

GA 及び IA による砂時計型ニューラルネットワークの最適化

An Optimization of Sandglass-Type Neural Network Using GA and IA

小山 達矢[†]
Tatsuya Koyama[†]

大枝 真一[‡]
Shinichi Oeda[‡]

木更津工業高等専門学校 情報工学科本科[†]

木更津工業高等専門学校 情報工学科[‡]

Information Engineering Course, Kisarazu National College of Technology[†]

Department of Information Engineering, Kisarazu National College of Technology[‡]

1. まえがき

自然界の生物は環境の変化に適応しながら進化を繰り返し、生存を続けている。これらの生物が持つ柔軟な適応能力から着想を得て、生物学的知見を計算機上で実現するための理論的研究がなされてきた。代表的な例として、進化過程を模倣した GA や、脳のニューロン活動をモデル化したニューラルネットワーク (以下, NN) などがある。

NN の応用例のひとつとして、情報圧縮、特徴抽出を行うための砂時計型 NN が考案されている[1]。この砂時計型 NN を用いて、入力信号の特徴から情報の分類ができる[2]。しかしながら、こうした実問題に適用する砂時計型 NN は一般に規模が大きく、その学習にかかる時間は軽視できない。そのため、学習時間に多大な影響を与える初期結合荷重の決定が重要となる。

本研究では、砂時計型 NN による個体の学習と GA 及び IA による集団の進化を組み合わせた手法を用いて、顔画像の学習を行う砂時計型 NN の初期結合荷重の最適化を行う。

2. 砂時計型ニューラルネットワーク

砂時計型 NN は 5 層からなる階層型 NN であり、入力層、出力層と比較して中間ニューロンの数が極めて少ないという特徴を有する。この NN に入力を与え、それを復元出力する恒等写像を学習させることによって、中間層に情報が圧縮され、そこから特徴表現を抽出できる。

本研究では、砂時計型 NN に学習させるデータとして、顔の表情画像を用いる。顔画像を 2 次元離散コサイン変換し、その低周波成分のみを学習データとして扱う。表情変化の多くは画像の低周波成分に反映されるため、この処理によって入力信号の数を減らし、ノイズとなる高周波成分を取り除くことができる。本研究では、入力データとして 2 次元離散コサイン変換後の、DC 係数を除く 16×16 の領域を用いた。図 1 に、元の顔画像と 16×16 の低周波成分から復元した顔画像を示す。



元画像



2次元離散コサイン変換後
(低周波成分のみ)

図 1 低周波成分から復元した顔画像

Ekman らは表情画像から基本感情の分類を行っており、それによれば感情カテゴリは大きく分けて“喜び”、“悲しみ”、“嫌悪”、“怒り”、“恐れ”、“驚き”の 6 基本感情に分類できると述べている[3]。そこで、この 6 基本感情を表出した顔画像を 2 枚ずつ 7 人分撮影し、そのうち 4 人分のデータを訓練事例に用いることとした。残りの 3 人分のデータはテストデータとして学習後に用いる。

3. 進化的構造適応学習法

入力データに対し教師信号が常に一定で変化しない訓練事例を“静的環境”とし、逆に入力データに対し教師信号が変化する訓練事例を“動的環境”としたとき、議論の乏しかった動的環境における有効な学習法として、進化的構造適応学習法が提案されている[4]。これは進化論からの類推に基づき、個体における生涯での“学習”と、集団における世代をまたいだ“進化”の、2 つの異なる適応過程を、相互補完的なものとして捉えるものである。この手法では、集団内の各個体は NN で構成されており、BP 法による結合荷重の修正によって“学習”を行う。また GA による遺伝的操作によって個体を再編成し、“進化”を実現する。ここで、NN の結合荷重が各個体の遺伝子となる。

4. 先行研究における課題

文献[2]では、砂時計型 NN によって顔画像を学

習させる実験を行っているが、学習が完了するためにおよそ 60,000 回の BP 学習を要していた。通常、NN の初期結合荷重はランダムに与えるが、この値は学習回数や学習中の収束過程に多大な影響を与える。ここで、顔画像の学習に特化した初期結合荷重を得ることができれば、新しい人物の顔画像を学習する場合（動的環境での学習）でも短時間で再学習が可能となる。

本研究では、環境の変化に適應する生物の進化の機構に着目し、砂時計型 NN に対して進化的構造適應学習法を適用する。研究の目的は、顔画像の学習に特化した、最適な初期結合荷重を探索することであり、そのための計算時間は問題としない。

5. 計算機実験

5.1 実験 1: GA による探索

集団内の個体数を 20 個体とし、1 世代において 1 個体が 10,000 回の BP 学習を行う。初期個体の遺伝子は 0 を中心とした様々な振幅の実数乱数で与える。学習後の平均誤差を基に適合度を算出し、ルーレット選択、多点交叉、突然変異を施して次世代の子を生成する。次世代へ最優良個体を 1 個体保存するエリート戦略を用いて、これを 20 世代まで繰り返した。図 2(a)に、各世代における 20 個体の集団平均誤差の変動を示す。振動しているが、全体として誤差は減少する傾向にあると見られる。

5.2 実験 2: IA による探索

実験 1 の発展として、GA の代わりに IA（免疫アルゴリズム）を用いて実験を行った。IA では、各世代における最優良個体を記憶細胞として保存し、これと類似した子が生成されないように抑制することで集団の多様性を維持する。図 2(b)に、IA を用いた場合の集団平均誤差の変動を示す。実験 1 と比較して、改善は見られなかった。親和度の計算方法やパラメータの指定を検討する必要がある。

5.3 実験 3: 未知データの学習

実験 1 及び実験 2、また先行実験で行ったランダムサーチでそれぞれ得られた最優良解を初期結合荷重に用いて、テストデータを学習させた。図 3 に、学習時の平均誤差の変動を示す。GA 及び IA により得られた初期結合荷重の方が、新しい人物の顔画像を早く学習できていることがわかる。

6. まとめ

本研究では NN を GA で最適化することによって、顔画像を学習する砂時計型 NN の初期結合荷重の最適化を行った。その結果、ランダムに与えた場合

より少ない学習回数で誤差が収束する初期結合荷重を得ることができた。今後は実時間内で動作するアプリケーションへの適用を考慮し、IA のパラメータ調整や新手法の導入によって、提案手法の改良を行っていく予定である。




図 2 学習後の集団平均誤差の変動




図 3 未知データ学習時の誤差曲線

謝辞 本研究は科研費(19700226)の助成を受けたものである。

参考文献

- [1] Malthouse, E.C. : Limitations of nonlinear PCA as performed with generic neural networks, pp.165-173, IEEE Trans. On Neural Networks, 9, 1998.
- [2] 市村匠, 大枝真一他: 並列砂時計型ニューラルネットワークと情緒生起手法を用いた感情指向型インタフェースの応用, pp.225-238, ヒューマンインタフェース学会誌, Vol.3, No.4, 2001.
- [3] Ekman, P. : 表情分析入門, 誠信書房, 1987.
- [4] 大枝真一他: 進化論に基づくニューラルネットワークの構造適應学習アルゴリズムの構成, pp.72-73, 情報処理学会誌, Vol.5, No.8, 2004.