

Фильтр внимания Калмана для моделирования пользовательского поведения в предсказании CTR

В.А. РУБИН, О.С. РУДЬКО, С.П. ЖОГАЛЬ, Н.А. АЛЁШИН, А.И. КУЛЫБА

Прогнозирование показателя кликов (CTR) является одной из основных задач для поисковых систем электронной коммерции. Поскольку поиск становится все более персонализированным, необходимо улавливать интерес пользователя на основе богатых данных о поведении. Существующие алгоритмы моделирования поведения пользователей разрабатывают различные механизмы привлечения внимания, чтобы подчеркнуть релевантное запросу поведение и подавить нерелевантное. Несмотря на широкое изучение, эти механизмы внимания по-прежнему страдают от двух недостатков. Во-первых, обычные механизмы внимания в основном ограничивают поле внимания только поведением одного пользователя, что не подходит для электронной коммерции, где пользователи часто ищут новые запросы, которые не имеют отношения к каким-либо историческим поведением. Во-вторых, эти механизмы внимания обычно предвзято относятся к часто встречающимся моделям поведения, что неоправданно, поскольку высокая частота не обязательно указывает на большую важность. Для решения этих двух проблем мы предлагаем новый механизм внимания, названный «Фильтр внимания Калмана», который рассматривает взвешенное объединение внимания как максимальную апостериорную оценку (МАО). Включая априорные данные, фильтр внимания Калмана прибегает к глобальной статистике, когда релевантными являются лишь несколько моделей поведения пользователя. Кроме того, для исправления смещения в сторону частого поведения используется механизм ограничения частоты. Офлайн-эксперименты на эталонных и реальных производственных массивах данных объемом 10 миллиардов, а также онлайн-анализ показали, что фильтр внимания Калмана превосходит все сравниваемые современные технологии.

Ключевые слова: электронная коммерция, прогнозирование, фильтр Калмана, поведение пользователей, CTR.

Click-through rate (CTR) prediction is one of the fundamental tasks for e-commerce search engines. As search becomes more personalized, it is necessary to capture the user interest from rich behavior data. Existing user behavior modeling algorithms develop different attention mechanisms to emphasize query-relevant behaviors and suppress irrelevant ones. Despite being extensively studied, these attention mechanisms still suffer from two limitations. Firstly, conventional attention mechanisms generally restrict attention to a single user's behavior, which is inappropriate for e-commerce, where users are often looking for new queries that are not related to any historical behavior. Secondly, these attentions are usually biased towards common patterns of behaviour, which is unreasonable since a high frequency does not necessarily indicate great importance. To tackle the two limitations, we propose a novel attention mechanism termed «Kalman Filtering Attention» (KFAtt), that considers the weighted pooling of attention like a maximum a posteriori (MAP) estimation. By incorporating a priori, KFAtt resorts to global statistics when only a few user behaviour patterns are relevant. Moreover, a frequency limiting mechanism is incorporated to correct the bias towards frequent behavior. Offline experiments on both benchmark and a 10 billion scale real production dataset, together with an Online A/B test, show that KFAtt outperforms all compared state-of-the-arts.

Keywords: e-commerce, forecasting, Kalman filter, user behavior, CTR.

Введение. Прогнозирование CTR является одной из фундаментальных задач для поисковых систем электронной коммерции. В отличие от ранних систем, которые учитывали только ключевые слова запроса, современные поисковые системы стали более персонализированными с целью «понять, что именно пользователь имеет в виду, и дать ему именно то, что он хочет». Следовательно, моделирование поведения пользователей, т. е. извлечение скрытых интересов пользователей из исторического поведения, рассматривается как один из ключевых компонентов в прогнозировании CTR для поисковых систем электронной коммерции.

В настоящее время популярной стратегией моделирования поведения пользователей является оценка скрытого интереса пользователя с помощью взвешенного объединения исторических поведений пользователя. Эти весовые коэффициенты учитывают различные механизмы внимания, чтобы подчеркнуть релевантное для запроса поведение и подавить нерелевантное для запроса. Несмотря на широкое изучение, существующие механизмы внимания для моделирования поведения пользователя по-прежнему страдают от двух ограничений:

– Традиционное внимание в основном предполагает, что интерес пользователя к текущим ключевым словам запроса должен быть покрыт его историческим поведением. Однако это предположение обычно не выполняется в сценариях электронной коммерции, где пользователи часто ищут новые запросы, которые не имеют отношения к каким-либо историческим поведением. В этом случае внимание только к историческому поведению, независимо от того, как распределяются веса объединения, в основном отклоняется от реального интереса пользователя и, таким образом, вводит в заблуждение систему прогнозирования CTR.

– Обычные представления рассматривают все исторические поведения независимо друг от друга, независимо от иерархических отношений между поведением и соответствующими им запросами. Более очевидно, что поведения, относящиеся к одному и тому же запросу, очень однородны, но вносят дублирующий вклад во взвешенное объединение. Это, безусловно, смещает весовые коэффициенты внимания в сторону частых запросов, что неоправданно, поскольку высокая частота не обязательно указывает на большую важность. Учитывая огромный разброс в частоте запросов, этот перекокс становится еще более сильным. Нерелевантный, но частый запрос легко перевесит любой близкий по значению, но нечастый запрос, что в конечном итоге ухудшит качество поиска и в итоге ухудшит прогнозирование CTR.

Для решения первого ограничения предлагается алгоритм Kalman Filtering Attention (KFAtt-base), который расширяет поле внимания за пределы поведения одного пользователя. Этот алгоритм основан на фильтрации Калмана [1], которая широко используется в теории управления для оценки ненаблюдаемых переменных с помощью серии измерений. В частности, исторические модели поведения могут быть смоделированы как измерения скрытого интереса пользователя, каждое из которых имеет различные степени неопределенности.

Формулируется оценка скрытого интереса пользователя и предоставляется простое, но эффективное решение в приближенной форме. По сравнению с обычным вниманием это решение содержит дополнительное глобальное предшествование, которое позволяет несмещенно предсказывать скрытый интерес, даже когда мало исторических поведений являются релевантными.

Для решения второго ограничения предлагается KFAtt-freq, расширение KFAtt-base, которое учитывает однородность поведения при одном и том же запросе. В отличие от KFAtt-base, которая рассматривает каждое поведение как независимое измерение, KFAtt-freq моделирует каждый дедулицированный запрос как датчик, а поведение по этому запросу – как повторяющиеся измерения от этого датчика.

Эта оценка скрытого интереса формируется как MAP и выводится решение в приближенной форме. По сравнению с обычным вниманием, а также KFAtt-base, это решение уменьшает суммарные веса поведений по одному и тому же запросу и, таким образом, исправляет смещение внимания в сторону частых запросов.

Наконец, для онлайн-приложений промышленного масштаба предлагается модуль моделирования поведения на основе KFAtt, который включает в себя множество методов моделирования корреляций поведения и удовлетворяет требованиям к задержкам в режиме онлайн. Этот модуль состоит из двух частей: кодера на основе трансформатора для захвата корреляций и динамики длинных последовательностей поведения и декодера на основе KFAtt для извлечения скрытого интереса пользователей к конкретной цели.

Связанные работы. Прогнозирование CTR, целью которого является предсказание вероятности того, что пользователь нажмет на объявление, является одной из основных задач в индустрии онлайн-рекламы. Первые модели CTR обычно линейные [2], основанные на коллаборативной фильтрации [3] или древовидные [4]. С развитием глубокого обучения большинство последних моделей CTR используют парадигму встраивания и многослойного перцептрона (MLP) [5], [6], [7]. На основе этой парадигмы вводятся полиномиальные сети для взаимодействия признаков [8], [9].

Моделирование поведения пользователей является важнейшим компонентом в прогнозировании CTR, который обычно извлекает обширную и глубокую информацию об интересах пользователей [10], [11], [12]. Ограниченные вычислительными ресурсами ранние работы, в основном, основаны на независимых от цели способах [13], [14], [15], которые являются сверхэффективными или даже могут быть рассчитаны в автономном режиме. Поскольку

они извлекают только общий интерес пользователей, а не интерес к конкретным запросам или предметам, их вклад в прогнозирование CTR в основном ограничен. В последнее время в моделировании поведения пользователей используются различные механизмы привлечения внимания для извлечения интереса, зависящего от цели [16], [17], [18]. Сосредоточившись на поведении, релевантной цели, эти алгоритмы достигли передовых результатов в предсказании CTR. Несмотря на их большой успех, большинство последних алгоритмов моделирования поведения сосредоточены на применении внимания к различным сетевым структурам, например, RNN [19], Memory Network [20] и Transformer [18].

В то же время, лишь немногие из них посвящены рассмотрению ограничений самих механизмов внимания. Для механизмов внимания, моделирования поведения, идея не предполагать цель во входных последовательностях появляется в [21]. В то время как они только изображают неопределенность, делается несмещенная оценка путем включения априорных данных. В [22] смещение в сторону часто встречающихся моделей поведения решается путем включения глобальной обратной частоты слов. В данной статье вместо этого рассматривается дисперсия частот в поведении пользователей и предотвращается перегрузка внимания нерелевантными, но частыми поведением.

Метод. Сначала будет рассмотрена история моделирования поведения пользователей в контексте прогнозирования CTR. Затем будет представлен KFAAtt: механизм внимания, специально разработанный для моделирования поведения. Наконец, будет описано поведение KFAAtt в модуле моделирования поведения в реальной онлайн-системе прогнозирования CTR.

Предварительные данные. Прогнозирование CTR, предсказывающее вероятность того, что пользователь нажмет на элемент, является одной из основных задач поисковых систем в индустрии электронной коммерции. Модель прогнозирования CTR в основном использует пять полей характеристик, т. е. CTR = f(запрос, поведение пользователя, профиль пользователя, профиль элемента, контексты).

Поведение пользователей довольно точно отражает их сиюминутные и развивающиеся интересы, а иногда даже раскрывает их будущие клики. Следовательно, моделирование поведения пользователя рассматривается как ключевой компонент в задаче прогнозирования CTR [23]. Модуль моделирования поведения обычно формулируется как:

$$V_q = User - Behaviour(q, k_{1:T}, v_{1:T}).$$

А именно, цель состоит в том, чтобы предсказать скрытый интерес пользователя V_q по текущему запросу q , учитывая T исторически нажатых элементов $v_{1:T}$ вместе с соответствующими словами запроса $k_{1:T}$. В литературе довольно часто стратегия моделирования поведения заключается в использовании механизма внимания над исторически щелкнутых пользователем элементов, т. е.

$$V_q = \sum_{t=1}^T a_t v_t,$$

где $a_t > 0$ – вес комбинации, полученной из внимания. Интуитивная идея заключается в том, чтобы сосредоточиться на кликах по похожим запросам:

$$a_t = \frac{\exp(q^T k_t)}{\sum_{t=1}^T \exp(q^T k_t)}.$$

Обратим внимание, что термин *запрос* фактически указывает на общую настройку, не ограничиваясь ключевыми словами в сценарии поиска.

Например, в рекомендациях запрос может быть категорией продукта, которую просматривает пользователь. Или проще, $k = v$ представляют собой элемент, по которому кликнули, а q – целевой элемент, что было использовано в DIN [16]. Продвинутое механизмы привлечения внимания для изучения α включают DIN [16], DSIN [19] и другие.

Несмотря на обширные исследования, большинство существующих механизмов внимания, используемых в моделировании поведения пользователей, по-прежнему страдают от двух ограничений:

1. Ограниченное поле внимания только на историческом поведении одного пользователя, которое часто не может охватить текущий интерес.

2. Смещение весов внимания в сторону частого поведения. В результате предсказанный скрытый интерес V_q обычно отклоняется от реального интереса пользователя и в итоге ухудшает работу системы предсказания CTR.

Фильтр внимания Калмана для моделирования пользовательского поведения.

Для решения первого ограничения можно рассмотреть механизм внимания Kalman Filtering Attention (KFAtt), который расширяет поле внимания за пределы исторического поведения одного пользователя.

Этот алгоритм вдохновлен фильтрацией Калмана [1], которая широко используется в теории управления для оценки ненаблюдаемых переменных с помощью серии датчиков. Теперь переформулируем моделирование поведения пользователя в постановке задачи фильтрации Калмана.

Целью является оценка ненаблюдаемой переменной V_q , т. е. интереса пользователя к текущему запросу q . Предполагается, что V_q имеет гауссовское распределение, $V_q \sim N(u_q, \sigma_q^2 I)$. Эта случайность характеризует расхождение интересов множества пользователей по одному и тому же запросу. В частности, u_q представляет собой средний интерес по одному и тому же q для всех пользователей. А σ_q представляет разнообразие интересов всех пользователей, которое является неотъемлемым атрибутом запросов. Например, σ_q для запроса «подарок на новый год» велик, а σ_q для «кроссовки Nike» мал. На практике u_q и σ_q могут быть рассчитаны по q с помощью двухслойных MLP, обученных совместно с моделью CTR.

Можно моделировать каждый клик как измерение скрытого интереса, а соответствующий запрос – как датчик для этого измерения. А именно, фильтрация Калмана измеряет V_q с помощью T несмещенных датчиков $k_{1:T}$ и получает серию измерений $v_{1:T}$, каждое с разной степенью неопределенности. Предполагается, что эти измерения имеют гауссовские распределения, обусловленные измеряемой переменной:

$$v_t | v_q \sim N(v_q, \sigma_t^2 I), t \in \{1, \dots, T\}.$$

Неопределенность σ_q зависит от расстояния между датчиком k_t и измеряемой переменной q , а именно, от расстояния между текущим запросом и историческим запросом.

Теперь можно оценить скрытую переменную v_q , используя максимальный апостериорный критерий (MAP):

$$V_q = \arg \max p(v_q) \prod_{t=1}^T p(v_t | v_q) = \arg \max f(v_q | u_q, \sigma_q^2 I) \prod_{t=1}^T f(v_t | u_q, \sigma_t^2 I),$$

где f представляет собой функцию плотности вероятности. Эта оптимизация имеет простое решение в замкнутой форме:

$$V_q = (q, k_{1:T}, v_{1:T}) = \frac{\frac{1}{\sigma_q^2} u_q + \sum_{t=1}^T \frac{1}{\sigma_t^2} v_t}{\frac{1}{\sigma_q^2} + \sum_{t=1}^T \frac{1}{\sigma_t^2}}.$$

Замечания: помимо исторических кликов $v_{1:T}$, используемых в традиционном внимании, данное решение также включает глобальное предшествование u_q . Для нового запроса с небольшим количеством близких исторических кликов все σ^2 велики. Данное решение автоматически прибегает к глобальному среднему значению u_q , т. е. к тому, что большинство других пользователей кликают по этому запросу. Теперь выделим первое преимущество перед обычными методами привлечения внимания: благодаря включению глобального приоритета поле внимания никогда не ограничивается поведением одного пользователя, но можно сделать несмещенное предсказание скрытого интереса даже при наличии небольшого количества релевантных поведений.

Калмановская фильтрация внимания в реальной онлайн-системе. Ранее рассматривался исключительно механизм внимания. В то же время моделирование поведения в промышленных масштабах на самом деле включает в себя множество методов для точного извлечения пользовательского интереса и удовлетворения требований онлайн-систем к низкой задержке. Теперь можно представить весь модуль моделирования поведения, развернутый в онлайн-системе прогнозирования CTR, который состоит из двух частей: кодера на основе трансформатора [24], который фиксирует корреляции и динамику поведения, и декодера на основе KFAtt для прогнозирования интереса пользователя к конкретному запросу.

Выводы. Был предложен новый механизм внимания, названный фильтр внимания Калмана, который рассматривает взвешенное объединение во внимании как максимальную апостериорную оценку. KFAtt устраняет общие ограничения существующих механизмов внимания, а именно, ограниченное поле внимания в рамках поведения одного пользователя и смещение в сторону частого поведения, что способствует значительному повышению производительности в следующих задачах прогнозирования CTR. Можно заключить, что KFAtt является широко применимым методом, который не ограничивается сценариями поиска. В будущем можно рассмотреть возможность применения KFAtt к большему количеству механизмов внимания (например, самовнимание, совместное внимание) и к большему количеству типов данных (например, последовательность, изображение, граф). Еще одним интересным подходом можно назвать изменение точечной оценки KFAtt на интервальную оценку, что может помочь отобразить надежность предсказания.

Литература

1. Kalman, R. E. A New Approach to Linear Filtering and Prediction Problems / R. E. Kalman // *Journal of Basic Engineering*. – 1960. – 82 (Series D). – P. 35–45.
2. Richardson, M. Predicting clicks: estimating the click-through rate for new ads / M. Richardson, E. Dominowska, R. Ragno // *In Proceedings of the 16th international conference on the World Wide Web*. – 2007. – P. 521–530.
3. Shen, S. Personalized click model through collaborative filtering / S. Shen, B. Hu, W. Chen, Q. Yang // *In Proceedings of the fifth ACM international conference on Web search and data mining*. – 2012. – P. 323–332.
4. He, X. Practical lessons from predicting clicks on ads at Facebook / X. He, J. Pan, O. Jin [et al.] // *In Proceedings of the Eighth International Workshop on Data Mining for Online Advertising*. – 2014. – P. 1–9.
5. Cheng, H-T. Wide & deep learning for recommender systems / H.-T. Cheng, L. Koc, J. Harmsen, T. Shaked [et al.] // *In Proceedings of the 1st workshop on deep learning for recommender systems*. – 2016. – P. 7–10.
6. Chen, J. Deep ctr prediction in display advertising / J. Chen, B. Sun, H. Li, H. Lu, X.-S. Hua // *In Proceedings of the 24th ACM international conference on Multimedia*. – 2016. – P. 811–820.
7. Liu, H. Category-specific CNN for visual-aware ctr prediction at jd.com. / H. Liu, J. Lu, H. Yang, X. Zhao [et al.] // *In Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. – 2020. – P. 2686–2696.
8. Guo, H. Deepfm: a factorization-machine-based neural network for ctr prediction / H. Guo, R. Tang, Y. Ye, Z. Li, X. He // *In Proceedings of the 26th International Joint Conference on Artificial Intelligence*. – 2017 – P. 1725–1731.
9. Zhang, L. Field-aware neural factorization machine for click-through rate prediction / L. Zhang, W. Shen, J. Huang, S. Li, G. Pan // *IEEE Access*, 7. – 2019. – P. 75032–75040.
10. Kim, H. R. Learning implicit user interest hierarchy for context in personalization / H. R. Kim, P. K. Chan // *In Proceedings of the 8th international conference on Intelligent user interfaces*. – 2003. – P. 101–108.
11. Attenberg, J. Modeling and predicting user behavior in sponsored search / J. Attenberg, S. Pandey, T. Suel // *In Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*. – 2009. – P. 1067–1076.
12. Elkahky, A. M. A multi-view deep learning approach for cross-domain user modeling in recommendation systems / A. M. Elkahky, Y. Song, X. He // *In Proceedings of the 24th International Conference on World Wide Web*. – 2015. – P. 278–288.

13. Covington, P. Deep neural networks for youtube recommendations / P. Covington, J. Adams, E. Sargin // In Proceedings of the 10th ACM conference on recommender systems. – 2016. – P. 191–198.
14. Song, Y. Multi-rate deep learning for a temporal recommendation / Y. Song, A. M. Elkahky, X. He // In Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval. – 2016. – P. 909–912.
15. Yu, F. A dynamic recurrent model for next basket recommendation / F. Yu, Q. Liu, S. Wu, L. Wang, T. Tan // In Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval. – 2016. – P. 729–732.
16. Zhou, G. Deep interest network for click-through rate prediction / G. Zhou, X. Zhu, C. Song, Y. Fan [et al.] // In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. – 2018. – P. 1059–1068.
17. Ge, T. Image matters: Visually modeling user behaviors using advanced model server / T. Ge, L. Zhao, G. Zhou, K. Chen [et al.] // In Proceedings of the 27th ACM International Conference on Information and Knowledge Management. – 2018. – P. 2087–2095.
18. Zhou, C. Atrank : An attention-based user behavior modeling framework for a recommendation / C. Zhou, J. Bai, J. Song, X. Liu, Z. Zhao, X. Chen, J. Gao // In Thirty-Second AAAI Conference on Artificial Intelligence. – 2018. – P. 4564–4571.
19. Zhou, G. Deep interest evolution network for click-through rate prediction / G. Zhou, N. Mou, Y. Fan, Q. Pi, W. Bian, C. Zhou, X. Zhu, K. Gai // In Proceedings of the AAAI Conference on Artificial Intelligence. – 2019. – Vol. 33. – P. 5941–5948.
20. Pi, Q. Practice long sequential user behavior modeling for click-through rate prediction / Q. Pi, W. Bian, G. Zhou, X. Zhu, K. Gai // In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. – 2019. – P. 2671–2679.
21. Heo, J. Uncertainty-aware attention for reliable interpretation and prediction / J. Heo, H. B. Lee, S. Kim, J. Lee, K. J. Kim, E. Yang, S. J. Hwang // In Advances in Neural Information Processing Systems. – 2018. – P. 909–918.
22. Zhang, R. Learning to control the specificity in neural response generation / R. Zhang, J. Guo, Y. Fan, Y. Lan, J. Xu, X. Cheng // In Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. – 2018. – Vol. 1. – P. 1108–1117.
23. McMahan, H. B. Ad click prediction: a view from the trenches / H. B. McMahan, G. Holt, D. Sculley, M. Young, D. Ebner, J. Grady [et al.] // In Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining. – 2013. – P. 1222–1230.
24. Vaswani, A. Attention is all you need / A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, I. Polosukhin // In Advances in neural information processing systems. – 2017. – P. 5998–6008.