

遺伝的アルゴリズムを用いたニューラルネット 構造解析による顔画像認識

中畠 昌大* 雨森 道紘

弘前大学理工学部電子情報システム工学科

平成11年6月1日

1. はじめに

人間は顔を見て、その人物が知人であれば即座に識別することができる。この人間の識別能力は顔に含まれる複数の情報を処理し、総合的に判断していると考えられる。本研究では、エッジ抽出等による認識法とは別に、人間の認識の仕方により近いと考えられる階層型ニューラルネットワークを用いる。この方法では、輪郭や各造作を含めた濃淡パターンが幾つかの顔画像の特徴に情報圧縮されて後に個人識別が行われていると推定される。そこで、認識が行われた後で、中間層で得られる顔画像の特徴についても解析をする。階層型ニューラルネットワークの中間層には学習によって獲得した入力データの特徴が集約され、学習を繰り返すことによって一種の多変量解析を行う機能を持つと考えられる。顔画像のニューラルネットによる認識には、小杉等[4]による研究があるが、ニューラルネットワークにおける問題点は、その能力や収束安定性などを決める学習パラメータの値をあらかじめ設定しなければならないことである。従来までこれらのパラメータは、多くの経験と知識に基づいて決められていた。本研究では、遺伝的アルゴリズム(GA)を用いて、ニューラルネットワークの最適なパラメータを決定する。ニューラルネットに遺伝的アルゴリズムを用いる手法は最近幾つかなされているが[6]、これは問題を生物遺伝子の進化に模して高速に最適

値を探索を手法である。本研究では次の3つを目的として行う。

- (I) まず、GAを使って階層型ニューラルネットワークの最適な学習パラメータを探索する。その際に、ニューラルネットワークに適応するときの有効なGA手順を考察する。
- (II) 次に、GAで求めた学習パラメータを使って、顔画像をニューラルネットワークに学習させ、顔画像認識を行う。
- (III) さらに、学習後のニューラルネットワークで中間層から顔画像の特徴が抽出されること確かめ、その得られた特徴を解析する。

2. ニューラルネットワークの構造と学習法

認識に使用するニューラルネットワークは、図1のように中間層を1層をもつ3層の階層型ニューラルネットワークとする。入力層に顔画像のデータを入力し、中間層をへて、出力層で個人を識別する。入力層のユニット数(NI)は、ネットワークに与える入力画像データの大きさにより決まる。中間層ユニット数(NH)は、GAにより、最適値を求めて決定する。出力層のユニット数(NO)については、認識させる人数分のユニットを設け各人に対応させる。ニューラルネットワークの学習法は

*東京都江東区豊洲3-3-3(株) NTTデータ

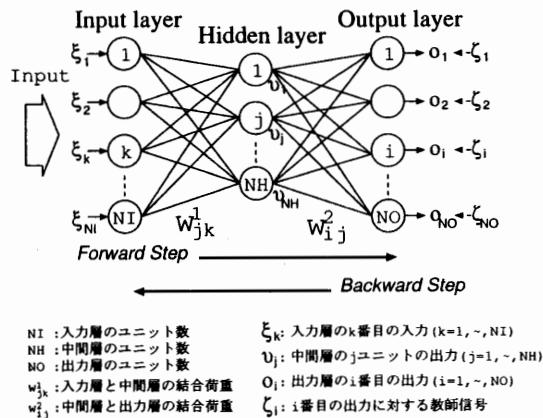


図1：3層ニューラルネットワーク

Momentum法と学習率更新法を加えたBack Propagation(BP)法とした。用いたBPのアルゴリズムは、以下のとおりである。

[step. 1] 初期化

結合荷重 w_{jk}^1 , w_{ij}^2 の初期値を以下の範囲で設定する。

$$-w_d \leq w_{jk}^1 \leq w_d$$

$$-w_d \leq w_{ij}^2 \leq w_d$$

w_d : 初期結合荷重の分布幅

[Step. 2] Forward Step

入力パターン $P = \{\xi_1, \xi_2, \dots, \xi_{N_I}\}$ を提示して中間層の出力 v_j と出力層の出力 o_i を計算する

$$v_j = f \left(\sum_{k=1}^{N_I} w_{jk}^1 \xi_k - \theta_1 \right)$$

$$o_i = f \left(\sum_{j=1}^{N_H} w_{ij}^2 v_j - \theta_2 \right)$$

$$f(x) = \frac{1}{1 + \exp(-\beta x)}$$

β : 出力関数の傾き θ_1 : 中間層の閾値

θ_2 : 出力層の閾値

[Step. 3] Backward Step

出力層の出力値と教師信号の平均2乗誤差 E を

評価関数として、誤差 E を最小にするため結合荷重の修正量 ΔW を計算する。

$$E = \frac{1}{P} \frac{1}{NO} \sum_p \sum_{i=1}^{NO} (\zeta_i - o_i)^2$$

$$\Delta W = -\eta(t) \frac{\partial E}{\partial W}$$

[Step. 3.5] 学習率の更新(Delta-bar-delta法)

$$\eta(t+1) = \begin{cases} \eta(t) + \kappa & (\text{if } \bar{\delta}(t-1) \delta(t) > 0) \\ \phi \cdot \eta(t) & (\text{if } \bar{\delta}(t-1) \delta(t) < 0) \\ \eta(t) & (\text{otherwise}) \end{cases}$$

where

$$\delta(t) = \frac{\partial E(t)}{\partial w(t)}$$

$$\bar{\delta}(t) = (1 - \theta) \delta(t) + \theta \bar{\delta}(t-1)$$

κ : 学習率増加係数 ($\kappa > 0$)

ϕ : 学習率減少係数 ($0 < \phi < 1$)

θ : 勾配平均化係数 ($0 < \theta < 1$)

[Step. 4] 結合荷重の更新

結合荷重の更新には、Momentum法として慣性項をつけ加える。

$$W(t+1) = W(t) + \Delta W + \alpha (W(t) - W(t-1))$$

α : 慣性係数 ($0.0 \leq \alpha \leq 1.0$)

[Step. 5] 終了判定

以下の条件のいずれかを満たした場合は学習を終了する。満たさない場合は、Step. 2に戻り学習を繰り返す。

(1) 2乗誤差 E が ϵ 以下になった。 $(\epsilon$ は 0 に近い定数)

(2) 学習回数が最大学習回数を超えた。

3 GAを用いたニューラルネットの構造決定

本研究では、階層型ニューラルネットワークをBack Propagation学習法で学習する場合に誤差空間の形成と探索点の動きに影響を及ぼす学習係数(η)、sigmoid 関数の傾き(β)、初期結合荷重の分布幅(w_d)、中間層のユニット数(NH)、慣性係数(α)、学習率増加係数(κ)減少係数(ϕ)の7種類のパラメータをGAを用いて決定する。

3.1 遺伝子型の定義

GAの仮想生物個体は、表1に示す7種類の値を遺伝子として持たせた。これら7種類のパラメータを遺伝子として持つ図2のような個体を複数個考える。

遺伝子1～遺伝子3はBack Propagation学習のスピードや収束性にかかわる。遺伝子2と遺伝子4はネットワークの構造と能力にかかわる。遺伝子5はMomentum法で使用する係数で、遺伝子6と遺伝子7はDelta-bar-delta法で使用するパラメータである。

Momentum法とDelta-bar-delta法を併用する場合は、遺伝子1～遺伝子7まですべてを使用するが、その場合の遺伝子1は学習係数の初期値となる。

	パラメータ	データ型	範囲
遺伝子1	η 学習係数	float	$\eta > 0$
遺伝子2	β sigmoid 関数の傾き	float	$\beta > 0$
遺伝子3	w_d 初期結合荷重の分布幅	float	$w_d > 0$
遺伝子4	NH 中間層のユニット数	int	$1 \leq NH \leq 64$
遺伝子5	α 慣性係数	float	$0.0 \leq \alpha \leq 1.0$
遺伝子6	κ 学習率増加係数	float	$\kappa \geq 0.0$
遺伝子7	ϕ 学習率減少係数	float	$0.0 \geq \phi \geq 1.0$

表1：個体の遺伝子と Back Propagation
学習パラメータ

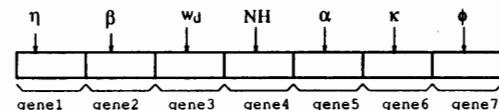


図2：個体の遺伝子型

3.2 初期集団の発生

初期集団の個体として、上記の7種類の遺伝子についてそれぞれ以下の範囲で乱数を発生させ、1個体をつくる。その個体を N_p 個発生させて集団を形成する。

3.3 適応度の設定

本実験では、次の3つの点を考慮した適応度関数を考える。

(1)各学習パターンに対する出力層の出力値と教師信号の平均2乗誤差Eが小さくなるようにする(2)学習が少ない回数で終了するようになる。(3)ネットワークの構造が小さくなるようになる。以上の条件を考慮して次に示すように適応度を定義する。

	パラメータ	データ型
遺伝子1	$0 < \eta < MAX_{\eta}$	float
遺伝子2	$0 < \beta < MAX_{\beta}$	float
遺伝子3	$0 < w_d < MAX_{w_d}$	float
遺伝子4	$1 \leq NH \leq NH_{max}$	int
遺伝子5	$0.0 \geq \phi \geq 1.0$	float
遺伝子6	$0.0 \leq \kappa \leq MAX_{\kappa}$	float
遺伝子7	$0.0 \geq \phi \geq 1.0$	float

表2：初期集団の発生

3.4 適応度の定義

(i) 学習が収束した場合

$$\begin{aligned} fitness(E) = & A \frac{\log(E)}{\log(E_{\min})} + B \frac{T_{\max} - T}{T_{\max}} \\ & + C \frac{NH_{\max} - NH}{NH_{\max}} \end{aligned}$$

(ii) 学習が収束しない場合

$$fitness(E) = A \frac{\log(E)}{\log(E_{\min})}$$

E_{\min} : 誤差の最小値として与える定数

T_{\max} : 最大の学習回数

T : 誤差が ϵ 以下になる学習回数

NH_{\max} : 中間層の最大ユニット数

A, B, C : 優先項係数 ($A + B + C = 1.0$)

学習が収束した場合の適応度の 1 項目は誤差に関する項で、誤差が小さくなれば適応度が大きくなることを示している。2 項目は学習回数に関する項で、学習回数が小さくなれば適応度が大きくなることを示している。3 項目はネットワークの規模に関する項で、規模が小さくなれば適応度が大きくなることを示している。また、各項の係数 A, B, C は、どの条件を優先するかの重みづけ係数である。

それに対して、学習が収束しない場合とは、 T_{\max} 回の繰り返しで誤差が ϵ 以下にならなかつたときで、この場合は誤差の値だけにより適応度を決める。そうしなければ、誤差が大きいにもかかわらずネットワークの規模が小さくなってしまうことが起きるので、(ii) の誤差に関する項のみでまず誤差を下げ、誤差が ϵ 以下になつたら、(i) を適応する。

3.5 適応度計算の手順

Back Propagation 学習法においては、乱数によって設定した初期結合荷重が大きく影響する。そこで、各個体で初期結合荷重を変えて

N_{test} 回の学習を行い、その平均の適応度を現世代の各個体の適応度とした。ただし、前世代から生き残った個体については、前世代の同じ個体の適応度との平均をとったものを現世代の各個体の適応度とした。具体的な適応度計算の手順は次のとおりである。

(Step. 1) Decode

各個体の遺伝子型を表現型に変換する。すなわち、各個体の遺伝子から値を取り出して、Back Propagation 学習のパラメータにそれぞれ設定する。

(Step. 2) Back Propagation

(Step. 1) で設定したパラメータで、1 度の学習につき T_{\max} 回の繰り返しの Back Propagation 学習を行う。それから、学習の結果得られた誤差 E と回数 T から適応度の定義に基づいて $fitness(E)$ を計算する。

(Step. 3) 平均適応度を求める

初期結合荷重を変えて (Step. 2) を N_{test} 回繰り返し、各適応度の平均 $\overline{fitness(E)}$ をとる。

(Step. 4) 現世代の適応度

t 世代目の各個体の適応度 $fitness^*(t)$ を以下の 2 つの場合に分けて計算する。

(a) 前世代からの生き残り個体の場合

$$fitness^*(t) = \frac{1}{2} \overline{fitness(E)} + \frac{1}{2} fitness^*(t-1)$$

(b) 新しい個体の場合

$$fitness^*(t) = \overline{fitness(E)}$$

3.6 遺伝規則

本研究で用いる GA では、淘汰、交差、突然変異の 3 つの遺伝規則に従って世代交代を行う。また、各世代における全個体数は、常に一定数

N_p だけ存在する。また、適応度の高い順に一定の割合 P_a の個体は以下の遺伝操作をおこなわずに、そのまま次世代に残す。

(1) 淘汰

淘汰過程においては、適応度の低い個体を消滅させる。消滅する個体数は、全個体数 N_p のある一定の割合 P_x に相当する個体数 $N_x = P_x \cdot N_p$ が淘汰されることとする。

(2) 交差

その適応度に応じてルーレット選択により個体のペアを選択し、パラメータブロックごとの一様交差を用いる。淘汰されなかった $N_p - N_x$ 個の個体の中から、ルーレット選択で、ペア $(1 - P_a) N_p$ 組を選択し、そのペア内で遺伝子に割り当てた各パラメータブロックごとに一様交差し、それぞれのペアで1つの新しい個体を生成する。一様交差は、2つの親の遺伝子ごとに確率 P_c でどちらかの親の遺伝子を遺伝し、1つの子孫を作る操作である。

(3) 突然変異

突然変異は、各遺伝子を突然変異確率 P_m で、個体のある遺伝子が突然変異を行う。突然変異の方法は遺伝子ごとに5つの方法を定め、乱数でどの操作を行うかを決める。appendix 1 にその方法が表に示されている。最後に、各突然変異量の変化による全体へ影響を調べるために N_p, P_a, N_{test} を変化させたシミュレーション結果がappendix 2 に示されている。

4 基礎実験方法

GAの能力を試すために、論理演算XOR を識別する最適な階層型ニューラルネットの構造を得るGAの基礎実験を行った。他の基本的な論理演算AND やORは線形分離可能であるのに対して、XOR 問題は線形分離不可能である。したがって、この問題は非線形の出力関数を持つ階層型のニューラルネットにより線形分離不可能な問題を解くことにあたる。

実験方法

[基礎実験]

論理演算XOR のMomentum 法とDelta-bar-delta 法を加えたBack Propagation学習で用いる学習パラメータと中間層数の決定。

実験は、ニューラルネットの学習係数の初期値 (η)、sigmoid 関数の傾き (β)、初期結合荷重の分布幅(W_d)、慣性係数(α)、学習率増加係数(κ)減少係数(ϕ)と中間層数(NH)の7種類のパラメータの決定を行う。

	η	β	W_d	NH	α	κ	ϕ
基礎実験	○	○	○	○	○	○	○

表3：基礎実験で求めるパラメータ

世代交代数を100世代とし、学習終了条件および適応度の計算で使われる定数は、 $E_{min} = 0.00001$, $T_{max} = 1000$, $\epsilon = 0.001$, $NH_{max} = 32$, $N_{test} = 10$ 、適応度の優先項係数は、 $A = 0.5$, $B = 0.3$, $C = 0.2$ として、上記の実験を行った。実験でのその他のGAパラメータは表に示した。

	実験
全個体数	$N_p = 20$
遺伝操作確率	$P_x = 0.3$ $P_c = 0.5$ $P_m = 0.05$ $P_a = 0.3$
適応度平均数	$N_{test} = 10$

表4：GAパラメータ

100世代目の個体について、初期結合荷重を変えて50回のBack Propagation学習を行い、適応度の平均が最も高かった個体を最も優秀な個体として、その個体をデコードして得られた値をBack Propagation学習パラメータの最適値と決定する。

4.1 実験結果

100世代目までの世代交代による最大適応度と平均適応度の変化の様子を図3に示す。

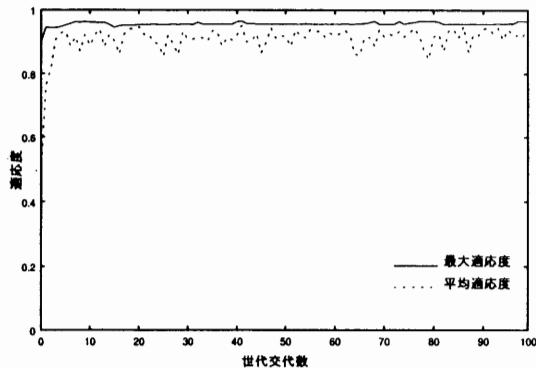


図3：（基礎実験）世代ごとの適応度変化

表5には100回の世代交代後の最も優秀な個体の遺伝子型を示す。

	η	β	W_d	NH	α	κ	ϕ
experiment 2	0.701	1.998	1.103	4	0.877	0.967	0.09240

表5：基礎実験で求められたパラメータ

また、最も優秀な個体について、Back Propagation学習の誤差減少の様子を図4に示す。さらに、異なる初期結合荷重で1000度の学習を行ったところ1000度全てにおいて、50回以上の繰り返し数で ϵ 以下に収束した。

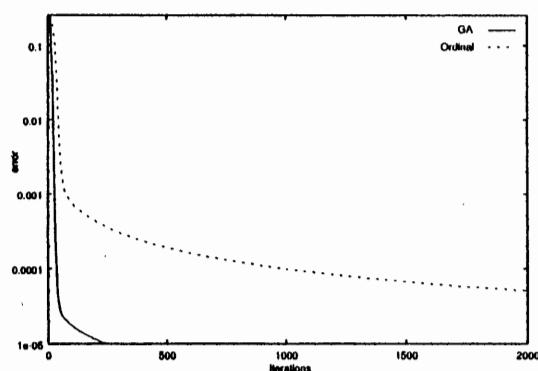


図4：基礎実験の誤差減少の様子

4.2 基礎実験結果の考察

今回の実験で、ニューラルネットワークのパラメータを、GAの手法により求めた。Momentum法やDelta-bar-delta法のパラメータを同時に探索しても100回の世代交代で、十分パラメータを求めることができ、また、求められた学習パラメータは学習を高速化するだけでなく、初期値によらずに振動を防ぐ収束安定性に特に優れていることが確かめられた。ニューラルネットワークの場合、同じ個体でも、初期結合荷重により一度の学習では適応度が大きくかわる場合がある。先に示した適応度の計算方法で、現世代の適応度を、前世代の適応度との

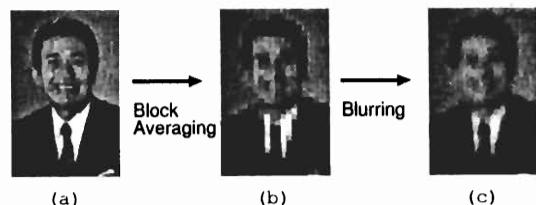


図5：ブロック画像

平均をとって現世代適応度とする方法を考案したが、この方法により安定して最大適応度の個体を得られるようになり、またこの方法は、大規模なニューラルネットワークを構成することになれば、計算時間上 N_{test} の回数を増やすことができないので、特に有効になる。

5 顔画像の特徴抽出

5.1 認識に使用する顔画像データ

計算機による顔の個人識別については、画像からエッジを抽出し、その形状やお互いの位置関係を見出して認識を行う方法が従来用いられてきた。しかし鼻や口などは陰影が柔らかなため、正確にエッジを抽出することすら困難である場合が多い。

そこで、輪郭や各造作を含めた濃淡パターン全体として顔画像を情報圧縮した特徴を用いて、

ニューラルネットによって識別することを考える。そのとき、顔画像を少数のブロックに分割して、そのブロック内の画素の濃度の平均値をそのブロックの代表値として使用する。これは Marr のチャンネル理論での低周波の成分を用いるものにあたる[9]。図 5 のように、元画像(a)をブロック化することにより、高周波の成分は除去される(図 5 (b))。しかし、新たに顔の濃淡よりも大きい周波数のブロック化ノイズが加わる。しかし、このブロック画像(b)をぼかすことによって正方形のノイズを除去した画像(c)では、認識が改善するのがわかる。すなわち、人間はブロック画像をぼかしたり、すこし離れたところから見たり、目を細めてみたりすることにより認識しやすくなるのである。さらに、ニューラルネットのもつ学習能力と、特徴の自動抽出能力に注目し、このブロック画像をニューラルネットの入力とする。

5.2 人間の顔画像の認識

30人の顔画像を認識させるニューラルネットワークの構築を行った。Olivetti Research Laboratory の顔画像データベースより30人の顔画像を取り出して使用した。具体的には、図 6 のように、人物画像を $n \times m$ のブロックに分割し、各ブロック内の画素の平均値をブロックの代表値とした。そして、この代表値をニューラルネットワークの入力とする。出力層のユニットは各人に 1 ユニットずつ対応させ、ある人物の顔画像のブロック画像が入力されたとき、対応する出力層ユニットが 1 を出力することで個人を識別する。

今回は $n=12, m=14$ の 168 画素を入力とした。この 168 画素のパターンを 30 パターン用意した。使用した顔画像は図 7 にすべて表示した。入力層のユニット数は、この画素数にあわせて 168 とし、出力層のユニット数は、30 人を認識するので 30 にした。中間層のユニット数については、最適値を後で決定する。

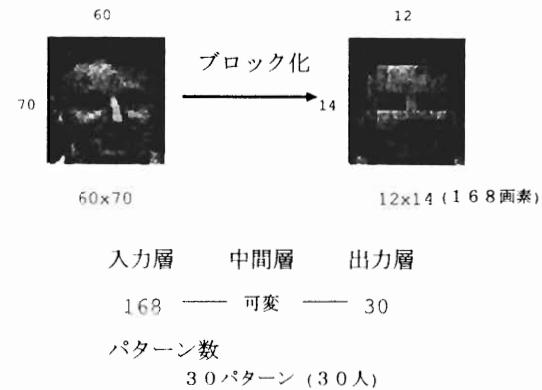


図 6：ニューラルネットに入力する顔画像



図 7：認識させる全顔画像 30 パターン

5.3 GAによる顔認識学習パラメータの探索

顔画像認識問題に対して、GAを使ってBack Propagation のパラメータを探索した。Momentum法とDelta-bar-delta 法を付加して行うニューラルネットの学習係数の初期値(η)、sigmoid 関数の傾き(β)、初期結合荷重の分布幅(W_d)、慣性係数(α)、学習率増加係数(κ)減少係数(ϕ)と中間層数(NH)の 7 種類のパラメータの決定を行った。

[方法]

全個体数を $N_p=20$ 個体、世代交代数を100世代として実験を行った。遺伝操作の発生確率は、 $P_x=0.3, P_a=0.3, P_c=0.5, P_m=0.1$ とした。学習終了条件および適応度計算で使われる定数は、 $E_{min}=0.00005, T_{max}=1500, \epsilon=0.005, NH_{max}=32, N_{test}=2$ 、適応度の優先項係数は、 $A=0.5, B=0.3, C=0.2$ とした。

[結果]

GAによるBack Propagation顔認識のパラメータ探索の結果として、図 8 に世代ごとの適応度変化、表 6 には100回の世代交代後の最も優秀な個体の遺伝子を示した。

η	β	W_d	NH	α	ϕ	κ
0.001	0.552	1.656	7	0.701	0.523	0.06469

表 6 : 認識実験で求められたパラメータ

100回世代交代後の最も優秀な個体から取り出したBack Propagationパラメータを用いて、顔画像を学習させたときの学習の誤差減少の様子を図 9 に示す。学習後の結合荷重を用いて学習画像を 1 人ずつ入力していくこと、学習に用いた30人の顔画像は100%すべて認識した。

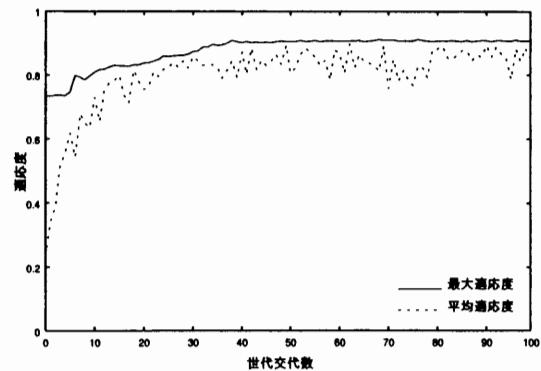


図 8 : 顔認識問題GAの世代ごとの適応度変化

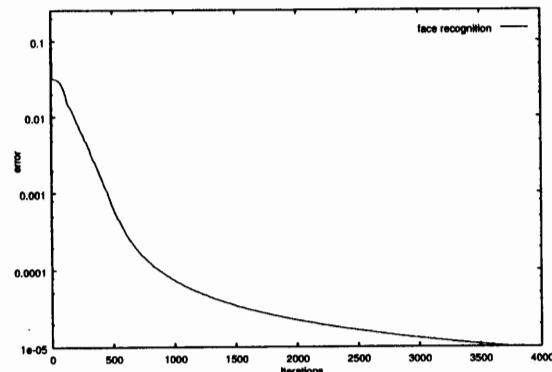


図 9 : 顔認識問題の学習の誤差減少の様子

5.4 顔画像の特徴抽出

3層のニューラルネットワークでは、それぞれの層間でデータ表現の変換がなされると考えられる。まず、入力画像は入力層と中間層との結合荷重により中間層で何らかの特徴空間へ変換される。さらに、中間層の出力を受けて出力層では、中間層から出力層への結合荷重により中間層の特徴空間に基づいて個人識別がなされる。すなわち、中間層の各ユニットはそれぞれ異なる特徴を表現していることになる。

5.5 中間層出力の特徴

中間層から特徴を取り出すために、すべての入力データを順次ニューラルネットに入力し、このときの中間層の各ユニットの出力値を図10に示した。ここで、各ユニットが明るいほど出力の値が大きいことを表す。中間層のあるユニットに注目したとき、大きな値を導く顔画像群は共通の特徴を持つはずである。しかし、どの中間層にどんな特徴があらわれるかは、そのときの初期値などに依存し、中間層の特徴をすぐにとらえることは難しい。また、中間層ユニットの出力値は、入力画像の値と対応する結合荷重を掛け合わせ和をとったものである。したがって、抽出する特徴は結合画像の中にある。図11は、入力層から中間層への結合荷重の全要素をパターン化したものである。正の結合荷重は白、負の結合荷重は黒で表した。正の結合荷重は、入力の明るいところほど中間層の出力を押し上げ、負の結合荷重は、入力の明るいところほど中間層の出力を減少させる。従って、中間層の出力を大きくするためには、正の結合荷重に対しては入力の明るい部分、負の結合荷重に対しては入力の暗い部分が寄与することになる。

そこで、この結合荷重パターンと入力データを照らしあわせ、さらに中間層の出力も考慮にいれて、中間層の各ユニットごとの結合荷重パターンの特徴と、そのユニットに大きな値を導く入力画像の共通点を調べた。

その結果、中間層ユニット1については、顔

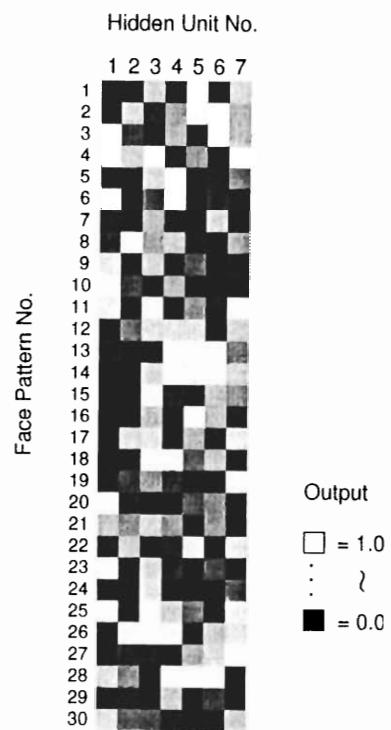


図10：中間層の各ユニットの出力値

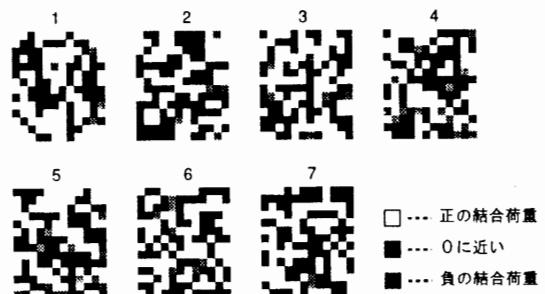


図11：入力層の各ユニットと中間層との結合荷重

パターン6や23が強く反応している。そこでパターン6と23の顔元画像に入力層から中間層ユニット1の間の結合荷重を重ね合わせた(図12)。その結果、この中間層ユニット1は目の位置がやや下である顔パターンに反応していることがわかった。同様に、中間層ユニット7は、パターン19や22に強く反応しているので、結合荷重を重ね合わせたところ、これらのパターンは目が離れているパターンであることがわかった。このように、

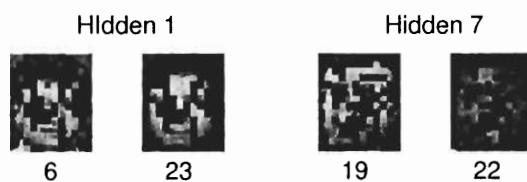


図12：入力画像と結合荷重の重ね合わせ

中間層の各ユニットの結合荷重と元画像を重ね合わせることによって、どの部分が中間層ユニットの反応に関係しているかある程度推量することができる

5.5.1 多次元尺度法(MDS)による解析

パターン間の類似性を調べるために、中間層の各ユニットの出力値の類似度により、MDSを用いて2次元での表示を用いて顔画像の分類を行った。まず、すべての入力データを順次、ニューラルネットに入力し、このときの中間層の各ユニットの出力値をベクトルで表し、各パターン間のなす距離を計算した。そして、その距離行列をMSDにより2次元空間にマッピングして、類似顔画像の特徴を解析した。図13は、各パターンごとに中間層出力の距離を多次元尺度法で2次元平面にマッピングしたものである。図中にプロットされた数字は図7に示した各顔パターンを示す。この結果を見ると、前節で中間層の出力により似た特徴をもっと判断した顔パターン6と23が近い位置に配置されているのがわかる。つまり、このあたりに配置されてい

るパターンは、目の位置がやや下である顔パターンである。同様に、パターン19と22も近い位置に配置されているのがわかる。このあたりに配置されているパターンは、目の位置がやや下の顔パターンである。その他のパターンについても、特徴が似ているパターンどうしが、近い位置に配置されている。このことから、中間層の出力だけより、顔パターンの特徴を分類することができることがわかった。

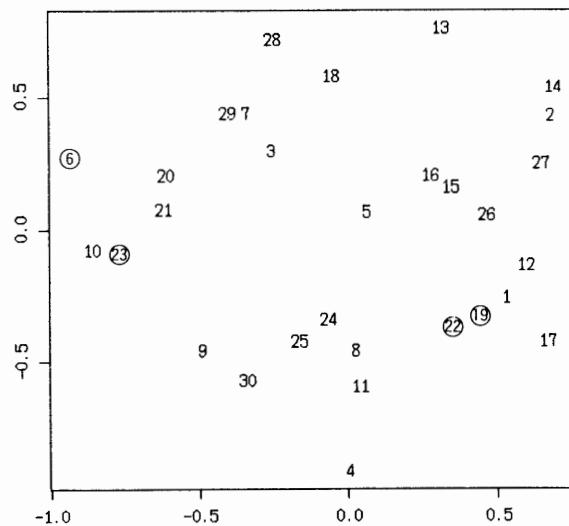


図13：MDSによる中間層の出力からのパターンマッピング

5.5.2 得られた顔の特徴

顔認識ニューラルネットワークで、中間層の出力をもとに、その出力が入力層と中間層の結合荷重のどの部分に起因しているかを照らし合わせ、いくつかの特徴をとらえることができた。解析の結果、目の位置や口の位置などの特徴が表れていることがわかった。しかし、すべての中間層についてはっきりと特徴を解析できなかった。これは、陰影情報による顔の凸凹の度合や、のっぺり顔やふくら顔など抽出できる特徴が明確に定義できないことにもよる。そこで、特徴の明確な画像を人工的に作成して同様の実験を試みた。

6 明確な特徴を示す単純型顔画像による解析

図14のように特徴が明確な模式的な顔画像を描いて、これをニューラルネットワークの入力としてパターン認識を行った。ニューラルネットワークのパラメータは、前節と同様にGAで決定した。

モデル顔画像

図14のように目の位置を上中下、左中右の9種類に口の位置を上中下の3種類の全組合せである27パターンのモデル的な顔画像を作った(図15)。モデルの画素数は、5章の顔画像と同じサイズの12x24ドットとして描いた。

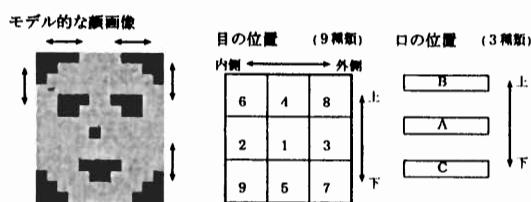


図14：使用した明確な特徴を持つモデル顔画像

このモデル顔画像27パターンを識別するニューラルネットワークのBack Propagation学習パラメータをGAで検索した。Momentum法とDelta-bar-delta法を付加して行うニューラルネットの学習係数の初期値(η)、sigmoid関数の傾き(β)、初期結合荷重の分布幅(W_d)、慣性係数(α)、学習率増加係数(κ)減少係数(ϕ)と中間層数(NH)の7種類のパラメータの決定を行った。GA探索の方法は、5.3節と同様にして行った。

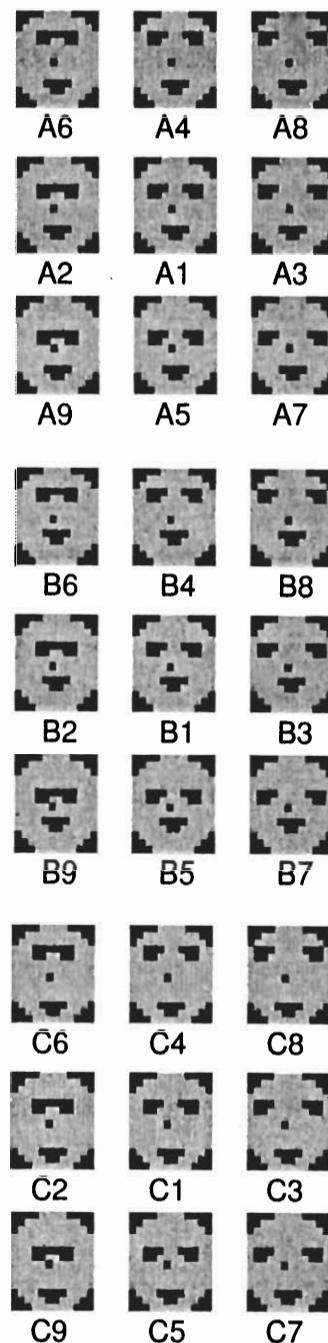


図15：モデル顔画像全30パターン

[GA探索の結果]

GA探索の結果、図16に適応度の変化の様子を示す。表7には、100回の世代交代後の最も優秀な個体の遺伝子型を示す。

η	β	W_d	NH	α	ϕ	κ
0.014	0.505	1.262	10	0.750	0.688	0.03299

表7：GAで求められたパラメータ

このパラメータを用いて、モデル顔画像をニューラルネットワークの入力としてパターン認識を行った。ネットワークは、誤差が0.00001以下になるまで学習させた。前と同様にすべての入力データを順次、ニューラルネットに入力して、中間層の出力を調べた。このときの中間層の各ユニットの出力値を図18に示す。ここで、各ユニットが明るいほど出力の値が大きいことを表す。図18(a)は口の位置(A,B,C)が同じパターンごとにグループにして並べた。図18(b)は目の位置(1, …, 9)同じパターンごとにグループにして並べ変えただけのものである。

その結果、中間層8は、口の位置Bに強く反応している。中間層2、は目の位置が9と5に強く反応し、中間層7は、目の位置が3と8に強く反応している。つまり、目の位置に対応したユニットや口の位置に対応したユニットがそれそれぞれあることがわかる。図19は、各パターンごとに、中間層の出力を要素とするベクトルで表し、各パターン間のなすユークリッド距離を多次元尺度法で2次元平面に近似展開したものである。口の位置のグループA,B,Cごとに線で結んだ。その結果、口の位置の同じグループは近くに配置された。さらにそのグループ内では、目の位置が近い順に9,5,7,3,8,4,6,2と配置された。これは、図14の目の位置の図と同じ順番となった。

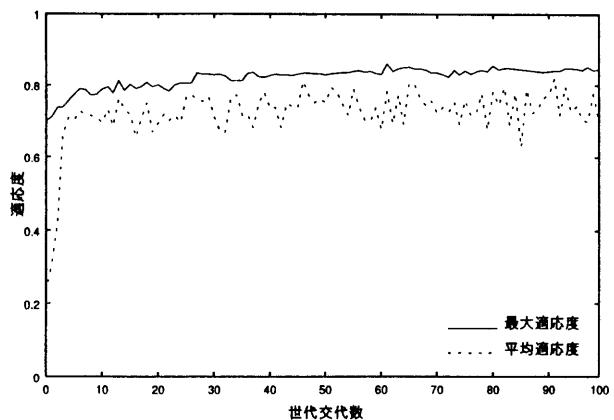


図16：モデル顔画像認識のためのGAの世代ごとの適応度変化

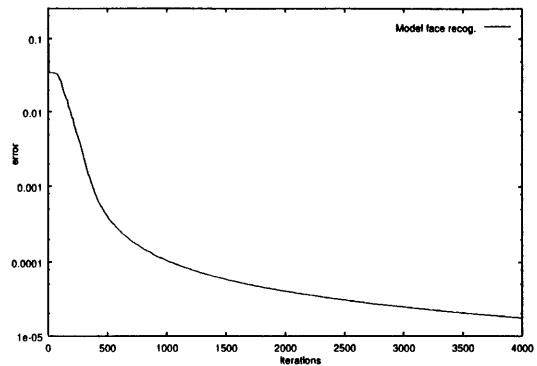


図17：モデル顔画像学習の誤差減少の様子

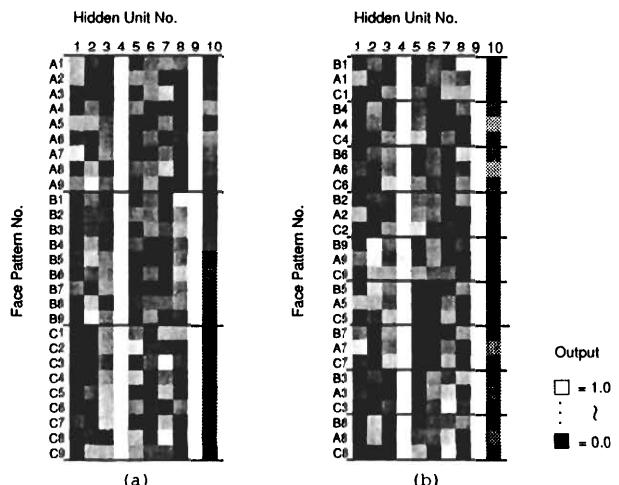


図18：中間層の各ユニットの出力値

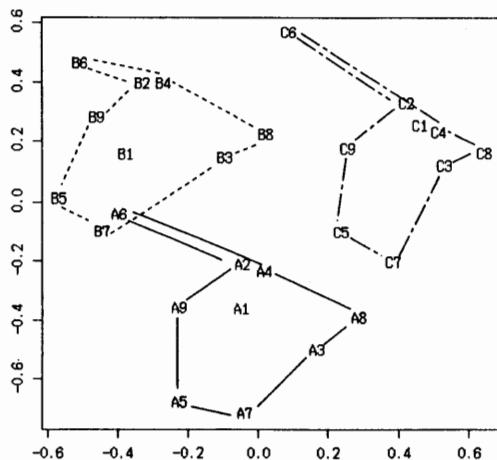


図19：MDSによる中間層出力からのパターンマッピング

6.1 考察と今後の展望

本研究では、階層型ニューラルネットワークの学習パラメータについて、(I)遺伝的アルゴリズム(GA)を用いて最適値を求めた。GAでは、同じ個体でもニューラルネットワークの初期値により世代ごとに適応度が変化するという特有の性質がある。その性質に対応するために、現世代の適応度を前世代の適応度との平均をとる手法を新たに考案し、集団の最大適応度を安定化することができた。GAで求めたパラメータは、学習を高速化させる能力だけでなく、初期値によらず振動を防ぐ収束安定性に特に優れており、また容易に求められようになり、従来まで試行錯誤により求めていたニューラルネットワークの1つの弱点が克服された。次に(II)学習パラメータはGAによるニューラルネットワークを用いて、輪郭や各造作を含めた濃度パターン全体としての顔画像を入力として、顔画像による個人識別を行った。学習終了後のニューラルネットワークに学習で用いたパターンを入力したところ100%認識した。更に、(III)学習後のニューラルネットワークに各顔パターンを順次入力して、中間層からパターン毎の出力を取り出して解析した。そして、多次元尺度法を使って中間層出力のパターン間の類似性を2次元空

間上にマッピングした。その結果、中間層にはそれぞれ入力した顔画像の特徴が現れていることが確かめられた。しかし、より特徴を明確に解析するために、人工的な顔画像を用いて同様な実験を行ない特徴を解析した。結果として、多次元尺度法に示されたように、中間層の出力には明確な特徴が確認された。今後の課題としては、実用性を考慮した入力画像の異なったブロック化の方法や、画像の大小や回転への適用の検討が挙げられる。また、未学習画像への対応の検討も必要である。

参考文献

- [1] V.ブルース著、吉川左紀子訳、”顔の認知と情報処理、”サイエンス社、1990.
- [2] D.E.Rumelhart, G.E.Hinton, and R.J.Williams, ”Learning internal representations by error propagation,” Parallel Distributed Processing, vol.I, pp.318–362, 1986.
- [3] Robert A. Jacobs, ”Increased Rates of Convergence Through Learning Rate Adaptation,” Neural Networks, Vol.1, pp.295–307, 1988.
- [4] 小杉信, ”モザイクとニューラルネットを用いた顔画像の認識,”信学論, Vol. J 76-D-II, No.6, pp.1132-1139, 1993.
- [5] 賈柑, 戸田尚宏, 白井支朗, ”ニューラルネットワークにおける逆伝搬学習アルゴリズムの初期値設定に関する一考察,”信学論, Vol. J 73-D-II, no.8, pp.1179-1185, 1990.
- [6] 高橋裕樹, 中嶋正之, ”遺伝的アルゴリズムを用いた最適な階層型神経回路網の構造決定に関する一考察,”信学論, Vol. J 79-D-II, No.11, pp.1920-1928, 1996.
- [7] 長尾智晴, 安居院猛, ”ジェネティックアルゴリズム,”昭晃堂, 1993.

- [8] Harmon L. D. and Julesz B., "Masking in visual recognition: Effects of two-dimensional filtered noise", Science, 180, 15, pp.1194–1197 (June 1973).
- [9] David Marr著, 乾敏郎訳, "Vision," 産業図書, 1987.

7 appendix 1

突然変移パラメータの値

遺伝子	操作
遺伝子 1	(操作 1) 遺伝子を $0 \leq x < \text{MAX}_w$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子に $0 \leq x < 0.4$ で与えられる乱数 x を加える。 (操作 3) 遺伝子から $0 \leq x < 0.4$ で与えられる乱数 x を引く。 (操作 4) 遺伝子を 1.2 倍する。 (操作 5) 遺伝子を 0.8 倍する。
遺伝子 2	(操作 1) 遺伝子を $0 \leq x < \text{MAX}_w$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子に $0 \leq x < 0.4$ で与えられる乱数 x を加える。 (操作 3) 遺伝子から $0 \leq x < 0.4$ で与えられる乱数 x を引く。 (操作 4) 遺伝子を 1.2 倍する。 (操作 5) 遺伝子を 0.8 倍する。
遺伝子 3	(操作 1) 遺伝子を $0 \leq x < \text{MAX}_w$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子に $0 \leq x < 0.4$ で与えられる乱数 x を加える。 (操作 3) 遺伝子から $0 \leq x < 0.4$ で与えられる乱数 x を引く。 (操作 4) 遺伝子を 1.2 倍する。 (操作 5) 遺伝子を 0.8 倍する。
遺伝子 4	(操作 1) 遺伝子を $1 \leq x \leq \text{NH}_{\max}$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子を +2 する。 (操作 3) 遺伝子を +1 する。 (操作 4) 遺伝子を -2 する。 (操作 5) 遺伝子を -1 する。
遺伝子 5	(操作 1) 遺伝子を $0 \leq x < 1.0$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子に $0 \leq x < 0.1$ で与えられる乱数 x を加える。 (操作 3) 遺伝子から $0 \leq x < 0.1$ で与えられる乱数 x を引く。 (操作 4) 遺伝子を 1.2 倍する。 (操作 5) 遺伝子を 0.8 倍する。
遺伝子 6	(操作 1) 遺伝子を $0 \leq x < 1.0$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子に $0 \leq x < 0.1$ で与えられる乱数 x を加える。 (操作 3) 遺伝子から $0 \leq x < 0.1$ で与えられる乱数 x を引く。 (操作 4) 遺伝子を 1.2 倍する。 (操作 5) 遺伝子を 0.8 倍する。
遺伝子 7	(操作 1) 遺伝子を $0 \leq x < \text{MAX}_w$ で与えられる乱数 x で置き換える。 (操作 2) 遺伝子に $0 \leq x < 0.002$ で与えられる乱数 x を加える。 (操作 3) 遺伝子から $0 \leq x < 0.002$ で与えられる乱数 x を引く。 (操作 4) 遺伝子を 1.2 倍する。 (操作 5) 遺伝子を 0.8 倍する。

8 appendix 2

突然変異操作

N_p, P_a, N_{test} を変化させて、お互いのパラメータの相互の影響について示す。一つのパラメータを変化させるときは、その他のパラメータを固定している。適応度の計算手順の (Step 4) で、現世代の適応度を、前世代との平均をとつて計算した場合と、平均をとらない場合との比

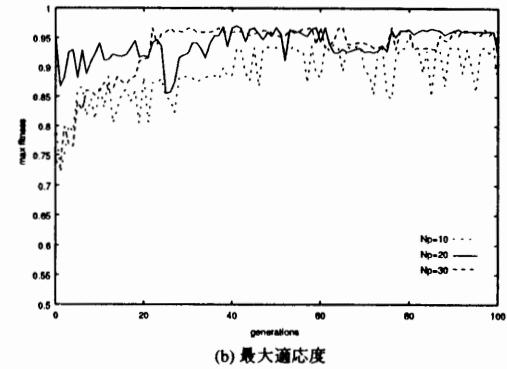
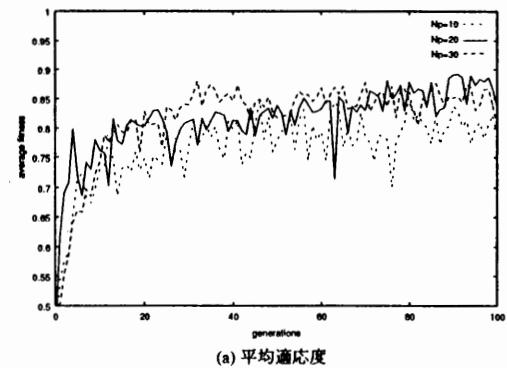


図20：個体数 N_p を変化させたときの適応度

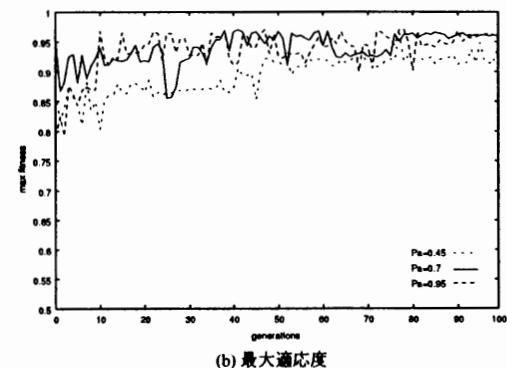
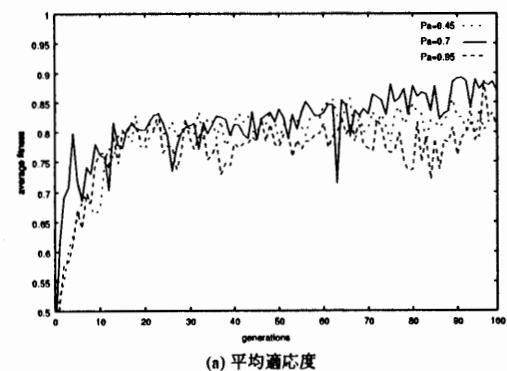


図21： P_a を変化させたときの適応度

較も示す。最大適応度と平均適応度の変化の様子を図22～図23に示した。

個体数を変えたところ、 $N_p=30$ の場合は35世代ごろに、 $N_p=20$ の場合は75世代ごろに、平均適応度が0.83程度になり、収束している。 $N_p=30$ の最大適応度は、21世代以降0.90から0.95の間で安定しているが、 $N_p=10$ の場合は、100世代近くなても不安定である。これは $N_p=10$ では個体数が少なすぎて100世代では不十分であるためと思われる。

生存率 P_a について、 $P_a=0.45$ の場合は最大適応度があがるのが遅れている。 $P_a=0.95$ の場合は平均適応度が70世代以降も不安定である。このことから、 P_a の値を大きくすると、そのぶん多い世代交代数が必要であることがわかる。この P_a の値は、初期値により結果が大きく変わる問題に対しては大きくし、逆に初期値に影響されない問題に対して小さく設定することが必要であると言える。

テスト回数 N_{test} は、大きくすると平均適応度の安定性が得られるが、最大適応度に関しては平均化されてグラフ上は最大適応度が押さえられている。ただし、初期値によらない収束安定性のよいパラメータを求めるならば、 N_{test} は大きい方がよいと思われる。

図23によると、適応度の計算手順の（Step 4）で、現世代の適応度を、前世代との平均をとって計算した場合（Averaging）と平均をとらない場合（No Averaging）では、平均をとらない場合の最大適応度の方が安定が悪い。これは、よい個体が現れても、次世代でたまたま適応度が低くなり再生できることによると考えられる。

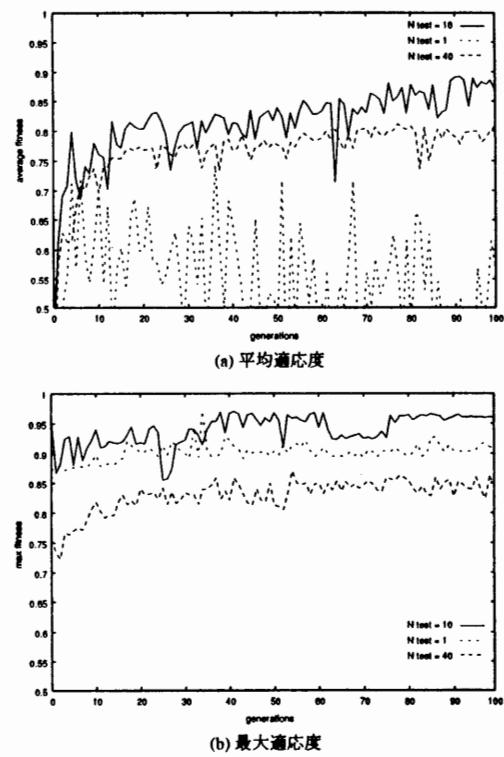


図22： N_{test} を変化させたときの対応度

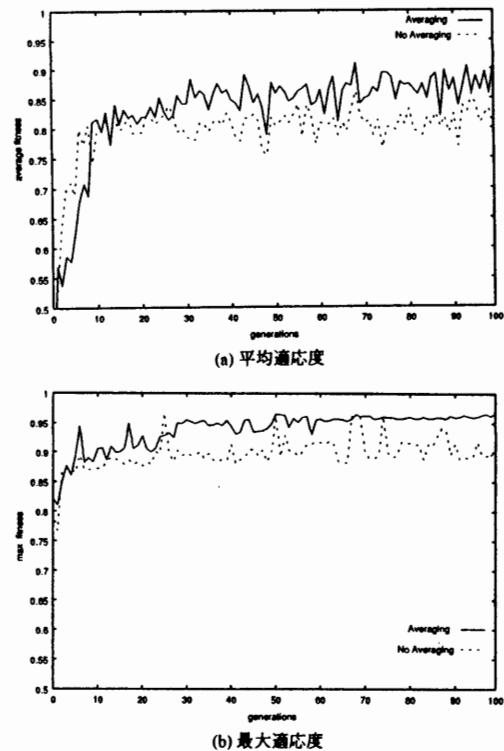


図23：適応度を前世代と平均化させたときと平均化しないときの対応度

A designing of neural network using genetic algorithms, and human-face recognition using this network

Masahiro Nakahata

Michihiro Amenomori

*Department of Electric Information System
Engineering*

*Faculty of Science Technology, Hirosaki
University, Hirosaki 036, Japan*

abstract

We examined human face recognition using feed forward neural network. When we construct neural network, (1) some parameter values which also contain a number of node in hidden layer were derived using Genetic Algorythm(GA) method. (2) 30 face data from human face database (Olivetti Research Laboratory) were learnt by this network. The recognition rate (100 %) was checked by this network. (3) To confirm clearly that the output of each node of hidden layer is reflecting in special feature of a face, we made 30 images of characteristic artificial face (changing an arrangement of mouth and eyes). Then, the role of that output for new face images were examined using MDS (multi-dimensional-scaling) method. The results clearly show that output of nodes in hidden layer reflect well in the features of faces.