

画像の多重解像度表現を用いた有効な特徴量選択に関する研究 Selection of Effective Features in Multi-Resolutions of images

高井 日淑[†] 長尾 智晴[†]
Hisumi Takai Tomoharu Nagao

1. はじめに

近年、計算機による画像分類のニーズが増えている。画像分類の研究として、分類器の精度向上に関する研究と分類に有効な特徴量を選択する研究と大きく分けて2種類の研究がなされている。後者の研究では、画像全体の特徴量や局所的な特徴量が用いられているが、画像全体の特徴量は局所的な特徴を失いやすく、逆に局所的な特徴に注目し過ぎるとまわりとの関係性を失いやすくなってしまふ。そこで、局所部分の範囲をどう決定するかが大きな課題となっている。

そこで本研究では、この問題を解決するための第一歩として、解像度別の特徴が画像分類の精度向上につながることを示す。実験として、複数の解像度別の画像から算出された特徴量を特徴量選択型 SVM[1]を用いて画像の分類を行う。

2. 特徴量選択型 SVM

特徴量選択型 SVM は、遺伝的アルゴリズム(Genetic Algorithm; GA)とサポートベクターマシン(Support Vector Machine; SVM)を用いた手法である。

特徴量選択型 SVM における処理手順を図 2 に示す。与えられた画像から特徴量を算出する。次に GA を用いて、算出された複数の特徴量の中から、分類に有効な特徴量を選択する。ここで、選択された特徴量を用いて SVM を構成し、画像の分類を行う。このときの分類正答率を GA の適応度として学習を行う。この処理を終了条件に達するまで行い、最終的に選択された特徴量を用いて、分類器を作成する。

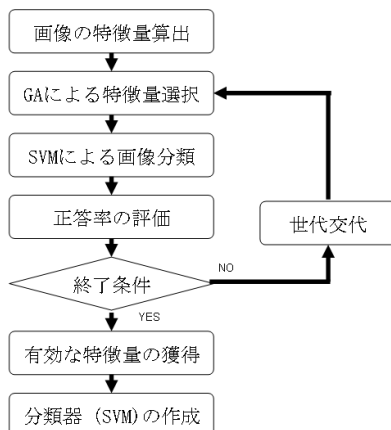


図 1 特徴量選択型 SVM の処理手順

3. 画像の多重解像度表現

本報告では、特定の周波数をもつ画像を wavelet 変換を用いて高周波成分と低周波成分に分割する。具体的には図 1 のように LL, LH, HL, HH 成分に分割を行う。1 回の wavelet 変換をレベル 1 とし、wavelet 変換を行うごとにレベルの値が増える。2 回目以降は LL 成分を用いて wavelet 変換を行う。また wavelet 変換後の値を利用して特徴量を算出する。




図 2 多重解像度画像

4. 実験

本実験では、複数の解像度別の画像から算出された特徴量が有効に働くことを確認するために2つの実験を行った。

- 6種類のテクスチャ画像の分類
- 頭部・非頭部の分類

各実験では、特徴量選択型 SVM を用い、wavelet 変換を用いた特徴量があるものとないもので比較を行う。また、多重解像度のレベルは2までとする。

4.1 実験に使用する画像

1つ目の実験は、Vision Texture[2]のテクスチャ画像を分割して使用した。クラス数は6クラスで、図 3 に示す。画像のサイズは 64x64[pixel]である。




図 3 テクスチャ画像

2つ目の実験は、頭部・非頭部の 32x32[pixel]の画像を用いた。頭部の方向は、前、右横、左横、後向きと4方向の向きを持つ画像を使用した。

[†] 横浜国立大学 大学院環境情報学府, Graduate School of Environment and Information Sciences, Yokohama National University

4.2 実験設定

4.2.1 実験に用いる画像枚数

画像の枚数を表 1, 2 に示す. それぞれ, 括弧内は各クラスの画像枚数とする. 表 2 の未知画像の括弧内は, (頭部・非頭部) それぞれの枚数を示す.

表 1 テクスチャ画像の画像枚数

| | 画像枚数 |
|-------|---------|
| 学習画像 | 258(43) |
| GA評価用 | 258(43) |
| 未知画像 | 252(42) |
| 合計 | 768 |

表 2 頭部・非頭部画像の画像枚数

| | 画像枚数 |
|-------|---------------|
| 学習画像 | 100(50) |
| GA評価用 | 100(50) |
| 未知画像 | 1479(759・720) |
| 合計 | 1679 |

学習画像 : SVM で分類器を作成する際の画像
 GA 評価用 : GA によって特徴量選択を行う際, 適応度算出に用いられる画像
 未知画像 : 汎用能力を検証するための学習に用いていない画像

4.2.2 SVM, GA のパラメータ

SVM, GA のパラメータを表 3, 4 に示す. 表 3 は両方の実験に使用したパラメータである.

表 3 SVM のパラメータ

| カーネル関数 | Gaussカーネル |
|-----------|-----------|
| カーネル関数の定数 | 0.8 |
| 学習係数 | 0.95 |
| 学習回数 | 3000 |

表 4 GA のパラメータ

| | |
|---------|--------|
| 個体数 | 50 |
| 交差率 | 1 |
| 世代交代モデル | トーナメント |
| 選択方法 | MGG |

5. 実験結果・考察

未知の画像の実験結果を表 5 に示す.

表 5 実験結果

| | wavelet特徴 | |
|----------|-----------|----------|
| | あり | なし |
| テクスチャ実験 | 98.8[%] | 98.8[%] |
| 頭部・非頭部実験 | 76.0[%] | 62.70[%] |

5.1 テクスチャ画像を用いた実験

テクスチャ画像の実験では, wavelet を用いた特徴量の分類器もそうでない特徴量の分類器も同じ正答率だった. wavelet 特徴を用いたものは, 特徴量数が 129 種類中 6 種類と大幅に減少した. また, 選ばれた特徴量はレベル 1 や 2 などから算出された特徴が 5 種類あり, 解像度別の特徴が有効に働いていることが確認できた. wavelet 特徴を用いていないものは 39 種類中 7 種類選ばれ, 古典的な特徴量(最小値や中央値など)が多く用いられていた. 図 4 に示すのが誤認識した画像であるが, どちらの分類器も Grass を Bark と間違える傾向にある. Bark が Stone, Grass, Metal などと共通した特徴量をもっていることがわかった.

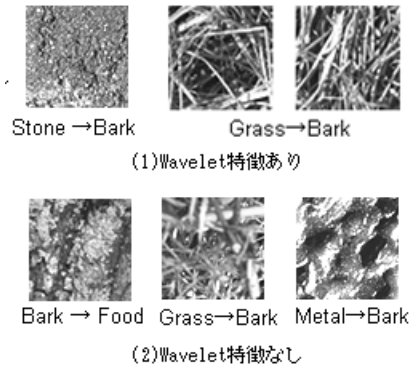


図 4 誤認識した画像

5.2 頭部・非頭部画像を用いた実験

頭部・非頭部の実験では, wavelet を用いた特徴量の方が, 10%以上精度が高くなった. 誤認識した画像は, 頭部の方向が横向きや後ろ向きの画像が多い傾向にあった. 選択された特徴量数は 24 種類である. 選ばれた特徴量はレベル 0 から 2 まで使われていた. また, エッジ特徴が多く使われる傾向にあった. wavelet を用いていない特徴量を用いた実験では特徴量が 15 種類選ばれた. 使用されている特徴量は画像の位置関係を利用した相関係数の特徴などが多く使われる傾向にあった.

6. まとめ

本報告では, 解像度別の特徴が画像分類の精度向上につながることを確認するために, 複数の解像度別の画像から算出された特徴量を GA と SVM を用いた特徴量選択型 SVM で, 画像の分類を行った.

テクスチャ画像を用いた実験と頭部・非頭部画像を用いた実験のどちらも, 全てのレベルの特徴量を使用されていたため, 解像度別の画像特徴が有効に働くことが確認できた.

今後の課題として, 解像度のレベルを画像に合ったレベルに自動で調整できる手法の提案を行うことが上げられる.

参考文献

[1]余部治昭, 長尾智晴, “特徴量選択型 SVM を用いた欠陥画像分類”, FIT2006 第 5 回情報科学技術フォーラム
 [2]VisionTexture(<http://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html>)