

順位関係を持つ複数の暗黙的評価を活用する NCR モデルによる推薦モデルの提案

1X19C114-9 松岡龍汰
指導教員 後藤正幸

1. 研究背景・目的

近年、複数の候補から価値のあるものを選び出し、意思決定を支援する推薦システムの構築が盛んに行われている。従来の推薦システムにおける商品推薦においては、ユーザが直接アイテムを評価したデータである明示的評価を用いた評価値予測のモデルが多かった。しかし、最近の EC サイトにおける商品推薦においては、購入履歴などの行動履歴データ（以下、暗黙的評価）を活用したモデルが主流になっている。

暗黙的評価を用いたアイテムのランキングモデルの1つに Neural Collaborative Ranking(以下、NCR)[1]が提案されている。NCRは購買などの暗黙的評価が観測されなかったアイテムの中で、次に暗黙的評価が観測される確率の高いアイテムを推定し順位付けを行う手法である。NCRでは、暗黙的評価が観測されたアイテムの方が観測されなかったアイテムよりも相対的に好ましいと仮定することで、暗黙的評価が観測されなかったアイテムを評価している。一方、現実問題では、EC サイトにおける購買と閲覧のように程度の異なる複数の暗黙的評価が観測される場合が存在するが、NCRはこのような複数の暗黙的評価を考慮できない。

そこで本研究では、複数の暗黙的評価を活用したフレームワークである Ding[2]らの方法を援用し、NCRに上位と下位の複数の暗黙的評価を考慮したモデルを提案する。また、実データを用いて、精度評価を行うことにより、提案手法の有用性を示す。

2. 準備

2.1. 問題設定

本節ではまず、ユーザのアイテムに対する暗黙的評価を用いたランキングを対象問題とする。 U をユーザ集合、 I をアイテム集合とし、ユーザ $u \in U$ の暗黙的評価が観測されたアイテム集合を I_u^+ 、観測されなかったアイテム集合を I_u^- と定義する。ただし、 $I = I_u^+ \cup I_u^-$ 、 $I_u^+ \cap I_u^- = \phi$ を満たす。ユーザ u がアイテム j よりアイテム i を好むことを表す (u, i, j) を示す集合 D_S を式 (1) で定義し、正の嗜好を示す集合と呼ぶ。

$$D_S = \{(u, i, j) | u \in U, i \in I_u^+, j \in I_u^-\} \quad (1)$$

また、式 (1) の D_S を正の嗜好を示す集合と呼ぶ。

また、任意の (u, i, j) を示す集合 D に対して、アイテムへの好みの順序関係を入れ替えた集合 \bar{D} を式 (2) で定義する。

$$\bar{D} = \{(u, j, i) | (u, i, j) \in D\} \quad (2)$$

このように \bar{D} を定めると、ユーザ u がアイテム i よりアイテム j を好むことを表す (u, j, i) を示す集合を \bar{D}_S と表すことができ、これを負の嗜好を示す集合と呼ぶ。

2.2. Neural Collaborative Ranking(NCR)

NCRでは、単純にユーザからの暗黙的評価が観測されたアイテムは、観測されなかったアイテムよりも相対的に好まれると仮定し、ユーザとこれらのアイテムの相対的な嗜好の

差をモデル化する。

ここで、NCRのアーキテクチャを図1に示す。

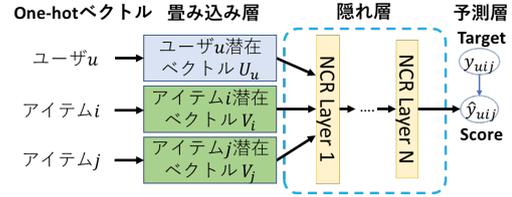


図 1: NCR のアーキテクチャ

式 (1) で定義した D_S から (u, i, j) を入力とし、畳み込み層で低次元の潜在空間へ変換したベクトル U_u, V_i, V_j を獲得する。獲得した各潜在ベクトルを隠れ層に入力することで、潜在空間で各アイテム同士が持つ非線形な特徴を学習できる。最後に、予測層では式 (3) で定義される、ユーザ u がアイテム j よりアイテム i を好む確率 \hat{y}_{uij} を出力する。

$$\hat{y}_{uij} = f_{NN}(U_u, V_i, V_j) \quad (3)$$

ただし、 $f_{NN}(\cdot)$ はニューラルネットワークを表す関数で、予測層にシグモイド関数を通すことで次元の確率値に変換する関数である。ここで、NCRの尤度関数を式 (4) に示す。

$$p(D_S, \bar{D}_S | U, V, \theta_g) = \prod_{(u, i, j) \in D_S} \hat{y}_{uij} \prod_{(u, i, j) \in \bar{D}_S} (1 - \hat{y}_{uij}) \quad (4)$$

ただし、 θ_g は隠れ層でのパラメータベクトル、 U, V はそれぞれ畳み込み層でのユーザとアイテムの潜在特徴行列である。式 (4) が最大になるように各パラメータを最適化することで、式 (3) の学習が行われ、モデルの出力 \hat{y}_{uij} は対応する組 (u, i, j) が D_S に属する予測確率を示す。また、学習の際、 D_S からサンプリングした (u, i, j) の組を正のインスタンス、 \bar{D}_S からサンプリングした (u, i, j) の組を負のインスタンスと呼び、 y_{uij} の正解ラベルは、入力 (u, i, j) が正のインスタンスであるときに 1、負のインスタンスであるときに 0 と定義される。

3. 提案手法

3.1. 着想

EC サイトなどの行動履歴には、あるアイテムに対してレベルの異なる複数の暗黙的評価が観測される場合が多い。例えば、購入を上位の暗黙的評価と定めると、購入の前段階である閲覧という行動は下位の暗黙的評価と考えることができる。しかし、従来の NCR のモデルでは複数の暗黙的評価を想定しておらず、これらを区別して学習することはできない。したがって、従来の NCR のモデルでは複数の暗黙的評価が観測されるような問題設定において、観測されるデータを十分に活用することができない。

そこで本研究では、程度の異なる複数の暗黙的評価を用い

たフレームワークである Ding らの研究を援用し、上位と下位の複数の暗黙的評価を考慮した拡張 NCR モデルを提案する。具体的には、上位の暗黙的評価が観測されたアイテムと暗黙的評価が観測されなかったアイテムのみならず下位の暗黙的評価が観測されたアイテムを追加することで、多様な関係性を考慮可能な学習法を提案する。

3.2. サンプリング方法の定式化

本研究では、NCR のモデルに上位の暗黙的評価のみならず下位の暗黙的評価を加えて学習できるように次のようなサンプリング方法の定式化を行い、式 (3) で与えた予測モデルの学習を行う。まず、 \mathcal{I}_u^+ の中で上位の暗黙的評価が観測された集合を \mathcal{I}_u^{++} 、上位の暗黙的評価は観測されなかったが下位の暗黙的評価は観測された集合を \mathcal{I}_u^{+-} と定義する。ただし、 $\mathcal{I}_u^+ = \mathcal{I}_u^{++} \cup \mathcal{I}_u^{+-}$ 、 $\mathcal{I}_u^{++} \cap \mathcal{I}_u^{+-} = \phi$ を満たすものとする。また、ユーザ u とアイテム i, j の組 (u, i, j) について、 \mathcal{I}_u^{++} 、 \mathcal{I}_u^{+-} 、 \mathcal{I}_u^- を用いて以下の 3 つの集合 $\mathcal{D}_\alpha, \mathcal{D}_\beta, \mathcal{D}_\gamma$ をそれぞれ式 (5)、式 (6)、式 (7) で定義する。

$$\mathcal{D}_\alpha = \{(u, i, j) | u \in \mathcal{U}, i \in \mathcal{I}_u^{++} \wedge j \in \mathcal{I}_u^{+-}\} \quad (5)$$

$$\mathcal{D}_\beta = \{(u, i, j) | u \in \mathcal{U}, i \in \mathcal{I}_u^{++} \wedge j \in \mathcal{I}_u^-\} \quad (6)$$

$$\mathcal{D}_\gamma = \{(u, i, j) | u \in \mathcal{U}, i \in \mathcal{I}_u^{+-} \wedge j \in \mathcal{I}_u^-\} \quad (7)$$

これらの集合を区別することで、上位の暗黙的評価が観測されたアイテムは下位の暗黙的評価が観測されたアイテムや暗黙的評価が観測されなかったアイテムよりも好まれ、下位の暗黙的評価が観測されたアイテムは暗黙的評価が観測されなかったアイテムより好まれるとして、複数の暗黙的評価を加えて定義することが可能になる。ここで、 $\mathcal{D}_\alpha, \mathcal{D}_\beta, \mathcal{D}_\gamma$ と各集合の負の嗜好を示す集合である $\bar{\mathcal{D}}_\alpha, \bar{\mathcal{D}}_\beta, \bar{\mathcal{D}}_\gamma$ を用いたとき、尤度関数は式 (8) で表される。

$$\begin{aligned} & p(\mathcal{D}_\alpha, \bar{\mathcal{D}}_\alpha, \mathcal{D}_\beta, \bar{\mathcal{D}}_\beta, \mathcal{D}_\gamma, \bar{\mathcal{D}}_\gamma | U, V, \Theta_g) \\ &= \prod_{(u, i, j) \in \mathcal{D}_\alpha} \hat{y}_{uij} \prod_{(u, i, j) \in \bar{\mathcal{D}}_\alpha} (1 - \hat{y}_{uij}) \prod_{(u, i, j) \in \mathcal{D}_\beta} \hat{y}_{uij} \\ & \quad \prod_{(u, i, j) \in \bar{\mathcal{D}}_\beta} (1 - \hat{y}_{uij}) \prod_{(u, i, j) \in \mathcal{D}_\gamma} \hat{y}_{uij} \prod_{(u, i, j) \in \bar{\mathcal{D}}_\gamma} (1 - \hat{y}_{uij}) \end{aligned} \quad (8)$$

式 (8) が最大になるように各パラメータを最適化することで、複数の暗黙的評価を考慮して、より各ユーザの嗜好を反映した表現の獲得が期待できる。また、学習の際には $\mathcal{D}_\alpha, \mathcal{D}_\beta, \mathcal{D}_\gamma$ からそれぞれ正のインスタンス、 $\bar{\mathcal{D}}_\alpha, \bar{\mathcal{D}}_\beta, \bar{\mathcal{D}}_\gamma$ からそれぞれ負のインスタンスをサンプリングし、学習データとして用いる。

4. 実験

本章では、提案手法の推定精度を評価するため、実データを用いて実験を行う。

4.1. 実験条件

本研究では、一般的な推薦システムのデータセットである MovieLens 1M を用いる。MovieLens 1M は 5 段階の明示的評価のデータセットである。この明示的評価を暗黙的評価として用いるために、評価値が 5 のデータを \mathcal{I}_u^{++} 、評価値が 4~1 のデータを \mathcal{I}_u^{+-} 、それ以外の未評価のデータを \mathcal{I}_u^-

と定義した。各ユーザ u に対し、 \mathcal{I}_u^{++} 内の最新のデータをテストデータ、2 番目に新しいものを検証用データとし、それ以外の \mathcal{I}_u^{++} と \mathcal{I}_u^{+-} 、 \mathcal{I}_u^- をも学習データに用いる。また、テストを行う際には、ユーザが評価値 5 をつけたテストデータと \mathcal{I}_u^- から 100 件をランダムにサンプリングした合計 101 件のランキングで評価する。評価指標に Hit Ratio (以下、HR) と Normalized Discounted Cumulative Gain (以下、NDCG) を用いる。どちらもユーザの上位の暗黙的評価が観測される可能性が高いアイテムが上位に順位付けられたかを示す評価指標であり、両指標においても上位 10 件に順位付けられたか否かで評価を行う。各インスタンスは以下のような方法でサンプリングを行う。 \mathcal{D}_α はすべての \mathcal{D}_α から (u, i, j) の組を確率 1/800,000 で正のインスタンスとしてサンプリングした。 $\mathcal{D}_\beta, \mathcal{D}_\gamma$ はすべてのユーザ u からの上位の暗黙的評価が観測されたアイテム集合 \mathcal{I}_u^{++} と下位の暗黙的評価が観測されたアイテム集合 \mathcal{I}_u^{+-} からすべてのアイテム i と \mathcal{I}_u^- からランダムにサンプリングしたアイテム j を 1 組を正のインスタンスとしてサンプリングし、 $\bar{\mathcal{D}}_\beta, \bar{\mathcal{D}}_\gamma$ から同様に、それぞれ 2,3 組を負のインスタンスとしてサンプリングした。

4.2. 実験結果

提案手法と比較手法の実験結果を表 1 に示す。

評価指標	提案手法	NCR
HR	0.819	0.713
NDCG	0.528	0.422

提案手法は、従来手法である NCR よりもどちらの手法においても高い精度を示しており、提案手法は有用な手法であると言える。

4.3. 考察

本研究では、HR よりも、順位によってスコアを正規化した NDCG の方が相対的な増加率が大きくなった。これはユーザの嗜好を反映した表現の獲得ができたことによるものだと考えられる。

5. 結論と今後の課題

本研究では、程度の異なる複数の暗黙的評価を用いた NCR モデルを提案した。提案手法は従来手法と比較して複数の評価指標において有用性を示した。今後の課題として、実際の購入履歴データで精度の比較検証を行うことが考えられる。

参考文献

- [1] Bo Song, Xin Yang, Yi Cao, Congfu Xu, "Neural Collaborative Ranking", *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, 2018
- [2] Jingtao Ding, Guanghui Yu, Xiangnan He, Fuli Feng, Yong Li, "Sampler Design for Bayesian Personalized Ranking by Leveraging View Data", *Published in: IEEE Transactions on Knowledge and Data Engineering*, 2021