

## マーケットバスケット分析における注意機構を用いた商品推薦手法の提案および実装

上野 裕太郎<sup>†</sup> 篠埜 功<sup>‡</sup>

芝浦工業大学大学院 理工学研究科 電気電子情報工学専攻

### 1 はじめに

近年、実店舗でユーザのかごの中に入っている商品が分かるような技術が用いられている。これまでに、ユーザのかごの中身をもとに次に購入する商品の推薦を行う手法がいくつか考案されている。Leら [1] は Factorization Machine(FM) を応用したモデル Basket-Sensitive Factorization Machine(BFM) を提案し、学習したモデルを用いてユーザ及びかごの中の商品をもとに商品を推薦する。BFM では商品とユーザをベクトルで表し、ユーザと推薦商品、ユーザとかごの中の商品、ユーザと推薦商品、かごの中の商品同士の内積を計算する。従って BFM は商品、ユーザ間の相互作用を考慮した FM モデルである。BFM では内積のみで計算しているため 3 つ以上の商品間の相互作用を考慮していない。しかし、ある特定の商品の組み合わせのときに必ず現れる商品など、かごの中の商品の組み合わせによってかごの中の商品の重要度が変わるはずである。

そこで本研究では、かごの中の商品に対してどの商品が重要かについて学習する注意機構 [2] を Leらのモデルに加え、商品の重要度を考慮した商品のベクトル化の手法を検討する。後者の手法に基づき商品推薦システムを実装し、Leらのモデルとの比較実験を行う。

### 2 マーケットバスケット分析における商品推薦

Web 上の商品推薦においてはユーザの性別、出身国などの個人情報と過去の商品履歴や商品の評価をもとに推薦する商品を選ぶ。しかし、マーケットバスケット分析では一般にユーザの個人情報が扱えないことが多く、購買履歴のみをもとに商品推薦を行う。

### 3 準備

全商品の集合を  $I = \{i_1, \dots, i_m\}$ , それぞれの商品に対応する埋め込みベクトル集合を  $E = \{e_1, \dots, e_m\}$ ,  $e_i \in \mathbb{R}^k$  とする。また、それぞれのユーザに対応する埋め込みベクトル集合を  $U =$

$\{u_1, \dots, u_n\}$ ,  $u_i \in \mathbb{R}^k$  とする。トランザクションデータベースはトランザクションの集合  $D = \{t_1, \dots, t_{|D|}\}$  であり、 $|D|$  は総トランザクション数とする。トランザクション  $t_i$  における推薦商品のベクトルを  $s^{t_i} \in E$  とする。かご  $t_i$  の中に存在している商品を表すベクトルを  $B^{t_i} = (b_1^{t_i}, \dots, b_m^{t_i})$ ,  $b_i^{t_i} \in \{0, 1\}$  とし、 $|B^{t_i}|$  はかご  $B^{t_i}$  の中の商品数を表す。

### 4 提案手法

本研究では、かごの中の商品は推薦対象の商品と異なる重要度を持つと考え、FM に Bahdanau らが提案した注意機構 [2] を用いて異なる重要度を考慮したモデルを構築し学習する。

#### 4.1 注意機構を用いた相互作用

かごの中の商品と推薦すべき商品、かごの中の商品とユーザの相互作用を注意機構を用いて計算する。注意機構を用いることでかごの中の商品を異なる重要度で重み付けし、それぞれの相互作用を計算することができる。1 つのトランザクション  $t_i$  について下記の手順で注意を計算する。まず、推薦すべき商品のベクトルと変換行列  $W^Q \in \mathbb{R}^{k \times d}$  を用いて、query ベクトル  $q^{t_i} \in \mathbb{R}^d$  を計算する。

$$q^{t_i} = s^{t_i} \cdot W^Q$$

次にかごの中の商品ベクトルと変換行列  $W^K \in \mathbb{R}^{k \times d}$  と変換行列  $W^V \in \mathbb{R}^{k \times d}$  を用いて、key ベクトル  $k_i \in \mathbb{R}^d$ , value ベクトル  $v_i \in \mathbb{R}^d$  を計算する。

$$k_i^{t_i} = b_i^{t_i} e_i^{t_i} \cdot W^K, \quad v_i^{t_i} = b_i^{t_i} e_i^{t_i} \cdot W^V$$

計算した key ベクトル, value ベクトルを並べて key 行列  $K^{t_i} = (k_1^{t_i}, \dots, k_{|B^{t_i}|}^{t_i}) \in \mathbb{R}^{d \times |B^{t_i}|}$ , value 行列  $V^{t_i} = (v_1^{t_i}, \dots, v_{|B^{t_i}|}^{t_i}) \in \mathbb{R}^{d \times |B^{t_i}|}$  を作る。query ベクトル  $q^{t_i}$ , key 行列  $K^{t_i}$ , value 行列  $V^{t_i}$  を用いて以下の式に従って注意を計算する。

$$\text{Attn}(q^{t_i}, K^{t_i}, V^{t_i}) = \text{softmax}(q^{t_i} K^{t_i}) V^{t_i T}$$

softmax 関数はベクトル  $x \in \mathbb{R}^n$  が与えられたときベクトル  $x$  の  $i$  番目の要素を以下の式 (1) に従って正規化する関数である。

$$\text{softmax}(x) = \frac{\exp(x_i)}{\sum_{k=1}^n \exp(x_k)} \quad (1)$$

Factorization Machine with Attention Mechanism for Next Basket Recommendation

<sup>†</sup> Yutaro Ueno, Shibaura Institute of Technology

<sup>‡</sup> Isao Sasano, Shibaura Institute of Technology

1つの注意をヘッドと呼び、それぞれのヘッドに対して query ベクトル, key ベクトル, value ベクトルに変換する行列  $W_k^Q, W_k^K, W_k^V$  を用意し、複数の注意を計算する。得られた複数のヘッドを連結し、1つのベクトルにする。1つにしたベクトルを  $d$  次元のベクトルにする変換行列  $W^O \in \mathbb{R}^{rh \times d}$  を掛け、ベクトル  $a^{t_i}$  を得る。

$$\begin{aligned} & \text{MulHead}(q^{t_i}, K^{t_i}, V^{t_i}) \\ &= \text{cat}(\text{head}_1, \dots, \text{head}_r)W^O \\ & \text{where } \text{head}_k = \text{Attn}(q_k^{t_i}, K_k^{t_i}, V_k^{t_i}) \end{aligned}$$

商品に対応する埋め込みベクトルの次元  $k$ , query ベクトル, key ベクトル, value ベクトルの次元  $d$ , ヘッドの数  $r$  はハイパーパラメータである。

#### 4.2 目的関数と学習

最小化する目的関数は1つのトランザクション  $t_i$  について式 (2) で表される。

$$\begin{aligned} y(t_i) = & w_0 + w_u + w_s + \sum_{i=1}^m b_i^{t_i} w_i + e_i^{t_i} u^{t_i} \\ & + e_t^{t_i} a^{t_i} + u^{t_i} a^{t_i} + \sum_{i=1}^{|B^{t_i}|} \sum_{j=i+1}^{|B^{t_i}|} e_i^{t_i} e_j^{t_i} \quad (2) \end{aligned}$$

第1項から第4項はそれぞれすべての項目、ユーザ、推薦商品、かごの中の商品のバイアスを表している。第5項は推薦商品とユーザの相互作用。第6項、第7項はそれぞれ推薦商品とかごの中の商品、ユーザとかごの中の商品の注意機構を加えた相互作用を表している。第8項はかごの中の商品同士の相互作用である。

式 (2) を最適化手法の確率的勾配降下法を利用し、それぞれの学習パラメータを最適化する。

### 5 実験と評価

提案手法に基づき、商品推薦行うモデルを Python 3.6.9, PyTorch 1.3.0 を用いて実装した。モデルはユーザ ID と商品履歴を受け取り、スコア順に並び替えた推薦リストを作成する。提案手法の有効性を示すために実装したモデルを用いて BFM モデル [1] との比較実験を行った。

#### 5.1 実験データ

実験には 2000 年 11 月から 2001 年 2 月に中国のスーパーマーケットで収集された TaFeng データセットを利用した。データセットは学習用, テスト用, 検証用を 3:1:1 の割合で分割した。データの前処理としてトランザクション数が 2 以下のユーザの削除, 総トランザクション数の 5% 以上に出現している商品の削除, かごの中の商品と推薦商品で最低 3 つの商品が必要な商品が 2

つ以下のトランザクションの削除を行った。また、ユーザの購入履歴に出現している商品をそのユーザに対して正の商品, 1 度も出現していない商品を負の商品とし学習データを作成した。データの前処理を施した TaFeng のデータセットは 61,991 トランザクションの購買履歴, 22,326 個の商品, 10,599 のユーザからなるデータセットである。1 トランザクションに含まれる平均の商品数は約 8 個である。

#### 5.2 評価指標

実験の評価として上位の商品を指数関数的に評価する Half-Life Utility (HLU), 推薦されるべき商品が上位 10 位以上である割合を表す R@10 を評価指標として採用した。HLU は以下の式で表される。

$$\text{HLU} = \frac{100}{|T_{test}|} \times \sum_{t_i \in T_{test}} 2^{\frac{1-r_t}{\alpha}}$$

$r_t$  はトランザクション  $t_i$  における推薦されるべき商品の予測順位を表す。HLU のパラメータは [1] の実験設定をもとに  $\alpha = 5$  とした。

#### 5.3 実験結果

5.2 節の評価手法用いて BFM [1] との比較をした。実験結果を表 1 に示す。評価指標 HLU において、提案手法が BFM よりも高い精度であることが分かる。

表 1 BFM と提案手法の比較実験

	HLU	R@10
提案手法	1.4802	0.0232
BFM	1.4787	0.0232

### 6 まとめと今後の課題

注意機構を用いてかごの中の商品に対して異なる重み付けをし、異なる重要度を考慮したモデルを提案し、先行研究のモデルよりも評価指標 HLU において 0.1% 向上したことを確認した。

今後の課題として頻出パターンマイニング手法との比較や商品推薦の多様性を考慮したモデルの検討が考えられる。

#### 参考文献

- [1] Le et al. Basket-Sensitive Personalized Item Recommendation. *IJCAI 2017*. pp. 2060–2066.
- [2] Bahdanau et al. Neural Machine Translation by Jointly Learning to Align and Translate. *ICLR 2015*.