

# 購買の時間的前後関係を用いた類似度学習による代理ラベル抽出

米川慧, 牛コウ, 黒川茂莉, 小林亜令

KDDI 総合研究所

## 1 はじめに

スマートフォンやIoT(Internet of Things)デバイス等の普及により、オンライン・オフラインにおけるユーザの行動データは広く収集されるようになり、オンラインストアや実店舗・販売機では商品の購買履歴データが収集されている。企業のマーケティング活動においては、これら購買履歴データを用いて機械学習の手法に基づく購買予測が行われ、広告ターゲティングや商品推薦に活用されている。購買予測の方法としては、一般的な分類器の他、推薦システムにおける協調フィルタリングやコンテンツフィルタリングが用いられる。

事業環境の変化の加速に伴い、入れ替わりの激しい商材が増えている。購買履歴の存在しない新規商品の購買予測を行うことを考えた場合、分類器や協調フィルタリングは学習に際して教師情報として購買有無のラベルが必要となるため対応できない。コンテンツフィルタリングでは商品の内容を特徴ベクトルで表現し、既存商品と新規商品の類似度を測ることで新規商品の推薦が可能となるが、商品によっては一度購買した商品に類似した商品は当面の間は購買されないなどの時間的な関係が考えられるため、内容の類似度のみに基づく方法は必ずしも有効でない。本論文では、新規商品の購買予測を分類器に学習させる際に必要となる購買有無ラベルを擬似的に作成するため、購買の時間的前後関係を考慮した類似度学習により、購買行動の観点から類似度の高い既存商品を抽出する手法を提案し、その有効性を示す。

## 2 関連研究

購買予測は、推薦システムと捉えることができる。推薦システムのアプローチは協調フィルタリングとコンテンツフィルタリングに大別される。協調フィルタリングは対象ユーザと購買履歴が類似したユーザを手掛かりに既存商品の推薦をするが、新規商品には適用できない。一方、コンテンツフィルタリングは対象ユーザの購買済み商品と内容の類似した商品を特定して推薦するため新規商品にも適用できる。内容の類似度を測った例として、商品の説明文を Doc2Vec(Paragraph Vector)によりベクトル化し、ユーザが高評価した商品のベクトル群と推薦候補商品のベクトルとの間で類似度を算出した研究があるが[1]、類似度算出において商品内容のみを考慮しており、ユーザの評価行動の関連は考慮していない。

類似度学習は、事例ペアに定義される指標関数を学習する。教師情報として、指標値自体を用いる場合、事例ペアの正負関係を用いる場合、事例トリプレット(3つ組)中の事例ペア間の順序関係を用いる場合がある。類似度学習をコンテンツフィルタリングに用いた例として、楽曲の音響特徴ベクトルを入力として楽曲間の鑑賞ユーザ

### Similarity Learning Based on Chronological Order of Purchases for Surrogate Label Extraction

Kei Yonekawa, Hao Niu, Mori Kurokawa, Arei Kobayashi  
KDDI Research, Inc., Chiyoda-ku, Tokyo, Japan  
ke-yonekawa@kddi-research.jp

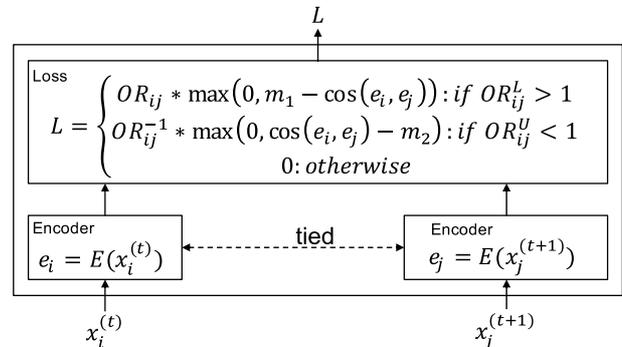


図1: 提案手法の概念図

群の共通度を類似度学習した研究があり[2]、ユーザの鑑賞行動の関連を考慮しているが、行動の時間的な前後関係は考慮していない。

## 3 提案手法

提案手法では、異なる期間の商品間の購買行動の関連を教師情報とした類似度学習により、未来の期間における新規商品の購買有無ラベルを代理するに値する既存商品を抽出する。図1に概念図を示す。

まず、教師情報として期間を横断した商品購買のオッズ比を求める。購買履歴を期間 $t$ と期間 $t+1$ に分け、期間 $t$ に購買された商品集合 $I$ と期間 $t+1$ に購買された商品集合 $J$ を特定する。購買履歴を用いて、商品ペア $(i, j)$  ( $i \in I, j \in J$ )毎に、商品 $i$ の購買ユーザ群における商品 $j$ の購買確率 $p$ と、商品 $i$ の非購買ユーザ群における商品 $j$ の購買確率 $q$ とを求め、オッズ比 $OR = p(1-q)/q(1-p)$ を求める。同時に、フィッシャーの正確確率検定により、オッズ比の有意水準 95%の信頼区間の上限値 $OR_{ij}^U$ と下限値 $OR_{ij}^L$ を求める。次に、類似度学習のモデルを構成する。商品ペア $(i, j)$ の特徴ベクトル $(x_i^{(t)}, x_j^{(t+1)})$ を符号化器 $E: \mathbb{R}^{d_x} \rightarrow \mathbb{R}^{d_e}$ にそれぞれ与えて得られる特徴表現 $(e_i, e_j)$ に対し下記のように損失関数を定義する。

$$L = \begin{cases} OR_{ij} * \max(0, m_1 - \cos(e_i, e_j)) & \text{if } OR_{ij}^L > 1 \\ OR_{ij}^{-1} * \max(0, \cos(e_i, e_j) - m_2) & \text{if } OR_{ij}^U < 1 \\ 0 & \text{otherwise} \end{cases}$$

これは[3]の対比損失において、マージン調整を容易とするため、指標関数にコサイン関数を採用し、負例のマージン $m_2$ だけでなく正例にもマージン $m_1$ を追加し、また、購買行動の統計的有意性を教師情報として与えるため、オッズ比の下限値が1より大きければ正例としオッズ比で重み付け、上限値が1より小さければ負例としオッズ比の逆数で重み付け、それ以外の場合は損失計算をしない、とした形式である。損失関数をミニバッチ確率的勾配法により符号化器のパラメータに関して最小化し、最適化された符号化器 $E^*$ を用いた特徴表現 $(e_i^*, e_j^*)$ のコサイン類似度を計算することで、異なる期間の商品間の購買行動の関連が加味された商品間の類似度が得られる。

## 4 実験・考察

提案手法の初期的評価としてECサイトにおける商品の閲覧履歴データを用いて実験を行った。タスクはオッズ比のランキング予測問題とした。学習データは $t=2017$ 年12月,  $t+1=2018$ 年1月, 試験データは $t=2018$ 年2月,  $t+1=2018$ 年3月の閲覧履歴とした。対象ユーザは期間ペア毎に $t, t+1$ の両方に1商品以上ずつ閲覧のあるユーザとした。新規商品に対する汎化を確認するため各期間の閲覧履歴からそれ以前の期間に出現した商品を除外した。商品数は4期間の過去から順に6908, 5344, 5196, 4667である。商品ペアの閲覧オッズ比から極端に閲覧人数の少ない商品は除外した。具体的には、低いオッズ比の検出力を弱くではあるが担保するため、商品 $i$ の閲覧ユーザ群の人数を $M$ とし $Mq \geq 2$ を要請した。すなわち、商品 $i$ の非閲覧ユーザ群を $N$ とすると経験的には $M \ll N$ であるため、商品 $j$ の閲覧確率は概ね $q$ であり、群間に傾向がなければ $p = q$ ゆえに商品 $i$ の閲覧ユーザ群における商品 $j$ の閲覧人数を $a$ とすると $a$ としては $Mq$ が期待される。これが2以上となることを要請すれば、期待に反して $a < 2$ の場合には、単に $M$ や $q$ が小さいために観測できないのではなく実際にオッズ比が低い可能性が高いと言える。学習データの正負はオッズ比の上下限界を加味して決定され、正例1,997,696件, 負例255,334件を得た。試験データは正負の判断が必要なく3,384,242件を得た。商品の特徴ベクトルは、商品説明文を用いた埋込み次元数128のDoc2Vecにより学習・推定し全データで標準化した。

符号化器 $E$ には2層の全結合ニューラルネットワークを用い、ユニット数は各層64, 活性化関数は隠れ層でReLU, 出力層で線形とした。損失関数の重み $OR_{ij}$ (正例)が無限の場合はなかったが $OR_{ij}^{-1}$ (負例)が無限の場合は観測中の最大に近い100とした。マージンは $m_1 = 0.5, m_2 = -0.5$ とした。最小化にはAdam(学習率0.001)を用い、バッチサイズは64とし、正負比は1に調整し、事前に学習データの10%を無作為に検証データとし10ステップ毎に検証損失の最小値更新を調べ、10回連続で未更新ならば学習を停止し、検証損失が最小のモデルを採用した。

評価対象は、提案手法の特徴表現(ours), Doc2Vec(d2v), 128次元が独立に一様分布 $U(0,1)$ に従うランダムベクトル(rand)である。評価指標は、各手法のコサイン類似度の降順で予測順位を定め、商品 $j$ 毎に $r$ 位の商品 $i_r$ の関連度 $OR_{i_r, j}$ を上位 $k$ 件まで考慮した $DCCG_j@k = \sum_{r=1}^k OR_{i_r, j} / \log_2(r+1)$ を理想値で正規化した $nDCCG_j@k$ (normalized Discounted Cumulative Gain)を用い、 $k=5, 10, 20, 30$ を調べた。評価は10回行い平均と標準偏差を得た。全 $j \in J$ の平均値を図2に、 $j$ が特定の4商品(Item1, 2, 3, 4=ドーナツ, ワイン, エステチケット, 体温計)の場合の値を図3に、 $j$ が体温計の場合の具体例を表1に示す。

図2の全体評価では $k=10$ のみoursがd2vより有効となった( $t$ 検定: $p = 0.06$ )。学習データ内の交差検証によるハイパーパラメータサーチにおいて $E_{j \in J}[nDCCG_j@10]$ を指標としたことが一因と考えられる。図3の個別評価ではItem4のみoursがd2vより有効となった。Item1~3は嗜好性が強く、Item4は必要性に応じるためだと考えられる。表1の例では、正解には機器1点が含まれるが、d2vには機器が7点と多く、体温計の説明文中の機器に特徴的な単語が影響したと考えられる。提案手法では機器が4点に減り、食品が加わっている点に特徴が見られる。

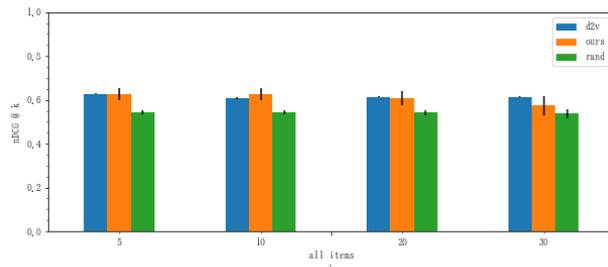


図2: 全商品を対象とした評価結果

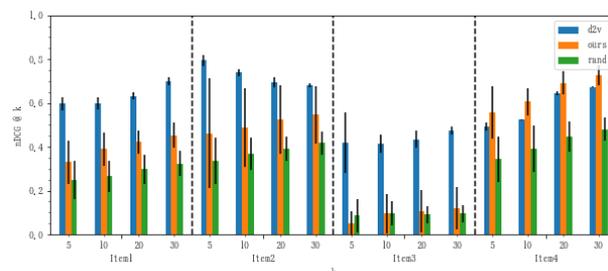


図3: 特定の4商品を対象とした評価結果

表1: 体温計の類似度上位10商品

正解		提案手法		Doc2vec	
オッズ比	商品名	オッズ比	商品名	オッズ比	商品名
7.018	ルームシューズ	3.801	衣類脱臭機	1.754	痩身機器
6.121	傘	7.018	ルームシューズ	4.001	電子メモ帳
5.866	サーカステキケット	3.272	美顔器	4.955	充電パッド
5.297	インスタントコーヒードライエットシューズ	4.001	電子メモ帳	3.95	目覚まし時計
5.158	充電パッド	2.976	チョコレート菓子	2.364	HDD
4.955	カフエチケット	1.652	うなぎ	2.461	カーボンヒーター
4.802	水筒	2.859	インスタント味噌汁	2.547	シューズラック
4.778	バタークリーム	3.95	目覚まし時計	3.003	インナーウェア
4.527	アイライナー	3.634	ナッツ	3.801	衣類脱臭機
4.455		2.489	ツボ押し器	2.489	ツボ押し器

## 5 おわりに

本論文では、新規商品の代理ラベル抽出向けに、商品間の購買行動の時間的前後関係を考慮した類似度学習の手法を提案した。実データを用いた実験では、商品の表面的な内容を超えてユーザ行動の遷移を捉えられる可能性が示唆された。今後は、説明文からのend-to-end学習や、説明文以外の特徴量の活用についても検討していきたい。

## 参考文献

- [1] Boratto, L., Carta, S., Fenu, G., Saia, R.: Representing items as word-embedding vectors and generating recommendations by measuring their linear independence, *RecSys*, vol.1688 (2016).
- [2] McFee, B., Barrington, L., Lanckriet, G.: Learning content similarity for music recommendation, *IEEE Trans. Audio. Speech. Lang. Processing*, vol.20, no.8, pp.2207–2218 (2012).
- [3] Hadsell, R., Chopra, S., LeCun, Y.: Dimensionality reduction by learning an invariant mapping, *CVPR*, pp.1735–1742 (2006).