

顧客と商品の補助情報を考慮した Attention 機構付き Embedding モデルによる顧客特性分析

1X19C012-6 石井達也
指導教員 後藤正幸

1. 概要

近年 EC サイトの普及に伴い、蓄積された購買履歴データから顧客の特性を分析し、マーケティングに活用することが企業にとって重要な課題になっている。そのため的手法として、顧客と商品の埋め込み表現（高次元の実数値ベクトル）を用いてその特性を表現する方法が注目されており、ニューラルネットワークを用いて埋め込み表現を学習する user2vec[1]はその代表的な手法である。しかし、user2vec では顧客の補助情報（性別、年代など）や商品の補助情報（ジャンル、発売年など）を活用していないことや、顧客と商品の関連付けが明確には行われないことが課題として挙げられる。

上記の問題に対して、より正確に顧客と商品の特性を捉えるためには、顧客と商品の特徴を表す補助情報を考慮し、商品に対する関連性を顧客ごとに評価することが有効であると考えられる。そこで本研究では、顧客と商品固有の埋め込み表現と補助情報の埋め込み表現を同時に学習することによって補助情報を考慮しつつ、Attention 機構 [2] を用いて顧客と商品の関連付けを行う手法を提案する。これにより、購買データに加え、様々な補助情報も考慮して、顧客と商品を関連付けた特性分析が可能となる。最後に、人工データを用いた評価実験により提案手法の有効性を示す。

2. 準備

2.1. user2vec

user2vec は顧客と商品の埋め込み表現を学習するモデルである。user2vec では、顧客が購入した商品を、その前後に購入した商品に基づいて予測する学習タスクを解くことによって、各埋め込み表現を学習する。

2.2. Attention 機構

Attention は入力系列の各要素を、系列内の重要度に応じて動的に重み付けする機構である。系列に対する検索条件 (Query)、系列の索引 (Key)、系列の内容 (Value) を入力とし、Query と Key の内積を用いて各要素の重みを求め、Value の重み付け和を出力する。Query を Q 、Key を K 、Value を V 、入力の次元数を d_{in} としたときの Attention 機構の出力を式 (1) に示す。なお、 $\text{softmax}(\cdot)$ はソフトマックス関数である。各要素の重みを観察することによって、Query に対する各要素の関連度が解釈可能である。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_{in}}}\right)V \quad (1)$$

3. 提案手法

3.1. 着想

提案手法では、user2vec を以下のように拡張する。

1. 顧客と商品の補助情報の活用

user2vec では、顧客と商品固有の埋め込み表現のみを学習し、補助情報を活用していない。

提案手法では、顧客と商品固有の埋め込み表現に加えて、補助情報の埋め込み表現を足し合わせたベクトルを顧客と商品の潜在表現とする。顧客と商品固有の埋め込み表現に着目することにより、補助情報の影響を排除した特性分析が可能である。

2. 顧客と商品の関連付け

user2vec では、学習時に顧客と商品の埋め込み表現を単純に足し合わせるため、顧客と商品の関連付けが明確には行われない。

提案手法では、Attention 機構における顧客と商品の埋め込み表現の内積によって関連性を表現する。これにより、顧客と商品を関連付けた特性分析が可能である。

3.2. 提案モデル

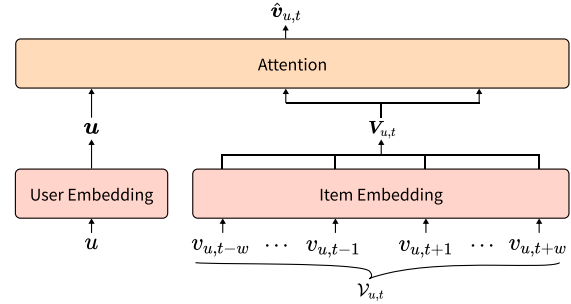


図 1: 提案モデルのモデル構造

顧客を $u \in \mathcal{U}$ 、商品を $v \in \mathcal{V}$ 、顧客の補助情報（性別、年代など）を $p \in \mathcal{P}$ 、商品の補助情報（ジャンル、発売年など）を $q \in \mathcal{Q}$ とする。顧客 u の補助情報 p の値を p_u とし、商品 v の補助情報 q の値を q_v とする。顧客 u の購買商品系列を $H_u = [v_{u,1}, \dots, v_{u,|H_u|}]$ とする ($v_{u,i} \in \mathcal{V}$)。以上のもとで、提案モデルのモデル構造を図 1 に示す。

モデルで用いる埋め込み表現の次元数を d とする。顧客 u 固有の埋め込み表現を $e_u \in \mathbb{R}^d$ 、 p_u の埋め込み表現を $e_{p_u} \in \mathbb{R}^d$ 、 $E_u = \{e_u\} \cup \{e_{p_u} | p \in \mathcal{P}\}$ 、 E_u 内の各埋め込み表現を e_{user} として、顧客 u の潜在表現 $u \in \mathbb{R}^d$ を式 (2) のように与える。

$$u = \frac{e_u + \sum_{p \in \mathcal{P}} e_{p_u}}{|\mathcal{P}| + 1} = \frac{\sum_{e_{user} \in E_u} e_{user}}{|E_u|} \quad (2)$$

同様に、商品 v 固有の埋め込み表現を $e_v \in \mathbb{R}^d$ 、 q_v の埋め込み表現を $e_{q_v} \in \mathbb{R}^d$ 、 $E_v = \{e_v\} \cup \{e_{q_v} | q \in \mathcal{Q}\}$ 、 E_v 内の各埋め込み表現を e_{item} として、商品 v の潜在表現 $v \in \mathbb{R}^d$ を式 (3) で与える。

$$v = \frac{e_v + \sum_{q \in \mathcal{Q}} e_{q_v}}{|\mathcal{Q}| + 1} = \frac{\sum_{e_{item} \in E_v} e_{item}}{|E_v|} \quad (3)$$

提案手法では user2vec と同様に、顧客 u の $t \in \{w + 1, \dots, |H_u| - w\}$ 番目の購入商品 $v_{u,t}$ を、前後 w 個の商品 $\mathcal{V}_{u,t} = \{v_{u,t-w}, \dots, v_{u,t-1}, v_{u,t+1}, \dots, v_{u,t+w}\}$ に基づいて

予測する。顧客の潜在表現 \mathbf{u} 、商品 $v \in \mathcal{V}_{u,t}$ の潜在表現をまとめた行列 $\mathbf{V}_{u,t} = [\mathbf{v}_{u,t-w}, \dots, \mathbf{v}_{u,t-1}, \mathbf{v}_{u,t+1}, \dots, \mathbf{v}_{u,t+w}] \in \mathbb{R}^{2w \times d}$ 、式 (1) の Attention 機構を用いて、 $v_{u,t}$ の予測ベクトル $\hat{v}_{u,t} \in \mathbb{R}^d$ を式 (4) で与える。

$$\hat{v}_{u,t} = \text{Attention}(\mathbf{u}, \mathbf{V}_{u,t}, \mathbf{V}_{u,t}) \quad (4)$$

3.3. 学習方法

提案手法では、 $\hat{v}_{u,t}$ を用いて、正例 $v_{u,t}$ とネガティブサンプリングした負例 $v_{neg} \in \mathcal{V}_{neg}$ の 2 値分類問題を解くことによって損失を求め、これを最小化するように学習する。損失 \mathcal{L} を式 (5) に示す。なお、 $\sigma(\cdot)$ はシグモイド関数、 $BCE(\cdot)$ はバイナリクロスエントロピー関数である。

$$\mathcal{L} = BCE(1, \sigma(\hat{v}_{u,t} \cdot \mathbf{v}_{u,t})) + \frac{1}{|\mathcal{V}_{neg}|} \sum_{v_{neg} \in \mathcal{V}_{neg}} BCE(0, \sigma(\hat{v}_{u,t} \cdot \mathbf{v}_{neg})) \quad (5)$$

得られた損失に対して誤差逆伝播法を適用し、各埋め込み表現を更新する。学習時には、1 バッチごとに各埋め込み表現を各次元の最大値で割ることによって正規化する。

3.4. モデルの分析

提案モデルは、商品 $v \in \mathcal{V}_{u,t}$ の潜在表現をまとめた行列 $\mathbf{V}_{u,t}$ を Attention 機構により重み付けし、 $\hat{v}_{u,t}$ を出力する。その際、商品 v の重みは \mathbf{u} との内積 $\mathbf{u} \cdot \mathbf{v}$ によって求める。内積 $\mathbf{u} \cdot \mathbf{v}$ は式 (6) のように展開されるため、顧客と商品の埋め込み表現の各組 $(\mathbf{e}_{user}, \mathbf{e}_{item})$ について $\mathbf{e}_{user} \cdot \mathbf{e}_{item}$ が大きければそれらの関連が強くなり、小さければ関連が弱いといった分析が可能となる。

$$\mathbf{u} \cdot \mathbf{v} = \frac{\sum_{\mathbf{e}_{user} \in E_u} \mathbf{e}_{user}}{|E_u|} \cdot \frac{\sum_{\mathbf{e}_{item} \in E_v} \mathbf{e}_{item}}{|E_v|} = \frac{1}{|E_u||E_v|} \sum_{\mathbf{e}_{user} \in E_u, \mathbf{e}_{item} \in E_v} \mathbf{e}_{user} \cdot \mathbf{e}_{item} \quad (6)$$

4. 評価実験

本章では、顧客の購買履歴を想定した人工データに提案手法を適用する。次に、提案手法により得られた埋め込み表現を用いて、あらかじめ設定した顧客と商品の特性が抽出できることを確認することにより、提案手法の有効性を示す。最後に、補助情報の影響を排除した顧客特性分析の例を示す。

4.1. 人工データの概要

人工データには、顧客の補助情報として性別 (男性、女性) と年代 (20, 30, 40, 50, 60)、商品の補助情報としてジャンル (M: 男性向け, E: 男女兼用, F: 女性向け)、発売年 (1960, 1970, 1980, 1990, 2000) を用いる。顧客を性別と年代の各組に対して 1,000 人ずつ生成し、商品をジャンルと発売年の各組に対して 50 個ずつ生成する。

各顧客 u の購買商品系列の人工データ H_u は、 u と関連が強い商品ほど多く購入されるように生成する。本実験では、顧客の性別が男性の場合にはジャンル M、女性の場合にはジャンル F と関連が強くなり、年代が X の顧客は発売年が $(2020 - X)$ の商品と関連が強くと仮定し、 H_u を生成する。

生成した商品系列 H_u から、 $t \in \{w + 1, \dots, |H_u| - w\}$ について、 $\mathcal{V}_{u,t} = \{v_{u,t-w}, \dots, v_{u,t-1}, v_{u,t+1}, \dots, v_{u,t+w}\}$ の各要素を入力、 $v_{u,t}$ を正例として学習データを作成する。

4.2. 実験設定

モデルのパラメータは、各埋め込み表現の次元数 $d = 128$ 、ウィンドウサイズ $w = 5$ 、ネガティブサンプリングのサイズ $|\mathcal{V}_{neg}| = 5$ とする。埋め込み表現の初期値は平均 0、標準偏差 0.2 の正規分布に従って生成する。学習時には、バッチサイズを 64、エポック数を 3 に設定し、学習率を 1.0×10^{-3} に設定した Adam を用いる。

4.3. 実験結果と考察

顧客の補助情報と商品の補助情報の内積のヒートマップを図 2 に示す。図 2 において、顧客の補助情報の埋め込み表現は、関連が強い商品の補助情報と内積が大きく、反対に関連が弱いと小さい。この結果から、顧客と商品の補助情報の特性を抽出できていることがわかる。

性別:男性	11.61	-1.12	-8.50	0.03	1.80	0.95	-0.57	1.62
性別:女性	-9.40	3.06	12.36	-0.58	-0.16	0.56	1.41	2.64
年齢:20	-1.22	-1.24	1.82	-2.65	-1.70	-0.87	-2.32	10.70
年齢:30	0.68	0.10	0.68	-2.77	-3.36	-2.76	12.29	-2.90
年齢:40	1.72	0.42	1.17	-0.23	-1.20	15.37	-5.60	-1.72
年齢:50	1.42	1.28	0.66	-4.71	15.14	-4.60	-1.91	-2.47
年齢:60	2.13	4.26	3.74	16.79	-4.17	-1.46	-0.37	-0.63
	ジャンルM	ジャンルE	ジャンルF	発売年:1960	発売年:1970	発売年:1980	発売年:1990	発売年:2000

図 2: 顧客の補助情報と商品の補助情報のヒートマップ

提案手法で得られる顧客固有の埋め込み表現 $\mathbf{e}_u (u \in \mathcal{U})$ には、補助情報の影響を排除した顧客特性が学習されていると考えられる。ここでは事例として、ランダムに抽出した 20 代男性の顧客 3 人の埋め込み表現と商品の補助情報の埋め込み表現の内積のヒートマップを図 3 に示す。図 3 のように、他の 20 代男性に比べて、顧客 A は発売年が 1990 年の商品を好み、顧客 C はジャンル F の商品を好むといった分析が可能となる。

顧客A	0.86	0.17	-0.42	-2.24	0.27	-0.97	1.39	-0.19
顧客B	1.35	-0.38	-1.52	-0.20	-1.20	1.01	-0.38	0.36
顧客C	-0.91	0.69	1.34	0.77	0.15	0.91	0.14	0.15
	ジャンルM	ジャンルE	ジャンルF	発売年:1960	発売年:1970	発売年:1980	発売年:1990	発売年:2000

図 3: 20 代男性と商品の補助情報のヒートマップ

5. まとめと今後の課題

本研究では、顧客と商品の補助情報の埋め込み表現を学習し、Attention 機構によって顧客と商品の特性を関連づける分析モデルを提案した。そして、人工データを用いた評価実験により提案手法の有効性と分析例を示した。今後の課題としては、実データ分析による検証や、コールドスタート問題に対する補助情報の埋め込み表現の活用が挙げられる。

参考文献

- [1] V. Phi, L. Chen, and Y. Hirate, "Distributed representation-based recommender systems in e-commerce," *DEIM Forum*, 2016.
- [2] D. Bahdanau, K. Cho, and Y. Bengio, "Neural machine translation by jointly learning to align and translate," *CoRR*, 2014.