

## SIFT 特徴の軸方向左右反転による疑似特徴を利用した教師特徴の増補

増尾 拓朗<sup>†</sup> 小嶋 和徳<sup>†</sup> 伊藤 慶明<sup>†</sup> 石亀 昌明<sup>†</sup>

岩手県立大学大学院ソフトウェア情報学研究科<sup>†</sup>

### 1. はじめに

本研究では, bag-of-keypoints<sup>1)</sup>手法による一般物体認識における SIFT 特徴量を軸方向に対して左右反転して記述することで, 教師画像の左右反転画像の特徴量を擬似的に取得する. 得られた左右反転特徴を追加的な教師データとして扱うことで, 一般物体認識の精度向上を図る.

本研究ではこれまで, Caltech101<sup>2)</sup>及び Caltech256<sup>2)</sup>の一部画像を用いての分類実験を行った<sup>3)</sup>. これらの実験では, 意図的に教師画像とは左右逆向きの画像を評価画像に含めて実験を行い, 提案手法による精度向上を確認した.

本稿では, より一般的な画像である Graz\_02を対象とし, 認識精度及び処理時間について先行研究との比較を行い, 提案手法の有効性の確認を行う.

### 2. 一般物体認識の概要

#### 2.1. SIFT 特徴量

画像中のエッジから, 注目画素とその近傍画素の輝度差が大きく, 輝度勾配方向が明確な画素を SIFT 特徴点として検出する. 特徴点とその周辺画素領域中で最も強い勾配強度を持つ方向を特徴点の軸方向とし, その軸方向に沿って正規化された4×4ブロック・各ブロック8方向の勾配ヒストグラムにより特徴量の記述を行う. SIFT 特徴量には, スケールに影響されない, 回転に影響されないというメリットがある.

#### 2.2. 一般物体認識の流れ

まず, 全ての教師画像から SIFT 特徴量を抽出する. 抽出した全ての SIFT 特徴量を K-means 等でクラスタリング, 量子化し, コードブックを作成する. このコードブックを用い

て各教師画像の SIFT 特徴量の量子化ヒストグラムを生成し, 認識用の特徴量とする. 次に, サポートベクタマシン (SVM) 等の識別器を用いてカテゴリ別の特徴量分布の学習を行う. 評価画像の分類を行う際には, 学習時と同じプロセスで評価画像から SIFT 特徴量の抽出, 教師画像から生成したコードブックを用いた量子化ヒストグラムの生成, 学習した特徴量分布との比較を行い, 画像の分類を行う.

### 3. SIFT 特徴の軸方向左右反転

一般物体認識の処理の中で, 特徴量のクラスタリングには教師画像数及びクラスタ数の増加に伴い膨大な処理時間が必要となる. そこで, SIFT 特徴量の左右反転を行い新たな教師データとして追加 (補強) することで, 少ないクラスタ数での認識率を向上させるとともに学習時間の抑制を図る.

前述の通り, SIFT 特徴量は軸方向に沿った4×4ブロック・各ブロック8方向の勾配ヒストグラムで記述される. そこで, 左右反転の教師データは図2に示す通り, 記述領域の列を軸方向に対して左右反転し, ブロック内の8方向ヒストグラムを本来とは逆回りに記述することで擬似的な反転画像の特徴とする.




図1: SIFT 特徴の軸方向左右反転の概要

これにより, 計算時間を要する SIFT 特徴量を, 追加的な計算なしに得ることができる. 本手法を教師画像及びコードブックに対して行い, 認識精度の向上を図る.

A Supplement of Supervised Data by Horizontal Reverse of SIFT Orientation

<sup>†</sup> Takuro Masuo, Kazunori Kojima, Yoshiaki Ito, Masaaki Ishigame, Graduate School of Software and Information Science, Iwate Prefectural University

## 4. 実験

### 4.1. 実験方法

提案手法の有効性を確認するため、実験データに対し先行研究<sup>1)</sup>手法と提案手法を用いて比較実験を行う。クラスタリングには K-means++<sup>5)</sup>を使用し、クラスタ数は 100, 200 及び 500 とする。分類には LIBSVM<sup>6)</sup>の RBF カーネルを用いる。

### 4.2. 実験データ

実験に用いるデータを表 1 に示す。

表 1: 実験に用いるデータ

画像	Graz_02 <sup>4)</sup>			
カテゴリ	bike	cars	person	none
画像数	300	300	300	300

bike, cars, person カテゴリは付属のアノテーション画像を用いて背景除去済みのものを使用する。none カテゴリは背景 (カテゴリ無) 画像である。各カテゴリ 300 枚の画像から、100 枚を評価画像、200 枚を学習画像とし、クロスバリデーションによる評価を行う。

### 4.3. 実験結果

実験結果を表 2 に示す。

表 2: 先行研究と提案手法の結果比較

クラスタ数	手法	正答率	K-means++ 処理時間
100	先行研究	85.00%	9hour20min
	提案手法	87.67%	
200	先行研究	86.87%	12hour
	提案手法	88.43%	
500	先行研究	87.75%	27hour30min
	提案手法	88.50%	

同クラスタ数同士での比較では、クラスタ数が 100 の時先行研究では 85.00%に対し本手法では 87.67%、200 の時先行研究が 86.87%に対し本手法が 88.43%、500 の時先行研究が 87.75%に対し本手法が 88.50%となり、いずれも本手法により精度の向上が見られた。また、本手法によるクラスタ数 200 時の結果が先行研究におけるクラスタ数 500 時と同等となっている。このことから、本手法は認識精度を維持したまま処

理時間を短縮することができると思われる。

カテゴリ別で見ると、cars, person カテゴリの認識精度に向上が見られた。4 カテゴリの特徴数の関係を見ると、none, bike, person, cars の順に特徴数が多かった。このことから、本実験では、cars や person のような特徴数の少ないデータに対する特徴の補強方法として有効であると考えられる。

## 5. おわりに

本稿では、SIFT 特徴の軸方向左右反転による疑似特徴を用いた教師データ、コードブック補強の有効性を示すため、Graz\_02 に対して実験を行った。実験の結果から、本手法は教師データが少ないデータに対し有効であり、クラスタ数を抑えても高い認識精度を維持しつつ、処理時間を削減できる利点を確認した。今後は多カテゴリ分類問題における性能を調査する必要があると考えている。

### 参考文献

- 1) C. Dance, J. Willamowski, L. Fan, C. Bray, and G. Csurka, "Visual categorization with bags of keypoints", Workshop on Statistical Learning in Computer Vision, ECCV, pp.1-22, 2004.
- 2) "Computational Vision at CALTECH", <http://www.vision.caltech.edu/>, (閲覧 1 月 11 日).
- 3) 増尾拓朗, 小嶋和徳, 伊藤慶明, 石亀昌明, "SIFT 特徴の軸方向左右反転による疑似特徴を利用した教師データ補強の検討", 電気関係学会 TSJC2010, p.112, 2010.
- 4) "GRAZ\_02", [http://www.emt.tugraz.at/~pinz/data/GRAZ\\_02/](http://www.emt.tugraz.at/~pinz/data/GRAZ_02/), (閲覧 1 月 11 日)
- 5) David Arthur et al., "k-means++: The advantages of careful seeding", Proc. of the eighteenth annual ACM-SIAM symposium on Discrete algorithms, pp.1027-1035, 2007.
- 6) "LIBSVM", <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>, (閲覧 1 月 11 日).