

УДК 004.8

В. І. Ладигець,

*Аспірант кафедри інформаційних технологій
проектування та прикладної математики,
orcid.org/0000-0002-4326-7325*

С.А. Теренчук

*Кандидат фізико-математичних наук,
доцент кафедри інформаційних технологій, доцент
orcid.org/0000-0001-6527-4123*

Київський національний університет будівництва і архітектури, Київ

ПРОЕКТУВАННЯ МЕТОДУ РЕКОМЕНДАЦІЇ ДЛЯ ІНФОРМАЦІЙНОЇ СИСТЕМИ ПЛАНУВАННЯ ХАРЧУВАННЯ

Роботу присвячено розв'язуванню такої комплексної науково-прикладної задачі дієтології, як формування рецептів страв різних категорій приїму їжі. Мета статті полягає в розробці методу рекомендацій рецептів на основі машинного навчання, що дозволяє враховувати особисті вподобання і дієтичні обмеження користувача. Запропонований метод складається з трьох таких етапів: генерації кандидатів, оцінювання та ранжування рецептів. На етапі генерації кандидатів використовується двохвежева модель, що використовує нейроні мережі. Ця модель дозволяє ефективно вбудовувати інформацію про користувача та страви у спільний векторний простір і швидко знаходити релевантні рецепти за допомогою алгоритму пошуку найближчих сусідів. Після цього на етапі генерації кандидатів відбувається фільтрація, що відсіює рецепти, які містять алергени чи обмежені користувачем продукти. Етап оцінювання передбачає оцінку користувачем рецептів, які отримані з етапу генерації кандидатів, і формування списку рекомендацій, які розставляються в порядок рекомендацій на наступному етапі. Для цього на етапі оцінювання застосовуються такі моделі машинного навчання, як матрична факторизація, моделі на основі дерев прийняття рішень і глибинного навчання. Ці моделі машинного навчання враховують вподобання користувача. Також на етапі оцінювання запропоновані модулі, що враховують такі контекстуальні фактори, як історія переглядів, день тижня і доступний час для приготування страв. Етап ранжування реалізується за допомогою алгоритму максимальної граничної релевантності, що забезпечує баланс між

відповідністю пропозицій рецептів вподобанням користувача і різноманітністю рекомендацій. Наукова новизна роботи полягає в тому, що вперше розроблено метод, який дозволяє враховувати персональні сподобання користувача та його вподобання щодо інгредієнтів та технік приготування страв. Запропонований метод має високий потенціал для побудови інтелектуальних систем персоналізованого планування харчування, що сприяє поширенню здорового способу життя користувачів.

Ключові слова: *глибинне навчання, інформаційна система, інформаційна технологія, машинне навчання, модель двох веж, нейронна мережа, система рекомендацій, штучний інтелект.*

Вступ. Проблема ефективного планування здорового збалансованого харчування людини стає дедалі актуальнішою в умовах сучасного способу життя. Значна кількість людей стикається з труднощами в підборі раціональних рецептів, що відповідають індивідуальним потребам, дієтичним уподобанням і рекомендаціям лікарів або дієтологів.

Сучасні системи планування харчування переважно орієнтовані на універсальні рішення і тому часто не враховують індивідуальні особливості користувачів. Це призводить до недостатньої ефективності таких систем і знижує мотивацію користувачів до їх використання. Саме тому розробка ефективних методів рекомендації рецептів, які максимально відповідатимуть потребам і уподобанням користувачів, лишається актуальним завданням сучасних прикладних інформаційних технологій.

Огляд актуальних наукових досліджень. В роботі [1] показано, що багато рецептів, які отримали високі оцінки на онлайн-платформах, містять нездорові інгредієнти, такі як велика кількість цукру і жирів, та показано необхідність розробки систем, які можуть рекомендувати більш здорові альтернативи, адаптуючи плани харчування до потреб користувачів.

В дослідженні [2] підкреслено необхідність формування персоналізованих рекомендацій, оскільки при виборі їжі користувачі в першу чергу керуються своїми вподобаннями.

Підходи глибокого навчання, що запропоновані в [3], ефективно фіксують складні моделі харчових уподобань, але обмежені кінцевими базами даних про харчування. Окрім того запропоновані в [3] підходи потребують великих обсягів маркованих навчальних даних і обчислювальних ресурсів, що створює проблеми з масштабованістю систем.

Наразі великої популярності набули методи колаборативної фільтрації, фільтрації на основі вмісту та гібридні моделі, що поєднують ці методи. Зазначені гібридні моделі показали багатообіцяючі результати в балансуванні між відповідністю пропозицій рецептів вподобанням користувача і різноманітністю рекомендацій [4].

Дослідження [5] підкреслює важливість урахування різних атрибутів користувачів для поліпшення рекомендацій рецептів при побудові систем планування харчування, що базуються на експертних знаннях. Проте системи на основі знань можуть ненавмисно посилити існуючі нездорові уподобання користувача, що призведе до ефекту «ехо-камери», і негативно вплине на досягнення довгострокових цілей харчування.

Система рекомендацій щодо новизни чи повторення страв, яка описана в [6] надто спрощує наміри користувачів, і це може призвести до ігнорування важливих нюансів. Навчання з підкріпленням для інтерактивного формування плану харчування супроводжується проблемами з високими вимогами до даних для навчання, холодним запуском і обчислювальними витратами.

Метою статті є розробка методу рекомендацій рецептів на основі машинного навчання, що дозволить урахувати особисті вподобання і дієтичні обмеження користувача.

Виклад основного матеріалу. В цій роботі набула подальшого розвитку концепція створення гібридних систем, що фокусуються на рекомендації плану харчування, а не пропозиції рецептів однієї страви.

На рис.1 показано концептуальну модель персоналізованої інтелектуальної системи планування збалансованого раціону харчування людини, що розробляється.

На етапі генерації кандидатів відбувається вибір підмножини рецептів з множини усіх наявних і фільтрація рецептів, що містять інгредієнти, які не підходять за обмеженнями користувача. Якісний генератор кандидатів може знайти 500 рецептів з показником відгуку >90%. Це означає, що він успішно відображає найбільш релевантні позиції ціною включення деяких менш релевантних рецептів. Крім того, враховується охоплення різних показників інтересів користувача і різноманітність каталогу.

Генератор кандидатів зазвичай оцінюється за показником Recall@N. Забезпечення охоплення передбачає вибір кандидатів із різних категорій рецептів чи використання декількох генераторів.




Рис. 1. Концептуальна модель персоналізованої інтелектуальної системи планування збалансованого раціону харчування людини

Схему роботи трьох етапного методу рекомендації рецептів, що використовує методи машинного навчання для відбору рецептів і розробляється для формування рецептів страв різних категорій проїмю їжі, показано на рис. 2.




Рис. 2. Схему роботи трьох етапного методу рекомендації рецептів

Схему генерації рецептів-кандидатів методу рекомендації рецептів показано на рис. 3.

На цьому етапі запропоновано застосовувати модель штучного інтелекту двох веж [7], де кожна вежа представлена нейронною мережею, що дозволяє здійснити вкладання користувачів і рецептів

в спільний векторний простір. При чому одна нейронна мережа кодує характеристики користувача, а інша – характеристики страв.




Рис. 3. Схема генерації рецептів кандидатів

Профіль користувача складається з:

- фізіологічних даних (вік, зріст, вага, стать, рівень активності);
- дієтичних обмежень (алергічні реакції, обмеження в споживанні продуктів);
- цілей (щодо здоров'я, балансу поживних речовин, бажаної ваги);
- даних системи (email, ip адреса для локації, мова інтерфейсу);
- вподобань (улюблені кухні, інгредієнти що подобаються чи не подобаються);
- поведінкових особливостей (перегляди, кліки на рецепти, час витрачених на прочитання рецептів, збережені рецепти).

Профіль рецепту складається з:

- ID; назви, прийому їжі (сніданок, обід, перекус, вечеря), кухня;
- інгредієнтів і їх кількості, необхідного обладнання, технік, що використовуються для приготування, наявність алергенів;
- калорійності, розподілу макронутрієнтів;

- інструкцій з приготування, складності приготування, часу приготування;
- тег та ключових слів.

Після обчислення вбудованих даних для швидкого отримання сету потенційних страв-кандидатів і формування плану збалансованого харчування із мільйонів варіантів використовується алгоритм пошуку найближчих сусідів (ANN) [8].

При надходженні запиту на рекомендацію, вбудовування користувача генерується вежею користувача, а алгоритм ANN знаходить страви-кандидати, вбудовування яких найкраще відповідає вбудовуванню користувача.

ANN-індекс за мілісекунди повертає найкращі рецепти-кандидати, навіть якщо каталог містить мільйони позицій, завдяки розумному скороченню пошуку найближчих векторів medium.com.

Двохвежева архітектура природно сумісна з таким підходом до індексації, оскільки розділяє обчислення користувача та елемента так, що представлення елемента обчислюються один раз і повторно використовуються uber.com. Таке розділення суттєво прискорює роботу системи, оскільки перетворює проблему $\mathcal{O}(U \times M)$ (порівняння всіх користувачів U з усіма товарами M) на офлайн-обчислення $\mathcal{O}(M)$ товарів і онлайн-пошук $\mathcal{O}(U \times \log M)$ (чи подібний), що робить досяжними рекомендації в реальному часі навіть для дуже великих M .

Додаткова фільтрація відсіває рецепти, які містять інгредієнти або техніки приготування, що підпадають під обмеження користувача.

Після відбору кандидатів на етапі оцінювання використовуються методи машинного і глибинного навчання для коригування оцінок кожного елемента, що дає змогу підвищити якість рекомендацій, оскільки ступінь релевантності страв для кожного користувача визначається точніше.

Схему роботи етапу оцінювання рецептів показано на рис. 4.

Ключовим нововведенням цієї роботи є впровадження модульної системи плагінів, що коригує оцінки моделі штучного інтелекту (SVD/GBDT/W&D), використовуючи контекстуальні дані та дані сесії користувача (1).

$$s'_{\{base\}(u,i)} = s_{\{base\}(u,i)} + \Delta_{p(u,i)}, \quad (1)$$

де: $s_{\{base\}(u,i)}$ – оцінка основної моделі рецепту i для користувача u , p – плагін, що створює зміщення $\Delta_{p(u,i)}$.




Рис. 4. Схема роботи етапу оцінювання рецептів

В основу роботи запропонованих модулів урахування нещодавньої історії переглядів і взаємодій, дня тижня і часу приготування покладено (2 – 6):

$$\Delta p(u, i) = \alpha \cdot F_{clicks}(u, i) + \beta \cdot F_{views}(u, i) - \gamma \cdot F_{bounces}(u, i); \quad (2)$$

$$(\Delta t) = e^{-\lambda \Delta t}; \quad (3)$$

$$F_{click}(u, i) = \sum_{c \in C_{u,i}} w(t - t_c); \quad (4)$$

$$F_{views}(u, i) = \sum_{v \in V_{u,i}} w(t - t_v); \quad (5)$$

$$F_{bounces}(u, i) = \sum_{b \in B_{u,i}} w(t - t_b), \quad (6)$$

де: α, β, γ – параметри налаштування модулів, що вказують на вагу фактору; $C_{u,i}$ – множина кліків на рецепт i користувачем u в сесії; $V_{u,i}$ – множина переглядів рецепту i користувачем u в сесії; $B_{u,i}$ – множина подій негативної взаємодії користувача u з рецептом i ; λ – коефіцієнт забування.

Формула (7) представляє зміщення $\Delta p(u, i)$ модулю врахування дня тижня.

$$\Delta_{p(u,i)} = \log \frac{P_{u,i,d}}{P_{u,d}}, \quad P_{u,i,d} = \frac{n_{u,i,d} + \mu}{n_{u,i} + 7\mu}; \quad P_{u,d} = \frac{n_{u,d} + \mu}{N_u + 7\mu}; \quad (7)$$

де: $d \in \{1, 2 \dots 7\}$ – день тижня; $n_{u,i,d}$ – кількість взаємодій користувача u з рецептом i в день d ; $n_{u,i}$ – кількість всіх взаємодій користувача u з рецептом i за весь час; $n_{u,d}$ – кількість всіх взаємодій користувача u з усіма рецептами в день d ; N_u – загальна кількість взаємодій користувача u ; μ – коефіцієнт згладжування;

Під взаємодією розуміється додавання користувачем u рецепту i до плану харчування в минулому

Формула 10 представляє зміщення $\Delta_{p(u,i)}$ модулю наявного часу для приготування.

$$\Delta_{p(u,i)} = \begin{cases} \lambda \cdot \left(1 - \frac{t_i}{T_u}\right), & t_i \leq T_u; \\ -\mu \cdot \left(\frac{t_i}{T_u} - 1\right), & t_i > T_u, \end{cases} \quad (10)$$

де: t_i – час (в хвиликах), необхідний для приготування рецепту i , T_u – час (в хвиликах), що користувач вказав як наявний для приготування рецепту,

λ, μ – параметри модулю.

На рис. 5 представлено схему роботи етапу ранжування.

На цьому етапі елементи впорядковуються відповідно до оцінок користувача, враховуючи додаткову бізнес-логіку чи обмеження (підтримка новизни, забезпечення різноманітності, дотримання рекламних пріоритетів). В результаті формується оптимізований перелік рекомендацій, що відповідає контексту і уподобанням користувача.

Основна концепція максимальної граничної релевантності (MMR) полягає в ітеративному відборі страв не тільки на основі індивідуальної релевантності до уподобань користувача, а й на основі їх відмінності від вже рекомендованих елементів. Цей подвійний критерій допомагає уникнути повторюваних рекомендацій, які з часом можуть знизити задоволеність користувачів. MMR працює шляхом обчислення комбінованого балу для кожної потенційної рекомендації.

Перша частина цього балу оцінює, відповідність уподобань користувача (на основі історії користувача і його харчових потреб або явних оцінок). Друга складова оцінює відмінність від тих страв, що вже включені до набору рекомендацій, використовуючи показники схожості на основі поживної цінності, типу кухні,

різноманітності інгредієнтів і смакових характеристик. Для етапу ранжування для кожного рецепту ключові слова та теги вкладаються до векторного простору за допомогою алгоритму Word2Vec [10].




Рис. 5. Схема роботи етапу ранжування

Векторне представлення рецептів страв за ключовими словами і тегами використовується для ранжування рецептів за допомогою алгоритму максимальної граничної релевантності MMR [11]:

$$MMR(i) = \lambda \cdot r(i) - (1 - \lambda) \cdot \max_{j \in S} Sim(i, j), \quad (11)$$

де $MMR(i)$ – оцінка рецепту i після ранжування; S – множина рецептів, що вже була поміщена в готовий список рекомендацій; $r(i)$ – оцінка рецепта i , що отримана з попереднього етапу, $Sim(i, j)$ – косинусна відстань між рецептом i та j , що отримана на основі ключових слів та тегів; λ – параметр, що при формуванні списку рекомендацій визначає важливість різноманітності.

Висновки.

1. Для забезпечення високої персоналізації, адаптивності до вподобань і цілей користувача розроблено концептуальну модель персоналізованої інтелектуальної системи планування збалансованого харчування людини. Модель передбачає можливість додавати та забирати модулі в залежності від потреб і наявності контекстуальних даних та даних сесії, а також застосовувати їх тільки до рецептів, відносно яких наявні дані. Це збільшує гнучкість системи і дозволяє перенавчати моделі штучного інтелекту рідше, зберігаючи ресурси.

2. Для врахування контекстуальних даних і даних сесії користувача в реальному часі запропоновано трьох етапний метод рекомендацій рецептів.

3. Контекстні та сесійні моделі корекції оцінок дозволяють корегувати отримані від наперед навченої моделі оцінки для рецептів..

Список використаних джерел

1. Chelmis, C. and Gergin, B., Recipe networks and the principles of healthy food on the web. *Proceedings of the International Aaai Conference on Web and Social Media*, 2023, Vol. 17, p. 95-102.

2. Elswailer, D., Trattner, C., & Harvey, M., Exploiting food choice biases for healthier recipe recommendation., 2017, p. 575-584.

3. Papastratis, I., Konstantinidis, D., Daras, P. et al. AI nutrition recommendation using a deep generative model and ChatGPT. *Sci Rep* 14, 14620 2024, DOI: <https://doi.org/10.1038/s41598-024-65438-x>

4. Journal, I., Meal map pro. *Interantional Journal of Scientific Research in Engineering and Manaqement*, 2023, Vol. 07(11), p. 1-11,

5. Elswailer, D. and Harvey, M., Towards automatic meal plan recommendations for balanced nutrition. 2015. DOI: <https://doi.org/10.1145/2792838.2799665>

6. Liu, C., Jin, H., & Wang, J., Investigating the moderating effects of context-aware recommendations on the relationship between knowledge search and decision quality. *Journal of Organizational and End User Computing*, 2024, Vol. 36(1), p. 1-21.

7. Wang, J., Yessenalina, A., & Roshan-Ghias, A., Exploring heterogeneous metadata for video recommendation with two-tower model. 2021. DOI: <https://doi.org/10.48550/arxiv.2109.11059>

8. Xiao, Y., Guo, J., Lan, Y., Xu, J., & Cheng, X. (2018). Fast approximate nearest neighbor search via k-diverse nearest neighbor graph. *Proceedings of the Aaai Conference on Artificial Intelligence*, 2018, Vol. 32(1) DOI: <https://doi.org/10.1609/aaai.v32i1.12138>

9. Jeong, S.-Y., & Kim, Y.-K., Deep Learning-Based Context-Aware Recommender System Considering Change in Preference. *Electronics*, 2023, Vol. 12(10), 2337.

10. Yousuf, H., Al-Hamad, A., & Salloum, S., An overview on cryptodb and word2vec approaches. *Advances in Science Technology and Engineering Systems Journal*, 2020, Vol. 5(5), p. 1282-1287.

11. Forst, J., Tombros, A., & Roelleke, T., Less is more: maximal marginal relevance as a summarisation feature., 2009, p. 350-353.

Ladyzhets Viktor, Terenchuk Svitlana

Designing the recommendation method for a meal planning information system

The work is devoted to solving such a complex scientific and applied problem of dietetics as the formation of recipes for dishes of different food categories. The purpose of the article is to develop a method for recommending recipes based on machine learning, which allows taking into account the personal preferences and dietary restrictions of the user. The proposed method consists of three stages: candidate generation, scoring, and recipe ranking. At the candidate generation stage, a two-tower model using neural networks is used. This model allows for the effective integration of user and dish information into a common vector space and the quick retrieval of relevant recipes using a nearest neighbor search algorithm. After that, during the candidate generation stage, filtering takes place, which weeds out recipes that contain allergens or products restricted by the user. The scoring stage involves the user evaluating the recipes obtained from the candidate generation stage and forming a list of recommendations, which are ranked in order of recommendation in the next stage. For this purpose, machine learning models such as matrix factorization, decision tree-based models, and deep learning are used in the evaluation stage. These machine learning models take into account user preferences. The scoring stage also proposes modules that take into account contextual factors such as viewing history, day of the week, and time available for cooking. The ranking stage is implemented using a maximum marginal relevance algorithm, which ensures a balance between the relevance of recipe suggestions to user preferences and the diversity of recommendations. The scientific novelty of the work lies in the fact that, for the first time, a method has been developed that allows taking into account the user's personal preferences and their preferences regarding ingredients and cooking techniques. The proposed method has high potential for building intelligent personalized meal planning systems that promote a healthy lifestyle for users.

Keywords: *artificial intelligence, information technology, deep learning, machine learning, two-tower model, neural network, recommendation systems.*

References

1. Chelmis, C. and Gergin, B. (2023). Recipe networks and the principles of healthy food on the web. *Proceedings of the International Aaai Conference on Web and Social Media*, 17, 95-102. <https://doi.org/10.1609/icwsm.v17i1.22129>

2. Elswailer, D., Trattner, C., & Harvey, M. (2017). Exploiting food choice biases for healthier recipe recommendation., 575-584.
3. Papastratis, I., Konstantinidis, D., Daras, P. et al. AI nutrition recommendation using a deep generative model and ChatGPT. *Sci Rep* 14, 14620 (2024). <https://doi.org/10.1038/s41598-024-65438-x>
4. Journal, I. (2023). Meal map pro. *Interantional Journal of Scientific Research in Engineering and Management*, 07(11), 1-11.
5. Elswailer, D. and Harvey, M. (2015). Towards automatic meal plan recommendations for balanced nutrition.. <https://doi.org/10.1145/2792838.2799665>
6. Liu, C., Jin, H., & Wang, J. (2024). Investigating the moderating effects of context-aware recommendations on the relationship between knowledge search and decision quality. *Journal of Orqanizational and End User Computing*, 36(1), 1-21. <https://doi.org/10.4018/joeuc.345930>
7. Wang, J., Yessenalina, A., & Roshan-Ghias, A. (2021). Exploring heterogeneous metadata for video recommendation with two-tower model.. <https://doi.org/10.48550/arxiv.2109.11059>
8. Xiao, Y., Guo, J., Lan, Y., Xu, J., & Cheng, X. (2018). Fast approximate nearest neighbor search via k-diverse nearest neighbor graph. *Proceedings of the Aaai Conference on Artificial Intelligence*, 32(1). <https://doi.org/10.1609/aaai.v32i1.12138>
9. Jeong, S.-Y., & Kim, Y.-K. (2023). Deep Learning-Based Context-Aware Recommender System Considering Change in Preference. *Electronics*, 12(10), 2337.
10. Yousuf, H., Al-Hamad, A., & Salloum, S. (2020). An overview on cryptodb and word2vec approaches. *Advances in Science Technology and Engineering Systems Journal*, 5(5), 1282-1287.
11. Forst, J., Tombros, A., & Roelleke, T. (2009). Less is more: maximal marginal relevance as a summarisation feature., 350-353.

Посилання на статтю:

АРА: Ladyzhets, V., Terenchuk, S. (2024). Designing the recommendation method for a meal planning information system. *Shliakhy pidvyschennia efektyvnosti budivnytstva v umovakh formuvannia rynkovykh vidnosyn*, 53(2), 377-388.

ДСТУ: Ладижець В. І., Теренчук С.А. Проектування методу рекомендації для інформаційної системи планування харчування. *Шляхи підвищення ефективності будівництва в умовах формування ринкових відносин*, 2024, 53(2), 377-388.