

ユーザクラスターリングと CNN を用いた ファッションコーディネート推薦システム

中村喜宏*, 池田雅隆**

Fashion Coordination Recommendation System using User Clustering and CNN

Yoshihiro NAKAMURA and Masataka IKEDA***

Currently, in the fashion field, coordination recommendation schemes have been implemented using collaborative filtering and lifelogging to provide suggestions based on purchase history and items that match items owned by the user. However, even if the purchasing histories are similar, the fashion tastes are not necessarily similar, and there is a possibility that the recommended coordination may be biased. Therefore, we propose a coordination recommendation method that takes individual user preferences into account. In this research, we asked experiment collaborators to evaluate coordinated images, and clustered users based on the evaluation information. The evaluation information for each cluster was treated as preferences and learned by CNN. We experimentally confirmed whether there is a difference in the learning accuracy of the CNN for the evaluation information between the groups clustered by preference and the groups with various preferences mixed together without clustering. The results showed that the prediction accuracy of the clustering method was 83.7%, while that of the non-clustering method was 73.3%, indicating that the clustering method is effective in reflecting individual preferences. The overall configuration of the system, including the operation of the recommendation service, is also outlined.

Keywords: Fashion coordination, Clustering, Recommendation, CNN

1. 序論

近年、人工知能を用いた商品やサービスのレコメンデーションシステムの開発が進んでいる。ファッション分野においては、協調フィルタリングやライフログを用いて、購買履歴に基づいた提案や自身が所有するアイテムに合うアイテムを推薦する衣服のコーディネート推薦方式が提案されている。しか

し、購買履歴が類似していたとしても、必ずしも嗜好が類似しているとは限らず、推薦されるコーディネートに偏りが生じる可能性が考えられる。例えば、他ユーザとの購買履歴の類似度により黒系の衣服の組み合わせが推薦されたとしても、本来は比較的明るい系統の衣服の組み合わせを好んでいる可能性がある。そのため、自身では気付かない良い配色や形状の組み合わせが他のアイテムにも存在する可能性があり、十分な提案ができていないと言えな

*日本大学生産工学部数理情報工学科 教授

**ミズノ株式会社

かった。そこで我々は、個々の嗜好に沿ったコーディネート提案のために、嗜好情報をもとにユーザをクラスタリングし、類似の嗜好を持つクラスターごとにCNNに嗜好情報を学習させる方法を提案する。CNNに学習させることで、従来手法では不可能であったまだ誰も購入や評価を行っていない商品についても、CNNが学習した嗜好をもとに新たな商品の評価値の予測を行える可能性がある。また嗜好の似通ったクラスター毎に個別のCNNに学習させることで、効率的な学習と予測精度の向上が期待できる。

提案方式の有効性を検証するため評価実験を行った。はじめに、ファッションに対する嗜好情報を集めるために、実験協力者に30通りのコーディネートの評価してもらった。さらに評価情報をもとにクラスター分析を実施し、嗜好ごとにユーザのクラスタリングを行った。人の嗜好はそれぞれであり、配色や形状などのファッションにおける基本的なルールベースに合う人ばかりではないため、嗜好ごとにクラスタリングを行い、自身が位置するクラスターの評価情報をもとに衣服を提案することで効率的に自身が好む衣服の組み合わせを見つけることが期待できる。

本研究では、予備実験として「実験協力者の嗜好が属するスタイルを基準としたクラスタリング」、本実験として「服装コーディネートに対する評価情報を基準としたクラスタリング」の2通りの方法で嗜好に対する予測精度を測った。予備実験と本実験では共に、クラスターごとの評価情報をCNNによって学習した。スタイルや嗜好ごとにクラスタリングしたグループとクラスタリングを行わずに様々なスタイル、嗜好を混合させたグループの評価情報の予測精度に差が生じるのかを調査し、クラスターごとに分けて学習する方式の有効性を検証した。さらに、単一品目で色や柄が表現される単純化モデルのスニーカーに対しても嗜好ごとにクラスタリングしたグループとクラスタリングを行わずに様々な嗜好を混合させたグループの評価情報の予測精度に差が生じるのかを調査した。

さらに、ユーザや服装が追加されたときや、ユーザからの評価情報を学習モデルにフィードバックするなどの推薦サービスの運用を含めた全体構成についても考察した。

2. 関連研究

ファッションにおけるコーディネートの推薦システムについて様々な方式が提案されている。

2.1 アイテムベース協調フィルタリング

山田らによって提案された方式¹⁾は、新しい服装発見などを目的とした、他ユーザや店舗情報との協調フィルタリングによる推薦手法である。協調フィルタリングとは、推薦システムを実現する手法の一つであり、ECサイトなどでよく用いられ、興味や関心、利用情報が似た他ユーザからの情報をもとに商品が推薦される手法である。そのため、誰にも所有されていないアイテムの中で、良い配色や形状の衣服の組み合わせが他にも存在する可能性がある。

2.2 ユーザ評価の提示によるファッションへの意識変化

知見らによって提案された方式²⁾は、コーディネートを検索する際に、他者の好みをお気に入り数などの評価値として表示するユーザの意識変化を測る手法である。自身の選択と他者から見た評価の差異を強調することで、好むスタイルの差異を意識させることが期待できる。しかし、他者の評価を把握することは可能だが、自身に似合うスタイルなのか評価するのは困難である。

2.3 服装の印象とセルフイメージを考慮した手法

高宮らによって提案された方式³⁾は、ファッションコーディネートにおける、セルフイメージと憧れるコーディネーションが与える印象のどちらも考慮した、利用者にとって新しいコーディネーションのレコメンドシステムである。コーディネーションの印象とセルフイメージが異なることから、憧れで止まってしまう可能性が考えられるが、潜在的な購買と着用の可能性を推測したコーディネーションのレコメンドが期待される。

2.4 BingoFit

BingoFit⁴⁾は、着用回数の偏りや着用する衣服のワンパターン化を解決するために所有する衣服の活用を促進させるビンゴゲーム型衣服提案システムである。このシステムによって新しいコーディネートの発見や着用回数が少ない衣服を着用するきっかけを生むことができる。しかし、自身の所有するアイ

テムからコーディネートを組み合わせるため、自身に似合う異なるスタイルの衣服の組み合わせが所有しないアイテムの中にも存在する可能性がある。

2.5 ラフ分析による嗜好を考慮した服装提案システム

三露らによって提案された方式⁵⁾は、ユーザの持っている服の情報をデータベース化し、さらに服装の評価と履歴を用いて常識的に違和感のない嗜好を考慮した服装を提案する方式である。服の印象とサイズ感の分布を嗜好情報として扱い、服装履歴からシステムがユーザの嗜好を理解し、それらをフィードバックして提案を行う。しかし、嗜好情報には色や柄、素材等の要因も存在するため、これらも嗜好として分析する必要があると考えられる。

3. 実験準備

3.1 アンケートの実施

ユーザの嗜好や嗜好が属するスタイルを調査するために、19歳から25歳までの男女30名にアンケートの協力をしてもらった。トップスとボトムス、靴の組み合わせによるコーディネート画像を、日本ファッションスタイリスト協会による Styling Map 6) を参考に30枚用意した。Styling Map では、服装のコーディネートが色や形状によって、アクア、ブライト、クリスタル、アースの4つのスタイルに分類されている。また、クリスタルとアーススタイルが比較的似ていることから本研究では、アクア、ブライト、アースの3つのスタイルに絞り、コーディネート画像を用意した。具体的にアクアスタイルとブライトスタイル、アーススタイルの服装のコーディネートを5枚ずつ用意し、3つのスタイルをミックスさせた15枚の画像も用意した。合計30枚のコーディネート画像をアンケートに使用した。アンケートには、コーディネート画像の採点と、実験協力者をスタイルごとに分類するためのファッションにおける質問項目を用意した。作成したコーディネート画像⁷⁾の例を Fig. 1 に示す。



Fig. 1 Coordinated image of each style

3.2 アンケートの概要 (予備実験用)

「実験協力者の嗜好が属するスタイルを基準としたクラスタリング」による予備実験を行うために、ファッションにおける質問項目を用意し、実験協力者を回答結果によってアクア、ブライト、アースのいずれかのスタイルに分類した。

3.3 アンケートの概要 (本実験用)

「服装コーディネートに対する評価情報を基準としたクラスタリング」による本実験を行うために、実験協力者には30枚のコーディネート画像を1点から7点で採点してもらった。点数の評価指標としては1点に近いほど自身が好まない服装とし、7点に近いほど好む服装と設定した。

3.4 画像データの学習

本研究では、ニューラルネットワークの1つであるCNN (Convolutional Neural Network) を用いて画像データの学習と評価を行った。CNNは、位置ずれや拡大縮小に強く、データの配色を構成するRGB要素の特徴も捉えることができ、画像のフィルタ処理においてフィルタの値を学習することで特徴抽出を行うニューラルネットワークである。

4. 予備実験

4.1 嗜好が属するスタイルによるクラスタリング

予備実験では、「個々の嗜好が属するスタイル」によってクラスタリングを行った。スタイルは、アンケートのファッションにおける質問項目を用意し、質問の回答結果によって実験協力者の嗜好が属するスタイルを決定した。その後、スタイルごとに分けたグループの評価情報と様々なスタイルを混合させたグループの評価情報をCNNによって学習し、予測精度に差が生じるのか予備実験を行った。

4.2 スタイルの分類

アンケートによって30枚のコーディネート画像を評価してもらい、日本ファッションスタイリスト協会によるテイストチェック⁸⁾をもとに5つの質問を用意し、実験協力者24名をスタイルごとに分類した。質問は全て3択とした。

5つの質問を以下に示す。

(1) あなたの好きな色はどれですか? (1)~(3)の中から選択してください。(まとまりのある、カラフル、深みのある色合いなどから選択)

(2) あなたの好きな形はどれですか？(1)～(3)の中から選択してください。(異なるシャツ, 靴の形から選択)

(3) あなたの好きなスタイリングイメージはどれですか？(1)～(3)の中から選択してください。(清潔, 元気, ワイルドなどのキーワードから選択)

(4) あなたの好きなアウター/ジャケットはどれですか？(1)～(3)の中から選択してください。(異なるアウターのスタイルから選択)

(5) あなたの性格に近いものはどれですか？(1)～(3)の中から選択してください。(穏やか, ポジティブ, 自分を飾らないなどの性格のキーワードから選択)

以上の質問により, 実験協力者24名を各3つのスタイルに分類した。結果的に, アクアスタイルに12名, ブライトスタイルに10名, アーススタイルに2名が分類された。

4.3 予備実験に用いる学習モデルの作成

評価してもらったコーディネート画像の合計30枚を25枚の訓練データと5枚のテストデータに分類した。予測精度の評価には, より偏りの少ない評価を行うために6分割交差検証を行った。

スタイル分類の結果, アーススタイルが2名で少数であったため, 今回はアクアスタイルとブライトスタイル, 両方のスタイルを混合させた3つのグループによって比較した。アクアスタイルは12名で, 訓練データは12×25枚で300枚, テストデータは12×5枚で60枚。ブライトスタイルは10名で, 訓練データは10×25枚で250枚, テストデータは10×5枚で50枚。また, 比較用で作成したアクア, ブライトの両スタイルの合計22名を混合させた訓練データは, 22×25枚で550枚, テストデータは22×5枚で110枚とする。

CNNの実装には, 開発環境としてPython, TensorFlow-GPU, Kerasを用いた。使用した計算機のスペックは, CPU: Intel Core i7-6700, メモリ: 16GB, GPU: GeForce GTX1070/ 8 GB, OS: Windows10である。1モデルの学習に要した時間は, グループによって差はあるが約7分から13分程度であった。

4.4 予測精度の評価方法

予測精度は, 実験協力者が評価したコーディネート画像の採点結果をCNNでの予測結果と比較して

測った。具体的には, 同じクラスター内の実験協力者でも採点結果に差異があることから, 採点結果において同じ点数をつけた人数が多かった上位3位までの点数を正解とし, 正解を回答した実験協力者の中で, 何人がCNNでの上位3位までの予測結果と一致したかの割合を求め, この値を予測精度とした。つまり正解の点数の再現率で予測精度を測った。再現率を用いた理由は, 正解データの中から予測できた割合を測るためである。

Table 1に実験協力者の3位までの評価結果とCNNで予測した3位までの結果の例を示す。Table 1では, あるテストデータ(コーディネート画像)に対して, アクアスタイルに該当する12名が採点した結果を赤色, 実際にCNNで予測した結果を黒色で示している。例えば, 赤色で示している実験協力者の採点結果では, テストデータに対して12人中6人が5点と評価し, 人数比によって1位となる。また, 12人中3人の3点という評価が2位, 12人中2人の4点という評価が3位となる。以上の結果, 3位までの点数を付けた人数は12人中11人となり, 採点人数が多かった点数を順位ごとに並べた。一方で, 黒色で示しているCNNでの予測結果では, テストデータは5点である可能性が1番高いと予測され, 2番に6点, 3番に4点が予測されている。このCNNの予測は, 評価値1点から7点に対応づけたCNNの出力層の7個の出力のうち, 出力値(0~1)が大きいものから順に上位3位までを予測結果とした。以上の結果より, 赤色で示した実験協力者の評価結果の3位までに入った点数の5点, 3点, 4点のうち, CNNでの予測結果では5点と4点が3位までに入ったことになる。結果的に5点と4点を付けた12人中8人の採点結果を予測できていることが分かる。精度としては, 実際の評価結果の3位までに入っている11人の中で, CNNでの予測結果の3位までに入っていたのは8人であるため8/11で72.7%となる。このように, 全グループの各モデルにおいて実験協力者のテスト

Table 1 Prediction result and Actual result

Prediction result			Actual result		
1st	5	6/12	1st	5	6/12
2nd	6	0/12	2nd	3	3/12
3rd	4	2/12	3rd	4	2/12
total		8/12	total		11/12
(%)		72.7%	(%)		100%

データに対する評価結果を CNN の予測結果と比較して精度を測った。

5. 予備実験の結果・考察

Table 2 にモデルごとの予測精度と平均を、Fig. 2 にスタイルごとの平均の予測精度を示す。各グループの各モデルの予測精度、平均を比較すると、アクアスタイルは3位までの評価情報を平均76.2%で予測できた。ブライトスタイルの平均は63.5%、比較用で作成したアクアスタイルとブライトスタイルを混合させたグループの平均 (all) は75.8%となった。また、各クラスターの人数比を考慮した平均値と比較すると、スタイルごとに分けて学習した結果 (aqua.bright_ave) は70.4%となり、アクアスタイルとブライトスタイルを混合させたグループの予測精度の平均 (all) である75.8%よりも5.4%低い値となった。以上の結果よりスタイルごとの評価情報の予測精度の平均が、スタイルを混合させた評価情報の予測精度の平均を上回るという仮説は立証されなかった。結果的に、実験協力者の嗜好が属するスタイルごとにクラスターを分けて学習する方式には有効性が示されなかった。

スタイルごとの予測精度の平均 (aqua.bright_ave) に比べ、スタイルを混合させた評価情報の予測精度の平均 (all) が高かった理由を以下に考察する。今回の予備実験では、スタイルごとに評価情報を分けて学習したが、同じスタイルに該当している実験協

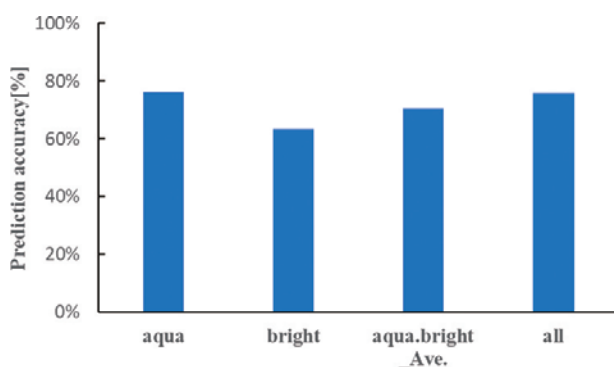


Fig. 2 Average of prediction accuracy by style

Table 2 Prediction accuracy and average of each model

	model ①	model ②	model ③	model ④	model ⑤	model ⑥	Ave.
aqua	69.6%	76.7%	76.0%	81.7%	84.8%	68.3%	76.2%
bright	71.4%	56.6%	52.2%	65.8%	73.3%	61.8%	63.5%
aqua.bright_Ave.	70.4%	67.6%	65.2%	74.5%	79.6%	65.3%	70.4%
all	67.3%	73.7%	82.6%	80.4%	77.9%	73.0%	75.8%

力者同士でも、同じコーディネート画像に対して異なる評価をしている人数の割合が多かった。そのため、同じスタイルの実験協力者同士の評価情報を学習したもので精度が上がらなかったと考えられる。また、実験協力者が評価に用いたコーディネート画像は、アクアスタイルやブライトスタイルなどの各スタイルの特徴を考慮して作成したが、各スタイルの特徴を完全に反映することができず偏りがあった可能性も考えられる。その結果、アクアスタイルやブライトスタイルに分類された実験協力者においても、自身が該当するスタイルのコーディネート画像を高い値や低い値などの様々な異なる採点をしていた実験協力者が多い可能性があった。さらに、比較用で作成したアクアスタイルとブライトスタイルを混合させたグループ (all) の訓練データは、22 × 25 枚で 550 枚、テストデータは 22 × 5 枚で 110 枚であるため、アクアスタイル (訓練データ 300 枚、テストデータ 60 枚) やブライトスタイル (訓練データ 250 枚、テストデータ 50 枚) 単一の訓練データ、テストデータに比べて大幅にコーディネート画像のデータ数が多かった点も予測精度に差が生じた要因だと考えられる。

6. 本実験

6.1 服装コーディネートの評価情報によるクラスターリング

本研究では、個々のコーディネートに対する評価値が異なるため、CNN によって個々の好みの全てを学習することは困難であると仮定した。そこで、推薦する上で好みを反映させるためには嗜好や自身の嗜好が属するスタイルによってクラスターを分けて学習を行う方式に有効性が示されるのではないかと仮説を立てた。しかし、「実験協力者の嗜好が属するスタイルを基準としたクラスターリング」による予備実験では、スタイルごとにクラスターを分けて学習を行う方式に有効性が示されなかった。仮にクラスターごとの予測精度が高ければ、同じクラ

スターの人同士の嗜好を考慮したコーディネート
の提案が期待でき、クラスターを分けることで、数あるコーディネートの中から効率的に自身に合うコーディネート
を推薦できる可能性が考えられる。そこで、「嗜好が属するスタイルを基準としたクラスタリング」ではなく、「服装コーディネートに対する評価情報を基準としたクラスタリング」で構成されたグループとクラスタリングを行わずに様々な嗜好を混合させたグループの評価情報に対する CNN
での予測精度を比較し、クラスターごとに分けて学習する方式の有効性を検証するために本実験を行った。

6.2 クラスタリングの実施

アンケートの 30 枚のコーディネート画像における評価情報をもとにクラスター分析を行い、嗜好ごとに cluster_0 と cluster_1, cluster_2 の 3 つのグループに分類した。クラスター分析とは、互いに似た性質を持つものを集め、グループを形成する手法である。結果的に、cluster_0 と cluster_1 はともに 11 名、cluster_2 は 8 名に分類された。クラスター分析には、k-means 法⁹⁾を用いた。さらに、クラスターの分類方法の基準を明らかにするために主成分分析¹⁰⁾を行った。主成分分析とは、多くの変数を持つデータを集約して主成分を作成する統計的分析手法である。Fig. 3 に第 1 主成分と第 2 主成分に対する個々の実験協力者のプロットを示す。主成分分析の結果、第 1 主成分は実験協力者の 30 枚のコーディネートに対する合計得点が基準となっていた。第 2 主成分は 30 枚の中の特定のコーディネート
の得点が基準となっていた。Fig. 4 に第 30 主成分までの寄与率を示す。

6.3 本実験に用いる学習モデルの作成

用意した合計 30 枚のコーディネート画像の中で 24 枚を訓練データ、6 枚をテストデータとした。予測精度の評価には、より偏りの少ない評価を行うため 5 分割交差検証を行った。

cluster_0 と cluster_1 はともに 11 名で、訓練データは 11 × 24 枚で 264 枚、テストデータは 11 × 6 枚で 66 枚。cluster_2 は 8 名で、訓練データは 8 × 24 枚で 192 枚、テストデータは 8 × 6 枚で 48 枚。また、比較用で作成した cluster_0, 1, 2 の合計 30 名を混合させたグループの訓練データは、30 × 24 枚で 720 枚、テストデータは 30 × 6 枚で 180 枚とする。

CNN の実装には、予備実験と同様の開発環境、




Fig. 3 Plot diagram by cluster analysis




Fig. 4 Contribution ratio

計算機を用いた。本実験の 1 モデルの学習に要した時間は、グループによって差はあるが約 5 分から 17 分程度であった。

7. 本実験の結果・考察

7.1 コーディネートを対象とした場合


本実験として、アンケートの評価情報によるクラスターごとの予測精度とクラスターを混合させたグループの予測精度の差を評価実験によって検証した。予備実験と同様に

予測精度の測り方は、実験協力者の採点結果において採点人数が多い上位 3 位の点数をつけた人数に対して CNN で 3 位までに予測できている人数の割合で精度を測った。

Table 3 にモデルごとの予測精度とその平均を、Fig. 5 にクラスターごとの平均の予測精度を示す。クラスターごとの各モデルの予測精度の平均を比較すると、cluster_0 は平均 86.6% で 3 位までの評価情報を予測できた。cluster_1 の平均は 88.3% となり、cluster_2 の平均は 73.4% となった。比較用の cluster_0 と cluster_1, cluster_2 を混合させたグループの平均 (all) は 73.3% となった。また、各クラス

Table 3 Prediction accuracy and average of each model

	model ①	model ②	model ③	model ④	model ⑤	Ave.
cluster_0	84.0%	83.9%	89.9%	81.5%	93.9%	86.6%
cluster_1	81.3%	96.6%	87.9%	90.9%	84.8%	88.3%
cluster_2	73.0%	74.2%	85.0%	80.8%	54.2%	73.4%
cluster_012_Ave.	80.1%	86.0%	87.9%	84.8%	80.0%	83.7%
all	73.5%	83.2%	76.7%	68.3%	64.7%	73.3%

**Fig. 5** Average of prediction accuracy by cluster (Fashion Coordination)

ターの人数比を考慮した平均と比較すると、クラスターごとに分けて学習した結果 (cluster_012_ave) は 83.7% となり、クラスターを混合させたグループの平均 (all) である 73.3% よりも 10.4% 高い値となった。クラスターごとに分けた予測精度とクラスターを混合させたグループの予測精度に有意差があるか有意水準 5% で片側 t 検定を行った。結果、 $t(4) = 4.03$, $p = 0.00 < 0.05$ で有意差が認められた。

クラスターを混合させた評価情報の予測精度の平均 (all) に比べ、クラスターごとの評価情報の予測精度の平均 (cluster_012_ave) が高かった理由を以下に考察する。本実験では、クラスター分析によってグループの分類を行ったことで、予備実験の「嗜好が属するスタイルを基準としたクラスタリング」によるグループの分類と比べて、実験協力者の嗜好を捉えることができたと考えられる。また、主成分分析によって、実験協力者による採点結果の合計得点だけでなく、特定のコーディネート画像の採点結果の情報もクラスターを分ける際の重要な指標になっていたことも明らかになったため、ファッションにおける嗜好に対してより効果的なクラスタリングができたと考えられる。ここで特定のコーディネート画像とは、実験協力者により採点結果のばらつきが大きく、主に第 2 主成分に大きく寄与している画像のことである。Fig. 6 に、特定のコーディネート画像の例を示す。いずれの画像も実験協力者

**Fig. 6** Examples of specific coordination images

の嗜好により評価が大きく分かれやすいコーディネートであるのがわかる。cluster_2 に関しては、採点結果において比較的高めの点数をつける特徴のある Cluster_0 や、特定のコーディネート画像に偏りの大きい点数をつける特徴のある Cluster_1 に属する実験協力者の中間に位置する人が多く、cluster_0 や cluster_1 に比べて、嗜好に対する分かりやすい特徴を持った実験協力者が少なかった。そのため、嗜好の学習が困難となりクラスターごとの予測精度の平均の中で一番低い値となったと考えられる。

7.2 スニーカーを対象とした場合

トップスやボトムスで構成される服装のコーディネートに比べ、単一品目で色や柄が表現される単純化モデルとしてスニーカーが挙げられる。実験協力者には、スニーカーの画像 30 枚を 1 点～5 点で採点してもらい、スニーカー画像でも嗜好ごとのクラスター分けの有無によって予測精度に差が生じるのか実験を行った。Fig. 7 に評価に用いたスニーカー画像¹¹⁾の例を、Fig. 8 にスニーカーの評価情報に対する第 1 主成分と第 2 主成分に対する個々の実験協力者のクラスターごとのプロットを示す。嗜好ごとに cluster_0 と cluster_1, cluster_2 の 3 つのグループに分類し、結果的に、cluster_0 は 12 名、cluster_1 は 13 名、cluster_2 は 5 名となった。予備実験、本実験 (コーディネートの評価) 同様に実験協力者の採点結果において採点人数が多かった点数に対して CNN で 2 位までに高い値で学習、予測ができていた割合で精度を測った。今回は 5 点満点で採点してもらったため、2 位までの予測結果を評価に用いた。Table 4 にモデルごとの予測精度とその平均を、

Fig. 9 にクラスターごとの平均の予測精度を示す。各クラスターの各モデルの予測精度、平均を比較すると、cluster_0 の平均は 77.4% であり、cluster_1 の平均は 76.9%、cluster_2 の平均は 70.1% となった。cluster_0 と cluster_1、cluster_2 を混合させたグループの平均 (all) は 67.2% となった。また、各クラスターの人数比も考慮した予測精度の平均 (cluster_012_ave) は 76.0% となり、クラスターを混合させたグループの平均 (all) である 67.2% よりも 8.8% 高い値となった。しかし、クラスターごとに分けた予測精度の平均とクラスターを混合させた予測精度の平均に有意差があるか有意水準 5% で片側 t 検定を行ったところ、有意差が認められなかった。

クラスターを混合させた評価情報の予測精度の平均 (all) に比べ、クラスターごとの評価情報の予測精度の平均 (cluster_012_ave) が高かった理由と有意差が認められなかった理由を以下に考察する。コーディネートの評価情報によるクラスタリングと



Fig. 7 Sneaker images




Fig. 8 Plot diagram by cluster analysis

同様に、主成分分析によって、採点結果の合計得点だけでなく、特定のスニーカー画像の採点結果もクラスターを分ける際の重要な指標になっていたことも明らかになったため、個々の嗜好に対して効果的なクラスタリングができたと考えられる。具体的に、派手なピンク色 (Fig. 7 の image_02) や柄があるスニーカー (Fig. 7 の image_03) などは実験協力者で評価の差が生じたため、クラスター分けに好影響を及ぼしていたと考えられる。結果的に特徴がある画像データとして扱われ、ユーザに対し、効果的なクラスタリングができたと考えられる。

有意差が認められなかった理由としては、各モデルの予測精度の差が顕著に表れたからだと考えられる。特に、model ①ではクラスターごとの予測精度が 62.8% であるのに対し、クラスターを混合させたグループの予測精度は 75.4% であった。結果的に前者の精度の平均が後者の精度の平均を大きく下回ったため、有意差が認められなかった。

また、スニーカーの評価情報に対する予測精度の平均 (76.0%) は、服装のコーディネートの評価情報に対する予測精度の平均 (83.7%) と比較して、7.7% 低い値となった。理由としては、スニーカー画像はコーディネート画像に比べて、形状が類似しているものが多かったため嗜好の学習が困難であったと考えられる。しかし、スニーカーなどの単一品目にデザインが集約されている単純化モデルに対し




Fig. 9 Average of prediction accuracy by cluster (Sneakers)

Table 4 Prediction accuracy and average of each model

	model ①	model ②	model ③	model ④	model ⑤	Ave.
cluster_0	61.7%	100.0%	73.3%	83.3%	68.8%	77.4%
cluster_1	68.8%	93.3%	75.3%	66.8%	80.5%	76.9%
cluster_2	50.0%	81.1%	77.8%	90.3%	51.1%	70.1%
cluster_012_Ave.	62.8%	93.9%	74.9%	77.3%	70.9%	76.0%
all	75.4%	85.6%	64.4%	44.7%	65.9%	67.2%

でもクラスターを分けることで、分けないグループに比べて高い精度を出すことができた。実際に、cluster_0とcluster_1, cluster_2のクラスターごとに分けた予測精度の平均がクラスターを混合させた予測精度の平均 (all) を全て上回った。よって、単一品目の色や柄などのデザインに対しても、嗜好ごとにクラスターを分ける方式の有効性を確認できた。

8. 推薦システムの運用と全体構成

8.1 推薦システムの仕組み

嗜好ごとに分けたユーザのクラスターを用いたコーディネート推薦方式について、運用を含めたシステムの全体構成を Fig. 10 に示す。

Fig. 10 の①～③まではユーザのクラスタリングまでの過程である。はじめに、推薦システムを使用する①の新規ユーザに対して、②の過程でコーディネート例を評価してもらう。③で②での評価情報をもとにクラスタリングを行う。本実験ではクラスタリングに、k-means 法を用いたが、効率の面では機械学習による自動化が望ましいと考えられる。また、今後システム化する上で、評価してもらう画像の数がเพิ่มด้วยユーザに労力をかけてしまう恐れが考えられる。そこで、実験結果からクラスタリングの際に、特徴のあるコーディネート画像の評価がクラスタリングに大きく貢献していることが明らかになったため、そのような特徴のある複数枚の画像に対する評価値を入力として機械学習で新規ユーザのクラスタリングが行える可能性が考えられる。具体的には、各主成分に関係性が深い変数ほど絶対値が大きくなる主成分負荷量を基準に、評価してもらうコーディネート画像を選択する方法などが考えられ、今後のさらなる検討が必要である。④～⑥までは、③でクラスタリングしたユーザの嗜好を学習し、推薦するまでの過程である。④でクラスターごとに CNN で学習を行ったそれぞれのモデルに新規ユーザの嗜好情報を追加していく。⑤では、嗜好が追加された学習モデルによって高い評価が得られた新規のコーディネートを紹介する。また、自身が所有するボトムスに合うトップスの購入を行う際に、ボトムスを固定し、複数のトップスを入れ替えたコーディネートの中から CNN の評価が高かったコーディネートのトップスを推薦することなども可能となる。つまり、トップスやボトムスなどの全てを新規のコーディネートから推薦されるだけでなく、所有するコーディネートを軸にした評価や推薦

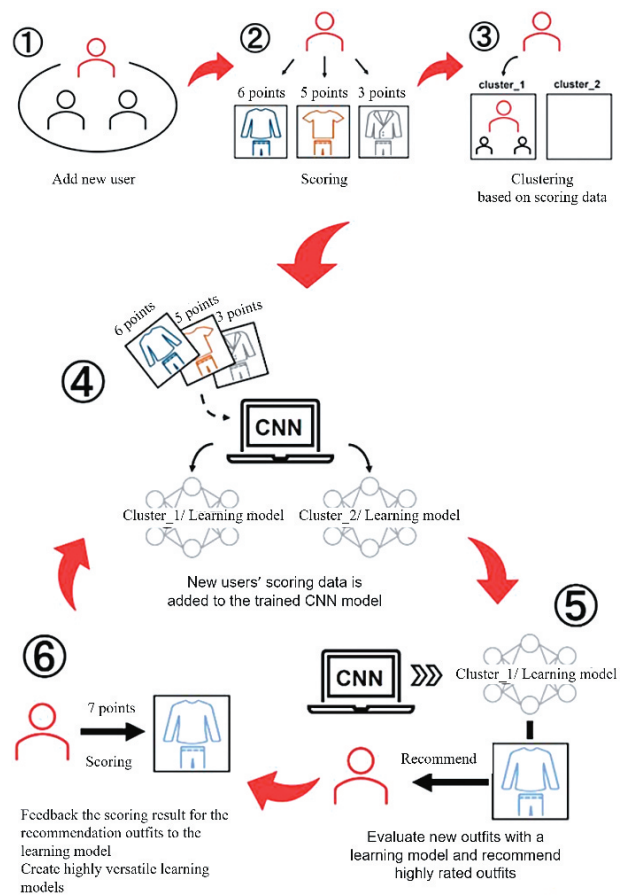


Fig. 10 Overall configuration of recommendation system

ができることで、容易な選択が可能となる。後に⑥によって推薦結果をユーザに評価してもらう。最後に、⑥の過程から④の過程に再度移行し、ユーザの評価を学習モデルにフィードバックする。結果的に④～⑥の過程を循環することで汎用性の高い学習モデルを作成していく。以上の過程を繰り返すことで推薦システムを運用する。

8.2 推薦システムのメリット

従来の協調フィルタリングにおける推薦手法には、購買履歴などのデータを使用したものだけではなく、本研究と同様にユーザの評価情報を用いて、嗜好に沿った推薦をする手法も存在する。しかし、ユーザによって一度も評価がされていない新規のアイテムに関しては推薦ができないというデメリットが生じる。

そこで、本研究で検証した推薦システムに関しては、クラスターごとの学習済みモデルに対して、新規のコーディネートの評価が可能である。ユーザが一度も着用したことがないコーディネートに対しても評価を行うことができるため、評価結果が高ければ着用を薦めることができ、仮に評価結果が低かったとしても、1つの指標をユーザに与えることがで

きる。

8.3 推薦システムの運用における課題

新規ユーザが増えることで、毎回ユーザの嗜好情報を学習モデルに追加するにはシステム上で時間を要し、効率的ではない。そのため、ある程度の新規ユーザが集まった時点でまとめて追加して学習するなどの追加学習の頻度についても検討が必要である。

また、服装に対するユーザの嗜好は時間の経過とともに変化することが考えられる。ファッショントレンドの変化については、クラスターの多くのユーザが影響を受けると考えられるため、④の過程で新規のユーザの嗜好情報を随時追加して学習することである程度の対応ができると思われる。しかし、一部のユーザもしくは個人の嗜好の大きな変化に対しては、どのように対応するか検討する必要がある。1つの対応方法としては、ユーザが推薦システムの推薦に対する評価が低い状態が続くようであれば、再度クラスタリングをやり直し、別のクラスターに移動することで改善できる可能性が考えられる。さらに、ファッショントレンドの変化が速い場合には、上記の⑥から④を循環する過程において評価結果のフィードバックでは対応できない可能性も考えられ、今後検討が必要だと考える。

9. 結言

本研究では、個々のユーザの嗜好を考慮したコーディネート推薦方式について検討した。具体的には、ファッションに対する嗜好をクラスタリングしたグループとクラスタリングを行わずに様々な嗜好を混合させたグループの評価情報の予測精度に差が生じるのかを調査し、クラスターごとに分けて学習する方式の有効性を検証するために評価実験を行った。結果的に、服装のコーディネートを対象とした場合では、クラスターごとに分けて学習する方式の予測精度の平均 (cluster_012_ave) が 83.7%、クラスターを分けなかった場合の予測精度の平均 (all) は 73.3% となり、推薦するに当たり、個々の嗜好を反映するにはクラスターごとに分けて学習する方式に有効性があることが示された。また、コーディネートだけでなく、スニーカーに対しても嗜好ごとにクラスターを分ける場合が、クラスターを分けなかった場合に比べて高い精度を出すことができた。よって、単一品目にデザインが集約されている単純

化モデルに対してもクラスターを分けて嗜好を学習する方式が効果的であることが示された。

今後の課題としては、個々の嗜好を学習したモデルを使用し、実際に推薦システムとして運用可能なのか検証する必要がある。本研究では、30人を対象に嗜好を分類したが、新たなユーザを追加するにはどのようにしてクラスター分類を行うのか、また、一度に何人までの嗜好情報を追加していくのが適切なのかを考える必要がある。さらに、学習済みモデルの汎用性を向上させる方法も検討する必要がある。

本研究は、共著者である池田正隆氏が大学院前期課程2年次のときに行ったものである。

参考文献

- 1) 山田貴子, 高見一正: 着衣ライフログのアイテムベース協調フィルタリングによるファッションコーディネート方式の評価. 情報処理学会第76回全国大会講演論文集, Vol.2014 (2014), No.1, 455-456.
- 2) 知見優一, 北山大輔: コーディネート検索におけるユーザ評価の提示によるファッションへの意識変化手法. 情報処理学会研究報告, Vol.2020-HCI-189 (2020), No.6, 1-6.
- 3) 高宮博志, 高橋直己, 坂本隆, 加藤俊一: 服装の印象とセルフイメージを考慮したコーディネーションのレコメンド手法. 日本色彩学会誌, 第44巻 (2020), 第3号, 249.
- 4) 青木由紀乃, 横山幸大, 中村聡史: BingoFit: 所有する衣服の活用に向けたビンゴゲーム型衣服提示システムの提案. 情報処理学会研究報告, Vol.2021-HCI-195 (2021), No.4, 1-8.
- 5) 三露庸介, 吉村枝里子, 土屋誠司, 渡部広一: ラフ分析による嗜好を考慮した服装提案システム. 情報処理学会研究報告知能システム, Vol.2016-ICS-183 (2016), No.13, 1-8.
- 6) “Styling Map とは”. 一般社団法人日本ファッションスタイリスト協会. 2022-12-12, <https://stylist-kyokai.jp/stylingmap/>.
- 7) “過去のスタイリングマップコーデ”. 一般社団法人日本ファッションスタイリスト協会. 2022-12-12, https://old.stylist-kyokai.jp/wp_2020/coordinate/.
- 8) “テイストチェック・男性の装い”, “テイスト

- チェック・女性の装い”。一般社団法人日本ファッションスタイリスト協会. 2022-12-12, <https://stylist-kyokai.jp/stylingmap/men/>, <https://stylist-kyokai.jp/stylingmap/women/>.
- 9) “クラスター分析”. 第2講－総務省統計局. 2022-12-12, <https://www.stat.go.jp/teacher/dl/pdf/c3learn/materials/third/dai2.pdf>.
- 10) 田中豊, 脇本和昌, “多変量統計解析法”, 現代数学社, (1983).
- 11) “ALL STAR”. CONVERSE ONLINE SHOP. 2022-12-12, <https://converse.co.jp/pages/all-star>.
(R5.6.8 受理)

Biographical Sketches of the Authors



Yoshihiro NAKAMURA is a professor at the Department of Mathematical Information Engineering, College of Industrial Technology, Nihon University. He received his M. E. degree and Dr. Eng. degree from Tokushima University Graduate School of Engineering in 1991 and 2002, respectively. Dr. Nakamura has been working for NTT Laboratories from 1991 to 2007, and for Nihon University from 2007 to the present. He is a member of the Information Processing Society of Japan, Human Interface Society, the IEICE. His research interests are human computer interaction.



Masataka IKEDA graduated from Department of Mathematical Information Engineering, Graduate School of Industrial Technology, Nihon University in 2023. While in graduate school, he engaged in research on recommendation systems. He currently works for Mizuno Corporation.