

進化的画像処理による学習画像の自動生成 Automatic Construction of Training Images by using Evolutionary Image Processing

藤田 耕作[†] 小林 雅幸[†] 長尾 智晴[†]
Kosaku Fujita Masayuki Kobayashi Tomoharu Nagao

1. はじめに

昨今盛んに研究が行われている深層学習などによる画像の事例ベース学習においては、どれだけ多くの学習データ（教師画像）を用意することができるか否かが、生成される画像認識器の認識精度に大きな影響を与える。一方、適用分野によっては学習画像の枚数を増やすことができない場合がある。このため、数少ない正解付きの学習画像に多少の変形などの加工を加えた画像を生成し、それらの画像を元にした学習画像と同じクラスの学習画像として用いる半教師つき学習を行うことが試みられている。認識対象が人物の顔などの合成が比較的容易、あるいはCG; Computer Graphicsによって生成可能な場合はCG技術が用いられることが多い。しかしながら、一般物体認識における認識対象画像のような一般的な画像に対しては適用困難である。また、画像のシフトや回転のような比較的単純な変換だけでは必要とされる学習画像の近傍の画像を生成することができるかどうかかわからない。そこで本報告では、筆者らの研究室で先に提案した進化的画像処理を用いて目標とする水増し用の学習画像を作ることを試みる。

2. 学習画像の水増しについて

図1に学習画像の水増しの考え方のイメージを示す。同図は画像認識を行う際の入力画像の特徴空間であり、 $p_1 \sim p_6$ がclass 1の学習画像、 $p_7 \sim p_{12}$ がclass 2の学習画像であるとする。このとき、SVM (Support Vector Machine) や階層型神経回路網によって、同図の太線のようなクラス識別面が生成されているとする。一般に学習画像の枚数が少ない場合、識別面の信頼性が低下するため、学習画像を増やす必要が生じる場合がある。しかしながら、それが不可能な場合は学習画像を元にして学習画像を水増しする必要が生じる。そこで、例えば画像 p_{11} の近傍に p_{13} という新しい学習画像を作り、ラベルがclass 2の学習画像に加えたい。

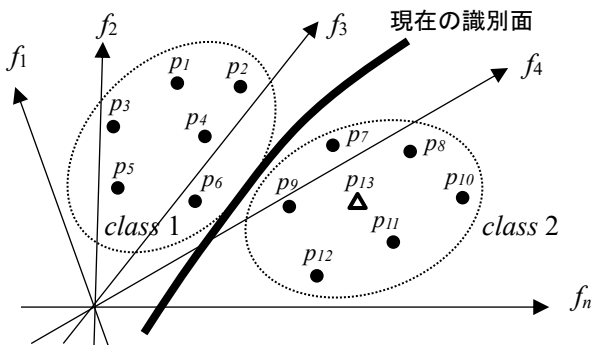


図1 特徴空間中の学習データと識別面

ここで、画像 p_{11} の特徴量が次のよう表せると仮定する。

$$p_{11} = f_{11}(f_1^{11}, f_2^{11}, \dots, f_n^{11}) \quad \dots (1)$$


そして、新しい学習画像 p_{13} が次式に示すように画像 p_{11} の各特徴量をそれぞれ $(\Delta_1, \Delta_2, \dots, \Delta_n)$ だけ微小変化させた画像であるとする。

$$p_{13} = f_{13}(f_1^{11} + \Delta_1, f_2^{11} + \Delta_2, \dots, f_n^{11} + \Delta_n) \quad \dots (2)$$

ここで、単に特徴空間中に任意の点を増やし、正解のラベルを与えて学習に用いるだけであれば、“その特徴点に対応する画像”をわざわざ作る必要はない。しかしながら、特徴空間の性質によっては、例え正解付きの学習画像の近傍であっても、認識器が別のクラスの画像であると認識してしまうことが充分考えられる。図2に例を示す。図2(a)の画像と同図(b)の画像は、特徴空間中ではごく近い距離の点であるが、意外にも学習済みのSVMによって異なるクラスの画像であると認識された。このように、例え特徴空間中の近傍であり、目視では同じクラスの画像であっても別のクラスに認識されることがある。正解付きの学習画像の近傍の点をその画像と同じクラスの画像であるとみなして学習してしまうことは危険であるといえる。



(a) フラミンゴクラスと認識



(b) ヒョウクラスと誤認識

図2 特徴空間中の近距離の2点に相当する画像が認識器によって別のクラスと認識された例

このため、指定した特徴量をもつ画像を生成する手法を開発し、必要に応じて、追加した特徴点の画像を生成して人が見ることによって、正解クラスの妥当性を確認することができるようにすることが望まれる。そこで本報告では、進化的画像処理を用いてその処理を実現する。

3. 進化的画像処理

進化的画像処理[1]は、筆者の一人である長尾が以前から提唱している画像処理・認識の自動構築法である。これは、画像処理・認識プロセスの構築問題を最適化問題としてとらえ、最適化法の一つである進化計算法を用いて解く一連の手法である。これまでに複数の方式が提案されており、実問題を含む様々な産業用/医用画像処理などに適用されてその有効性が確認されている。本報告では、遺伝的プログラミング(Genetic Programming; GP)を用いて画像処理フィルタを木構造状に組み上げることで所望の画像処理を自動構築する方式[2]を用いる。

[†] 横浜国立大学 大学院環境情報学府 長尾研究室
横浜市保土ヶ谷区常盤台 79-7

4. 指定する特徴量の画像生成法

ここでは提案する学習用画像の生成方式について述べる。

4.1 生成する水増し用の特徴点の生成

本報告では、クラス 1 に属する学習画像 $p_1 \sim p_N$ が与えられているものと仮定する。このとき、学習画像中の 1 枚の画像 $p_i (1 \leq i \leq N)$ を選択する。本報告ではランダムに選択したが、本来なら識別面の信頼性向上に有効と考えられる学習画像を、学習画像の特徴空間における分布密度・特性などを考慮して決定する必要があると考えられる。

次に p_i の特徴空間中の点 $f_i(f_1^i, f_2^i, \dots, f_n^i)$ の一定の近傍領域中に存在する他の学習画像を求める。そして、特徴点 $f_i(f_1^i, f_2^i, \dots, f_n^i)$ およびその近傍中の学習画像 (に対応する特徴点) から、乱数を用いて水増し用の学習画像の特徴点を必要数だけ生成する。

4.2 進化的画像処理による画像の生成

進化的画像処理では、原画像に対して何等かの変換を行って得た出力画像を評価する評価関数を用意し、ランダムに生成した画像処理群 (初期個体群) を進化計算で進化させて、この評価関数値が高い画像を出力する画像処理プロセスを自動構築する。従来は、図 3 に示すように入力画像の理想的な変換画像である目標画像を手で作って入力し、木構造状画像変換の出力画像と比較することで評価する場面が多かった。しかしここでは目標画像を作ることができないため、目標の特徴量 $f_t(f_1^t + \Delta_1, f_2^t + \Delta_2, \dots, f_n^t + \Delta_n)$ を与え、出力画像の特徴量 $f_{out}(f_1^{out}, f_2^{out}, \dots, f_n^{out})$ と比較し、近いものほど評価値が高いものとして評価する。

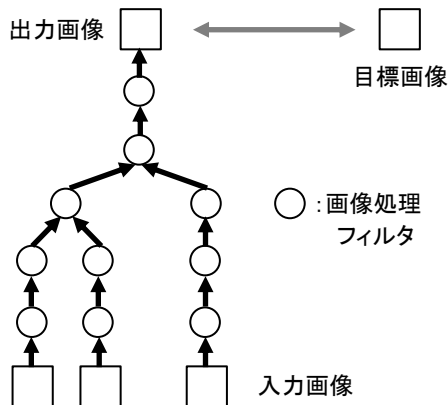


図 3 木構造状画像フィルタによる入力画像の変換と評価

5. 学習画像生成実験

提案手法による学習用画像の生成例を示す。

5.1 比較的単純な色特徴量を用いた実験

学習画像の特徴量として比較的単純な色特徴量を用いた場合の実験結果を図 4 に示す。原画像として選ばれた学習用画像に対して、その特徴空間中の近傍点として決定した目標特徴量とほぼ同じ特徴量の画像を生成することができた。同じ目標であっても複数通りの画像を生成することが

できていることから、提案手法による画像生成の多様性を確認することができた。




図 4 色特徴量を用いた出力画像の例

5.2 64 次元の特徴量を用いた実験

続いて前節より複雑かつ実問題で使われる画像特徴量 (64 次元) を用いた実験例を図 5 に示す。同図から、図 4 の場合よりも画像全体の変化と局所的な変化の両方を考慮することができていることがわかる。

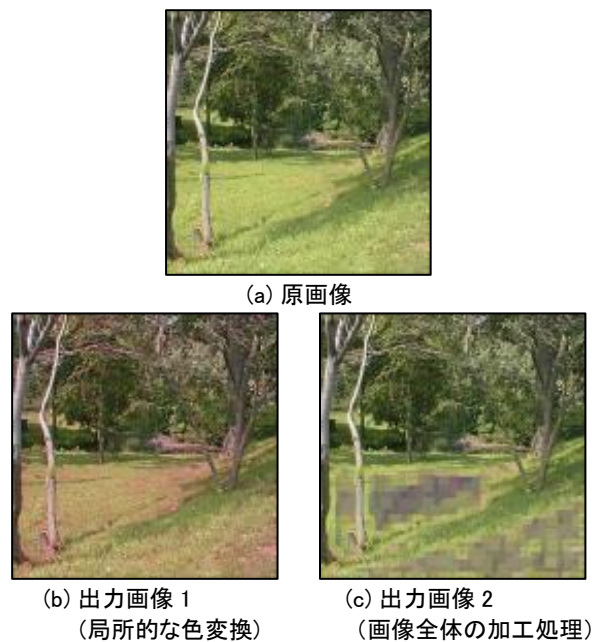


図 5 64 次元の画像特徴量を用いた出力画像の例

6. おわりに

本報告では、半教師つき学習における学習画像の水増しを進化的画像処理を用いて実行する方法について述べた。今後は、画像変換と特徴空間での移動方向・移動量との関係を求めることで提案手法の汎化を行うとともに、提案手法によって水増しされた学習画像を用いることによって画像認識器の認識精度の向上を見込むことができるか否かについて検証する必要がある。

参考文献

- [1] 長尾智晴, “進化的画像処理”, 昭晃堂 (2002).
- [2] 青木紳也, 長尾智晴: 木構造状画像変換の自動構築法 ACTIT; 映像情報メディア学会誌, Vol.53, No.6, pp.888-894 (1999).