

# タグ付き画像を用いたファッションスタイルの関係性の可視化

上村 幸汰<sup>†</sup> 桂井麻里衣<sup>††</sup> 真木 勇人<sup>†††</sup> 後藤 亮介<sup>†††</sup>

<sup>†</sup> 同志社大学大学院理工学研究科 〒610-0394 京田辺市多々羅都谷 1-3

<sup>††</sup> 同志社大学理工学部 〒610-0394 京田辺市多々羅都谷 1-3

<sup>†††</sup> ZOZO Research 〒150-0001 東京都渋谷区神宮前 5 丁目 52-2 青山オーバルビル 3F

E-mail: <sup>†</sup>{uemura,katsurai}@mm.doshisha.ac.jp, <sup>††</sup>{hayato.maki,ryosuke.goto}@zozo.com

あらまし コーディネートの系統（スタイル）は、ファッションスナップの検索や評価に有用な情報である。機械学習によるスタイル認識では、認識対象のラベルが付与された学習用データセットを構築する必要がある。本研究では、スタイルラベルの設計指針をもたらすデータドリブンアプローチの第一歩として、ユーザが投稿したタグ付き画像を用いてファッションスタイルの関係性を可視化する。はじめに、スナップ画像から人物領域を抽出し、領域内の画像特徴を算出する。次に、視覚的に類似した画像集合はスタイルを表出すると仮定し、特徴空間で近くに配置される画像ペアを用いてタグ共起頻度を算出する。最後に、各タグの出現頻度に基づきタグ共起頻度を正規化し、ノードをタグ、エッジをタグ間の関係としたネットワークからスタイルのコミュニティを検出する。コーディネートサイト WEAR から収集した 17 万枚のスナップ画像を用いた実験により、提案手法が単純な共起頻度に基づく手法に比べて意味的に理解しやすい関係性を抽出できることを示した。

キーワード ファッションスナップ, スナップ画像, スタイル認識, コーディネート, 可視化

表 1 FashionStyle14 データセット [6] で定義された 14 個のスタイルラベル。

conservative	dressy	ethnic	fairy	feminine	gal
girlish	casual	lolita	mode	natural	retro
rock	street				

## 1 はじめに

日常生活における衣服の着用は、自己表現や社会規範と密接に関わっており、他者から評価を受けるなどの社会・心理的機能をもつ [1]。ファッション意識とセンスには個人差があり、適切な衣服の組合せの選択に困難さを感じる場合や、意欲的に他者の装飾を参考にしたい場合がある。こうした被服支援のためのコーディネート検索・評価システム開発を目的とし、ファッションアイテム推薦手法 [2,3] や、コーディネートのファッション性評価手法 [4] が提案されてきた。これらの研究では、衣服を着用した人物の画像（以降、スナップ画像）から着用アイテムやコーディネートの系統（スタイル）を認識する。現在主流の機械学習アプローチでは、認識対象がラベルとして付与された学習用データセットの構築が必要不可欠である。ウェブで公開されている学習用データセットは、多くが衣類の種類や色・形状などのラベルで構成されており [5]、スタイルをラベル付けたデータセットは未だ数が少ない。2017 年に公開された FashionStyle14 データセット [6] では、表 1 に示す 14 個のスタイルラベルが専門家によって定義された。しかし、ファッションは多様であり、必ずしもデータベース中の画像をこれらのラベルで分類できるとは限らない。実際、文献 [7] による世界のファッショントレンドの分析では、ファッションは国や文化によって異なることが示唆されている。ゆえに、検索対象とするスナップ画像集合を適切に分類可能なスタイルラベルの設計指針が必要となる。

一方、ソーシャルメディアサイトを通じて自身のコーディネートを投稿するユーザが急激に増加している。例として、コ

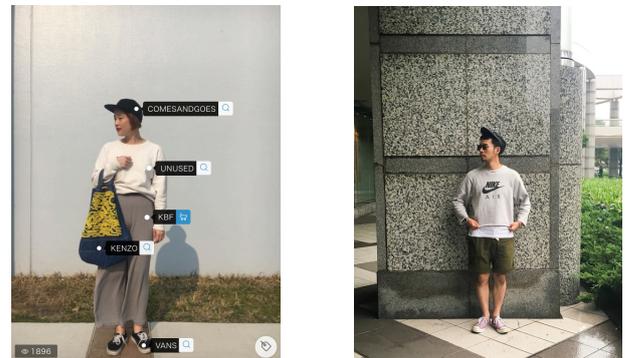


図 1 WEAR に投稿された画像とタグの例。

ディネート共有に特化したサービス WEAR<sup>1</sup>では、累計 800 万以上のスナップ画像が投稿されており、ユーザは閲覧数獲得のためにタグやコメント機能で自身のスタイルのポイントを説明する。WEAR の投稿画像とそれに付与されたタグの例を図 1 に示す。「オトナカジュアル」や「休日スタイル」、「スニーカーコーデ」など、ユーザ間で共通概念となるスタイルが存在する。したがって、ソーシャルメディアから適応的にスタイルラベル

1 : <https://wear.jp/>

を発見することで、ユーザの認識理解に即したコーディネート検索・評価システムの開発につながると考えられる。

本研究では、スナップ画像用スタイルラベルのデータドリブンな設計方針の構築を目的とし、大量のタグ付き画像を用いたスタイル間の関係可視化手法を提案する。ファッションスタイルは視覚的に連想される概念であるため、画像特徴を用いて関連性を抽出する。はじめに、スナップ画像から人物領域を抽出し、領域内の画像特徴を算出する。次に、視覚的に類似した画像集合はスタイルを表出すると仮定し、特徴空間で近くに配置される画像ペアに着目する。類似画像ペアに付与されたタグ集合からタグの共起頻度を算出し、ノードをタグ、エッジをタグ間の顕著な共起関係としたネットワークを構築する。最後にコミュニティ検出を適用することで、画像特徴に基づくファッションスタイルの関係性を可視化する。WEAR の約 17 万枚のスナップ画像を用いた実験では、単純なタグ共起頻度に基づく手法の結果と定性的に比較し、提案手法が視覚的な類似性を考慮してスタイルを発見できることを示した。

本稿の構成は以下の通りである。まず、2 章でファッションスタイル認識およびタグ間の関係抽出に関連する従来研究を紹介する。3 章ではタグ付き画像集合を用いたファッションスタイルの関係性の可視化手法を提案する。4 章で WEAR データセットを用いた可視化実験の結果を報告し、5 章で本研究のまとめと今後の課題を述べる。

## 2 関連研究

ファッション画像認識モデルを構築するには、正解ラベルの付与された画像が必要不可欠であり、いくつかの研究グループが学習用データセットを公開している。例として、DeepFashion データセット [5] には、衣服のカテゴリ、テクスチャ、素材、形状などのアトリビュートをもつ画像が約 80 万枚収録されている。Street2Shop データセット [8] では、ファッションショッピングサイトから収集したアイテム画像にストリートスナップ画像が対応付けられている。本研究で対象とするファッションスタイルは、アイテムアトリビュートよりも意味的に高次元な概念である。HipsterWars [9] データセットでは、1893 枚の画像を分類するために、bohemian, goth, hipster, pinup, preppy という 5 つのスタイルラベルが用いられた。しかし、具体的なラベル設計方法は議論されていない。1 章で述べた FashionStyle14 データセットのスタイルラベルは、ファッションの専門家の意見に基づいて決定された。データセットの手動構築には多大な労力を要するため、専門家の介入は重要であり、新たなラベルの追加は慎重に行う必要がある。一方、日々新語が生み出されるウェブでは、ファッションに関しても新たな共通概念を言語化することが多い。本研究で画像特徴に基づきファッションスタイルの関係性を可視化することで、対象とするデータに適応的なラベル選出が期待できる。

その他の関連研究として、ソーシャルメディア上の画像集合におけるタグ間の関係抽出が挙げられる。従来研究では、タグの共起頻度の利用のみならず、画像特徴に基づく視覚的な関連

性の重要性が示されてきた。文献 [10] では、画像特徴とテキスト特徴を用いて各タグの分布を算出し、分布間距離をタグ間の意味的な関係とみなした。文献 [11] は、視覚的な類似性とタグの共起頻度を組み合わせ、タグ間の階層的な関係を抽出した。抽出した関係は、画像検索や画像認識の高精度化に用いられる [12]。上記の研究の多くは、画像カテゴリを限定しておらず、ファッションドメインにおいてタグ間の関係を分析した研究はこれまでに報告されていない。ソーシャルメディアを通じたコーディネート共有文化の広がりにより、タグ付きスナップ画像が大量に蓄積されたことを背景に、本研究でスタイルの関係抽出と可視化に取り組む。

## 3 ファッションスタイルの関係性の可視化手法

本章では、タグ付き画像集合を用いたファッションスタイルの関係性の可視化手法を提案する。提案手法の概要を図 2 に示す。はじめに、スナップ画像とそれらに付与されたタグのペアを収集する。各画像に物体認識を適用し、人物領域から画像特徴を抽出する (3.1 節)。次に、データセット内の画像の類似関係をネットワークで表し、エッジで接続された画像ペアを用いてタグペアの共起頻度を算出する (3.2 節)。最後に、各タグの出現傾向を考慮してタグペアの共起頻度を正規化し、タグ間の関連度の強さを定量化する (3.3 節)。

### 3.1 スナップ画像の特徴抽出

SNS から収集したスナップ画像のうち、人物が写っていない画像はファッションスタイルのモデル化においてノイズになりうる。そこで、物体検出モデル YOLO v3 [13] を用いて、図 3 に示すように人物領域を検出する。以降、人物領域のみを切り出したスナップ画像集合を  $\{x_i\}_{i=1}^N$  とおく。また、 $i$  番目の画像のタグ集合を  $T_i$  とおき、データセットを  $\{x_i, T_i\}_{i=1}^N$  ( $N$  は画像枚数) で表す。

次に、人物領域から Convolutional Neural Network (CNN) 特徴量 [14] を算出する。CNN 特徴量とは、あるタスクに向けて予め学習された CNN に画像を入力し、全結合層から得られる出力を要素にもつベクトルを指す。本研究では、衣服の特徴を抽出する目的で、ファッションドメイン用に CNN を用意する。具体的には、FashionStyle14 データセット [6] を用いて、ImageNet で事前学習済みの VGG-16 [15] を 14 個のスタイル認識モデルへとファインチューニングする。ネットワークの構成は、VGG-16 の畳み込み 12 層までの重みを固定し、最後の三つの全結合層を 1,000 次元、300 次元、14 次元に変更した。最終的に、スナップ画像  $x_i$  を CNN に入力し、全結合層から出力された 1,000 次元ベクトルに L2 正規化を適用したものを  $x_i$  の画像特徴ベクトルとする。

### 3.2 類似スナップ画像集合を用いたタグ共起頻度の算出

タグ間の関係抽出における最も簡単な方法として、同一画像におけるタグの共起頻度の利用が挙げられる。しかし、単なる共起頻度に基づくアプローチでは、同義語タグの欠落に影響を受ける可能性がある。また、タグ間の視覚的な関連性を発見で

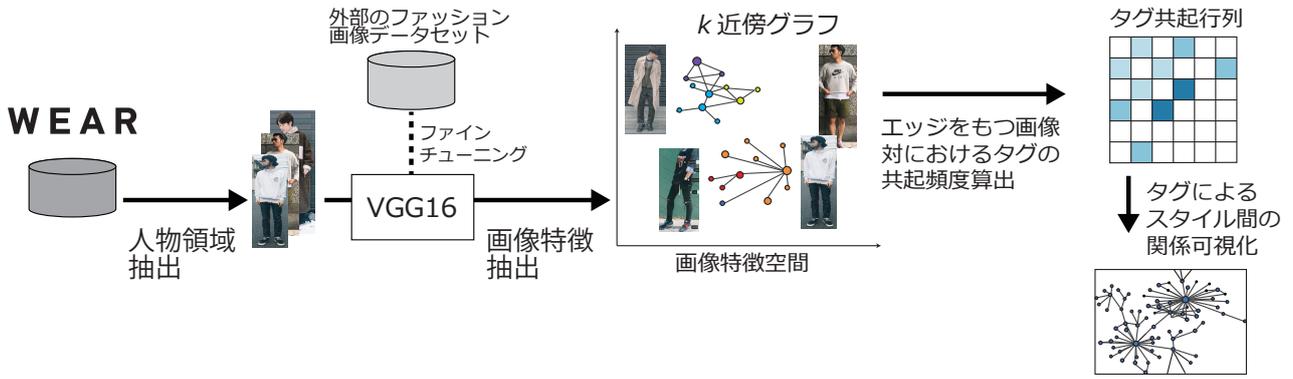


図 2 提案手法の概要.

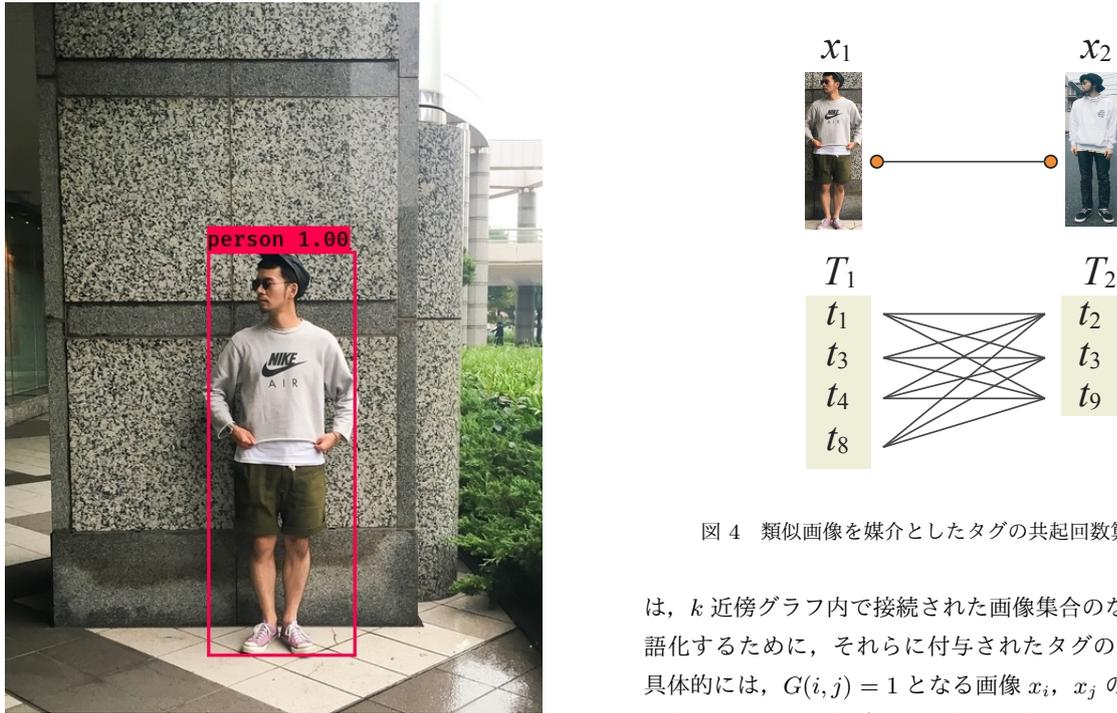


図 3 スナップ画像からの人物領域抽出の例.

きない. そこで本研究では, 視覚的に類似した画像集合はスタイルを表出すると仮定し, スタイルを言語化することを考える. まず, スナップ画像集合をノード, 画像間の類似関係をエッジとしたスナップ画像ネットワーク  $G$  を構築する. 具体的には, 集合  $\{x_i\}_{i=1}^N$  の画像特徴ベクトル間のペアワイズ距離を算出し, 次式のように  $k$  近傍グラフを構築する.

$$G(i, j) = \begin{cases} 1, & \text{if } x_i \in kNN(x_j) \text{ and } x_j \in kNN(x_i), \\ 0, & \text{otherwise.} \end{cases} \quad (1)$$

ここで,  $G(i, j)$  は二つの画像  $x_i, x_j$  に対応するノード間のエッジ重み,  $kNN(x)$  は画像  $x$  の  $k$  近傍に存在する画像の集合を表す. 本稿では  $k = 5$  に設定する.

データセット内タグ集合  $\{T_i\}_{i=1}^N$  のユニークなタグ数を  $K$  個とし,  $k \in \{1, \dots, K\}$  番目のタグを  $t_k$  で表す. 提案手法で

図 4 類似画像を媒介としたタグの共起回数算出の概要.

は,  $k$  近傍グラフ内で接続された画像集合のなすスタイルを言語化するために, それらに付与されたタグの共起に着目する. 具体的には,  $G(i, j) = 1$  となる画像  $x_i, x_j$  のタグ集合  $T_i, T_j$  において, 二つのタグ  $t_k, t_l$  ( $k, l \in \{1, 2, \dots, K\}$ ) の共起回数を次式のようにカウントする.

$$co(t_k, t_l) \leftarrow co(t_k, t_l) + 1, \quad \text{for } t_k \in T_i, t_l \in T_j, G(i, j) = 1. \quad (2)$$

上式の内容を図 4 に示す. 類似画像のエッジを媒介として, タグペアの共起回数を 1 ずつインクリメントする. ノードをタグ, エッジをタグ間の共起関係としたネットワーク (以降, タグ共起ネットワーク) を新たに構築し, 二つのタグ  $t_k, t_l$  に該当するノード間のエッジを  $co(t_k, t_l)$  で重み付ける.

### 3.3 タグの出現頻度を考慮したタグ間の関連度算出

前節で算出したタグ間の共起頻度は, 各タグのデータセット内出現頻度によって大きな影響を受ける. 例として, 「シンプル」「カジュアル」のようにスナップ画像でよく用いられるタグは, エッジで接続された先の画像にも付与されている確率が高く, 結果としてこれらの頻出タグは大半のタグと共起回数が多くなる. この問題を解決するために, 各タグの出現頻度を考慮して

共起頻度を正規化する。提案手法では、「二つのタグ  $t_k$  と  $t_j$  が類似画像を介して共起する回数は、各タグの出現頻度から推定できる」という帰無仮説の下で検定を行う。同様のアイデアが文献 [16] によって提案されている。まず、図 4 のように、任意のタグ間でエッジを計  $E$  回引くことを考える。前述の帰無仮説の下、二つのタグ  $t_k, t_l$  についてエッジが  $w$  回選ばれる確率を次式の二項分布により算出する。

$$P(\sigma_{kl} = w | d_k, d_l, E) = \binom{E}{w} p_{k,l}^w (1 - p_{k,l})^{E-w}, \quad (3)$$

$$p_{k,l} = \frac{d_k d_l}{2E^2}, \quad E = \frac{1}{2} \sum_{k=1}^K d_k. \quad (4)$$

上式において、 $\sigma_{kl}$  はタグ  $t_k, t_l$  のエッジ重みを表す変数であり、 $d_k$  はタグ  $t_k$  に該当するノードの次数である。次に、前節で算出した共起回数  $co(t_k, t_l)$  の片側検定を行う。具体的には、モデルから得られる  $p$  値に基づき、タグ  $t_k, t_l$  の共起回数の顕著さを次式により定量化する。

$$s(t_k, t_l) = -\log \{p_{value}(t_k, t_l)\} \quad (5)$$

$$p_{value}(t_k, t_l) = \sum_{m \leq co(t_k, t_l)} P(\sigma_{kl} = m | d_k, d_l, E). \quad (6)$$

算出される  $s(t_k, t_l)$  の値が大きいほど、二つのタグは各々の出現頻度を考慮しても顕著に共起しており、画像特徴に基づく関係が強いとみなす。最終的に、タグがノード、エッジがタグ間の関係となるネットワークにおいて、 $t_i, t_j$  に該当するノード間のエッジ重みに  $s(t_k, t_l)$  を与える。得られたネットワークにコミュニティ検出を適用することで、複数のタグから意味的なスタイルとその関係性を可視化する。

## 4 実験

本章では、提案手法の有効性を示すために、ファッションコーディネートサイト WEAR のタグ付き画像を用いた実験を行う。実験ではデータセット内の単純なタグの共起頻度に基づく手法と可視化結果を比較する。比較手法では、同一画像に付与されていたタグの共起頻度をカウントし、二つのタグ  $t_k, t_l$  ( $k, l \in \{1, \dots, \}$ ) の関連度を dice 係数により算出した。

$$dice(t_k, t_l) = \frac{2 \times cofreq(t_k, t_l)}{freq(t_k) + freq(t_l)} \quad (7)$$

ここで、 $freq(t_k)$  はタグ  $t_k$  の付与された画像枚数、 $cofreq(t_k, t_l)$  はタグ  $t_k, t_l$  が付与された画像枚数を表す。

以降、まずデータセットの詳細を説明し (4.1 節)、頻出タグ上位 100 個の関係可視化結果を報告する (4.2 節)。さらに、タグを絞り込んだ場合の実験結果を報告する (4.3 節)。

### 4.1 データセット

2018 年 10 月 25 日時点で閲覧可能であった WEAR データのうち、2013 年 1 月 1 日から 2018 年 10 月 25 日までの期間に投稿された 816,184 枚の画像を収集した。各画像には投稿者が付与した複数のタグの情報が紐付けられている。これら約 80

表 2 約 80 万枚の WEAR 画像集合における出現頻度上位 20 個のタグと画像枚数。

タグ	画像枚数	タグ	画像枚数
シンプル	122937	おしゃれさんと繋がりたい	59210
カジュアル	106752	休日スタイル	58242
シンプルコーデ	94788	春コーデ	55838
大人カジュアル	81665	秋のコーデ	55398
カジュアルコーデ	73272	ootd	51777
オトナカジュアル	71303	秋コーデ	48638
デニム	66841	ワイドパンツ	48523
スニーカー	66151	きれいめカジュアル	41178
夏コーデ	60984	夏	38764
プチプラ	59652	GU	38400

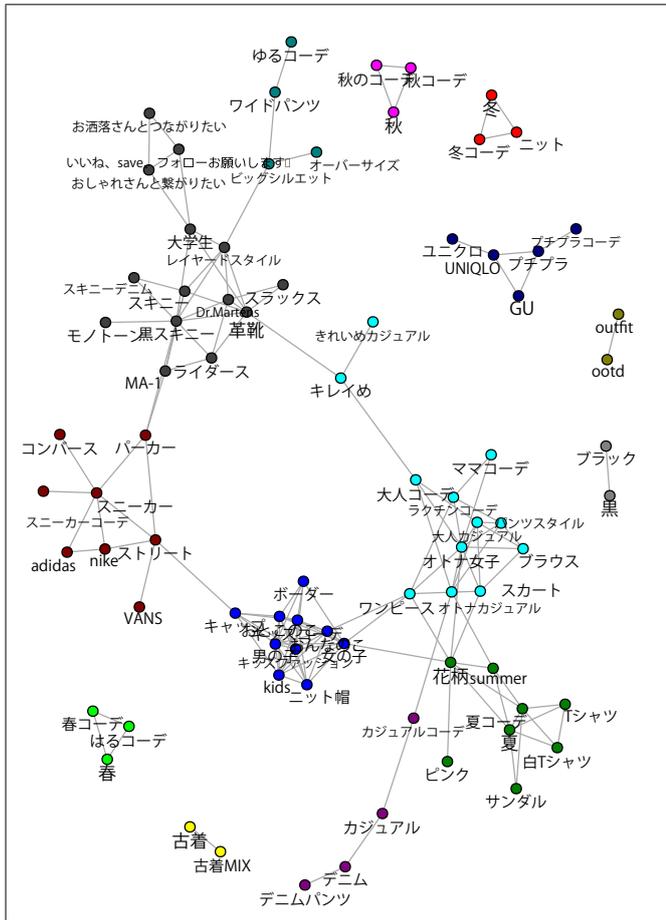
万枚の画像集合においてタグの出現頻度をカウントした。出現頻度上位 20 個のタグと対応する画像枚数を表 2 に示す。表に示すように、WEAR ではアイテム名のような具体的なタグや、スタイルを形容する抽象的なタグが自由に用いられている。なお、FashionStyle14 データセット [6] で用いられていたスタイルラベル (表 1) は、WEAR で適切な直訳を探すのが困難であった (例: fairy)。

次に、出現頻度が上位 100 個となるタグについて、約 80 万枚の集合からランダムに 1900 枚を抽出した。このとき、3.1 節の方法を適用し、人物の写っている画像のみが含まれるようにした。以上の手順により計 168,940 枚からなるタグ付き画像データセット (以降、WEAR データセット) を構築した。この WEAR データセット内のユニークなタグの総数は 31,510 であった。

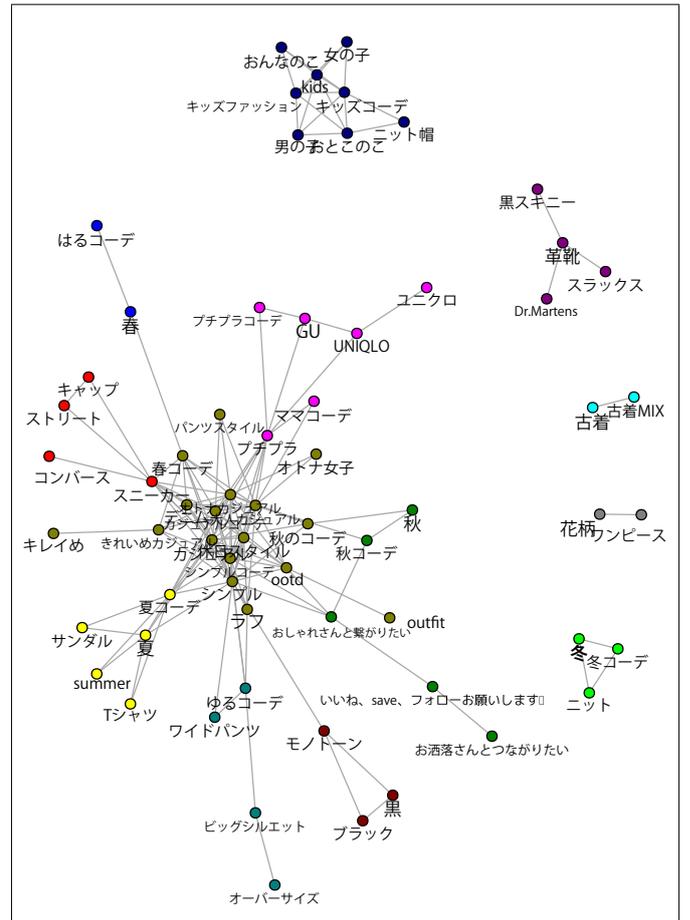
### 4.2 頻出上位 100 個のファッションタグ間の関係可視化

はじめに、WEAR データセット内で頻出上位 100 個となるタグ集合に提案手法と比較手法をそれぞれ適用した。得られたタグネットワークにはコミュニティ検出手法として Louvain 法 [17] を適用した。同一コミュニティに属するノードには同じ色を割り当てた。得られた実験結果 ( $N = 168,940$ ,  $K = 100$ ) を図 5 に示す。なお、見やすさのため、手法で構築したネットワークのうち、エッジ重みが上位 150 個となるエッジと対応するノードのみを描画した。図 5 において、提案手法は比較手法とは異なるネットワーク構造を示した。比較手法は最大連結成分が目立ち、提案手法の方がスタイルのコミュニティをうまく可視化できたといえる。また、比較手法では季節を表すタグが最大連結成分に属するが、提案手法では各季節が分かれて配置されている。このことから、特徴空間におけるスナップ画像集合がファッションの季節性を捉えられたと考えられる。

次に、デンドログラムを用いてスタイル間の関係を可視化する。提案手法と比較手法で構築した各タグネットワークに対し、エッジ重みの平均  $m$  と標準偏差  $s$  を算出した。これらの値から閾値  $m + s$  を算出し、重みが閾値以下となるエッジを全て除外したあと、Pons と Latapy [18] によるランダムウォークベースのコミュニティ検出を適用した。得られた結果を図 6 に示す。この図においても、提案手法は比較手法に比べ、コミュニティ



(a) 提案手法によるタグネットワーク。



(b) 比較手法によるタグネットワーク。

図5 提案手法および比較手法によって構築したタグネットワーク。エッジ重みが上位150個となる関係のみ表示した。

内のタグからスタイルを連想しやすい結果を示した。以上より、単純なタグ共起頻度に基づく手法ではファッションスタイル間の関係性の可視化に不適切であり、画像特徴を用いるべきといえる。

### 4.3 スタイルを形容する27個のタグ間の関係抽出結果

前節で可視化したタグは、概念の粒度にばらつきがあり、アイテムや色に関するタグ、表記揺れのタグが混在していた。そこで、アイテムではなくスタイルを形容すると考えられるタグのみを残すために、以下の文字列処理を適用した。まず、WEARが保有するアイテム文字列とブランド文字列のデータベースを利用し、これらの文字列と一致するタグを除去した。ブランド名の表記揺れ（例：打ち間違いやカタカナ・英語による派生など）については著者らが手動で統合した。次に、コーディネートに関係のないタグを除去するため、タグ文字列に形態素解析を適用し、以下のタグを除去した。

- 動詞を含むタグ（例：「お洒落さんと繋がりたい」）。
- 色とアイテム名の組合せによって構成されるタグ（例：「白スニーカー」）。
- 人物の年代または性別のみで構成されるタグ（例：「大学生」, 「おんなのこ」）。

また、スタイルやコーデの意で用いられていることが明確なタ

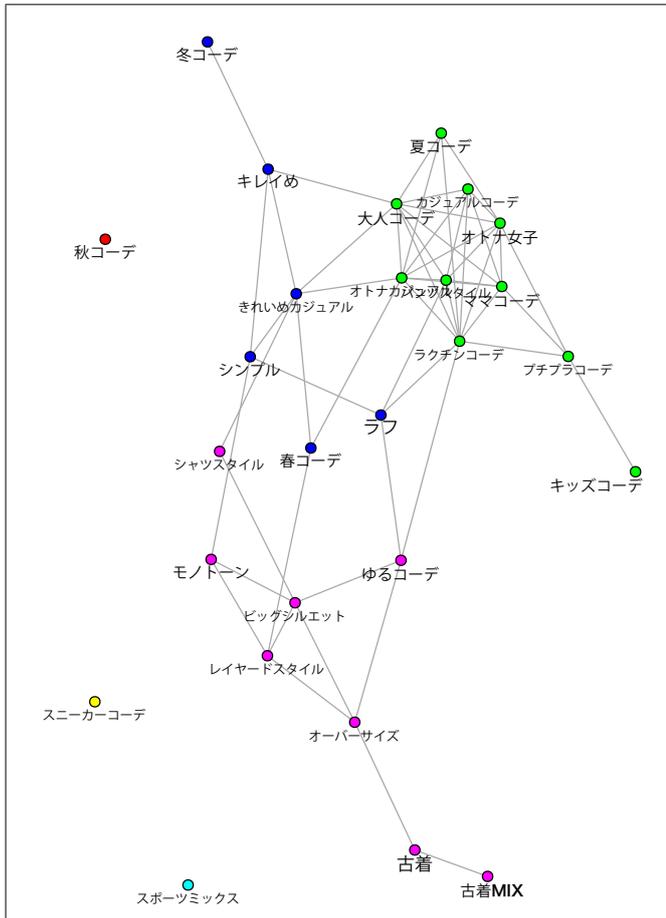
グのうち、一方の文字列が他方の文字列を包含する場合は一つのタグに統合した（例：「シンプル」と「シンプルコーデ」, 「はるコーデ」と「春コーデ」）。最終的に残った27個のタグと対応する画像枚数を表3に示す。これらのタグに対し、提案手法と比較手法をそれぞれ適用した。定性評価のため、重みが $m$ 以上となったエッジのみを描画した結果を図7に示す。図7(a)では、「古着」や「ゆるコーデ」が「レイヤードスタイル」, 「モノトーン」, 「シャツスタイル」に接続し、それらは「シンプル」, 「キレイめ」, 「大人コーデ」などのコミュニティとも関係をもつことがわかる。一方、提案手法に比べ、比較手法のネットワークはコミュニティを発見しにくい結果となった。

本実験で得られた結果のうち、例えば図7(a)から、「古着」と「オトナ女子」「キレイめ」は画像特徴で識別しやすいと考えられる。今後は、スナップ画像からの特徴抽出をさらに改良するとともに、タグネットワークの構造から実際にスタイルラベルを定義し、スナップ画像のスタイル認識へ応用する。さらに、複数名のファッション専門家によるタグのコミュニティ抽出結果の定性評価を予定している。

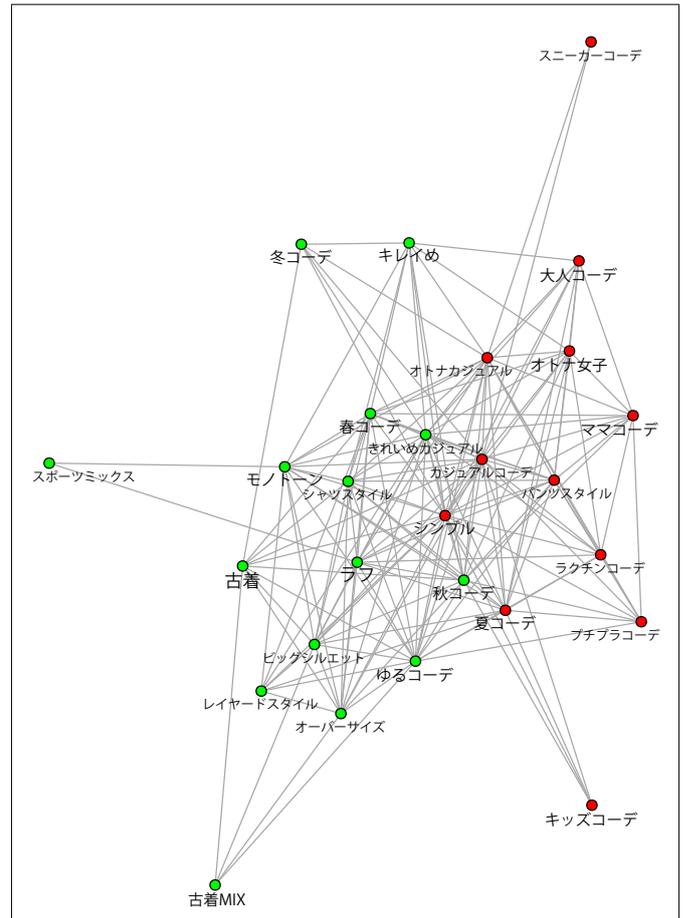
## 5 まとめ

本研究では、ファッション画像認識に適したスタイルラベル





(a) 提案手法によるタグネットワーク。



(b) 比較手法によるタグネットワーク。

図 7 4.3 節で選出した 27 個のタグに対し、提案手法と比較手法で構築したタグネットワーク。それぞれ同様の閾値算出方法でエッジ数を決定した。

sun. Neuroaesthetics in fashion: Modeling the perception of fashionability. In *CVPR*, pp. 869–877, 2015.

- [5] Z. Liu, P. Luo, S. Qiu, X. Wang, and X. Tang. Deepfashion: Powering robust clothes recognition and retrieval with rich annotations. In *CVPR*, pp. 1096–1104, 2016.
- [6] M. Takagi, E. Simo-Serra, S. Iizuka, and H. Ishikawa. What Makes a Style: Experimental Analysis of Fashion Prediction. In *ICCVW*, pp. 2247–2253. IEEE, October 2017.
- [7] K. Matzen, K. Bala, and N. Snively. Streetstyle: Exploring world-wide clothing styles from millions of photos. *arXiv preprint arXiv:1706.01869*, 2017.
- [8] M. H. Kiapour, X. Han, S. Lazebnik, A. C. Berg, and T. L. Berg. Where to buy it: matching street clothing photos in online shops. In *ICCV*, 2015.
- [9] M. H. Kiapour, K. Yamaguchi, A. C. Berg, and T. L. Berg. Hipster wars: Discovering elements of fashion styles. In *ECCV*, pp. 472–488. Springer, September 2014.
- [10] M. Katsurui, T. Ogawa, and M. Haseyama. A cross-modal approach for extracting semantic relationships between concepts using tagged images. *IEEE Trans. Multimedia*, Vol. 16, No. 4, pp. 1059–1074, June 2014.
- [11] Q. Fang, C. Xu, J. Sang, M. S. Hossain, and A. Ghoneim. Folksonomy-based visual ontology construction and its applications. *IEEE Trans. Multimedia*, Vol. 18, No. 4, pp. 702–713, 2016.
- [12] X. Chen and A. Gupta. Webly supervised learning of convolutional networks. In *ICCV*, pp. 1431–1439, 2015.
- [13] J. Redmon and A. Farhadi. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.

- [14] A. S. Razavian, H. Azizpour, J. Sullivan, and S. Carlsson. CNN features off-the-shelf: An astounding baseline for recognition. In *The IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, June 2014.
- [15] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [16] Navid Dianati. Unwinding the hairball graph: Pruning algorithms for weighted complex networks. *Phys. Rev. E*, Vol. 93, p. 012304, Jan 2016.
- [17] V. D. Blondel, J.-L. Guillaume, R. Lambiotte, and E. Lefebvre. Fast unfolding of communities in large networks. *Journal of Statistical Mechanics: Theory and Experiment*, Vol. 2008, No. 10, p. P10008, 2008.
- [18] P. Pons and M. Latapy. Computing communities in large networks using random walks. In *Proc. ISCIS*, pp. 284–293, 2005.