

обладнання та системи в цілому. Саме завдяки стандартам запропонована автором система управління енергоспоживанням обчислювальних серверів [6] може бути реалізована, а розуміння режимів роботи пристроїв та переходів між станами їх роботи дозволяє системним адміністраторам енергоефективно використовувати наявні обчислювальні ресурси серверного обладнання.

Список використаних джерел:

- 1 BatteryMAX (idle detection) [Електронний ресурс] / BatteryMax (idle detection) – Wikipedia – Режим доступу: [https://en.wikipedia.org/wiki/BatteryMax_\(idle_detection\)](https://en.wikipedia.org/wiki/BatteryMax_(idle_detection)) – 2017.
- 2 Advanced Power Management [Електронний ресурс] / Advanced Power Management – Wikipedia – Режим доступу: https://en.wikipedia.org/wiki/Advanced_Power_Management – 2017.
- 3 Advanced Configuration and Power Interface [Електронний ресурс] / Advanced Configuration and Power Interface – Wikipedia – Режим доступу: https://en.wikipedia.org/wiki/Advanced_Configuration_and_Power_Interface.
- 4 Serial ATA AHCI: Specification, Rev. 1.3.1 [Електронний ресурс] / Serial ATA AHCI: Specification, Rev. 1.3.1 – Режим доступу: <http://www.intel.com/content/www/us/en/io/serial-ata/serial-ata-ahci-spec-rev1-3-1.html> – 2017.
- 5 Active State Power Management [Електронний ресурс] / Active State Power Management – Wikipedia – Режим доступу: https://en.wikipedia.org/wiki/Active_State_Power_Management – 2017.
- 6 Шевченко С. О. Розробка розподіленої системи управління енергоспоживання обчислювальних серверів [Текст] / С. О. Шевченко // «Інноваційний розвиток науки нового тисячоліття» (м. Ужгород, 21-22 квітня 2017 р.). – Херсон : Видавничий дім «Гельветика», 2017.

Шуть В.А.

студент,

Національний технічний університет України

«Київський політехнічний інститут імені Ігоря Сікорського»

ГІБРИДНИЙ МЕТОД ДЛЯ РЕКОМЕНДАЦІЙНИХ СИСТЕМ ДЛЯ ВИРІШЕННЯ ПРОБЛЕМИ «ХОЛОДНОГО СТАРТУ»

У статті пропонується метод, який базується на поєднанні особистісних характеристик користувача і поставлених користувачем оцінок при обчисленні подібності користувачів. Його створено для рекомендаційних систем, щоб вони могли давати ефективні рекомендації новим користувачам, які взагалі ще нічого не оцінили або оцінили малу кількість продуктів. Буде проведено порівняльний аналіз запропонованого гібридного методу, традиційного методу, заснованого на оцінках користувача, і методу, заснованого на даних користувача. Результати проведених досліджень показують, що новий метод добре вирішує проблему холодного старту. Колаборативна фільтрація широко використовується для побудови рекомендаційних систем. Наприклад, активному користувачеві подобаються продукти А та Б, цей підхід потім порівнює вподобання активного користувача з іншими користувачами і за отриманими результатами знаходить подібних користувачів.

Процес знаходження сусідства – це фактично процес навчання для алгоритму рекомендаційних систем. Існує велика кількість різноманітних підходів для обчислення подібності $simr(u,v)$ між користувачами u та v [1-3]. Літера r означає, що схожість обчислюється на основі рейтингових даних, що відрізняється від подібності, яка базується на персональних – її обчислення буде запропоновано далі. Найбільш часто використовуваний метод обчислення подібності – це коефіцієнт кореляції Пірсона [3; 4].

Для того, щоб спрогнозувати значення невідомого рейтингу $\tilde{r}_{u,i}$ системи рекомендацій колаборативної фільтрації для користувача u та продукту i , необхідно здійснити агрегацію рейтингів для продукту системи i від деяких інших (як правило, k найбільш подібних) користувачів. Формально передбачення невідомого рейтингу $\tilde{r}_{u,i}$ може бути обчислене наступним чином:

$$\tilde{r}_{u,i} = \bar{r}_u + k \sum_{v \in \Omega_u} sim(u,v) * (r_{v,i} - \bar{r}_v),$$

де k – нормуючий коефіцієнт;

$\bar{r}_u$ – середній рейтинг користувача u ;

Ω_u – це множина k користувачів, що найбільш подібні до користувача u та які поставили оцінку продукту системи i .

Така функція агрегації враховує той факт, що різні користувачі системи можуть користуватися різними шкалами рейтингу при оцінці продуктів в системі.

Якщо розглядати рекомендаційну систему, в якій в якості оцінки використовується факт покупки продукту, то вище згадана формула набуде наступного вигляду:

$$\tilde{r}_{u,i} = \sum_{v \in \Omega_u} sim(u,v) * r_{v,i}.$$

Як описано вище, традиційні системи колаборативної фільтрації знаходять «сусідів» користувача на основі оцінок, які користувачі ставлять продуктам в системі. Проте, на практиці, матриця продукт-користувач R завжди розріджена. Тобто, кількість вже проставлених користувачами оцінок, як правило, істотно мала в порівнянні з кількістю оцінок, які потенційно ще можуть бути проставленими користувачами системи.

Вкрай важливою є можливість ефективного передбачення рейтингів маючи невелику кількість вже отриманих рейтингів. Якщо конкретний користувач оцінив деякі продукти, які були також оцінені далеко не всіма користувачами системи, то буде достатньо важко знайти достатню кількість сусідів та зробити ефективні рекомендації для конкретного користувача системи. Ця ситуація найчастіше трапляється, коли новий користувач додається в систему і при цьому не має поставлених оцінок для продуктів в системі або має дуже невелику кількість проставлених рейтингів для продуктів в системі. Для вирішення цієї проблеми ми пропонуємо новий метод обчислення міри подібності між користувачами системи, яка заснована на персональних характеристиках користувачів системи та враховує вподобання користувача, якщо вони є.

Будемо розглядати персональні характеристики користувачів як вектор. Для користувача u цей вектор буде мати такий вигляд:

$$p_u = (p_u^1, p_u^2, \dots, p_u^n)^T,$$

де p_u – вектор розмірності n .

Кожний вимір позначає одну персональну характеристику користувача в системі. Наприклад, якщо персональні характеристики користувача вимірюються так як в моделі Big Five Factor [6], яка описує користувача через основних п'ять психологічних рис, тоді p_u являє собою вектор з розмірністю 5 і кожний вимір відповідає одній з п'яти персональних психологічних рис. Також якщо користувач поставив «хорошу» оцінку хоча б одному продукту в системі, то схожих користувачів системи необхідно шукати серед користувачів, які також поставили «хорошу» оцінку хоча б одному спільному товару з активним користувачем. Отже, подібність заснована на персональних даних між двома користувачами u та v може бути обчислена наступним чином:

$$\text{simp}(u, v) = \sum_k 1 - \frac{|p_u^k - p_v^k|}{\max(p^k)}.$$

На виході досліджуваної системи отримується список рекомендацій, що являє собою список з n продуктів, які з найбільшою вірогідністю може купити активний користувач. Для оцінки ефективності створених рекомендацій використаємо чутливість. Чутливість це статистичний показник ефективності бінарної класифікації, вимірює частку позитивних результатів які були правильно ідентифіковані. Тобто в нашому випадку позитивний правильно ідентифікований результат це продукт системи $t_i \in T$, який придбає користувач в майбутньому та який знаходиться в списку рекомендацій. Таким чином чутливість можемо розрахувати за формулою:

$$TRP = \frac{|T|}{n}.$$

В результаті функціонування системи рекомендацій формується список рекомендацій, що складається з n продуктів системи. При порівнянні алгоритмів ми змінювали значення n від 1 до 20 з кроком 1. Результати показані на рисунку 2.




Рис. 2. Порівняння алгоритмів

У цій статті запропоновано враховувати персональні характеристики користувачів разом з їх вподобаннями в рекомендаційній системі для вирішення проблеми «холодного старту». Здійснено експериментальну оцінку якості сформованих рекомендацій на основі розрахунку чутливості для кожного з алгоритмів: алгоритму на основі персональних даних, традиційного алгоритму на основі рейтингів користувачів та запропонованого гібридного методу. Отримані результати показали, що застосування методу, заснованого на персональних даних, та гібридного методу в рекомендаційній системі дають кращі результати ніж традиційний метод, заснований на рейтингових оцінках користувачів. Зокрема алгоритм заснований на персональних даних показав кращі результати при $n \in [0; 8]$, а при $n \in [9; 20]$ кращі результати показав запропонований гібридний алгоритм.

Список використаних джерел:

1. Adomavicius, G. and Tuzhilin, A. 2005. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. IEEE Trans. Knowledge and Data Eng.
2. J. L. Herlocker, J. A. Konstan, A. Borchers, J. Riedl, An algorithmic framework for performing collaborative filtering.
3. G. Salton, M. McGill, Introduction to Modern Information Retrieval.
4. Ahn, H. J. 2008. A new similarity measure for collaborative filtering to alleviate the new user cold-starting problem. Information Sciences.
5. Park, S.-T., Pennock, D. M., Madani, O., Good, N., and DeCoste, D. 2006. Naive filterbots for robust cold-start recommendations, in: Proceedings of KDD 06, ACM, Philadelphia, PA, USA.
6. Gosling, S. D., Rentfrow, P. J., and Swann, Jr. W.B. 2003. A very brief measure of the Big-Five personality domains. Journal of Research in Personality.

Юсина К.М

студентка,

Институт телекоммуникационных систем,

Национальный технический университет Украины

«Киевский политехнический институт имени Игоря Сикорского»

АРХИТЕКТУРА СЕТИ МОБИЛЬНОЙ СВЯЗИ. ЭВОЛЮЦИЯ В СТОРОНУ 5G

Проект партнерства третьего поколения (3GPP) эволюционирующей пакетной системы (EPS) долгосрочного развития (LTE) относится к логической архитектуре, состоящей из сети радиодоступа (RAN), которая называется развитой универсальной наземной сетью радиодоступа (E-UTRAN) в случае LTE и развитое пакетное ядро (EPC) (Рисунок 1). Целью этой логической архитектуры является создание плоской сети на базе IP и предоставление стандартизованного набора сетевых элементов и сетевых интерфейсов. Стандартизованные элементы и интерфейсы позволяют операторам