1T-7

オンライン物体認識に関する一考察

カーンクアクーン ピシャイ ・ 木村 大毅
カーウィーウォン アラム ・ タンロアムサブ シリナート ・ 長谷川 修
東京工業大学

1. はじめに

人の生活環境で動作するロボットに搭載する画像認識システムには，以下の機能が求められる．

- 刻々と変化する環境に対応するための，未知の物体を逐次的に追加学習できる機能
- 複雑な物体配置においても（例えば，隠れ）頑健に動作する機能

従来のオンライン追加学習手法では，用いる特徴量が大局的な特徴量に限られていた．しかし一般に，大局的な特徴量は局所的な特徴量に比べ，複雑に配置された物体の認識には適さない[1]．

そこで本研究では，局所特徴量を用いることで，隠れが存在する複雑な物体配置でも頑健に動作するオンライン物体認識手法を提案する．

2. 問題定義

物体認識は，入力画像に対して，適切なクラスを推定するタスクである．これは，入力画像をx，クラスをyとしたときに，P(y|x)を最大化するyを求めることと定義できる．ここでは，画像xから抽出される特徴量z_nを用いてP(y|x)を以下の式(1)のように近似する．

$$P(y|x) \sim P(y|\bigcap_n z_n) \cdots\cdots\cdots\cdots\cdots\cdots (1)$$

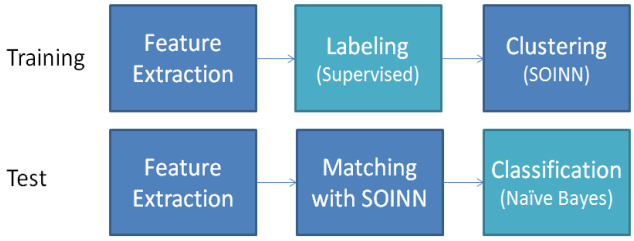

図1: 提案手法の処理の概要

3. 提案手法

提案手法の処理の概要を図1に示す．本研究では，優れた頑健性を有するSIFT特徴を局所特徴量として用いる．正規化されたSIFT特徴は，スケールや二次元回転に対する不変性と，照明変化に対する頑健性を持つ[1]．

学習では，画像から抽出したSIFT特徴を，自己増殖型ニューラルネットワーク（Self-Organizing Incremental Neural Network, 以下SOINN）に入力し，クラスタリングと情報の保持を行う．オリジナルのSOINNは教師なし学習手法であるが[2]，本研究では学習クラスのラベルを教師IDとして与える．この時，教師IDはクラスタリングに影響せず，SOINNが持つノイズ耐性やオンライン追加学習特性は保たれる．ただし，ノードが削除される際には，そのノードの最近傍ノードに教師ID情報を移動する．

テストでは，学習と同様に画像からSIFT特徴を抽出し，SOINN内にある全ノードがもつ特徴とマッチングを行う．この時のしきい値を特徴ベクトル間の角度θと設定する．この際，一つの画像に対して複数のマッチング特徴が得られ，それらをナイーブベイズ分類器[3]に適用し，画像のクラスを確率的に推定する．

4. 実験

提案手法の性能の定量評価実験には，Amsterdam Library of Object Images[4] (ALOI)を用いた．ALOIは，黒い背景で1000個の物体を回転させながら撮影した，特定物体の画像のデータベースである．図2に本実験で用いた画像例を示す．以下の実験1から3において，学習とテストでは異なる画像を用いた．

● 実験1

まず，提案手法の認識率を評価する．ここで認識率とは，クラスを正しく推定できた画像の枚数と全画像枚数の比と定義する．

An Online Object Recognition
Kankuekul Pichai, Daiki Kimura, Kawewong Aram, Tangruamsub Sirinart, Osamu Hasegawa
Tokyo Institute of Technology

Copyright ©2011 Information Processing Society of Japan.
All Rights Reserved.

図2: 実験に使用したALOIデータベースの画像例

次の３つの学習手法を比較する．

(ア) 全データを記録する手法（ベースライン）

(イ) 0,10,…,350度の画像から抽出したSIFT特徴をオンラインでSOINNに入力し学習させる手法

(ウ) 0,0,10,10,…,350,350度の画像から抽出したSIFT特徴オンラインでSOINNに入力し学習させる手法

実験結果を表1に示す．本実験に使用したクラス数は30，SOINNのパラメータλは4000，AgeMaxは10である．SOINNのパラメータは，予備実験の結果に基づき決定した．

表1の角度認識率とは，クラスに加え物体の角度（向き）まで正しく認識できた割合を示す．

表1: 認識率の比較

	SIFT数	ノード数	クラス認識率(%)	角度認識率(%)
（ア）	32856	32569	98.6	94.2
（イ）	32856	4043	85.8	21.5
（ウ）	65712	13464	95.8	78.8

● 実験2

ここでは，実験1(ア)～(ウ)のテストに要した時間の比較を行う．図3に実験結果を示す．

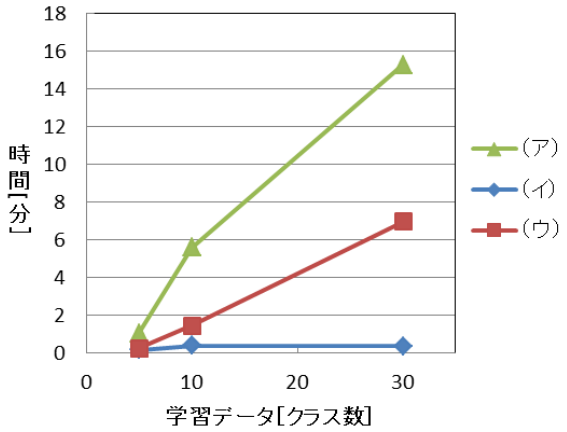

図3: テストに要した時間の比較

● 実験3

隠れのある物体配置でも頑健に認識できることを確認するために，図4(左)のような隠れがある物体の認識を試みた．初期の結果として，図4(右)に示すような良好な結果を得ることができた．

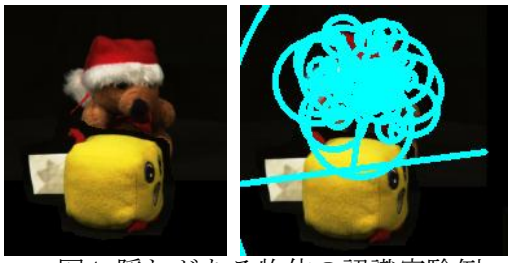

図4: 隠れがある物体の認識実験例
(左)隠れがある画像
(右)隠れがある物体を認識した結果

5. 考察

実験の結果，提案手法により，認識率をある程度保持したまま，テスト時間を短縮することができた．これはSOINNを用いることで，ノイズを含む画像データでも類似特徴の縮約が良好に行えたためと考えられる．

提案手法により，複雑な物体配置でも頑健なオンライン追加学習と物体認識が実現できる可能性が示唆された．

今後は，より多数のクラスの物体が複雑に配置された画像に対する頑健性の定量的性能評価を行う予定である．

6. むすび

本稿では，局所特徴量を用いることで，隠れのある物体配置でも頑健に動作する，オンライン追加学習可能な物体認識手法を提案した．今後のさらなる課題として，実環境で撮影した背景のある画像を用いた実験や，提案手法のロボットへの適用などが挙げられる．

【参考文献】

[1] M.P.Roth and M.Winter., Survey of Appearance based Methods for Object Recognition, *Inst. for Computer Graphics and Vision Graz University, Austria*, 2008.

[2] Furao Shen and Osamu Hasegawa, An Incremental Network for On-line Unsupervised Classification and Topology Learning, *Neural Networks*, 2005

[3] Alfons Juan and Hermann Ney, “Reversing and smoothing the multinomial naive bayes text classifer”, *In Proceedings of the 2nd International Workshop on Pattern Recognition in Information Systems*, 2002

[4] ALOI Dataset, http://staff.science.uva.nl/~aloi/

Copyright ©2011 Information Processing Society of Japan.
All Rights Reserved.