

分散表現を利用した特徴的頻出ビジュアルパターンの抽出

Extracting Characteristic Frequent Visual Patterns by Distributed Representation

河野邊 早¹ 尾崎 知伸^{2*}
Saki Kawanobe¹ Tomonobu Ozaki²

¹ 日本大学大学院総合基礎科学研究科

¹ Graduate School of Integrated Basic Sciences, Nihon University

² 日本大学 文理学部

² College of Humanities and Sciences, Nihon University

Abstract: Frequent pattern mining is one of the most important and fundamental tasks in data mining. The main drawbacks of frequent pattern mining include the explosion of discovered patterns as well as less comprehensibility. In this paper, an application of distributed representation techniques to frequent visual pattern mining is proposed in order to alleviate the drawbacks and to derive characteristic patterns with high understandability. More specifically, we attempt to identify characteristic patterns by a cluster analysis in the vector space and to help understanding of the meaning of patterns by associating tags. We assess the effectiveness of the proposed framework using a social media dataset.

1 はじめに

データ集合中に現れる特徴的な組み合わせをパターンとして抽出する頻出パターン発見 [1] は、データマイニングの基本的な問題であり、これまでにグラフ [2, 3] や動画像 [4], 軌跡 [5] などを含め、様々な拡張と幅広い分野での応用が行われている。一般に頻出パターン発見における問題点として、閾値の設定によっては大量のパターンが抽出されてしまう点や、得られたパターンの解釈が必ずしも容易ではないという点が指摘されている。前者に対する解決策として、頻度に着目した代表元に基づく圧縮表現 [6, 7] や、統計的なテストに基づくフィルタリング [8, 9], 直交するパターン集合の抽出 [10, 11] などが提案されている。また後者に対する解決策として、各パターンに対して、パターンの構成要素は類似しているが共起性が低いパターンや、逆に構成要素は異なるが共起性が高いパターン等に関連付けるといった手法が提案されている [12, 13]。

本論文では、これらの頻出パターン発見の問題点を緩和する新たな枠組みとして、共起等に基づく対象を低次元の実数ベクトルで表現する分散表現（単語埋め込み）技術 [14, 15, 16, 17] の、獲得パターンへの適用を提案する。より具体的には、分散表現技術を通じて

パターンを実数ベクトル空間上に配置することで、パターン間の距離に基づく代表的なパターンを抽出するとともに、各パターンに対して関連の強いパターン集合の獲得を目指す。なお、前者はパターン発見における一つ目の問題点（大量パターンの抽出）を、後者は二つ目の問題点（解釈困難性）をそれぞれ緩和することを目的としている。また、パターンの解釈容易性のさらなる向上を目的に、各データの関連情報を同一空間に配置することで、パターンと関連情報との強い繋がりを獲得し、パターンの解釈を支援することを試みる。

本論文では、提案する枠組みの適用先として、タグ付き画像データ集合に対するパターン発見を取り上げる。パターン発見の動画像分野への応用は継続的に行われており、これまでに数多くの手法が提案されている [18, 19, 20, 21, 22, 23, 24, 25, 26]。これらの研究と同様、本論文でも、画像特徴量からアイテムを特定し、その配置を含めた組み合わせをビジュアルパターンと定義して抽出の対象とする。抽出されたパターンを代表元だけに絞り込んだ上でそれらの分散表現を求め、クラスタリングを行うことで特徴的なパターンを特定する。またタグ情報とのすり合わせを行うことで、パターンの意味付けを試みる。提案する枠組みの全体像を図 1 に示す。

本論文の構成は以下の通りである。2 章では準備を行い、今回の抽出対象である頻出ビジュアルパターン

*連絡先：日本大学 文理学部 情報科学科
〒156-8550 東京都世田谷区桜上水 3-25-40
tozaki@chs.nihon-u.ac.jp

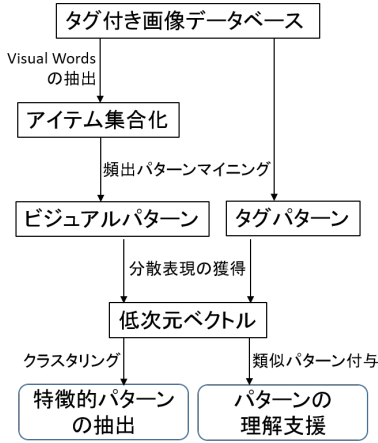


図 1: 提案する枠組みの全体像

の形式的な定義を示す。3章では、パターンに対する分散表現の獲得方法について述べる。4章で実験と考察を行い、最後に5章でまとめと今後の課題を述べる。

2 頻出ビジュアルパターンの抽出

2.1 タグ付き画像のトランザクション化

集合 \mathcal{T} をタグの全体集合とする。今、画像 I とそれに付与されたタグの集合 $T \subseteq \mathcal{T}$ の対をタグ付き画像と呼び、 $Img = \langle T, I \rangle$ と表記する。またタグ付き画像 $Img = \langle T, I \rangle$ の集合 $D = \{Img_1, \dots, Img_{|D|}\}$ を画像データベースと呼ぶ。

一方、SIFT[27] や HOG[28] などを用いて画像の特徴点及び特徴量を求め、それらをクラスタリングすることで生成される Visual Word[29] の集合を \mathcal{VW} と表記する。 m と n をパラメタとし、画像 I を $m \times n$ の格子状に分割する。このとき、領域 (x, y) と、その領域における Visual Word $w \in \mathcal{VW}$ の出現数 $c_w (> 0)$ をまとめて、 $\langle x, y, w : c_w \rangle$ と表記し、一つのアイテムと考える。このアイテムを、位置情報付きアイテムと呼ぶ。以上の準備の下、タグ付き画像 $Img = \langle T, I \rangle \in D$ を、タグ集合 T と位置情報付きアイテムの集合

$$V_I = \left\{ \left\langle x, y, w : c_w \right\rangle \left| \begin{array}{l} x \in \{1, \dots, m\}, \\ y \in \{1, \dots, n\}, \\ w \in \mathcal{VW}, c_w > 0 \end{array} \right. \right\}$$

の対に変換したものを $V(Img) = \langle T, V_I \rangle$ と表記し、一つのトランザクションと見做す。また、画像データベース D 中のすべてのタグ付き画像をトランザクション化することで得られる集合を

$$V(D) = \{V(Img) \mid Img \in D\}$$

と表記し、本研究での入力とする。 $V(D)$ から、位置情報付きアイテムの集合のみ、またはタグ集合のみを取り出した集合をそれぞれ

$$\begin{aligned} I(D) &= \{V_I \mid \langle T, V_I \rangle \in V(D)\} \\ T(D) &= \{T \mid \langle T, V_I \rangle \in V(D)\} \end{aligned}$$

と表記する。

2.2 頻出ビジュアルパターン

画像データベース D に対し、 D 中の位置情報付きアイテムの集合 $p_v \subseteq \bigcup_{x \in I(D)}$ をビジュアルパターンと呼ぶ。通常の頻出パターン発見同様、 D における p_v の支持度を

$$sup_D(p_v) = |\{V_I \in I(D) \mid p_v \subseteq V_I\}| / |D|$$

と定義する。また、支持度に関するパラメタ $\sigma (> 0)$ に対し、 $sup_D(p_v) \geq \sigma$ を満たすパターン p_v を頻出ビジュアルパターンと呼ぶ。さらに条件

$$\forall q_v [p_v \subset q_v \rightarrow sup_D(p_v) > sup_D(q_v)]$$

を満たす頻出ビジュアルパターン p_v を飽和ビジュアルパターンと呼び、その全体集合を $C_v(D, \sigma)$ と表記する。

一方で、 D 中のタグの集合 $p_t \subseteq \bigcup_{x \in T(D)}$ をタグパターンと呼ぶ。 D におけるタグパターン p_t の支持度は、

$$sup_D(p_t) = |\{T \in T(D) \mid p_t \subseteq T\}| / |D|$$

と定義され、 $sup_D(p_t) \geq \sigma$ を満たすパターンを頻出タグパターンと呼ぶ。さらに、 $\delta (\geq 0)$ をパラメタとし、条件

$$\forall q_t [p_t \supset q_t \rightarrow sup_D(p_t) + \delta < sup_D(q_t)]$$

を満たす頻出タグパターン p_t を δ -フリータグパターンと呼び、その全体集合を $F_t(D, \sigma, \delta)$ と表記する。

本研究では、画像データベース D から飽和ビジュアルパターンの集合 $C_v(D, \sigma)$ と δ -フリータグパターンの集合 $F_t(D, \sigma, \delta)$ を抽出する問題を考える。なお高度なアルゴリズムも考えられるが、一般的な頻出パターン発見手法を利用して頻出ビジュアルパターン集合と頻出タグパターン集合を求め、後処理として $C_v(D, \sigma)$ と $F_t(D, \sigma, \delta)$ を求めることも可能である。

3 分散表現の獲得とパターン間距離

トランザクション化されたタグ付き画像 $V(Img) = \langle T, V_I \rangle$ に出現するビジュアルパターン及びタグパターンの集合を、それぞれ

$$\begin{aligned} P_v(Img) &= \{p_v \in C_v(D, \sigma) \mid p_v \subseteq V_I\} \\ P_t(Img) &= \{p_t \in F_t(D, \sigma, \delta) \mid p_t \subseteq T\} \end{aligned}$$

と表記する。また、ビジュアルパターン $p_v \in C_v(D, \sigma)$ またはタグパターン $p_t \in F_t(D, \sigma, \delta)$ の出現集合を

$$\begin{aligned} Occ(p_v) &= \{Img \mid V(Img) = \langle T, V_I \rangle \in V(D), p_v \subseteq V_I\} \\ Occ(p_t) &= \{Img \mid V(Img) = \langle T, V_I \rangle \in V(D), p_t \subseteq T\} \end{aligned}$$

と表記する。

本研究では、各タグ付き画像に出現するパターンの集合を一つの単位と考え、word2vec[15, 16] や GloVe[17] などの分散表現獲得技術を利用し、各パターンを低次元ベクトル化する。より形式的には、データベース D とビジュアルパターンの集合 $C_v(D, \sigma)$ 、タグパターンの集合 $F_t(D, \sigma, \delta)$ から、新たなトランザクション集合 $\{P_v(Img) \mid Img \in D\}$ もしくは $\{P_v(Img) \cup P_t(Img) \mid Img \in D\}$ を獲得し、これらを使用して各パターンの低次元ベクトル化を行う。

パターン p に対する低次元ベクトルを \vec{p} と表記する。このとき二つのパターン p, q 間の距離として、ベクトルのコサイン距離

$$\cos(\vec{p}, \vec{q}) = 1 - \frac{\vec{p} \cdot \vec{q}}{|\vec{p}| |\vec{q}|}$$

を採用する。一方で、パターンの出現集合に着目した距離として、出現集合の Jaccard 距離

$$jac(p, q) = 1 - \frac{Occ(p) \cap Occ(q)}{Occ(p) \cup Occ(q)}$$

を利用する。パターン間の距離を考えることで、クラスタリングによる代表的パターンの抽出と、類似パターンの関連付けが達成される。

4 実験と考察

提案した枠組みの有効性を確認するため、ソーシャルメディアに関する実データを利用して評価実験を行った。実験では、国立情報学研究所が提供しているニコニコデータセット¹に含まれる「スポーツ」タグを持つ動画約8万件から、ランダムに2万件のデータを選択し、動画に付与されたタグ集合とサムネイル画像を対とするデータセットを作成した。データセット中の5000件のデータを利用して Visual Words を作成し、各画像を 13×10 の領域に分割することで、タグ付きサムネイル画像のトランザクション化を行った。得られたトランザクションデータベース $T(D)$ から、飽和ビジュアルパターンの集合 $C_v(D, 0.05)$ と、 δ -フリータグパターンの集合 $F_t(D, 0.01, 0.025)$ を抽出した。なお、得られたパターン数はそれぞれ 1819 及び 569 であった。

分散表現の獲得には、GloVe[17]²を利用した。なお、次元数は50、学習の繰り返し回数の最大値は15とした。

¹<http://www.nii.ac.jp/dsc/idr/nico/nico.html>

²<http://nlp.stanford.edu/projects/glove/>

表 1: セントロイド集合の出現数分布

	P_{cos}	P_{jac}
最小値	11.0	11.00
第1四分位数	14.0	30.0
中央値	30.0	33.0
平均値	33.8	38.6
第3四分位数	53.0	40.0
最大値	101.0	79.0
分散	494.1	216.3

4.1 パターン分布の視覚化

パターン間の距離として、分散表現のコサイン距離及び出現集合の Jaccard 距離をそれぞれ採用し、多次元尺度法を用いてビジュアルパターンとタグパターンの分布を視覚化した。図2に結果を示す(各距離の分布図において、スケールが異なる点に注意が必要である)。

図より、出現集合の Jaccard 距離を利用した場合と比較し、分散表現のコサイン距離を採用した場合にパターンの分布が広がっていることが確認できる。広く分布している方が、よりの確にパターン間の関連性を捉えていると考えられるので、その意味では分散表現を採用した効果が認められる。

ところで、Jaccard 距離を採用した場合に分布が広がらないことの要因として、出現集合に共通要素がないパターンの組はすべてその距離が1となってしまう、うまく差別化ができていない点あげられる。分散表現を採用した場合は、このような問題が回避されていると考えられる。

4.2 パターンのクラスタリング

飽和ビジュアルパターンの集合に対し、各パターン間距離を基にした分割型クラスタリング (K-medoid 法) を適用した上でクラスタ中心を集めることで、パターン数の圧縮を試みた。なおここで、対象は頻度に関する圧縮表現である飽和ビジュアルパターンであり、それを更に距離の観点から圧縮しているという点に注意が必要である。



今回の実験ではクラスタ数 $K = 200$ とし、約11%への圧縮を行った。分散表現のコサイン距離を用いた場合に得られるパターンの集合 P_{cos} と出現集合の Jaccard 距離を用いた場合に得られるパターンの集合 P_{jac} の間の Jaccard 類似度 $\left(\frac{P_{cos} \cap P_{jac}}{P_{cos} \cup P_{jac}}\right)$ は0.34であり、両者間で多くの異なるパターンが得られていることが分かる。

表1に、 P_{cos} 、 P_{jac} それぞれに含まれるパターン p の出現数 ($|Occ(p)|$) の分布を示す。表より、 P_{cos} の方

分散表現のコサイン距離

出現集合の Jaccard 距離

ビジュアルパターンのみ



ビジュアルパターン+タグパターン





図 2: 各距離に基づくビジュアルパターンの分布

表 2: コサイン距離と Jaccard 距離の差正負各上位 10 対パターン対 値

パターン対	値	パターン対	値
$\langle P_{137}, P_{192} \rangle$	0.62	$\langle P_{426}, P_{427} \rangle$	-0.69
$\langle P_{137}, P_{197} \rangle$	0.61	$\langle P_{140}, P_{141} \rangle$	-0.66
$\langle P_{137}, P_{193} \rangle$	0.61	$\langle P_{15}, P_{16} \rangle$	-0.65
$\langle P_{137}, P_{191} \rangle$	0.61	$\langle P_{100}, P_{101} \rangle$	-0.62
$\langle P_{75}, P_{137} \rangle$	0.61	$\langle P_{222}, P_{223} \rangle$	-0.60
$\langle P_{197}, P_{258} \rangle$	0.60	$\langle P_{129}, P_{130} \rangle$	-0.59
$\langle P_{137}, P_{201} \rangle$	0.60	$\langle P_{252}, P_{253} \rangle$	-0.59
$\langle P_{76}, P_{137} \rangle$	0.59	$\langle P_{16}, P_{17} \rangle$	-0.55
$\langle P_{367}, P_{432} \rangle$	0.59	$\langle P_{101}, P_{102} \rangle$	-0.53
$\langle P_{143}, P_{192} \rangle$	0.59	$\langle P_{432}, P_{433} \rangle$	-0.53

が四分位範囲、分散共に大きく、頻度という意味で多様なパターンが獲得できていることが伺える。

4.3 距離の違いに着目した特徴的パターン対の抽出

分散表現のコサイン距離と出現集合の Jaccard 距離は、いずれも共起性に着目した距離であると考えられる。このことに着目し、分散表現のコサイン距離と出現集合の Jaccard 距離との差が大きなビジュアルパターン対を、特徴的なパターン対として抽出する。2つのパターン p, q に対する距離の差 $\cos(\vec{p}, \vec{q}) - jac(p, q)$ を基準に、正負各上位 10 対を表 2 に示す。

表中に現れる 3 つのパターン $P_{367}, P_{432}, P_{433}$ に関しては、 $|P_{367}| = 4, |P_{432}| = 8, |P_{433}| = 9$ かつ $P_{367} \subset P_{432} \subset P_{433}$ という関係が成り立つ。その一方で、対 $\langle P_{367}, P_{432} \rangle$ はコサイン距離が大きく、対 $\langle P_{432}, P_{433} \rangle$ は Jaccard 距離が大きいなど、パターンの包含関係だけでは捉えきれない関係性が一部抽出できていると考えられる。特に P_{367} は P_{432} に包含されるも関わらず両者の意味は大きく異なり、差分 $P_{432} \setminus P_{367}$ にその要因があると推測できるため、距離の差分を考えることは、パターン間やパターンの構成要素に対するより詳細な分析にも繋がると考えられる。

4.4 異種パターン間の関連付け

各パターンの理解を支援するために、タグパターンに対し、分散表現のコサイン距離が小さいビジュアルパターンを対応付けることを試みた。得られた幾つかの例を表 3 に示す。表より、一つのビジュアルパターンが複数のタグパターンと類似していることが分かる。このことは、一つのパターンの解釈に複数の類似パター

表 3: タグパターンに対して類似性の高いビジュアルパターン対の例

タグパターン	ビジュアルパターン
{ バスケ }	$P_{87}, P_{622}, P_{1398}$
{ プロ野球, 野球 }	$P_{87}, P_{285}, P_{1129}$
{ 野球, mlb }	$P_{87}, P_{622}, P_{1398}$
{ 読売ジャイアンツ }	$P_{622}, P_{1398}, P_{1488}$
{ 阪神タイガース }	$P_{285}, P_{622}, P_{1398}$
{ 競艇 }	$P_{87}, P_{622}, P_{1398}$
{ 格闘技, k-1 }	$P_{87}, P_{1329}, P_{1398}$
{ サッカー, j リーグ }	P_{87}, P_{285}, P_{622}
{ 車載動画, モータースポーツ }	$P_{87}, P_{622}, P_{1398}$

ンが利用できることを表しており、その意味で解釈容易性の向上につながる結果であると考えられる。

5 まとめと今後の課題

本論文では、頻出パターン発見の問題点を軽減することを目的に、分散表現技術のパターンマイニング分野への導入を行った。またタグ付き画像データ集合におけるビジュアルパターンとタグパターンを対象に種々の実験を行い、その有用性を確認した。

今後の課題としては、提案した枠組みの構造データマイニングへの応用があげられる。また、更なる理解容易性の向上を目的に、加法構成性に基づきパターン間の関連性を解釈することを検討している。一方で、今回は比較として出現集合の Jaccard 距離を採用したが、出現集合をベクトル化した上で次元圧縮することでも有用な距離が得られる可能性があると考えている。その際、積層ノイズ除去自己符号化器 [30] 等の利用を検討している。

謝辞 本研究では、国立情報学研究所のダウンロードサービスにより株式会社ドワンゴから提供を受けた「ニコニコ動画コメント等データ」を利用した。

参考文献

- [1] J. Han, H. Cheng, D. Xin and X. Yan : Frequent pattern mining: current status and future directions, *Data Mining and Knowledge Discovery*, Vol.15, No.1, pp.55-86, 2007.
- [2] L. De Raedt, T. Washio and J.N. Kok (eds.) : *Advances in Mining Graphs, Trees and Sequences*, IOS Press, 2006.
- [3] C. C. Aggarwal and H. Wang (eds.) : *Managing and Mining Graph Data*, Springer, 2010.

- [4] H. Wang, G. Zhao and J. Yuan : Visual Pattern Discovery in Image and Video Data: A Brief Survey, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Vol.4, No.1, pp.24–37, 2014.
- [5] 耿 晓亮, 宇野 毅明, 有村 博紀 : 大規模軌跡データからの群パターン発見のための実用的アルゴリズム, *情報処理学会論文誌*, Vol.56, No.4, pp.1292–1304, 2015.
- [6] J.-F. Boulicaut, A. Bykowski and C. Rigotti : Free-Sets : A Condensed Representation of Boolean Data for the Approximation of Frequency Queries, *Data Mining and Knowledge Discovery*, Vol.7, No.1, pp.5–22, 2003.
- [7] J. Cheng, Y. Ke and W. Ng : δ -Tolerance Closed Frequent Itemsets, *Proc. of the 6th IEEE International Conference on Data Mining*, pp.139–148, 2006.
- [8] G. I. Webb : Discovering Significant Patterns, *Machine Learning*, Vol.68, No.1, pp.1–33, 2007.
- [9] W. Hämmäläinen and G. I. Webb : Statistically sound pattern discovery, *Proc. of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.1976, 2014.
- [10] M. Hasan, V. Chaoji, S. Salem, J. Besson and M. Zaki : ORIGAMI: Mining Representative Orthogonal Graph Patterns, *Proc. of the 7th IEEE International Conference on Data Mining*, pp.153–162, 2007.
- [11] A. J. Knobbe and E. K. Y. Ho : Pattern Teams, *Proc. of the 10th European Conference on Principles and Practice of Knowledge Discovery in Databases*, pp.577–584, 2006.
- [12] 尾崎 知伸, 大川 剛直 : グラフデータベースからの頻出相互関連部分グラフ集合の発見, *人工知能学会論文誌*, Vol.23, No.6, pp.514–525, 2008.
- [13] T. Ozaki and M. Etoh : Correlation and Contrast Link Formation Patterns in a Time Evolving Graph, *Workshops Proceedings of the 11th IEEE International Conference on Data Mining*, pp.1147–1154, 2011.
- [14] Q. Le and T. Mikolov : Distributed representations of sentences and documents arXiv preprint, arXiv:1405.4053v2, 2014.
- [15] T. Mikolov, K. Chen, G. Corrado and J. Dean : Efficient Estimation of Word Representations in Vector Space, arXiv preprint, arXiv:1301.3781, 2013.
- [16] T. Mikolov, I. Sutskever, K. Chen, G. S. Corrado and J. Dean : Distributed Representations of Words and Phrases and their Compositionality, *Advances in Neural Information Processing Systems 26*, pp.3111–3119, 2013.
- [17] J. Pennington, R. Socher and C. D. Manning : GloVe: Global Vectors for Word Representation, *Proc. of the 2014 Conference on Empirical Methods in Natural Language Processing*, pp.1532–1543, 2014.
- [18] B. Fernando, E. Fromont and T. Tuytelaars : Effective Use of Frequent Itemset Mining for Image Classification, *Proc. of the 12th European Conference on Computer Vision*, Vol.1, pp.214–227, 2012.
- [19] J. Yuan, Y. Wu and M. Yang : From Frequent Itemsets to Semantically Meaningful Visual Patterns, *Proc. of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.864–873, 2007.
- [20] S. Kim, X. Jin and J. Han : DisIClass: Discriminative Frequent Pattern-Based Image Classification, *Proc. of the Tenth International Workshop on Multimedia Data Mining*, Article No. 7, 2010.
- [21] Y. A. Sait and B. Ravindran : Visual Object Detection using Frequent Pattern Mining, *Proc. of the 23rd International Florida Artificial Intelligence Research Society Conference*, 2010.
- [22] A. J. T. Lee, R.-W. Hong, W.-M. Ko, W.-K. Tsao and H.-H. Lin : Mining spatial association rules in image databases, *Information Sciences*, Vol.177, pp.1593–1608, 2007.
- [23] H. Liu, and S. Yan : Common visual pattern discovery via spatially coherent correspondences, *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, San Francisco, pp.1609–1616, 2010.
- [24] L. Wang, Y. Wang, T. Jiang and W. Gao : Instantly telling what happens in a video sequence using simple features, *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.3257–3264, 2011.
- [25] W.-T. Chu and M.-H. Tsai : Visual pattern discovery for architecture image classification and product image search, *proc. of the 2nd ACM International Conference on Multimedia Retrieval*, Article No. 27, 2013.
- [26] 辻 智和, 古賀 久志, 横山 貴紀, 渡辺 俊典 : 頻出グラフマイニングを利用した動画画像解析, *電子情報通信学会論文誌 D*, Vol.J93-D, No.2, pp.86–99, 2010.
- [27] D. G. Lowe : Object recognition from local-invariant features, *Proc. of IEEE International Conference on Computer Vision*, pp.1150–1157, 1999.
- [28] N. Dalal and B. Triggs : Histograms of oriented gradients for human detection, *Proc. of IEEE Conference on Computer Vision and Pattern Recognition*, pp.886–893, 2005.
- [29] G. Csurka, C. R. Dance, L. Fan, J. Willamowski, C. Bray : Visual categorization with bags of keypoints, *Workshop on Statistical Learning in Computer Vision*, pp.1–22, 2014.
- [30] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio and P.-A. Manzagol : Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion, *The Journal of Machine Learning Research*, Vol.11, pp.3371–3408, 2010.