

AIの「おすすめ」が直前の情報に偏る現象を解明

～ネット通販や動画配信における推薦技術の改良方針として期待～

ポイント

- ・利用者が直前に見た商品などに推薦AIが強く依存する現象を、九つの実社会データで確認。
- ・AI内部で情報を保持する構造に着目し、直前の1件に依存する要因を解明。
- ・履歴に表れた利用者の関心を、より適切に反映する推薦技術の開発に期待。

概要

北海道大学大学院情報科学研究院の長谷山美紀教授、小川貴弘教授、藤後 廉准教授、櫻井慶悟助教、同大学大学院情報科学院修士課程の神崎恵土氏らの研究グループは、推薦AIにおいて、利用者が直前に閲覧・購入した1件の情報が推薦結果に強く影響する現象を、AIの内部構造の分析により明らかにしました。

ネット通販や動画・音楽配信サービスでは、利用者の閲覧・購買履歴を基に商品やコンテンツを推薦しています。しかし、直前の1件に強く依存する「最終アイテム依存」*¹により、それ以前の履歴に含まれる有用な情報が十分に反映されない可能性があります。研究グループは、九つの実社会データを用いて最終アイテム依存を確認し、代表的な推薦モデルの内部構造を分析しました。その結果、処理前の情報を加える「残差接続」*²と、履歴の最後のアイテムに対応する情報を推薦に用いる仕組みが組み合わさることで、直前の情報への強い依存が生じることが明らかになりました。さらに、再学習せずに残差接続の強さを変更し、推薦が直前の情報に依存する度合いを調整することに成功しました。本研究成果は、直前に見た商品やコンテンツだけでなく、これまでの閲覧・購買履歴全体に表れた利用者の関心も適切に反映する推薦技術の設計・改良に役立つと期待されます。

なお、本研究成果は、2026年9月27日（日）～10月2日（金）に米国・ミネアポリスで開催された20th ACM Conference on Recommender Systems(RecSys 2026)にてMain Track (Long Paper)として発表されました。RecSysは推薦システム分野を代表する難関国際会議であり、今年のMain Track (Long Paper)の採択率は18%でした。



直前に見た商品の情報が「おすすめ」に強く影響する「最終アイテム依存」の概念図

【背景】

ネット通販、動画・音楽配信、ニュース配信など、私たちが日常的に利用する多くのサービスでは、利用者の閲覧・購買履歴を時間順に並べ、「次に何を求めるか」を予測する逐次推薦^{*3}という技術が使われています。現在その中心となっているのが、トランスフォーマー^{*4}の因果的自己注意^{*5}を用いたモデルです。これらのモデルは、履歴内の複数のアイテムの情報を組み合わせ、最後のアイテムに対応する情報を数値で表したもの（最終位置の表現）を基に、次に選ばれるアイテムを予測します。

しかし近年、こうしたモデルの予測が、履歴の最終アイテムに過度に偏ることが指摘されていました。実際、代表的な因果的自己注意モデルである SASRec^{*6}では、多くのデータセットにおいて、最終アイテムを固定したままそれ以前の順序を入れ替えても性能の変化は比較的小さい一方、最終アイテムまで入れ替えると性能が大きく低下します。これは、直前の1件より前に閲覧・購入したアイテムの情報が、最終的な予測へ十分に反映されていない可能性を示しています。

自己注意の重みは履歴内の位置に応じて滑らかに変化する傾向がある一方、実際の予測では最終アイテムに突出した依存が観測されました。なぜこのような極端な差が生じるのかは、従来の自己注意の重みだけを見る分析では説明できませんでした。

【研究手法】

① 最終アイテム依存の評価

研究グループはまず、規模も性質も異なる九つの実社会データ（Amazon Beauty／Sports／Toys、Video、Diginetica、Steam、BeerAdvocate、MovieLens-1M、Zvuk）と、五つの代表的な推薦モデル（SASRec、GRU4Rec、BERT4Rec、DuoRec、BSARec）を用いて、最終アイテム依存の度合いを二つの方法で測定しました。一つは履歴の順序を入れ替えたときの性能変化を観察する方法、もう一つは直前に閲覧・購入したアイテムそのものが推薦の1位に現れる割合を測る方法です。

② 内部構造の分析と依存度の制御

次に、このうち SASRec と DuoRec について、自己注意のみを対象とするのではなく、自己注意・残差接続・層正規化^{*7}から構成される Attention ブロック全体を対象に、AI 内部の各位置の情報のうち他の位置から集約された情報が占める割合（混合率^{*8}）を、各情報のベクトル長に基づいて測定しました（図 1 左）。さらに、推薦時に残差接続で加える情報を係数 α （標準設定は 1）で調整する推論時残差スケールリング^{*9}を行い、内部構造と推薦結果の関係を調べました（図 1 右）。この調整は、各層の全位置に適用しました。

【研究成果】

各位置・各層・評価対象の履歴について平均した結果、自己注意の出力のみに着目すると、他の位置から集約された情報が占める割合（混合率）は 72～96% と高く、他のアイテムから多くの情報が集約されていることが確認されました。しかし、残差接続を加えた時点で、混合率は 12～40% へ急激に低下しました。層正規化による変化は比較的小さく、残差接続が、他の位置からの情報の相対的な寄与を低下させる主要な構造要因であることが分かりました。この自己情報を強く保持する「残差支配」^{*10}と、最終位置の表現だけを予測に用いる仕組みの組合せが、最終アイテム依存を構造的に説明します（図 1 左）。

また、推論時に残差の強さを弱めるほど、他の位置の情報が混ざる割合は増加し、最終アイテム依存は低下します。一方、残差を弱めるほど平均的な推薦精度は低下しており、最終アイテム依存の低減と推薦精度の間にはトレードオフが確認されました。さらに詳細に解析した結果、最終位置の表現

では実際に利用者が次に選んだアイテム（正解アイテム）を上位 10 件に含められない一方、一つ前から三つ前までの位置の表現では、同じ正解アイテムが上位 10 件に含まれる事例が確認されました。このような事例は、各データセットで最も多かった一つの先行位置だけでも、通常の推薦で正解した件数の約 24～46%に相当します。残差の強さを弱めることで、こうした最終位置での誤予測の一部を改善できることも示されました。なお、Toys データセットでは、テストデータの正解を参照せず、検証用データのみを用いて調整の強さを選択できることを確認しています。

【今後への期待】

最終アイテムを重視することは推薦精度に寄与する一方、その依存が極端になると、直前の 1 件より前に閲覧・購入したアイテムの有用な情報が、最終的な予測に十分反映されない可能性があります。本研究は、残差接続による自己情報の保持と、最終位置の表現だけを用いる予測方式の組合せが、最終アイテム依存を説明する重要な構造的要因となることを示しています。これは、推薦モデルが履歴中の情報を実際にどのように利用しているかを診断し、実社会で運用される様々な推薦モデルの設計及び改良を検討するための有用な指針となることが期待されます。

【謝辞】

本研究の一部は JSPS 科研費 JP24K02942、JP23K11141 の助成を受けたものです。

論文・学会情報

発表名	Residual Dominance as a Structural Account of Last-Item Reliance in Causal Self-Attention Recommenders（因果的自己注意推薦モデルにおける最終アイテム依存の構造的説明としての残差支配）
著者名	神崎恵土 ¹ 、櫻井慶悟 ² 、藤後 廉 ² 、小川貴弘 ² 、長谷山美紀 ² （ ¹ 北海道大学大学院情報科学院、 ² 北海道大学大学院情報科学研究院）
学会名	20th ACM Conference on Recommender Systems（RecSys 2026・推薦システム分野の主要国際会議）
開催日	2026 年 9 月 27 日（日）～10 月 2 日（金）
雑誌名	Proceedings of the 20th ACM Conference on Recommender Systems（推薦システム分野の国際会議予稿集）
D O I	10.1145/3773078.3831798
プロジェクトページ	https://github.com/keito0329/Residual

お問い合わせ先

北海道大学大学院情報科学研究院 教授 長谷山美紀（はせやまみき）

T E L 011-706-6078 F A X 011-706-6078

メール mhaseyama@lmd.ist.hokudai.ac.jp

U R L <https://www-lmd.ist.hokudai.ac.jp/member/miki-haseyama/>

配信元

北海道大学社会共創部広報課（〒060-0808 札幌市北区北 8 条西 5 丁目）

T E L 011-706-2610 F A X 011-706-2092 メール jp-press@general.hokudai.ac.jp

【参考図】




図 1. 最終アイテム依存の構造的解釈（左）と、残差接続の強さを変更する制御方法（右）。

【用語解説】

- * 1 最終アイテム依存… 推薦 AI が、利用者の履歴のうち直前に閲覧・購入した 1 件（最終アイテム）に極端に依存して次の推薦を決定する傾向（英語名：last-item reliance）。
- * 2 残差接続… 自己注意などの処理を通した結果に、その処理に入る前の情報をそのまま足し合わせる仕組み。深い AI を安定して学習させるために広く用いられる（英語名：residual connection）。
- * 3 逐次推薦… 利用者の閲覧・購買の履歴を時間順に並べ、次に利用する商品やコンテンツを予測する技術（英語名：sequential recommendation）。
- * 4 トランスフォーマー… 文章や行動履歴のような並びのデータを扱う AI の基本構造。現在の生成 AI や推薦 AI の多くがこの構造を用いる（英語名：Transformer）。
- * 5 因果的自己注意… 並びの中のどの要素を重視するかを重み付けし、関連の強い情報を組み合わせる「自己注意（Self-Attention）」の仕組み。因果的自己注意では、各位置から、その位置とそれ以前の情報のみを参照する（英語名：causal self-attention）。
- * 6 SASRec… 自己注意を用いた代表的な逐次推薦モデル。多くの研究で標準的な比較対象として使われている（self-attentive sequential recommendation の略）。
- * 7 層正規化… 数値の大きさのばらつきをそろえ、学習を安定させるための処理（英語名：layer normalization）。
- * 8 混合率… AI 内部の各位置の情報のうち、他の位置から得られた情報の割合を、ベクトル長に基づいて評価する指標。値が小さいほどその位置自身の情報が強く残っていることを示す（英語名：mixing ratio）。
- * 9 推論時残差スケールリング… 学習済みのモデルを再学習させずに、推論時だけ残差接続で足し合わせる情報の強さを変える操作。本研究では要因を検証するための手段として用いた（英語名：inference-time residual scaling）。
- * 10 残差支配… 本研究で命名した現象。残差接続によってその位置自身の情報が強く残り、他の位置から集約された情報が相対的に希薄化すること（英語名：residual dominance）。