їх відносної важливості. Проте, робота має певні обмеження, зокрема, відсутність експериментального порівняння ефективності різних стратегій та недостатню увагу до динамічних аспектів зміни пріоритетів.

У роботі [9] представлено адаптивну контекстно-орієнтовану оптимізаційну систему для вибору мультимедійних сервісів. Запропонований підхід дозволяє в режимі реального часу налаштовувати змінні входні параметри (наприклад, якість мережі, тип пристрою) для надання оптимальних порад. Робота демонструє ефективність інтеграції сучасних методів штучного інтелекту в адаптаційні процеси, що значно покращує якість користувацького досвіду.

Авторами дослідження [10] запропоновано модель, яка дозволяє враховувати індивідуальні вподобання користувачів і адаптувати рекомендації відповідно до їхніх пріоритетів. Підхід демонструє високу точність рекомендацій у задачах, де критерії можуть мати суперечливий характер. Основною відмінністю від попередньої роботи є те що ця модель інтегрує навчання переваг користувачів для врахування їхніх індивідуальних потреб, а попередня робота орієнтована на динамічну оптимізацію вагових коефіцієнтів.

#### Формулювання цілей статті

Метою роботи є розробка універсального інтегрованого методу для синтезу рекомендацій, який забезпечує персоналізований вибір за умов багатокритеріальної оптимізації з автоматичним обрахунком вагових коефіцієнтів у поєднанні з традиційними методами підбору рекомендацій (зокрема, методом колаборативної фільтрації).

#### Виклад основного матеріалу

На сьогодні, найпопулярнішими методами генерації рекомендацій є метод колаборативної фільтрації, алгоритми на основі вмісту (контенту), алгоритми класифікації. Усі вони здатні надавати певні рекомендації, проте вони не завжди здатні правильно оцінити варіанти у випадку кількох нечітких та суперечливих критеріїв. Цю проблему можна вирішити шляхом інтеграції трьох підходів:

- багатокритеріальний аналіз Парето – для виокремлення лише оптимальних альтернатив;
- оцінка втрат і здобутків - для аналізу переваг і недоліків кожного з варіантів;
- колаборативна фільтрація – для врахування побажань конкретного користувача.

Багатокритеріальний аналіз застосовується для оцінки альтернатив за кількома суперечливими критеріями, кожен із яких має свою важливість для користувача.

Множина альтернатив  $A = \{A_1, A_2, \dots, A_n\}$  оцінюється за критеріями  $C = \{C_1, C_2, \dots, C_m\}$ , де кожен критерій  $C_j$  може бути спрямований на максимізацію або мінімізацію. Для кожної альтернативи  $A_i$  обчислюється її узагальнена оцінка  $U(A_i)$ , яка враховує ваги критеріїв  $w_j$ :

$$U(A_i) = \sum_{j=1}^m w_j \cdot f'_j(A_i), \quad (1)$$

де  $w_j$  — вага критерію  $C_j$ , яка показує його відносну важливість  $\sum_{j=1}^m w_j = 1$ , а  $f'_j(A_i)$  — нормалізоване значення критерію  $C_j$  для альтернативи  $A_i$ , приведене до однакового масштабу.

Для приведення критеріїв до одного масштабу використовуються наступні формули:

- для критеріїв, які потрібно максимізувати:

$$\Leftrightarrow f'_j(A_i) = \frac{f_j(A_i) - \min(f_j)}{\max(f_j) - \min(f_j)}, \quad (2)$$

- для критеріїв, які потрібно мінімізувати:

$$\Leftrightarrow f'_j(A_i) = \frac{\max(f_j) - f_j(A_i)}{\max(f_j) - \min(f_j)}. \quad (3)$$

Ваги  $w_j$  визначають відносну важливість кожного критерію для користувача і обчислюються динамічно:

$$w_j = \frac{\text{freq}(C_j)}{\sum_{k=1}^m \text{freq}(C_k)}, \quad (4)$$

де  $\text{freq}(C_j)$  — частота використання критерію  $C_j$  у пошукових запитах чи переглядах.

Першим кроком багатокритеріального аналізу є звуження множини альтернатив за допомогою аналізу Парето. У задачах із великою кількістю альтернатив часто існують варіанти, які поступаються за всіма критеріями іншим альтернативам. У реальному житті можна навести приклад з сфери нерухомості: квартира, яка є і дорожчою, і має гірше розташування, очевидно, буде неліквідною та не є оптимальною опцією для розгляду. Виключення таких варіантів значно знижує ресурсозатратність та підвищує ефективність подальшого аналізу.

Множина Парето включає лише ті альтернативи, які є недомінованими (оптимальними):

$$\Leftrightarrow \exists(A_i): f_k(A_i) \geq f_k(A_j) \forall k \tag{5}$$

і хоча б один  $f_k(A_i) > f_k(A_j)$ .

Таким чином кожна опція в множині Парето є компромісною, що означає, що у заданій множині вона не є програшною одночасно по усіх критеріях.

Після визначення множини Парето кожна альтернатива має бути детально оцінена з урахуванням її переваг і недоліків. Для цього вводяться функції вигоди  $G(A_i)$  та втрат  $L(A_i)$ . Вигода визначає сильні сторони альтернативи за критеріями, які необхідно максимізувати, наприклад, рейтинг забудовника чи розташування. Натомість втрати відображають недоліки альтернативи за критеріями, які бажано мінімізувати, наприклад, ціна.

Формально ці функції можна описати так:

$$G(A_i) = \sum_{j=1}^m w_j \cdot f_j^+(A_i), \tag{6}$$

$$L(A_i) = \sum_{j=1}^m w_j \cdot f_j^-(A_i), \tag{7}$$

де  $f_j^+(A_i)$  та  $f_j^-(A_i)$  — нормалізовані значення критеріїв, відповідно для максимізації чи мінімізації. Цей підхід дозволяє кількісно порівняти альтернативи, враховуючи їхні вигоди та втрати залежно від ваг критеріїв. Врахування цих оцінок забезпечує об'єктивність у виборі альтернатив.

Для забезпечення персоналізації використовується колаборативна фільтрація. Вона враховує поведінкові дані інших користувачів зі схожими вподобаннями. Це дозволяє доповнити багатокритеріальну оцінку суб'єктивним фактором, який враховує соціальні та поведінкові аспекти. Для їх обрахунку система використовуватиме таку інформацію як пошукові запити, перегляди чи поточний контекст задачі.

Оцінка за допомогою колаборативної фільтрації визначається як:

$$P(A_i) = \frac{\sum_{u \in N} s(u, u_0) \cdot R_{u,i}}{\sum_{u \in N} s(u, u_0)}, \tag{8}$$

де  $s(u, u_0)$  — міра схожості між поточним користувачем  $u_0$  та іншими користувачами  $u$ , а  $R_{u,i}$  — оцінка альтернативи  $A_i$  користувачем  $u$ .

Результатом запропонованого підходу є загальна оцінка альтернативи  $U(A_i)$ , яка об'єднує вигоду, втрати та колаборативну оцінку. Це дозволяє врахувати як об'єктивні характеристики, так і персоналізовані вподобання:

$$\Leftrightarrow U(A_i) = \lambda \cdot (G(A_i) - L(A_i)) + (1 - \lambda) \cdot P(A_i), \tag{9}$$

де  $\lambda$  — параметр, що регулює вплив на загальну оцінку отриманих значень багатокритеріального аналізу та персоналізації.

На практиці запропонований метод можна продемонструвати на прикладі вибору житла. Нехай користувач розглядає нерухомість за критеріями зазначеними в таблиці 1.

Таблиця 1

**Критерії підбору нерухомості користувача**

Альтернатива	Ціна за м <sup>2</sup> (грн)	Рейтинг забудовника	Розташування (оцінка)
A1	27,000	7	9
A2	28,500	9	8
A3	28,000	7	8
A4	29,000	6	6

На першому етапі аналізу виконується відбір оптимальних (недомінованих) альтернатив за методом Парето. Це дозволяє виключити з розгляду ті варіанти, які повністю поступаються іншим за всіма критеріями. Альтернатива A1 (як і альтернативи A2 та A3 домінує над альтернативою A4, оскільки:  $C_1(A_1) < C_1(A_4)$ ,  $C_2(A_1) > C_2(A_4)$ ,  $C_3(A_1) > C_3(A_4)$ ). Таким чином, A4 виключається з подальшого аналізу.

Мінімізувавши критерій «ціна» ( $C_1$ ), отримано наступні результати:

$$\Leftrightarrow f'_1(A_1) = \frac{\max(C_1) - C_1(A_1)}{\max(C_1) - \min(C_1)} = \frac{28500 - 27000}{28500 - 27000} = 0, \tag{10}$$

$$\Leftrightarrow f'_1(A_2) = \frac{28500 - 28500}{28500 - 27000} = 0, \tag{11}$$

$$\Leftrightarrow f'_1(A_3) = \frac{28500 - 28000}{28500 - 27000} = 0.25. \tag{12}$$

В свою чергу, необхідно максимізувати критерій «рейтинг забудовника» ( $C_2$ ) та «розташування» ( $C_3$ ).

$$\Leftrightarrow f'_2(A_1) = \frac{C_2(A_1) - \min(C_2)}{\max(C_2) - \min(C_2)} = \frac{7 - 7}{9 - 7} = 0, \tag{13}$$

$$\Leftrightarrow f'_2(A_2) = \frac{9-7}{9-7} = 1, \quad (14)$$

$$\Leftrightarrow f'_2(A_3) = \frac{7-7}{9-7} = 0, \quad (15)$$

$$\Leftrightarrow f'_3(A_1) = \frac{C_3(A_1) - \min(C_3)}{\max(C_3) - \min(C_3)} = \frac{9-8}{9-8} = 1, \quad (16)$$

$$\Leftrightarrow f'_3(A_2) = \frac{8-8}{9-8} = 0, \quad (17)$$

$$\Leftrightarrow f'_3(A_3) = \frac{8-8}{9-8} = 0. \quad (18)$$

Нехай, ваги критеріїв, обраховані методом колаборативної фільтрації на основі пошукових запитів, є  $w_1=0.4$ ;  $w_2=0.35$ ;  $w_3=0.25$ .

Тоді обчислення вигоди для кожної альтернативи має такі значення:

- $G(A_1) = 0.4 \cdot 1 + 0.35 \cdot 0 + 0.25 \cdot 1 = 0.65$ ;
- $G(A_2) = 0.4 \cdot 0 + 0.35 \cdot 1 + 0.25 \cdot 0 = 0.35$ ;
- $G(A_3) = 0.4 \cdot 0.25 + 0.35 \cdot 0 + 0.25 \cdot 0 = 0.1$ .

В свою чергу, обчислення втрат для кожної альтернативи має такі значення:

- $L(A_1) = 0.4 \cdot (1-0) + 0.35 \cdot (1-1) + 0.25 \cdot (1-0) = 0.35$ ;
- $L(A_2) = 0.4 \cdot (1-0) + 0.35 \cdot (1-1) + 0.25 \cdot (1-0) = 0.65$ ;
- $L(A_3) = 0.4 \cdot (1-0.25) + 0.35 \cdot (1-0) + 0.25 \cdot (1-0) = 0.925$ .




Рис. 1. Графічне представлення обчислених функцій втрат та вигод для кожної альтернативи

Наступним кроком є синтез рекомендації одним методом колаборативної фільтрації, який враховує поведінкові дані інших користувачів зі схожими вподобаннями. Наприклад, якщо інші користувачі, які мають подібні уподобання (схожий бюджет, схожі запити щодо площі чи розташування), віддали перевагу певній квартирі, то ця альтернатива отримує вищу оцінку. У цьому прикладі допущено, що:

- $P(A_1) = 4.5$  - висока оцінка, що вказує на популярність цієї квартири серед подібних користувачів;
- $P(A_2) = 4.6$  - висока оцінка, що вказує на популярність цієї квартири серед подібних користувачів;
- $P(A_3) = 4.0$  – середня оцінка, вказує на помірну популярність квартири.

Для завершення обчислень необхідно мати значення параметру, що регулює вплив на загальну оцінку отриманих значень багатокритеріального аналізу та персоналізації ( $\lambda$ ). За умови, що для користувача значення багатокритеріального аналізу є важливішим за результат роботи персоналізації (тобто, аналітика його критеріїв є важливішою за вибір схожих до нього користувачів) значення  $\lambda$  є 0.6 та 0.4 відповідно. Тоді

- $U(A_1) = 0.6 \cdot (0.65 - 0.35) + 0.4 \cdot 4.5 = 1.98$ ;
- $U(A_2) = 0.6 \cdot (0.35 - 0.65) + 0.4 \cdot 4.6 = 1.66$ ;
- $U(A_3) = 0.6 \cdot (0.1 - 0.925) + 0.4 \cdot 4.0 = 1.105$ ;

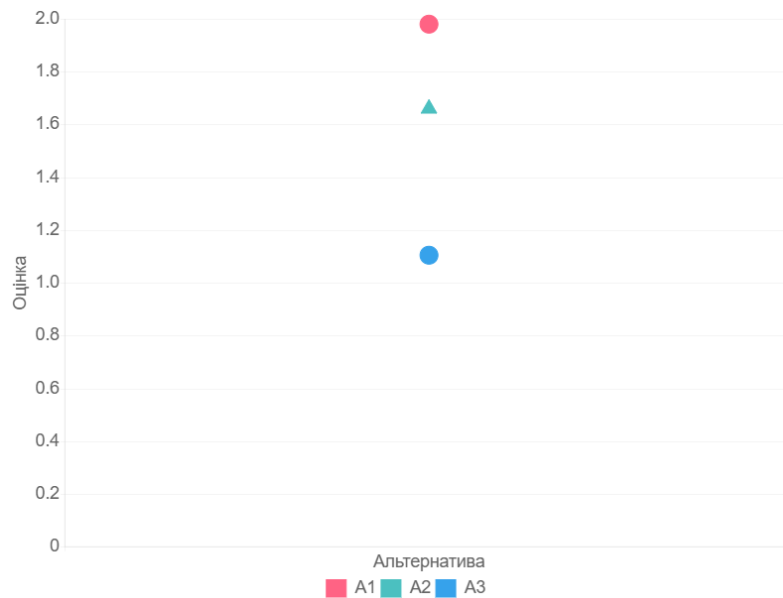


Рис. 2. Графічне представлення загальних оцінок для кожної альтернативи

Максимальним значенням є  $U(A_1)$ , що свідчить про те, що найбільш вдалою рекомендацією для користувача є альтернатива  $A_1$ .

Запропонований інтегрований метод синтезу інформаційних рекомендацій дозволяє враховувати багатокритеріальність та динамічні зміни ваги критеріїв. Даний підхід дозволяє системі ефективно підлаштовуватися до вподобань користувача та забезпечує високий рівень оптимізації рішення.

#### Висновки з даного дослідження

##### і перспективи подальших розвідок у даному напрямі

У статті запропоновано новий метод до синтезу рекомендацій, що базується на інтеграції багатокритеріального аналізу, динамічного визначення ваг критеріїв, оцінки втрат і здобутків, а також колаборативної фільтрації. Запропонована методика забезпечує персоналізацію вибору, враховуючи як об'єктивні характеристики альтернатив, так і поведінкові особливості користувачів. Практична реалізація на прикладі вибору квартири демонструє здатність методу адаптуватися до різних пріоритетів користувачів і забезпечувати оптимальний вибір навіть за умов суперечливих критеріїв.

Подальші дослідження можуть бути спрямовані на:

- розширення моделі для роботи з великими наборами даних і складнішими критеріями;
- інтеграцію алгоритмів машинного навчання для автоматичного налаштування ваг критеріїв та параметрів моделі;
- розробку методів, що дозволяють оптимізувати обчислювальні ресурси для роботи в реальному часі.

#### Література

1. Шевченко, С. В. (2024). Багатокритеріальна оптимізація рішень задач вибору. *Тези доповідей VII Міжнародної науково-практичної конференції «Інформаційні технології в освіті, науці і техніці» (ТОНТ-2024)*, 155.
2. Стецюк, П. І., Вакуленко, Д. В., & Ляшко, В. І. (2023). Оптимізаційні задачі для оцінок відносної важливості елементів у методі аналізу ієрархій. *Наукові записки НаУКМА. Комп'ютерні науки*, 6, 11–16. <https://doi.org/10.18523/2617-3808.2023.6.11-16>
3. Qian, C., Yu, Y., & Zhou, Z.-H. (2015). Subset selection by Pareto optimization. *Advances in Neural Information Processing Systems 28 (NIPS'15), Montreal, Canada*. Retrieved from [https://www.researchgate.net/publication/282632653\\_Subset\\_Selection\\_by\\_Pareto\\_Optimization](https://www.researchgate.net/publication/282632653_Subset_Selection_by_Pareto_Optimization)
4. Yang, Y., Yao, H., Li, R., & Wang, S. (2021). A collaborative filtering recommendation algorithm based on user clustering with preference types. *Journal of Physics: Conference Series*, 1848(1). <https://doi.org/10.1088/1742-6596/1848/1/012043>
5. He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). Neural collaborative filtering. *Proceedings of the 26th International Conference on World Wide Web*, 173–182. <https://doi.org/10.1145/3038912.3052569>
6. Liu, F., Wang, J., & Yang, J. (2023). A graph neural network recommendation method integrating multi-head attention mechanism and improved gated recurrent unit algorithm. *IEEE Access*, 11, 116879–116891. <https://doi.org/10.1109/ACCESS.2023.3325476>

7. Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *NIPS 2014 Workshop on Deep Learning*, 1–9. <https://doi.org/10.48550/arXiv.1412.3555>
8. Корендович, В. С. (2017). Застосування багатокритеріального аналізу для пріоритетного вибору. *Збірник наукових праць Центру воєнно-стратегічних досліджень Національного університету оборони України імені Івана Черняхівського*, 2(60), 129–136. <https://doi.org/10.33099/2304-2745/2017-2-60/129-136>
9. Laboudi, Z., Moudjari, A., Saighi, A., Draa, A., & Hadjadj, S. (2022). An adaptive context-aware optimization framework for multimedia adaptation service selection. *Neural Computing and Applications*, 34, 14239–14251. <https://doi.org/10.1007/s00521-021-06644-w>
10. Sreepada, R. S., Patra, B. K., & Hernando, A. (2017). Multi-criteria recommendations through preference learning. *Proceedings of the 4th ACM IKDD Conferences on Data Sciences (CODS '17)*, Article No. 1, 1–11. <https://doi.org/10.1145/3041823.3041824>

### References

1. Shevchenko, S. V. (2024). Bahatokryterialna optymizatsiia rishen zadach vyboru. Tezy dopovidei VII Mizhnarodnoi nauково-praktychnoi konferentsii «Informatsiini tekhnologii v osviti, nauksi i tekhnitsi» (ITONT-2024), 155.
2. Stetsiuk, P. I., Vakulenko, D. V., & Liashko, V. I. (2023). Optymizatsiini zadachi dlia otsinok vidnosnoi vazhlyvosti elementiv u metodi analizu iierarkhii. *Naukovi zapysky NaUKMA. Kompiuterni nauky*, 6, 11–16. <https://doi.org/10.18523/2617-3808.2023.6.11-16>
3. Qian, C., Yu, Y., & Zhou, Z.-H. (2015). Subset selection by Pareto optimization. *Advances in Neural Information Processing Systems* 28 (NIPS'15), Montreal, Canada. Retrieved from [https://www.researchgate.net/publication/282632653\\_Subset\\_Selection\\_by\\_Pareto\\_Optimization](https://www.researchgate.net/publication/282632653_Subset_Selection_by_Pareto_Optimization)
4. Yang, Y., Yao, H., Li, R., & Wang, S. (2021). A collaborative filtering recommendation algorithm based on user clustering with preference types. *Journal of Physics: Conference Series*, 1848(1). <https://doi.org/10.1088/1742-6596/1848/1/012043>
5. He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). Neural collaborative filtering. *Proceedings of the 26th International Conference on World Wide Web*, 173–182. <https://doi.org/10.1145/3038912.3052569>
6. Liu, F., Wang, J., & Yang, J. (2023). A graph neural network recommendation method integrating multi-head attention mechanism and improved gated recurrent unit algorithm. *IEEE Access*, 11, 116879–116891. <https://doi.org/10.1109/ACCESS.2023.3325476>
7. Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *NIPS 2014 Workshop on Deep Learning*, 1–9. <https://doi.org/10.48550/arXiv.1412.3555>
8. Korendovych, V. S. (2017). Zastosuvannia bahatokryterialnoho analizu dlia priorytetnoho vyboru. *Zbirnyk naukovykh prats Tsentru voienno-stratehichnykh doslidzhen Natsionalnoho universytetu obrony Ukrainy imeni Ivana Cherniakhovskoho*, 2(60), 129–136. <https://doi.org/10.33099/2304-2745/2017-2-60/129-136>
9. Laboudi, Z., Moudjari, A., Saighi, A., Draa, A., & Hadjadj, S. (2022). An adaptive context-aware optimization framework for multimedia adaptation service selection. *Neural Computing and Applications*, 34, 14239–14251. <https://doi.org/10.1007/s00521-021-06644-w>
10. Sreepada, R. S., Patra, B. K., & Hernando, A. (2017). Multi-criteria recommendations through preference learning. *Proceedings of the 4th ACM IKDD Conferences on Data Sciences (CODS '17)*, Article No. 1, 1–11. <https://doi.org/10.1145/3041823.3041824>