

## КОМПАРАТИВНИЙ АНАЛІЗ ЕФЕКТИВНОСТІ РЕКОМЕНДАЦІЙНИХ СИСТЕМ В МАРКЕТИНГУ

*Розробка і реалізація маркетингової стратегії сприяє ефективному використанню наявних ресурсів компанії та динамічним продажам компанії. Одним із ефективних інструментів маркетингової стратегії є рекомендаційні системи: системи, побудовані з використанням алгоритмів на основі пам'яті, та системи з алгоритмами на основі моделі. У дослідженні проведено порівняння рекомендаційних систем як інструменту маркетингових стратегій на основі бази даних 1M MovieLens. Для оцінки рекомендаційних систем у даному дослідженні використано RMSE.*

*Ключові слова: рекомендаційна система, маркетинг, стратегія, алгоритм, модель, користувач.*

NEHREY M., HNOT T.

National University of Life and Environmental Science of Ukraine, Kyiv

## COMPARATIVE ANALYSIS OF EFFECTIVENESS OF RECOMMENDER SYSTEMS IN MARKETING

*The aim of the research is a comparison of recommender systems as approaches for marketing strategies. The main objective of the study is detecting of advantages and disadvantages of different algorithms, which are used when building recommender system. Development and implementation of marketing strategy cause the effective use of resources and dynamic sales of a company. One of the most effective tools of marketing strategies is recommender systems: systems, which are built using memory-based algorithms and systems with model-based algorithms. We have used 1M MovieLens dataset in our study. To evaluate recommender systems we have focused on RMSE. Each algorithm was evaluated 10 times for different train/test splits in order to achieve more stable results. From memory-based approaches, Item-Based CF shows the best result. It performs much better than Most Popular and User-Based CF. The best performance was shown by Matrix Factorization techniques with Stochastic Gradient Descend (0.873). Moreover, for this method, it is enough to use only 7 factors to achieve a good result. Slope One also performs well. In comparison with Matrix Factorization, it needs much less time for training. Recommender systems became so popular because of active development of online marketing and increase of sales through the Internet. When selecting a recommender system it is advisable to consider the purpose of marketing strategy, product features, specifications and availability of customer data on their preferences.*

*Keywords: recommender system, marketing, strategy, algorithm, model, user.*

Постановка проблеми. Сучасному конкурентному середовищу притаманні високий рівень конкуренції, динамічність, глобалізація, швидка зміна вподобань споживачів. Для успішного функціонування на ринку компаніям необхідно розробляти і ефективно реалізовувати маркетингові стратегії. Основними задачами маркетингової стратегії є комплексне дослідження ринку, оцінка та прогнозування попиту, розробка заходів, що спрямовані на збільшення продажів і доходів компанії.

Маркетингова стратегія компанії повинна забезпечувати досягнення наступних цілей:

- створення ціннісної позиції, яка б задовольняла потреби споживачів;
- формування унікальної позиції на ринку, що виділяється на фоні конкурентів;
- використання ефективних каналів комунікації зі споживачами;
- надання споживачам легкого доступу до продукту;
- забезпечення лояльності споживачів, надання допомоги у купівлі і ефективне післяпродажне обслуговування.

Із розвитком інформаційних технологій для маркетингу відкриваються нові перспективи. Працюючи в епоху великих даних, коли вартість їх обробки досить мала в порівнянні з результатом, які вони можуть принести при правильному їх застосуванні, необхідним є використання сучасних інструментів стратегії маркетингу.

Аналіз останніх досліджень і публікацій. Незважаючи на те, що проблема використання інструментарію DataScience у маркетингових стратегіях є досить новою, її дослідженню присвячена значна кількість наукових робіт. Зокрема, застосуванню інформаційних технологій у маркетингу присвячено праці зарубіжних вчених: G. Armstrong, S. Adam, S. Denize та P. Kotler [1], D. Ryan [2], M. S. Yadav та P. A. Pavlou [3], P. K. Kannan [4], E. Phillips [5], – та вітчизняних науковців: С. М. Ілляшенка, Т. С. Іваною [6], В. В. Савельєва [7] та ін. Ґрунтовні дослідження побудови, використання та аналізу рекомендаційних систем проведено вченими: R. Francesco [8], S. Gorakala [9], J. Lee, M. Sun, G. Lebanon [10], J. Breese, D. Heckerman, C. Kadie [11], Z. Huang, D. Zeng, H. Chen [12], D. Lemire, A. Maclachlan [13], M. Vozalis, A. Markos, K. Margarities [14], M. Hahsler [15], S. Zhang, W. Wang, J. Ford, F. Makedon, J. Pearlman [16], G. Adomavicius, A. Tuzhilin, [17], В. І. Городецький [18], Л. Л. Півареліс, О. М. Савінов [19] та ін.

Виділення не вирішених раніше частин загальної проблеми, яким присвячується стаття. Порівняння рекомендаційних систем є предметом вивчення багатьох наукових досліджень. У роботі [11] порівняно декілька підходів побудови рекомендаційних систем. Автори зосередилися на порівнянні різних видів

подібності, що можуть бути використані для створення системи колаборативної фільтрації (косинусна подібність, кореляція Пірсона). У дослідженні порівнюються і рекомендації на основі пам'яті, і на основі моделі (кластеризації, Байєсівських мереж). Всі дослідження були проведені на трьох різних наборах даних.

Z. Huang, D. Zeng і H. Chen [12] у своїх дослідженнях порівняли колаборативну фільтрацію на основі користувачів, колаборативну фільтрацію на основі товарів, апроксимацію на основі SVD розкладу та інші алгоритми на основі розкладу матриці. За основу для порівняння вчені використовували класифікаційні критерії оцінювання (precision, recall, F1-measure and rank score), включаючи ремарки про складність обчислення.

Дослідженню більше десяти алгоритмів і підходів присвятили свої роботи Joonseok Lee, Mingxuan Sun, Guy Lebanon [10]. На основі даних Netflix було оцінено алгоритми за декількома критеріями: залежність точності від кількості користувачів, товарів, розрідженості матриці, складності обчислення.

Зазначені дослідження досить ґрунтовно аналізують переваги та недоліки рекомендаційних систем, проте, на нашу думку недостатньо уваги приділено проблемі вибору рекомендаційних систем з використанням комплексу критеріїв їх оцінки.

Метою дослідження є порівняння рекомендаційних систем як інструменту маркетингових стратегій. Основним завданням дослідження є встановлення переваг та недоліків окремих рекомендаційних алгоритмів, які використовуються під час побудови рекомендаційних систем.

Основний матеріал. Рекомендаційна система – підклас системи фільтрації інформації, яка формує рейтинговий перелік об'єктів, яким користувач може надати перевагу. Для цього використовується інформація про користувача, його історія в середовищі (наприклад, історія покупок), інформація про самі об'єкти і т. д. Також рекомендаційні системи порівнюють однотипні дані від різних людей і розраховують список рекомендацій для конкретного користувача.

Рекомендаційні системи аналізують думки членів спільноти (цільової аудиторії, соціальної мережі, покупців і т. ін.), щоб ідентифікувати інформацію або товари, якими швидше за все будуть цікавитися покупці (клієнти). Ці системи були розроблені для вирішення двох проблем, які не можуть бути вирішені за допомогою систем фільтрації інформації на основі ключових слів. По-перше, вони вирішують проблему вибору документів по темі не за ключовими словами, а за судженнями людей про якість документу. По-друге, вони дозволяють фільтрувати нетекстові документи на основі смаків і вподобань споживачів.

Перші дослідження в цій області (90-і роки ХХ ст.) були зосереджені головним чином на здатності цих систем генерувати рекомендації, які були оцінені користувачами системи. Рекомендаційні системи викликали значний інтерес і підтримку з боку своїх користувачів. Успішне використання рекомендаційних систем у бізнесі обумовило їх розвиток. Основними питаннями, що виникали в ході використання їх на практиці, була швидкість, з якою рекомендації можуть бути згенеровані, масштаб проблем, які можуть бути вирішені, та оцінка вартості рекомендацій для бізнесу або для клієнтів.

В кінці 90-х років ХХ століття науковці одного з найбільших на той час інтернет-магазинів – Amazon – розробили метод, який дозволяв рекламувати книжки клієнтам інтернет-ресурсу на основі асоціацій між ними. Впровадження цього методу, дало неймовірні результати – обсяги продажів зросли приблизно в 100 раз у порівнянні з рекомендаціями, які були надані критиками. На сьогоднішній день третину своїх продажів компанія Amazon здійснює за допомогою своїх рекомендаційних систем. В подальшому рекомендаційні системи набули значного поширення. В Україні подібні методи практично не використовуються, оскільки у вітчизняних підприємств немає розроблених алгоритмів та впроваджених рекомендаційних систем.

Більшість маркетингових стратегій вітчизняних компаній спрямовані на рекламу нових або популярних товарів, при чому оцінка цільової аудиторії не завжди є адекватною. Вітчизняним підприємствам доцільно впроваджувати стратегії, які передбачають рекламу товарів на основі математичних розрахунків. Суть таких моделей полягає у прогнозі товару, який з найбільшою ймовірністю буде проданий певному клієнту. Такі моделі досить прості за своєю сутністю, наприклад, пропонування товару, який користується найбільшим попитом. Проте вони можуть бути математично досить складними та побудованими з використанням інструментарію DataScience. До таких моделей відносять один тип з класу моделей машинного навчання – рекомендаційні системи.

Вихідні дані дослідження. У дослідженні використано базу даних 1M MovieLens. MovieLens – це проект GroupLens Research [21] дослідницької лабораторії факультету комп'ютерних наук та інженерії Університету Мінесоти. Проект був націлений на збір дослідницьких даних про персоналізовані рекомендації. MovieLens – рекомендаційна система і веб-сайт, що пропонує своїм користувачам фільми для перегляду, на основі їх уподобань, використовуючи колаборативну фільтрацію.

База даних 1M MovieLens містить приблизно 1 мільйон оцінок по п'ятибальній шкалі 6040 фільмів від 3706 користувачів [22]. Загальна статистика цих даних показана на рис. 1 (сіра лінія показує медіанні значення). Рівень розрідженості матриці – 0.045.

Рекомендаційні системи поділяються на дві основні категорії: системи з алгоритмами на основі пам'яті та системи із алгоритмами на основі моделі [10].

Алгоритми на основі пам'яті запам'ятовують всі значення оцінок і роблять рекомендації на основі співвідношення користувач-товар з рештою матриці. В алгоритмах на основі моделі модель з параметрами спочатку налаштовують на основі матриці оцінок, а потім дають рекомендації, виходячи з моделі.

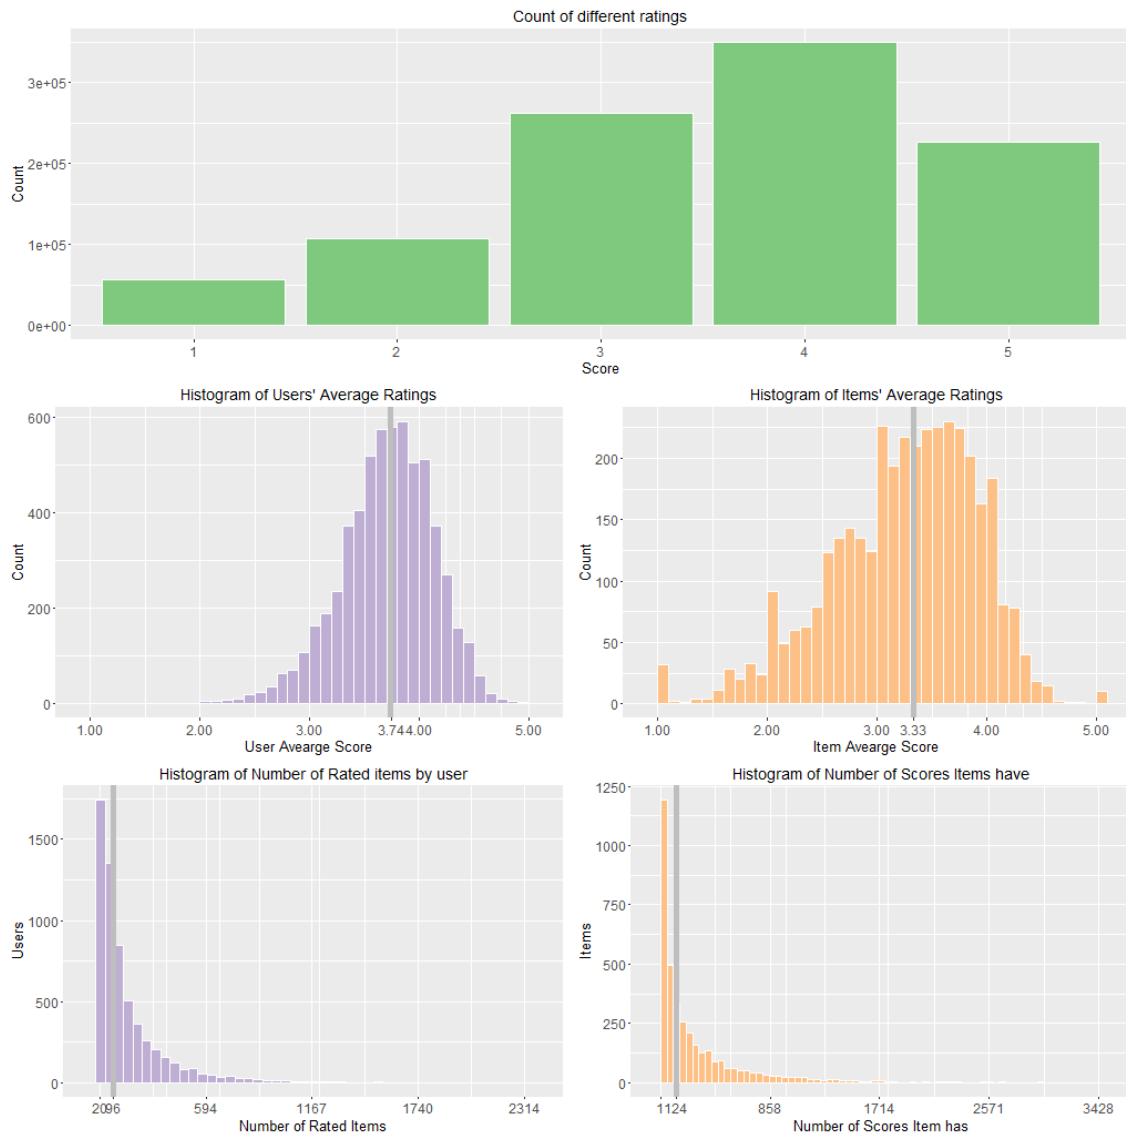


Рис. 1. Огляданих 1M MovieLens

Двома найпопулярнішими алгоритмами на основі пам'яті є колаборативна фільтрація на основі користувачів і колаборативна фільтрація на основі товарів. Ці алгоритми є прикладами алгоритмів на основі найближчих сусідів, що використовують оцінку схожих користувачів або товарів і дають рекомендації, беручи до уваги підсумок оцінок найбільш подібних користувачів/товарів. Метод колаборативної фільтрації на основі користувачів побудований на припущенні, що якщо двоє користувачів мають схожі вподобання стосовно деякого товару, то вони матимуть подібні вподобання щодо інших товарів. Аналогічно для методу колаборативної фільтрації на основі товарів, але з точки зору товарів.

Використовуючи алгоритми на основі моделі будують модель і рекомендують товар з найвищою оцінкою, яка прогнозується моделлю. Наприклад, метод SlopeOne передбачає використання набору лінійних регресійних моделей (одна модель для кожної пари товарів) з константою. Відповідно, ця константа відображає середню різницю між оцінками двох товарів. Використання цього алгоритму дає змогу досягти високої точності і швидкості обчислення. Інший приклад такого методу – апроксимація на основі SVD розкладу. Таким способом матрицю оцінок розкладають на частини за допомогою сингулярного розкладу, а потім реконструюють, зберігаючи тільки перших  $r$  найбільш значимих власних значень. Це дає можливість спрогнозувати пропущені значення в матриці оцінок.

В даному дослідженні розглянуто шість рекомендаційних алгоритмів (табл. 1).

Найбільш популярний товар. Використовуючи метод найбільш популярного товару (середня оцінка товару), обчислюють середню оцінку для кожного товару на основі наявних оцінок і прогнозують кожну

невідому оцінку як середню для товару [15]. В результаті, пропущені оцінки кожного товару будуть однакові для всіх користувачів.

Таблиця 1

## Рекомендаційні алгоритми

Категорія	Підкатегорія	Алгоритм
На основі пам'яті	Базисні підходи	Найбільш популярний товар
	На основі подібності	Колаборативна фільтрація на основі користувачів Колаборативна фільтрація на основі товарів
На основі моделі	Лінійна регресія	Slope One
	Факторизація матриці	Факторизація матриці з допомогою стохастичного градієнтного спуску
		Апроксимація на основі SVD розкладу

Алгоритм методу найбільш популярного товару:

Обчислення середньої оцінки для кожного товару:

$$\bar{r}_k = \frac{\sum_{j \in B_k} r_{jk}}{|B_k|}, \quad k \in \overline{1, n},$$

$B_k$  – множина індексів наявних оцінок для  $k$ -го товару.

Прогнозування пропущених оцінок в матриці  $R$  як середніх значень для товарів:

$$r_{jk} = \bar{r}_k,$$

$$r_{jk} = ? (\text{missed ratings}).$$

Колаборативна фільтрація на основі користувачів. Використовуючи колаборативну фільтрацію на основі користувачів будують прогнози на основі сумарної оцінки найближчих користувачів (найближчих сусідів). Найближчих сусідів визначають на основі подібності між користувачами, яку обчислюють, використовуючи наявні оцінки. Важливо зазначити, що в основі методу лежить припущення, що користувачі з подібними оцінками оцінюватимуть товари однаково.

Для визначення подібності між користувачами існує багато різних підходів, які використовують для налаштування рекомендаційних систем. Найпопулярнішими для колаборативної фільтрації є кореляція Пірсона та косинусна подібність.

Алгоритм колаборативної фільтрації на основі користувачів:

Для користувачів  $u \in \overline{1, m}$ :

Обчислення подібності між користувачем  $u$  та іншими користувачами.

Визначення  $n$  найбільш подібних користувачів до користувача  $u$ .

Обчислення невідомих оцінок користувача  $u$  як середніх з наявних оцінок  $n$  найбільш подібних користувачів або як зважених (на основі подібності) оцінок  $n$  найближчих користувачів.

Щоб знайти найкраще значення  $n$ , можна використовувати відокремлені дані для перевірки або перехресну перевірку.

В даному дослідженні використано косинусну подібність ( $n=50$ ) на основі перехресної перевірки. Результати для різної кількості користувачів показано на рис. 2. Оскільки дослід було проведено декілька разів (для досягнення більш стабільного результату), всі оцінки показано у вигляді коробкових графіків.

Колаборативна фільтрація на основі товарів. Метод колаборативної фільтрації на основі товарів дуже подібний до колаборативної фільтрації на основі користувачів. Але в цьому випадку подібність розраховують між товарами, а не користувачами. Припущення полягає в тому, що користувачеві сподобаються товари, подібні до тих, що йому вже сподобалися.

Алгоритм методу колаборативної фільтрації на основі товарів:

Побудова матриці подібності товарів на основі наявних оцінок користувачів.

Для користувача  $u \in \overline{1, m}$ :

Вибір тільки  $n$  найближчих товарів до кожного товару.

Обчислення прогнозу оцінки для кожного товару на основі наявних оцінок користувача  $u$ , зважуючи відомі оцінки користувача на коефіцієнти подібності.

Як і для колаборативної фільтрації на основі користувачів, використано косинусну подібність і вибрано  $n=350$  на основі перехресної перевірки. Результати для різних значень  $n$  показано на рис. 3.

Результати показали іншу поведінку, ніж для колаборативної фільтрації на основі користувачів. По-перше, можна досягти кращого результату завдяки збільшенню кількості ближніх товарів. Крім того, найкраще значення  $n$  є набагато більшим у порівнянні з колаборативною фільтрацією на основі користувачів.

Колаборативна фільтрація на основі товарів дає можливість досягти меншого значення середньоквадратичного відхилення на тестовому наборі, ніж колаборативна фільтрація на основі користувачів, що робить її кращою для даного набору даних.




Рис. 2. Середньоквадратичне відхилення для різної кількості користувачів




Рис. 3. Середньоквадратичне відхилення для різної кількості товарів

Slope One. Slope One був представлений Daniel Lemire і Anna Maclachlan [13]. Це один із найпростіших алгоритмів для виконання колаборативної фільтрації на основі подібності товарів. Його легко впровадити, а точність цього алгоритму прирівнюється до точності більш складних та ресурсомістких алгоритмів.

Алгоритм методу Slope One:

Для товару  $i \in \overline{1, n}$ :

Обчислення середньої різниці оцінки між товаром  $i$  та всіма іншими товарами  $k \in \overline{1, n}$ ,  $k \neq i$ :

$$Diff(i, k) = \frac{\sum_{j \in U_{ik}} r_{ji} - r_{jk}}{|U_{ik}|}, \quad i \in \overline{1, n}, \quad k \in \overline{1, n}, \quad k \neq i.$$

$U_{ik}$  – множина індексів користувачів, у яких наявні оцінки для  $i$ -го та  $k$ -го товарів.

Прогнозування оцінки користувача  $j$  товару  $k$ , на основі різниці в оцінках всіх пар товарів:

$$r_{jk} = \sum_{p \in \overline{1, n}, p \neq k} \frac{(r_{jp} + Diff(p, k)) \cdot |U_{kp}|}{\sum_{p \in \overline{1, n}, p \neq k} |U_{kp}|}, \quad r_{jk} = ? (\text{missed rating})$$

Факторизація матриці на основі стохастичного градієнтного спуску. Основна ідея методу факторизації матриці полягає в розкладі матриці  $R_{m \times n}$  на добуток двох матриць меншого розміру:  $P_{k \times m}$  і  $Q_{k \times n}$ :

$$R \approx P \cdot Q$$

Матриця  $P$  характеризує приховані характеристики користувачів. Таким чином, кожен  $k$ -й елемент стовпчика матриці  $P$  відображає кожного користувача. Кожен  $k$ -й елемент стовпчика матриці  $Q$  відображає кожний товар. Відповідно, щоб знайти оцінку товару  $i$  користувачем  $u$  потрібно перемножити два вектори:

$$r_{ui} = P[u] \cdot Q[i]$$

Алгоритм методу факторизації матриці на основі стохастичного градієнтного спуску:

Для товару  $i \in \overline{1, n}$ :

Обчислення матриці  $P$  і  $Q$ , шляхом мінімізації наступної функції з допомогою стохастичного градієнтного спуску:

$$\min_{P, Q} \sum_{(u, i) \in R} \left( (r_{u, i} - p_u \cdot q_i)^2 + \lambda (\|p_u\|^2 + \|q_i\|^2) \right).$$

Прогнозування оцінок шляхом множення матриць  $P$  і  $Q$ .

Цей метод має 3 гіперпараметри, які потрібно підбирати: кількість факторів ( $k$ ), крок градієнта спуску, штраф на великі значення ( $\lambda$ ). Результат застосування даного методу залежить від кількості латентних факторів. Мала кількість призводить до недонавчання, велика – перенавчання. Рис. 4 демонструє помилки під час тестування для значень від 1 до 20.

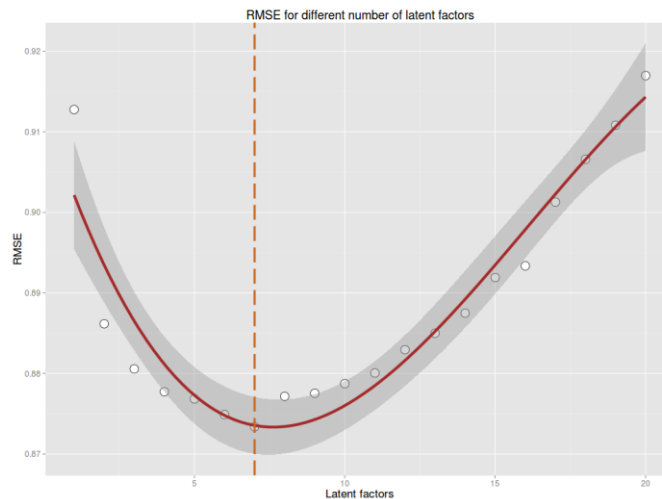


Рис. 4. Середньоквадратичне відхилення за різної кількості латентних факторів для факторизації матриці на основі стохастичного градієнтного спуску

Апроксимація на основі SVD розкладу. Алгоритм Singular Value Decomposition (SVD) базується на методі факторизації матриці, який розкладає матрицю  $R$  розміром  $m \times n$  наступним чином:

$$R = U \cdot S \cdot V^T.$$

Після розкладу матриця  $R$  може бути реконструйована, зберігаючи тільки перші  $r$  найбільш важливих власних значень. Це дає можливість спрогнозувати відсутні значення матриці оцінок [15].

Алгоритм методу апроксимації на основі SVD розкладу:

Заміна всіх відсутніх значень на середні значення оцінок товарів:

$$r_{jk} = r_{jk} - \bar{r}_k, \bar{r}_k = \frac{\sum_{j \in A_k} r_{jk}}{|A_k|}, k \in \overline{1, n},$$

$A_k$  – множина індексів наявних оцінок для  $k$ -го товару.

Нормалізація матриці шляхом віднімання середніх значень користувачів.

Виконання Singular Value Decomposition матриці  $R$ :

$$R = U \cdot S \cdot V^T.$$

Реконструювання матриці  $R$ , використовуючи  $r$  рядків матриці  $U$ ,  $r$  рядків і  $r$  стовпців матриці  $S$  і  $r$  стовпців матриці  $V$ :

$$R_{predicted} = U[1:r, :] \cdot S[1:r, 1:r] \cdot V^T[:, 1:r],$$

$r$  виражає кількість латентних факторів розкладу і найкраще значення цього параметра можна знайти за допомогою перехресної перевірки.

Найменше значення середньоквадратичного відхилення відповідає  $r=24$ . Але, як і для UBCF, можна зменшити це число до 10-15, і це не спричинить суттєвої втрати точності. На рис. 5 показано, що перші 24 основних компоненти пояснюють 17% варіативності, що є достатньо для прогнозування. Використання більшої кількості компонентів призведе до перенавчання.

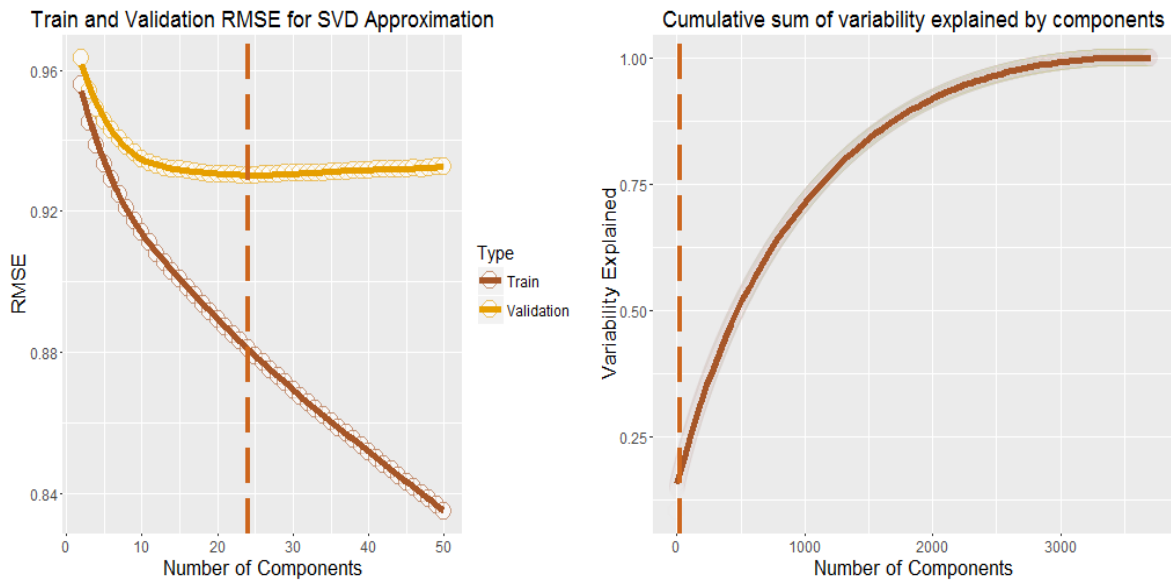


Рис. 5. Середньоквадратичне відхилення для навчальної і тестової вибірки для різної кількості латентних факторів для SVD апроксимації

Вибір рекомендаційних алгоритмів. Для оцінки рекомендаційних систем можна використовувати різні показники: середня абсолютна помилка (MAE), середньоквадратичне відхилення (RMSE), precision, recall, F1 score. Також рекомендаційні системи можуть бути оцінені на основі часу навчання, складності підбору значень для гіперпараметрів тощо. Різні оцінки можуть призвести до різних результатів.

Для оцінки рекомендаційних систем у даному дослідженні використано RMSE:

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{u,i} (p_{u,i} - r_{u,i})^2},$$

$p_{u,i}$ ,  $r_{u,i}$  – відповідно прогнозна та наявна оцінка  $i$ -го товару користувачем  $u$ .

Кожен алгоритм було оцінено 10 разів для різних поділів даних на навчальну і тестову частини для досягнення більш стабільних результатів.

На рис. 6 показано оцінку RMSE для різних алгоритмів.

З алгоритмів на основі пам'яті колаборативна фільтрація на основі товарів показує найкращий результат. RMSE для нього набагато нижча, ніж для алгоритму найбільш популярного товару чи методу колаборативної фільтрації на основі користувачів.

Найкращу точність показував алгоритм факторизації матриці з використанням стохастичного градієнтного спуску (0.873). Крім того, для цього методу достатньо використовувати лише 7 латентних факторів для досягнення хорошого результату. Slope One також показує непогану точність. В порівнянні з факторизацією матриці, він потребує менше часу для навчання.

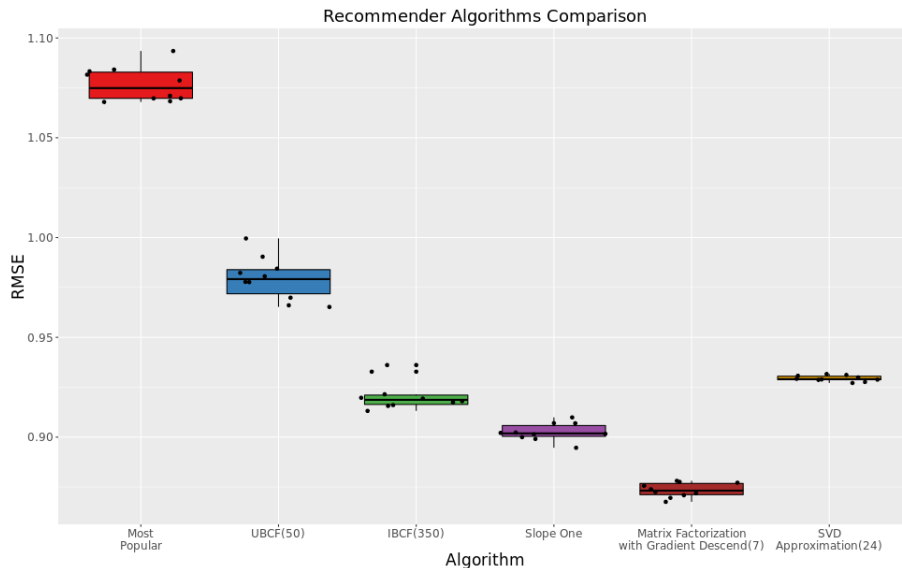


Рис. 6. Порівняння RMSE рекомендаційних алгоритмів

На рис. 7 зображено повне порівняння розглянутих алгоритмів. Хоча метод факторизації матриці є найкращим з точки зору точності, його важче налаштувати та знайти найкращі гіперпараметри.




Рис. 7. Порівняння алгоритмів для рекомендацій

Слід зауважити, що використання рекомендаційних систем має ряд недоліків, що спричинені наступним:

Використання неякісних даних: досить часто рейтинги товари і відгуки на них є неправдивими, оскільки формуються самими власниками товарів. До того ж, значна частка покупців взагалі не пише відгуки і не ставить оцінки товаром, тобто дані є розрідженими.

Недостатня кількість даних: при оцінці нових товарів або споживачів, інформації про них може бути дуже мало.

Робота із «проблемними» даними: оцінка подібних товарів з різними назвами може дати некоректні результати. Ускладнюють роботу і унікальні споживачі, смаки і вподобання яких суттєво відрізняються від загалу.

Висновки. Використання рекомендаційних систем обумовлено активним розвитком інтернет-маркетингу та зростанням обсягу продажів через Інтернет. Під час вибору рекомендаційної системи доцільно враховувати мету маркетингової стратегії, особливості продукту, характеристики споживачів і наявність даних щодо їх вподобань. Застосування однієї із вищезазначених рекомендаційних систем сприятиме підвищенню ефективності маркетингової стратегії компанії.

Машинне навчання, зокрема системи рекомендацій, кластеризація клієнтів, оптимізація логістики відкривають нові можливості для маркетингової діяльності підприємства. На нашу думку, обсяг продажів компаній, які використовуватимуть ці підходи, будуть суттєво зростати у порівнянні з компаніями, що використовують традиційні підходи у маркетингових стратегіях.

На нашу думку, перспективними напрямками досліджень рекомендаційних систем є підходи до їх побудови та впровадження, поєднання у рекомендаційних системах різних методів та використання різних даних для побудови рекомендацій та інтелектуальний аналіз даних.



## Література

1. Armstrong G. Principles of marketing / Armstrong, G., Adam, S., Denize, S., & Kotler, P. Pearson Australia, 2014. – 956 p.
2. Ryan D. Understanding digital marketing: marketing strategies for engaging the digital generation / Ryan D. – Kogan Page Publishers, 2016.
3. Yadav M. S. Marketing in computer-mediated environments: Research synthesis and new directions / Yadav Manjit S.; Pavlou, Paul A. // *Journal of Marketing*. – 2014. – 78.1. – P. 20–40.
4. Kannan P. K. Digital marketing: A framework, review and research agenda / Kannan P. K. // *International Journal of Research in Marketing*. – 2017. – 34(1). – P. 22–45.
5. Phillips E. Retailers scale up online sales distribution networks / Phillips E. // *The Wall Street Journal*. – 2015. – November 17.
6. Ілляшенко С.М. Проблеми і перспективи просування продукції вітчизняних підприємств в Internet / С.М. Ілляшенко, Т.Є. Іванова // *Вісник Одеського національного університету. Серія: Економіка*. – 2015. – Том 20. Випуск 1/2. – С. 101–107.
7. Савельєв В. В. Модель зміни поведінки споживачів як основа маркетингової стратегії / В. В. Савельєв // *Вісник Київського національного університету ім. Тараса Шевченка. Серія: Економіка*. – 2014. – Випуск 162. – С. 50–54.
8. Ricci F. Recommender Systems Handbook / Francesco Ricci, Lior Rokach, Bracha Shapira, Paul B. Kantor. – New York : Springer, 2010. – 845 p.
9. Gorakala S. Building a Recommendation System with R / Suresh K. Gorakala, Michele Usulli. – Birmingham : Packt Publishing Ltd., 2015. – 158 p.
10. Lee J. A comparative study of collaborative filtering algorithms / Lee Joonseok, Sun Mingxuan, Lebanon Guy / arXiv preprint arXiv:1205.3193. – 2012.
11. Breese J. S. Empirical analysis of predictive algorithms for collaborative filtering / Breese John S., Heckerman David, Kadie Carl // *Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence*. – Morgan Kaufmann Publishers Inc. – 1998. – P. 43–52.
12. Huang Z. A comparison of collaborative-filtering recommendation algorithms for e-commerce / Z. Huang, D. Zeng, H. Chen // *Proc. of IEEE Intelligent Systems*. – 2007. – 22. – P. 68–78.
13. Lemire D. Slope one predictors for online rating-based collaborative filtering / Lemire, Daniel; Maclachlan, Anna // *Proceedings of the 2005 SIAM International Conference on Data Mining*. – Society for Industrial and Applied Mathematics. – 2005. – P. 471–475.
14. Vozalis M. Evaluation of standard SVD-based techniques for Collaborative Filtering / M. Vozalis, A. Markos, K. Margaritis // *In Proc. of the 9th Hellenic European Research on Computer Mathematics and its Applications*. – 2009.
15. Hahsler M. Recommenderlab: A Framework for Developing and Testing Recommendation Algorithms / M. Hahsler // *Southern Methodist University*. – 2015.
16. Zhang S. Using singular value decomposition approximation for collaborative filtering / S. Zhang, W. Wang, J. Ford, F. Makedon, J. Pearlman // *In Proc. of the 7th IEEE International Conf. on E-Commerce Technology (CEC'05)*. – 2005. – P. 257–264.
17. Adomavicius G. Context-aware recommender systems / G. Adomavicius, A. Tuzhilin / *Recommender systems handbook*. – Springer US. – 2015. – P. 191–226.
18. Городецкий В.И. Онтологии и персонификация профиля пользователя в рекомендуемых системах третьего поколения / В.И. Городецкий, О.Н. Тушканова // *Онтология проектирования* – 2014 – № 3 (13) – Самара : Предприятие «Новая техника» – С. 7–31.
19. Пиварелис Л.Л. Разработка системы рекомендуемой товаров и услуги в интернет на основе интересов пользователей / Л.Л. Пиварелис, А.Н. Савинов // *Технические науки – от теории к практике* : сб. ст. по матер. LXIII междунар. науч.-практ. конф – Новосибирск : СибАК, 2016. – № 10(58). – С. 59–63.
20. Технологии цифрового маркетинга: создание рекламной кампании / В. Н. Григорьева, С. Г. Антонов, П. Ф. Воробьев, А. В. Григорьев, С. В. Федюнин, И. А. Шут / под ред. В. Н. Григорьевой. – СПб : Издательство «Левша Санкт-Петербург», 2017. – 250 с.
21. MovieLens проект [Электронный ресурс]. – Режим доступа : <https://movielens.org/>.
22. Hnot T., Gladkikh T. Recommender system comparison: the best performing algorithm [Электронный ресурс]. – Режим доступа : <https://www.softserveinc.com/en-us/tech/blogs/recommender-comparison-algorithm/>

Надійшла: 24.09.2017; рецензент: д. е. н., проф. Скрипник А.В.