

深層学習を用いたファッションブランドの推薦システムに 向けて：予備解析

脇田 夕嘉[†] 奥 健太[†] 川越 恭二^{††}

[†] 立命館大学大学院情報理工学研究科 〒525-8577 滋賀県草津市野路東一丁目 1-1

^{††} 立命館大学情報理工学部 〒525-8577 滋賀県草津市野路東一丁目 1-1

E-mail: [†]is0148xe@ed.ritsumei.ac.jp, ^{††}oku@fc.ritsumei.ac.jp, ^{†††}kawagoe@is.ritsumei.ac.jp

あらまし 近年, 衣服 EC サイトの利用者が増加している. EC サイト上で販売されている衣服アイテム数は膨大であり, 自身の好みの服を探すのは容易ではない. この問題の解決方法の 1 つにブランド検索があげられる. 自分の好みのファッションブランドから検索を行うことで, 好みの衣服発見の可能性を高め, 衣服を探索することを容易とする. そこで, 本研究では利用者の嗜好に合ったファッションブランド推薦システムを提案する. 本稿では, ファッションブランド推薦精度向上のために深層学習を用いることの有用性を示すための予備実験を行った結果を記述する. この予備実験から, 深層学習を用いた推薦手法が他の機械学習方法と比べ, 推薦精度が高いことが判明した.

キーワード ファッション, 推薦手法, 深層学習, 機械学習

1. はじめに

近年, インターネットの普及に伴い, EC サイトの利用者が増加している. EC サイトの中でも, 衣服・アクセサリのカテゴリを取り扱う EC サイトでは, 年々購入者が増加しており, その市場が拡大している [1]. しかし, EC サイト上で販売されている衣服の数は, 数十万点オーダと膨大であるため, 好みの衣服を探すには, 膨大な衣服サムネイル画像をひたすら眺めることになってしまう. そこで, 衣服アイテムそのものを推薦する研究が学術的のみならず, 販売する EC サイトや様々な企業が取り組んでいる.

しかし, インターネット上で衣服を購入した場合の失敗理由として, 中村ら [2] の調査では「思ったより安っぽかった」が 49.2%, 「サイズが合わなかった」が 47.4%, 「生地感が予測していたものと違った」が 41.5%となっている. それに対し, 実店舗での衣服アイテム購入例の失敗談としては, 「衝動買いをしてしまった」が 44.9%, 「店頭ではいいなと思ったが, 家で来てみたら似合わなかった」が 34.3%と続く.

この調査から, 利用者は実際に購入した場合に比べて, インターネット上で購入する場合, 衣服アイテムを画像でしか把握できず, 実際のイメージとかけ離れたために, 失敗していることがわかる. また, アイテム推薦で表示されるアイテムは 10 件ほどであり, すぐ見終わってしまう.

これを解決するためにファッションアイテム推薦ではなく, ファッションブランド検索に用いるためのファッションブランド推薦が重要であると考え.

ファッションブランド検索には 2 つの利点がある. 1 つ目は, 利用者がブランドのコンセプトを把握することで, そのブランドアイテムをイメージしやすい点である. ファッションブランドにはコンセプトがあり, ターゲット年齢層・価格帯などの現実的な設定や, 縫製方法や生地やデザインの形などの独自の雰

囲気や世界観が存在する. その独自の方向性やデザインが利用者の好みと一致したブランドを用いて, EC サイト上で検索を行うことで, 利用者の好みの衣服アイテムを発見する可能性を高める. また, ブランド検索を行った後に, 表示された複数のアイテムを閲覧するために利用者はブランドアイテムからブランド特徴イメージを取得する可能性が高い. このブランド特徴を用いることで, 単体のアイテムのイメージを, 補完をすることができる. つまり, そのブランドコンセプトに沿って作られたアイテムは, 利用者にはイメージしやすく, 購入後の失敗を防ぐことにも繋がる.

2 つ目は, インターネット上でファッションブランド検索を行った場合に, 適度にアイテム量を削減できる点である. これは, ブランドによって多少の誤差はあるが, 大抵のブランドがアウター, トップス, など様々なタイプのアイテムを一緒に売っている. 好みのブランドで検索することで, アイテム数を削減し, 利用者の好みでありそうな様々なタイプの服を複数眺めることができ, 利用者の見るアイテム範囲を狭めつつ, アイテムを選ぶ余地を与えることができる.

このことから私たちは, ファッションブランドを推薦するシステムの開発に取り組んでいる.

先行研究として利用者に好みのブランドを推薦する 1 つのアプローチとして, 利用者の好みのブランドを似ているテイストのブランドを推薦する手法を提案した. しかし, この手法は好みのブランドを把握している利用者のみにはしか適用できないという問題点があった. そこで, 私たちは利用者の入力しやすい情報のみを用いて推薦する手法を提案する.

一方, 情報推薦技術において, 推薦する利用者と協調フィルタリングをはじめ, アイテムの内容特徴から似ているアイテムを推薦する内容ベース型推薦手法がある [3]. これらを構築する上で, 機械学習がよく使用されている. そこで, 本研究で使用する機械学習を近年様々な分野において圧倒的な精度向上を達成




図 1 ファッションブランド推薦システムの流れ

し、注目を集めている深層学習を用いる。これはファッションブランド推薦を行う行う本手法にも、適用できると考えられる。例えば、ファッションブランドにはかわいらしさ、雰囲気、価格帯など分類するための要素を、多層に配置されている分別器が利用者の入力しやすい情報という少ない入力要素だけで抽出する可能性があるからである。このことから、深層学習を用いることによって得られる推薦精度は、様々な分野で評価されているとおり従来の手法より高精度になると考えられる。

アイテム推薦では、利用者の購買閲覧履歴などの暗黙的評価を用いて、協調フィルタリング手法や内容ベース手法を適用し、推薦することができる。しかし、ファッションブランドについてはそのファッションブランドのアイテムを購入したからといってそのブランドが好きだと断定できないため、安易に暗黙的評価のみを用いて推薦することができないという問題がある。

そこで本稿では、利用者の嗜好に合せたファッションブランド推薦を深層学習で作成したブランド分類モデルを用いた手法が他の従来機械学習よりも有用であるかを確認するために予備実験を行い、その結果について述べる。ブランド分類モデルは、購買履歴ではなくファッション SNS サイトで取得した利用者のプロフィール項目である利用者の入力しやすい情報を教師あり訓練データとして用いて学習を行い、ファッションブランドモデルを構築する。そして、他の機械学習である、SVM や決定木と分類精度を比較し、検証する。

2. 先行研究

ファッションブランドシステムの構築に向けて、利用者の好みのブランドを推薦する最初のアプローチとして、利用者の好みのブランドと同系統のブランドを推薦することで、利用者の好みであるブランドを推薦できるのではないかと考え、入力されたブランドと同系統のブランドを推薦する手法を提案した [4]。推薦手法として、SNS サイトの情報を用いた好きなブランドリストの相関を利用した手法。ブランドごとに、そのブランド好きな利用者の年齢性別情報を用いた手法。そして、以上の 2 つの手法を組み合わせたシリアル型ハイブリット手法の 3 つの手法を提案し、従来サイトとの精度比較を行なった。比較した結果、シリアル型ハイブリット手法が適合値、F 値において従来サイトよりも高い結果となり、高精度で同系統のブランドを推薦

することを示すことができた。

しかし、これらの手法は、好みのブランドがない利用者には対応しておらず、同系統ブランドのみしか推薦できないという問題点がある。そこで本研究の最終目標として、利用者が入力しやすい情報を用いて、かつ同系統ブランドのみの枠にとらわれない推薦手法の推薦を提案する。

3. ファッションブランド推薦システム

深層学習を用いた、ファッションブランド推薦手法を提案する。推薦の流れを図 1 に示す。

利用者は、入力しやすい情報である「性別」、年齢、「身長」、「利用者のよく着るブランド」を入力してもらう。その入力を、ファッションブランドレコメンデーションモデル手法 (FBRM) を用いて好きなブランドを予測し、利用者の好きなブランドを利用者に提示する。

3.1 訓練データセット

学習させるデータセットとして、日本で有名なコーディネート SNS である「WEAR」[4] のプロフィール項目である以下の 4 点を使用する。これは、図 1 で示した通り、利用者に入力してもらう利用者の入力しやすい項目と同じである。また、以下の仮定からこれらの項目が好きなブランドを推薦するための特徴になりうると考え、モデルの訓練データに用いている。

3.1.1 性別と年齢

ファッションブランドには、レディースブランド・メンズブランドやユニセックスブランドが存在し、商品売るためのターゲット層が存在するため、入力要素として使用する。

3.1.2 身長

服を着こなす上で、重要なことはサイズ感である。また、様々な意見交換サイトなどで、「低身長に似合う服ブランドはありますか?」や「高身長に似合う服ありますか?」など、自分の身体に合わせた、服ブランドを探している人が多いことがわかる。このことから、身長を学習データのパラメータとして使用する。

3.1.3 よく着るブランド

利用者の「よく着るブランド」＝「好きなブランド」と思われるが、必ずしもそうではない。例えば、他の人に自分の服を買ってもらうことや近くのお店などの限定的範囲でしか買わないこと、好きなブランドではないが使い勝手がいいのでよく買

うなどの様々な理由がある。また、服を買う際は持っている服のことも考慮しながら、買うことも多いことから、モデルの学習パラメータに用いる。

また、訓練データセットの正規化を行った。性別は女性・男性なのでそれぞれ1と2を割り当てる。年齢・身長は、表記されているそのままの数値を用いる。よく着るブランドについては様々なブランドが表記されているため、そのブランドを好きか嫌いかの one-not 表現に置き換える。また、好きなブランドに対しては複数提示されている事が多いが、出力目標要素は1次元にするため、好きなブランドごとにそれに対応した他の項目をつけたデータセットを構築し、それを用いることとする。

4. ファッションブランド推薦モデル

本章では、提案システムに用いる深層学習のモデルの構造について述べる。

4.1 モデルネットワークのアーキテクチャ

本手法で、使用するネットワークは、有向閉路がないようなニューラルネットである順伝番型ニューラルネットワークである[6]。フィードフォワードニューラルネットワーク (Feed Forward neural network) とも言う。これは、深層学習においてもっともポピュラーなネットワークである。ニューラルネットワークは、複数のパーセプトロンから構成されている。単体のパーセプトロンは図2のような構造をしている。




図2 パーセプトロンの構造

図2に表された Z がパーセプトロンである。隣接層間のみで結合した構造になっており、情報が入力側から出力側の一方方向にのみ電波する。出力 y は $f(\alpha)$ で出力される。 α は各入力パラメータ x_n ($1 \leq n \leq n$ は実数) とそれに対応した重み w を掛け合わせたものとバイアス b の総和であり、数式 (1)(2) のように表される。

$$\alpha = w_1 x_1 + w_2 x_2 + w_3 x_3 + \cdots + w_n x_n + b \quad (1)$$

$$= \sum_{i=1}^n w_i x_i + b \quad (2)$$

α を引数にすることにより、出力 y は数式 (3) のように表さ

れる。数式 (3) の f は、活性化関数と呼ばれ、様々な関数が提案されている。また、よりよいモデルを作成するためには、いかに最適な重み w を学習するかにある。そのために用いるのが、損失関数である。

$$y = z = f(\alpha) \quad (3)$$

4.1.1 活性化関数

通常は、単調増加する非線形関数が用いられる。古くから最もよく使われるのは、数式 (4) のようなロジスティックモイド関数 (logistic sigmoid function) である。しかし、近年では数式 (5) のような正規化線形関数 (rectified linear function) が使用されている。これは、Yann Lecun [7] らの論文では、この関数を使用した方が他の関数よりも報告がされている。その理由としては、単純で計算量が小さいことや他の関数よりも学習時間が早く、精度が高いからである。

$$f(\alpha) = \tanh(\alpha) = \frac{e^{\alpha} - e^{-\alpha}}{e^{\alpha} + e^{-\alpha}} \quad (4)$$

$$f(\alpha) = \max(0, \alpha) \quad (5)$$

4.1.2 損失関数

学習していく際に、入力とその入力から予測される出力の組を用いて損失関数を定義する。すなわち出力要素によって、最適な損失関数を考えなければならない。例えば、出力値が連続値の場合は最小二乗誤差 (Mean square Error) などが適切である。多クラス分類の場合は、パーセプトロンの活性化関数としてソフトマックス (soft max) 関数使用し、各クラスに属する事後確率として表現する。そして、実際の正解と予測された解の誤差を表す損失関数を交差エントロピーを使用し、算出する。

4.2 推薦モデルの設定項目

図2で示したパーセプトロンは階層的に結合することにより、図3のようなFFNNを作成する。図3に書かれているパラメータの設定をすることで様々なモデルを作成することができる。以下は設定できるパラメータである。

- x : 入力パラメータ
- y : 予測される出力結果
- p : 予測される出力結果
- h : 隠れ層の最大値
- n : 該当層のパーセプトロンの数
- o : 出力されるブランドの最大数
- z : 隠れ層の活性化関数
- g : 出力パーセプトロンの活性化関数
- L : 損失関数

5. 予備実験

今回は、深層学習 (DL) がファッションブランドモデルを作成する際に、他の機械学習よりも有用であるかの検証を行う。比較対象は、SVM とランダムフォレスト (RF) である。3つの手法はそれぞれ特別なチューニングを行っていないデフォルト設定とある程度チューニングしたものそれぞれの推薦精度の比較を行う。




図 3 FFNN

表 1 深層学習の各パラメータ

パラメータ	パラメータの詳細	設定値
x	入力パラメータ	182
y	予測される出力結果	1
p	入力要素の数	182
h	隠れ層の数	2
n	隠れ層のパーセプトロンの数	200
o	出力されるブランドの最大数	10
z	隠れ層の活性化関数	正規化線形関数
g	出力パーセプトロンの活性化関数	ソフトマックス関数
L	損失関数	交差エントロピー

5.1 実験に使用するデータセットと実験方法

今回は、ファッション SNS サイトである「WEAR」から 2015 年 9 月 27 日に取得した 115 人のプロフィール項目を使用する.. データセットを提案手法のように正規化を行った結果、データ総数 627 件であった。また、性別と年齢はそれぞれ 1 次元。よく着るブランドは 179 次元で構成される。好きなブランドはクラスタ数が 10 件である。

本実験では、このデータセットから、leave-one-out 交差検証を行い、推薦精度を比較する。

5.2 深層学習のデフォルト設定

深層学習を用いて推薦モデルの構築を行う。モデル構築には、データ分析や機械学習のフレームワークである「H2O」ライブラリを使用して、モデルを構築する。表 1 は、「H2O」のデフォルト設定を表したものである。

また、デフォルト設定の他にも隠れ層のパーセプトロンの数 n と隠れ層の数 h の数値を変更することにより、モデルのチューニングを行い、その $DL(n, h)$ の推薦精度も検証する。他の機械学習に関しても、SVM は (gamma, cost). RF は RF(ntree, mtry) と適度に値を変えることによって、チューニングを行い推薦精度を比較する。

6. 実験結果

表 2 実験結果

機械学習	チューニング前	チューニング後
DL	47.05%	左に同じ
SVM	7.02%	14.35%(gamma = 0.005, cost = 0.05)
RF	12.44%	17.70%(ntree = 1000, mtry = 5)




図 4 Deep Learning のチューニング結果

実験結果を表 2 と図 4 に示す。表 2 はチューニングをしないデフォルトのままとある程度チューニングを行った SVM とランダムフォレストとの比較を行った。チューニングなしである DL(200,2) の推薦精度が比較対象である SVM (0.005,0.05) に対しては 3 倍、RF(1000,5) に対しては 2.5 倍もの精度差があり、よりよい推薦精度を出すことができた。

また、好きなブランド数は 10 個であったため、このデータセットのチャレンジレベルは 10%であり、その期待値の約 4 倍もの精度を算出することができた。このことから、利用者の入

力しやすい情報のみでの深層学習はファッションブランド推薦モデルを構築する上で適していることが得られた。

次に深層学習のチューニングした推薦精度結果を図4に示す。現段階では、デフォルトであるパーセプトロンの数が $n=200$ 、隠れ層の数が $h=2$ の場合が一番高い精度となった。パーセプトロンの数が違う2つのパターンどちらの場合でも、層の数が多くなるほど推薦精度が下がることがわかる。しかし、今回の検証ではパーセプトロンの数の多さ少なさだけでは、推薦精度が高くなるような特徴は見受けられなかった。したがって、この結果だけでは最適なチューニングができていないとは断定できないため、隠れ層が2つの場合のパーセプトロンの数を変更した検証実験を行わなければならない。

テストデータでは、ブランドが10個であった。このブランド個数で推薦精度が50%という結果は、実用上必ずしも十分ではない。精度が低い理由として、深層学習に用いた内部表現の限界が考えられる。今回使用した内部表現は、SNSデータセットの中から取り出した「性別」「年齢」「身長」「よく着るブランド」情報である。今回の実験から、訓練データセットの入力要素である年齢と身長要素に値が入っているかどうか関係なくよく着るブランドの個数が少ないデータが多いほど推薦精度が下がることがわかった。これは、「年齢」要素に対しては、取得したSNSサイトの利用者の年齢が20代が多いことや、身長に対しても大きな値の変動があったとは考えられにくい。そのため、ファッションブランド判別において、年齢と身長は大きな判別要素とはみなせないが、よく着るブランド情報については有用であると判明した。このことから、今回使用した内部表現だけではより高い推薦精度向上を見込めるとは考えられにくい。

これからはSNSのプロフィール項目ではなく、ファッションブランドのアイテムの階層ニューラルネットワークを作成しそれを今回作成したモデルと組み合わせることによって、より精度の高いファッションブランド判別器を作成することを目指す。

7. 関連研究

深層学習を用いた画像や動画認識以外を除いたアプリケーションのためのいくつかの研究がある。

Huang [8] らは、DSSMと呼ばれる深層学習を用いて、いくつかの新しい潜在的意味モデルを提案した。正しい文書を取得することによって提案モデルの最適なパラメータを得るためにクイックスルーデータを使用した。ポイントは、深層学習を使用するなど、複数の隠れ層を表現層に用いて、非線形モデルへの線形セマンティックモデルを拡張した。彼らのモデルは、文書のランキングのタスクに、大幅なパフォーマンスの向上につながった。しかし、文書コンテキストの抽出であり、情報推薦をターゲットにしていないため、本研究のファッションブランド推薦に適用できるかは明確ではない。

Unger [9] らは、情報の質が異なる情報から収集された情報の質を向上させるために、利用者のコンテキスト情報表現を高次元のセンサを使って、CARS（コンテキストウェア推薦システム）を提案した。彼らは、使用するデータセットに深層学習技術である自己符号化器を使用した。自己符号化器は、目標出力

を伴わない訓練データを使った教師なし学習であり、入力データの特徴を抽出できる。この技術を用いることで、モバイルデバイスセンサによって収集されたデータから潜在コンテキストを抽出し、データの次元数を減らすことを可能とした。今回の私達の研究では、出力目標は決まっており、入力データの次元圧縮や特徴抽出を目標としていないため適用できない。

Hao [10] らは、Collaborative Deep Learning(CDL)と呼ばれる深層学習を用いた新しい協調フィルタリング手法を提案した。CDLの実現のために、SDAE（積層雑音除去自己符号器）ベースのベジアンモデルを使用し、それを拡張したものである。積層自己符号器とは、隣接する2層ごとに区切って自己符号器を構成して学習するものであり、このモデルを、ファッションブランド推薦に適用することができるかどうかは明らかではない。なぜならば、各利用者のいくつかの好きなブランド数は、彼らの使っているデータセットと比べて大きくないが小さくもない。そして、利用者にとって、好きなブランドの評価を、チェックをすることは利用者にとって非常に負担がかかると考えられるため、本手法には適用できないと推測できる。

8. おわりに

利用者が入力しやすい項目である「年齢」「性別」「身長」「よく着るブランド」4項目から深層学習を用いたモデルを作成し、ファッションブランド推薦手法を提案した。予備実験として、深層学習がファッション推薦モデルに適用できているかの検証を行った。実験と検証の結果から、他の機械学習であるSVMやRFよりも大幅に精度向上を示すことができ、深層学習がブランド予測にも適用できることを示すことができた。

今後の課題としては、大規模データセットを用いた場合や分類するファッションブランドの数を増やしてもd同等な推薦精度を算出するかの検証を予定している。また、より高い精度を出すためにファッションブランドのアイテム特徴を使用した深層学習手法を考えている。

謝辞

本研究の一部は文科省私大戦略的研究基盤形成支援事業(2015-19)の助成を受けた。

文献

- [1] 経済産業省商務情報政策局情報経済課:平成25年度我が国経済社会情報化(2014)サービス化に係る基盤整備(電子商取引に関する市場調査)報告書, <http://www.meti.go.jp/press/2014/08/20140826001/20140826001-4.pdf>,(2014)
- [2] 中村 雅章, 矢野健一郎: 消費者の個人属性が服のネットショッピングとリスク削減行動に及ぼす影響の考察, *Chukyo Business Review*, Vol. 10, pp. 133-164. (2014.3)
- [3] 神島 敏弘: 推薦システムのアルゴリズム (1), *人工知能学会誌*, vol.22, no.6, pp.826-837 (2007)
- [4] Yuka Wakita, Kenta Oku, Hung-Hsuan Huang, Kyoji Kawagoe, "A Fashion-Brand Recommender System Using Brand Association Rules and Features", 4th International Congress on Advanced Applied Informatics (AAI), pp.719-720
- [5] 株式会社スタートトゥデイ:WEAR, <http://wear.jp/>(参照 2015-

- [6] 岡谷貴之: 深層学習, 講談社, 2015, pp7-pp54
- [7] Yann Lecun, Yoshua Bengio, Geoffrey Hinton(2015). "Deep learning" Nature 521(7553), pp 436-444.
- [8] Po-Sen Huang, Xiaodong He, Jianfeng Gao, Li Deng, Alex Acero, Larry Heck, "Latent Context-Aware Recommender Systems", ACM International Conference on Information and Knowledge Management (CIKM), 2013
- [9] Moshe Unger, "Latent Context-Aware Recommender Systems", 2015 ACM, pp.383-386
- [10] Hao Wang, Naiyan Wang, Dit-Yan Yeung, Moshe Unger, "Collaborative Deep Learning for Recommender Systems", 2015 ACM KDD'15, pp. 1235-1244, 2015.