

ソーシャルキュレーションデータを用いた 画像コンテキストマイニング

木村 昭悟^{1,a)} 石黒 勝彦¹ Alejandro Marcos Alvarez^{1,t1} 山田 誠^{1,t2} 片岡 香織² 村崎 和彦²

概要: 本論文では、ソーシャルキュレーションサービスの画像データから、共通するコンテキストを持つ画像群を自動的に発見する手法を提案する。ソーシャルキュレーションは、日本語では一般に「まとめサイト」とも呼ばれ、キュレーターと呼ばれる人間が既存コンテンツを人手で収集・選択した結果を編集コンテンツ群として共有する仕組みである。その結果として得られた編集コンテンツ群は、通常のSNS上のコンテンツとは異なり、キュレーターにとって不要なコンテンツが除去され、キュレーターの意図や意見を反映した一貫した指針に基づいて生成されている。このことから、編集コンテンツ群を構成するコンテンツは、共通のコンテキストを保持していることが期待される。本論文では、このソーシャルキュレーションのプロセスに着目することで、共通のコンテキストを持つ画像群を非常にシンプルな手法で大量に発見することが可能であることを示す。さらに本論文では、発見した画像群を画像認識・検索のコーパスとして利用するための重要なステップとして、コンテキストの共通性を考慮した画像特徴量の低次元埋め込み手法を提案する。この手法を利用することで、類似するコンテキストを持つと思われる画像が類似する低次元特徴量を持つような埋め込みを実現すると共に、画像分類のタスクで同様の機能を実現する従来手法と比較して高い分類性能を実現できることを実験的に示す。

1. Introduction

任意の画像を柔軟に認識・理解する知能の構築は、パターン認識・メディア理解の研究分野における究極目標の一つでありながら、未だに挑戦的な研究課題の一つである。その理由として、画像の見た目と内容との間に存在するいわゆる“セマンティックギャップ”を埋める特徴量・モデル化等の技術が十分ではない点がある。特に、必ずしも自然言語との直接的な対応付けが容易ではない概念やコンテキストなどを獲得し表現することにおいては、計算機の能力は人間にはるか及ばないのが現状である。一方で人間は、言語・音・外部知識など各種の補助情報を利用することで、画像の内容を形成する概念を獲得していると考えられ、計算機においても同様の戦略が有効であると期待される。

上記の問題を解決しうる可能性を持つ新しいタイプの情

報資源として、ソーシャルメディアが非常に注目を集めている。ソーシャルメディアが注目を集めている一つの理由は、コンテンツ間の関連性・ユーザーネットワーク・位置情報など、従来のマルチメディアコンテンツにはあまり含まれなかった多様な付加情報が大量に獲得できる点にある。一方で、SNSの発展によって、誰もが情報を発信し消費できるようになったが故に、大量の画像コンテンツが次々と生み出されるようになり、人間ですらも、日々拡大する膨大な量のメディアコンテンツを扱いきれなくなっている。そのため、まずは、あまりに膨大すぎるデータの中から、価値あるメディアや情報源を効率的に抽出することが必要となる。SNS上のメディアコンテンツを解析する様々な先行研究の多くは、コンテンツから情報や価値を自動的に抽出し可視化することを目指している。

その一方で、自動的なソーシャルメディア解析とは異なる方向性で注目を集める一大潮流として、ソーシャルキュレーションがある。これは、ユーザである人間が自発的に人手でメディアの収集・評価・選択および編集を行い、その結果として得られた編集コンテンツ群を共有するプロセスとして規定され、日本では一般に「まとめサイト」の名で広く知られている。ソーシャルキュレーションを支えるのは、キュレーターと呼ばれる、メディアの取捨選択と再構成を行うユーザ層である。このキュレーターの介在によ

¹ 日本電信電話(株)コミュニケーション科学基礎研究所。
Communication Science Laboratories, NTT Corporation.

² 日本電信電話(株)メディアインテリジェンス研究所。
Media Intelligence Laboratories, NTT Corporation.

^{t1} 現在、リエージュ大学
Presently with Systems and Modeling Research Unit, University of Liege.

^{t2} 現在、Yahoo Labs。
Presently with Search & Anti-abuse Science, Yahoo Labs.

a) akisato@ieee.org

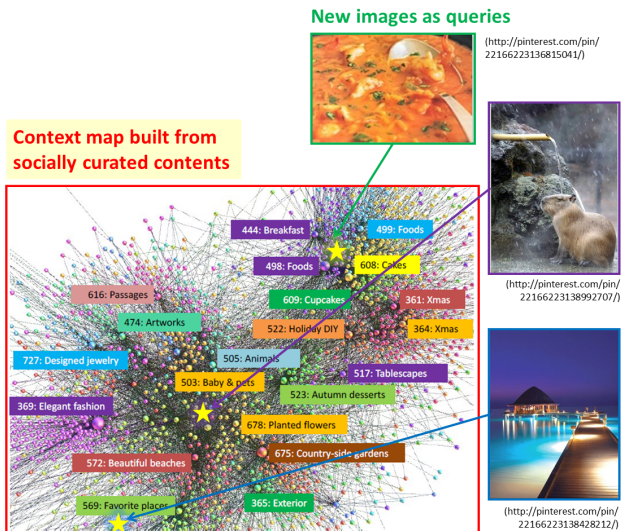


図 1 提案手法の概略

り、ソーシャルキュレーションは、一般的な自動解析・可視化技術とは異なった独自の再編集コンテンツを生み出すことが可能となる。すなわち、取捨選択された再編集コンテンツは、キュレーターの目と手によって人為的にかつ貫した方針によって収集され、同一のコンテキストを共有していることが期待される。

上記の背景に基づき、本論文では、ソーシャルキュレーションの特性に着目した、新しい画像コンテンツ解析の方法を提案する。特に本論文では、画像を対象コンテンツとするソーシャルキュレーションサービスである Pinterest を利用する。Pinterest には、画像コンテンツをまとめるグループである "board" を自由に作成できる機能がある。Pinterest では、この board を、ユーザ自身がアップロードした画像ではなく、他のユーザが持つ別の board に含まれる画像で構成することが一般的である。すなわち、board にユーザが画像コンテンツを集めていく作業は、画像コンテンツを対象としたソーシャルキュレーションと見なすことができる。また、多くのユーザは、自分自身が所望の画像を見つけやすいように、各 board に特定のコンテキストを持たせる。各 board が特定のコンテキストを持ち、かつ画像が board から board へコピーされていくことを考慮すると、数多くの画像を共有している board の対は、類似したコンテキストを持つことが期待される。本論文では、この知見を利用することで、類似したコンテキストを持つ画像群を発見する問題を、Pinterest 上での画像の共有講堂を表現するグラフから強連結構造を抽出する問題として定式化できることを示すと共に、独自に収集した大規模コーパスを用いて、グラフ構造の近接関係がコンテキストの類似関係と密接に関わることを実験的に示す (図 1 左)。

さらに本論文では、このように獲得したコンテキストの類似関係を、未知の画像の認識や検索のために利用する手法についても提案する。具体的には、グラフ表現されたコ



図 2 Pinterest の概要

ンテキストの類似関係を補助情報として利用する、画像特徴量の低次元埋め込みの新しい手法を提案する。この手法を利用することで、言語化が必ずしも容易は限らないコンテキストの類似関係を、低次元画像特徴量の類似関係に変換できるようになると共に、より高次の意味や概念を考慮した画像分類・認識・検索が可能となる (図 1 右)。

2. 画像コンテキストの自動発見

2.1 Pinterest の仕組み

まず、本論文で対象とするソーシャルキュレーションサービスである Pinterest の概要について、図 2 を用いて説明する。

Pinterest は、スクラップブックに写真や雑誌の切り抜きを貼り付けていくような感覚で、お気に入りの画像を集めたり共有できる、画像共有サービスと見ることができる。Pinterest のユーザは、"board" と呼ばれる画像のグループをいくつか所有し、一般的な SNS 同様に、フォローしている友人が共有したコンテンツが、"wall" と呼ばれるタイムラインに表示される。この wall でお気に入りの画像を見つけた際に、ほぼ 1 クリックでその画像を自分が所有するいずれかの board に "pin" (画像へのリンクを作成) することができる。ユーザが pin する手段は、主に以下の 2 通りが提供されている。

- (1) Pin: Web 上にある画像へのリンクを作成し、それをいずれかの board に紐付ける。
- (2) "Repin": 他のユーザのいずれかの board に存在する pin をコピーして、それを自分のいずれかの board に紐付ける。

この 2 通りの pin する手段が提供されることにより、まずあるユーザが興味を持つ画像を web で見つけて pin し、その画像を別のユーザが wall で見つけて repin し、また他のユーザが repin する、という、画像コンテンツの伝搬のサイクルが生まれる。

このように作成されたそれぞれの pin には、画像コンテンツだけでなく、画像の提供元、画像が pin された board、repin 元の board の所有者、画像を最初に pin したユーザや board、その pin が repin された board やユーザなど、様々な補助方法が含まれる。多くのユーザは、自分自身もしくは他のユーザが所望の画像を素早く見つけら

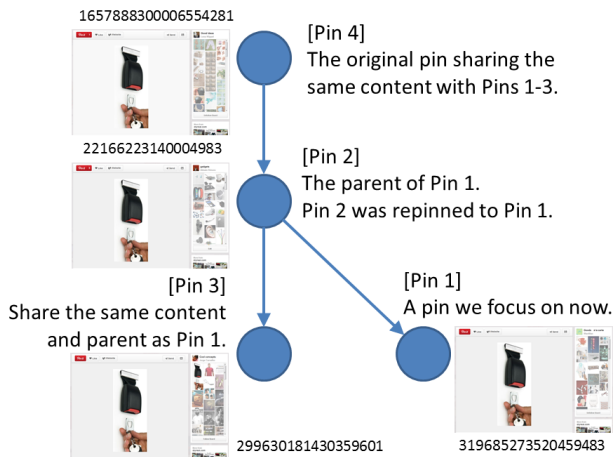


図 3 Pin diffusion graph

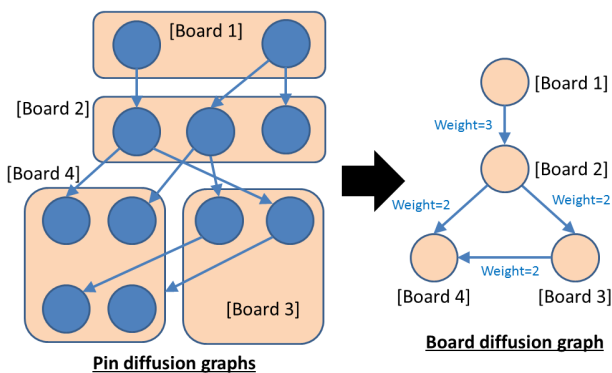


図 4 Board diffusion graph

れるように、各 board に自身が設定した特定の概念や内容を対応させ、その概念や内容に適合する画像のみをその board に pin する傾向が強く見られる。

2.2 類似コンテキストを持つ画像群の発見

各 board が特定のコンテキストを持ち、かつ repin によって複数の board を次々と伝搬していくことを考慮すると、伝搬を通じて数多くの画像を共有した board の対は、類似したコンテキストを持つことが期待される。この知見を利用すると、類似したコンテキストを持つ画像群を発見する問題は、伝搬を通じて数多くの画像を共有した board の集合を発見する問題に置き換えることができる。本節では、このような board の集合を効率的に発見する手法について説明する。

前節に示したように、各 pin から、pin された画像の出演元 URL、その pin が repin であるかどうか、repin 元の board を所有するユーザーを知ることができる。これらの情報から、当該 pin の repin 元である pin をただ一つに特定することができる。図 3 において、Pin 2 が Pin 1 の repin 元として特定された pin である。同様にして、すべての pin に対してその repin 元を辿ることにより、各 pin をノード、repin 元 pin に対応するノードから repin 先 pin に対応する

ノードへの経路を有向エッジとする、木形状の有向グラフを多数得ることができる。この有向グラフを pin diffusion graph と呼ぶ。Pin diffusion graph の例を図 3 に示す。

Repin 元 pin と repin 先 pin が異なる pin ID を持つことから、各 pin が属する board は一意に特定できる。つまり、すべての pin はいずれか 1 つの board に属することになる。このことから、図 4 に示すように、pin diffusion graph の各ノードを、所属する board ごとにまとめることができ、その結果は一意に定まる。その過程で、repin 元・repin 先双方の board を共有するエッジも一つにまとめられ、新しいエッジの重みはまとめられたエッジの数となる。このように構成された、board をノードとする新たな有向グラフを、board diffusion graph と呼ぶ。図 4 に、board diffusion graph の構成例を示す。

Board diffusion graph は、board から board への画像の伝搬の様子をグラフ表現したものである。このことから、本論文で解くべき問題である、類似したコンテキストを持つ画像群を発見する問題は、board diffusion graph で相互連結の強いノードの集合を検出する問題と読み替えることができる。この問題は、グラフクラスタリングとして広く知られており、モジュラリティ最大化として定式化する方法が標準的である。本論文では、モジュラリティ最大化基準のグラフクラスタリング手法として Louvain 法 [1], [2] を採用すると共に、多数のノードを含む巨大クラスタが生成されないように、一定数以上のノードを含むクラスタに再帰的にクラスタリングを実行する階層クラスタリングを行う。

3. コンテキストを考慮した画像特徴量の低次元埋め込み

本節では、このように獲得したコンテキストの類似関係を、未知の画像の認識や検索のために利用する手法についても提案する。具体的には、board diffusion graph という形でグラフ表現されたコンテキストの類似関係を補助情報として利用する、画像特徴量の低次元埋め込みの新しい手法を提案する。この手法を利用することで、コンテキストの類似関係を低次元画像特徴量の類似関係に変換することを可能とする。

本節で提案する低次元埋め込み手法は、learning using privileged information (LUPI) と呼ばれる、学習時のみに利用可能な補助情報を用いた機械学習手法の枠組を利用している [3], [4]。すなわち、特徴ベクトル $x \in \mathcal{X} \subset \mathbb{R}^d$ からクラスラベル $y \in \mathcal{Y} \subset \mathbb{N}$ を予測する予測器 $f: \mathcal{X} \rightarrow \mathcal{Y}$ の学習に、特徴ベクトルとは別に用意された補助情報 (privileged information) $v \in \mathcal{V} \subset \mathbb{R}^p$ を利用する枠組である。ここで注意すべきは、予測器 f は特徴ベクトルのみからクラスラベルを予測することから、補助情報は予測器の学習にしか用いることができない点というである。

3.1 問題設定

画像特徴量は d 次元ベクトル $\mathbf{x} \in \mathcal{X} \subset \mathbb{R}^d$ で表現され、それぞれクラスラベル $\mathbf{y} \in \mathcal{Y} = \{1, 2, \dots, C\}$ が与えられている。さらに、各画像特徴量に対して、別の p 次元ベクトル $\mathbf{v} \in \mathcal{V} \subset \mathbb{R}^p$ が補助情報として与えられているものとする。本節で説明する教師付き次元削減は、LUPI の一般的な設定と同様、この画像特徴量・補助情報・クラスラベルの三つ組み

$$D = \{(\mathbf{x}_i, \mathbf{v}_i, y_i) | \mathbf{x}_i \in \mathcal{X}, \mathbf{v}_i \in \mathcal{V}, y_i \in \mathcal{Y}, i = 1, \dots, n\}.$$

が学習データとして与えられたときに、各クラスの特徴量をより良く分離する低次元表現 $\mathbf{z} \in \mathcal{Z} \subset \mathbb{R}^m$ ($m \leq d$) を得るための変換 $f: \mathcal{X} \rightarrow \mathcal{Z}$ を獲得することが目的である。ここでは簡単のため、線形変換を対象とする。

3.2 局所線形判別分析

本節では、提案手法の基礎となる局所線形判別分析 (Local Fisher Discriminant Analysis: LFDA) [5] について説明する。

LFDA は、特徴量の局所的な構造を考慮した教師付き次元削減手法であり、クラス間分散を大きくし、クラス内分散を小さくするような線形変換 \mathbf{T}^* を一般化固有値問題によって求める。LFDA では、このクラス内・クラス間分散の計算で、特徴量の局所構造を考慮する。クラス間共分散行列 \mathbf{S}_b 及びクラス内共分散行列 \mathbf{S}_w はそれぞれ以下のよう

$$\begin{aligned} \mathbf{S}_b &= \frac{1}{2} \sum_{i,j=1}^n D_{i,j}^b (\mathbf{x}_i - \mathbf{x}_j) (\mathbf{x}_i - \mathbf{x}_j)^\top, \\ \mathbf{S}_w &= \frac{1}{2} \sum_{i,j=1}^n D_{i,j}^w (\mathbf{x}_i - \mathbf{x}_j) (\mathbf{x}_i - \mathbf{x}_j)^\top, \\ D_{i,j}^b &= \begin{cases} A_{i,j}(1/n - 1/n_c) & \text{if } y_i = y_j = c, \\ 1/n & \text{if } y_i \neq y_j, \end{cases} \\ D_{i,j}^w &= \begin{cases} A_{i,j}/n_c & \text{if } y_i = y_j = c, \\ 0 & \text{if } y_i \neq y_j. \end{cases} \end{aligned}$$

ここで、 n_c はクラス c に所属する特徴ベクトルの数、 $\mathbf{A} = \{A_{i,j}\}$ はアフィン行列と呼ばれ、その i 行 j 列の要素 $A_{i,j}$ に、 i 番目の特徴ベクトルと j 番目の特徴ベクトルとの間の類似性を表現する値を持つ。一般には、局所スケールリング法 [6] で特徴ベクトルからアフィン行列を計算すると良い性能が得られることが知られている [5]。

上記 2 つの共分散行列を用いることで、変換行列 \mathbf{T}^* の各列ベクトルは、以下の一般化固有値問題の解として選られる [7]。

$$\mathbf{S}_b \boldsymbol{\varphi} = \lambda (\mathbf{S}_w + \eta \mathbf{I}_d) \boldsymbol{\varphi}.$$

上記の一般化固有値問題の解のうち、固有値 λ が大きい順に m 本の固有ベクトル $\boldsymbol{\varphi}_1, \dots, \boldsymbol{\varphi}_m$ を取り出し、それを列

ベクトルとして並べた、以下の行列が、求める変換行列 \mathbf{T}^* となる。

$$\mathbf{T}^* = (\boldsymbol{\varphi}_1 | \boldsymbol{\varphi}_2 | \dots | \boldsymbol{\varphi}_m),$$

3.3 補助情報を用いた局所線形判別分析

LFDA では、アフィン行列 \mathbf{A} に特徴ベクトル間の類似関係を持たせ、この類似関係に応じてクラス内・クラス間共分散行列の計算に重み付けを与えていた。一方、本論文で採用する補助情報付き局所線形判別分析 (LFDA with privileged information: LFDA+) [8] では、アフィン行列の計算に補助情報を用いる。より具体的には、補助情報が類似する場合にアフィン行列の要素が大きく、補助情報が大きく異なる場合にアフィン行列の要素が小さくなるように設定することで、補助情報が類似する特徴ベクトルが共通に持つ特徴成分を強調する。

$$A_{i,j} = \exp\left(-\frac{\|\mathbf{v}_i - \mathbf{v}_j\|^2}{2\sigma^2}\right),$$

ここで σ は分散を制御するパラメータである。

3.4 補助情報の構成方法

本節では、補助情報の具体的な構成方法について説明する。補助情報は、前節で述べた通り、各画像 \mathbf{x}_i ($i = 1, 2, \dots, n$) について 1 本の多次元ベクトル \mathbf{v}_i が構成される。特に本節では、2 節で獲得したコンテキストの類似関係を考慮した以下の 3 通りの構成方法を提案する。

User: この構成方法では、所定の画像にどのユーザが興味を持ったかについての情報をベクトル化することにより、関心を持つユーザ層の類似性から画像の類似性を表現することを狙う。具体的には、Pinterest のユーザ数と同じ次元のベクトルを用意し、 j 番目のユーザが i 番目の画像を pin もしくは repin したときに、 i 番目のベクトル \mathbf{v}_i の j 次元目の要素 $v_{i,j}$ を 1 に、それ以外の場合には 0 とする。

Board: この構成方法では、所定の画像がどの board に属しているかについての情報をベクトル化することにより、所属 board の類似性から画像の類似性を表現することを狙う。具体的には、board 数を同じ次元数のベクトルを用意し、 j 番目の board が i 番目の画像を含むとき、 i 番目のベクトル \mathbf{v}_i の j 次元目の要素 $v_{i,j}$ を 1 に、それ以外の場合には 0 とする。

Cluster: この構成方法は、board diffusion graph から抽出した board クラスタに関する情報をベクトル化するもので、最もコンテキストに関する情報が多く含まれると期待される。具体的には、クラスタ数と同じ次元数のベクトルを用意し、 i 番目のベクトル \mathbf{v}_i の j 次元目の要素 $v_{i,j}$ を以下のように設定する。

$$v_{i,j} = n_{i,j}/n_i,$$

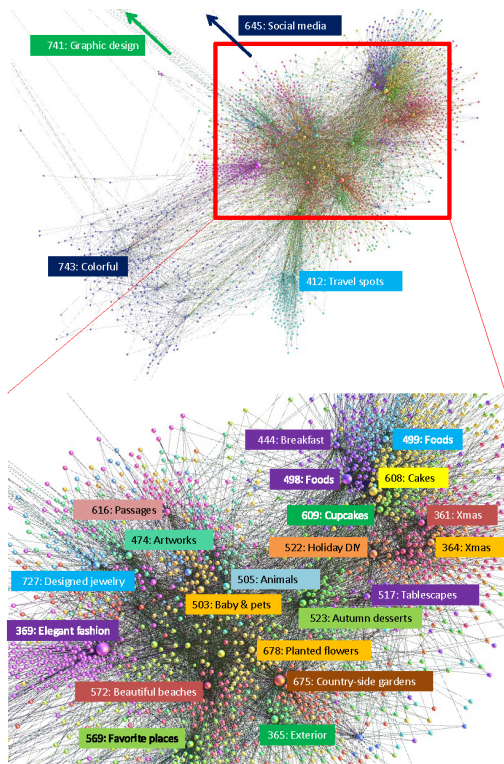


図 5 Board diffusion graph 及びそのクラスタリング結果の可視化

表 1 補助情報の特徴量として画像分類を行った際の分類性能 (in %). 行: 分類器の種類, 列: 補助情報の種類.

	User	Board	Cluster
Linear regression	87.09	98.94	97.36
$k = 1$	85.46	98.70	97.13
kNN $k = 5$	88.08	98.88	97.64
$k = 10$	88.78	98.84	97.62

$n_{i,j}$ は i 番目の画像が j 番目のクラスタに含まれる board に pin されたのべ回数, n_i は i 番目の画像が pin されたのべ回数の合計値である.

4. 実験

本節では, 提案手法の有効性を検証するために行った, Pinterest から収集した実際のソーシャルキュレーションデータを用いた実験の結果について説明する. 収集したデータは 19 万 boards, 104 万 pins によって構成される. 構成された board diffusion graph は 18 万ノード, 32 万エッジを持つスパースなグラフとなり, グラフクラスタリングによって約 1000 個のクラスタを抽出した. 図 5 に, board diffusion graph とそのクラスタリング結果を 2 次元平面上に可視化した結果を示す. 可視化には専用ツール Gephi を利用し, ノードの大きさが次数を, ノードの色が所属するクラスタを表現するように可視化を行った.

4.1 自動検出した画像群のコンテキストの共通性

本節ではまず, Pinterest の board に含まれる画像が共通

表 2 画像分類を行った際の分類性能 (in %). 行: 分類器 (k-NN) の種類, 列: 低次元埋め込み手法の種類. Graph Reg. = グラフ正則化を用いた従来手法 [10].

	Orig.	Graph	PCA	LFDA	Prop.
Linear regression	39.7	39.4	33.6	38.7	42.5
$k = 15$	37.9	-	35.7	42.5	45.1
kNN $k = 20$	38.1	-	36.2	42.7	45.4
$k = 25$	38.2	-	36.4	42.8	45.6

のコンテキストを持つかどうか, 2 節で説明した手法が類似コンテキストを適切に抽出できたかどうか, この 2 点を検証するために, 3 節で提案した補助情報を画像の特徴量と見なして画像分類を実行する予備実験を行った. あらかじめ定めた 10 クラス^{*1}に関連する board と, その board に属する 30 万 pins 及びユニーク画像 20 万枚をデータセットとして用いた. データセット内の各画像について, 3.4 節に説明した 3 通りの手法 (User, Board, Cluster) で補助情報を抽出し, これを画像特徴量とした. 20 万枚の画像を学習用 15 万枚とテスト用 5 万枚にランダムに分割し, 学習用画像の特徴量を用いて 10 クラスの分類器を学習し, テスト用画像で分類器の性能を測定した.

表 1 に, 3 通りの補助情報の構成方法及び 4 通りの分類器についての分類性能を示す. Board 補助情報がいずれの分類器においても非常に高い分類性能を示している表 1 の結果は, board に含まれる画像が共通するコンテキストを持っていることを示唆するものである. また, Cluster 補助情報が board 補助情報とほぼ同等の分類性能を示していることから, 2 節で説明した, board diffusion graph のクラスタリングに基づく提案手法が, キュレーションデータに内在する画像のコンテキストを適切に抽出できていることを示唆する結果であると言える.

4.2 コンテキストを考慮した特徴量の低次元埋め込みの効果

続いて, 抽出したコンテキストが画像の認識・検索に有用であるか, 提案の画像特徴量の低次元埋め込み手法が有効に機能するか, この 2 点について検証する. 本節では, 前節に示したデータから無作為に抽出した画像 12500 枚及び関連する pin や board の情報をデータセットとして利用する. このデータセットに含まれる Pinterest ユーザ数は 170, board 数は 630, board クラスタ数は 390 であった. 画像分類のための画像特徴として, 本節では, 大域的特徴量の一つである GIST [9] 960 次元を用いる.

続いて, 表 2 に, 提案手法を画像分類のタスクに利用した際の実験結果を示す. ここでは, PCA・LFDA の他に, 低次元埋め込みをしない GIST 960 次元 (Orig.), 及びグラフ構造を分類学習の正則化に利用する従来手法 [10] (Graph

^{*1} Architecture, fashion, cupcake, animals, chocolate, flowers, blue, sea, Christmas, green の 10 クラス.




図 6 特徴量埋め込み手法の比較. 横軸: 埋め込み次元数, 縦軸: 画像分類の分類率.

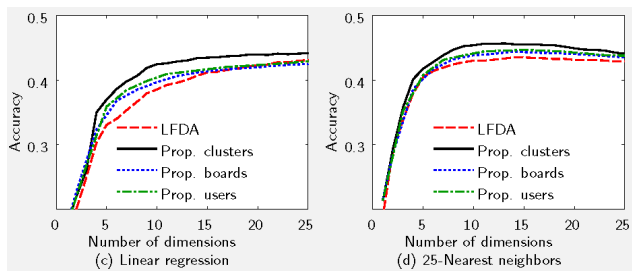


図 7 補助情報の比較. 横軸: 埋め込み次元数, 縦軸: 画像分類の分類率.

Reg.) と, 提案手法 (LFDA+, cluster 補助情報) の性能を比較する. 手法 Graph Reg. では, board diffusion graph を正規化のためのグラフ構造として利用した. 低次元埋め込みを行わない Orig. と提案手法 Prop. との比較から, コンテキストを考慮した補助情報を利用することにより, 特徴量次元数が大幅に減っているにもかかわらず, より優れた分類性能を示すことがわかる. また, 従来法 Graph Reg. と提案手法 Prop. との比較から, 提案する低次元埋め込みがグラフ構造の利用方法としてより適切であることがわかる. また, 提案手法と他の埋め込み手法との比較から, コンテキストを考慮した補助情報が分類性能向上に大きく寄与することがわかる.

図 6 及び 7 に, 埋め込み次元数を変化させたときの分類性能の変化の様子を示す. 図 6 では異なる特徴量埋め込み手法の比較を, 図 7 では異なる補助情報の構成方法の比較を行っている. 図 6 から, 提案手法がいずれの埋め込み次元においても他の手法よりも高い性能を示し, 非常に低い次元でほぼ最高の性能に到達していることがわかる. また, 図 7 から, わずかではあるが cluster information が他の構成方法よりも高い性能を示すことが見て取れる.

5. まとめ

本論文では, ソーシャルキュレーションのプロセスに着目することで, 共通のコンテキストを持つ画像群を非常にシンプルにかつ大量に発見する手法を提案すると共に, 発見した画像群を画像認識・検索のコーパスとして利用するための重要なステップとして, コンテキストの共通性を考慮した画像特徴量の低次元埋め込み手法を提案した. 提案

手法により, 言語化が必ずしも容易は限らないコンテキストの類似関係を, 低次元画像特徴量の類似関係に変換できるようになると共に, より高次の意味や概念を考慮した画像分類・認識・検索が可能となることを示した. 画像分類をタスクとする実験により, 提案手法の有効性を示した.

参考文献

- [1] Blondel, V., Guillaume, J.-L., Lambiotte, R. and Lefebvre, E.: Fast unfolding of communities in large networks, *Journal of Statistical Mechanics*, Vol. 2008, No. 10, p. P10008 (2008).
- [2] Shiokawa, H., Fujiwara, Y. and Onizuka, M.: Fast algorithm for modularity-based graph clustering, *AAAI* (2013).
- [3] Vapnik, V. and Vashist, A.: A new learning paradigm: Learning using privileged information, *Neural Networks*, Vol. 22, No. 576, pp. 544 – 557 (2009). *Advances in Neural Networks Research: {IJCNN2009}* 2009 International Joint Conference on Neural Networks.
- [4] Sharmanska, V., Quadrianto, N. and Lampert, C.: Learning to Rank Using Privileged Information, *Computer Vision (ICCV), 2013 IEEE International Conference on*, pp. 825–832 (2013).
- [5] Sugiyama, M.: Dimensionality Reduction of Multimodal Labeled Data by Local Fisher Discriminant Analysis, *Journal of Machine Learning Research* (2007).
- [6] Zelnik-Manor, L. and Perona, P.: Self-tuning spectral clustering, *NIPS* (2004).
- [7] Akisato, K., Masashi, S., Hitoshi, S. and Hirokazu, K.: Designing Various Multivariate Analysis at Will via Generalized Pairwise Expression, *IPSJ Transactions on Mathematical Modeling and its Applications (TOM)*, Vol. 6, No. 1, pp. 136–145 (2013).
- [8] Marcos Alvarez, A., Matsumoto, D., Kimura, A., Yamada, M. and Sakano, H.: Dimensionality reduction with privileged information, *Neural Computation* (2013). submitted.
- [9] Oliva, A. and Torralba, A.: Modeling the shape of the scene: A holistic representation of the spatial envelope, *IJCV* (2001).
- [10] Mahajan, D. K. and Slaney, M.: Image classification using the web graph, *ACM MM* (2010).