

増殖淘汰法および分類ネットを用いた手書き漢字認識

王 晋 申[†] 荒井正之^{††} 奥田健三[†]

多字種の手書き漢字認識は通常分類と識別との2段階で行われる。分類は幾つかの候補文字を選び、識別は数少ない候補文字を認識する。近年ニューラルネットワークの研究により少数の手書き漢字認識に対して十分な効果が得られたため、多字種の手書き漢字認識における分類が特に重要な課題となっている。2段階の漢字認識においては、前段の分類性能が後段の識別に大きな影響を与えるので、有効な分類方法の研究が必要である。われわれはニューラルネットによる印刷漢字の自己増殖分類法を分析し、増殖淘汰分類法および分類ネットを提案する。増殖淘汰分類法は漢字の統計的類似度によって約1,000字種の漢字を幾つかのグループに分類し、分類ネットは分類されたグループごとを複数ベクトルで表すことにより、手書き漢字のパターン変動に対処する。分類された漢字グループにおいてニューラルネットワークにより少数漢字を識別する。分類と識別ネットを識別関数により結合し、手書き漢字の認識システムを構成した。約1,000字種の漢字分類・認識実験により、分類率は95.2%となり、認識システムの認識率93.6%が得られた。

Hand-Written Kanji Recognition Using Self-Growing/Sifting Method and Classification Network

JINSHEN WANG[†], MASAYUKI ARAI^{††} and KENZO OKUDA[†]

Recognition for a lot of Hand-Written Kanji is ordinarily done with two stages of classification and discrimination. The several candidate characters are selected from a lot of kanji in the classification stage and then one of them is recognized as the result in the discrimination stage. As Neural Network are efficient on recognizing a rather small number of characters, the theme which should be studied is the classification for a lot of characters. In this paper we analyze self-growing method in classification for printed kanji recognition, and propose self-growing/sifting method and classification network for the classification of kanji. We classify a lot of characters into many groups by the self-growing/sifting method and classified characters are recognized by hierarchical neural networks using error backpropagation method. In the classification network we generate multiple vectors in each group so that to raise classification rate. The networks of classification and discrimination are combined by recognition function and recognition system of hand-written kanji is constructed. On the experiments for 996 characters, we have obtained 95.2% classification rate and 93.6% recognition rate.

1. ま え が き

近年ニューラルネットワークによる漢字認識方法が広く研究されている。その中でバックプロパゲーション法(以下BPネットと呼ぶ)が注目されている。この方法は少数の漢字の認識には有効であるが、多字種の漢字に対しては認識率が低下し、学習時間が非常に長くなるため適しないと考えられる。数千字種の手書き漢字認識問題において、分類・識別という2段階認

識方式が萩田らによって従来提唱されており^{1),2)}、前段の分類により候補文字を幾つか選び、後段の識別により候補文字から正解文字を1つ選択する。この2段階認識法は分類のための辞書と識別のための辞書との2つが必要となる。また分類段階において全字種を幾つかのグループに分類するのではなく、入力漢字によって、候補文字を選び出すのである。入力漢字が異なると、選ばれた候補漢字も異なるので、後段の識別にはBPネットを適用できない。

一方、ニューラルネットによる印刷漢字認識法として、combNETおよびcombNET-IIが岩田らによって提案されている^{3),4)}(以下その分類法をそれぞれ自己組織化法、自己増殖法と呼ぶ)。この2つの方法はともに全字種を幾つかのグループに分類し、その後

[†] 宇都宮大学工学部情報工学科
Department of Information Science, Faculty of Engineering, Utsunomiya University

^{††} 帝京大学理工学部情報科学科
Department of Information Sciences, School of Science & Engineering, Teikyo University

ループ内の漢字認識を行う。またグループに含まれる漢字種が変わらず、BP ネットが使用でき、多字種の印刷漢字に対して、良い認識結果が得られている。自己組織化法は T. Kohonen の自己組織化学習則⁶⁾による分類法で、自己増殖法は K-means 法⁹⁾から発展してきたものと考えられる。われわれはこの2つの方法を約1,000字種の手書き漢字分類に適用したところ、得られた分類率はかなり低かった。そのまま利用すれば1,000字種の手書き漢字に対して認識率の向上は期待できないと考えられる。

手書き漢字の認識を取り扱う本論文では、まず分類率と分類均等性の改善を目指すために文献4)の自己増殖分類法を改良した増殖淘汰分類法を考案し、次に手書き漢字のパターン変動に対して増殖淘汰法により分類される各グループに複数参照ベクトルを持たせる分類ネットを提案した。これにより、分類率の向上と分類ネットの学習時間の削減を図る。最後に漢字認識システムを構築し、996字種の手書き漢字の認識を行った結果について述べる。

2. 増殖淘汰分類法

ニューラルネットによる印刷漢字分類法において、自己組織化法を用いると、分類された各漢字グループ間で漢字数のばらつきが大きく、多字種の漢字認識に悪い影響を与えると指摘されている⁴⁾。この分類の非均等性は自己増殖法により、各グループ内の漢字数の上限を指定することで改善されたが、実際に自己組織化法、自己増殖法を1,000字種の手書き漢字分類に適用したところ、自己組織化法は学習時間が長く、各グループに分類された字種数がかなりばらつく。自己増殖法の分類率は、自己組織化法に比べ数パーセント低くなったので、自己増殖法の分類率を上げるため、その学習アルゴリズムを改良する。

2.1 自己増殖法の改良

自己増殖法により分類された漢字グループを調べたところ、類似文字と非類似文字が同グループに含まれることが多く、分類率低下の要因になると考えられる。自己増殖法の学習則を追究すると、2つの改善すべき点があると考えられる。1)第1過程では、実際に新しいニューロンを生成するときの整合度に関するしきい値 (R_{th}) を0にしているために、入力される漢字の類似性を問わず、すでに存在するニューロンにしか投入しない。2)第2学習過程では、ニューロン M_i に入っている漢字 X_k が再入力されるときに、先に X_k

が M_i の計算に参加し、 X_k は再び M_i に入りやすくなる。そのために第2学習過程では、各ニューロンのポテンシャルがあまり変化せず速やかに収束し、それ以上分類が進まず、それが分類率低下の原因になると考えられる。

そこで非類似漢字が類似漢字グループに含まれないようにするため、自己増殖法のアルゴリズムの第1, 2学習過程を改良した。1)第1学習過程では最初から類似漢字グループに非類似漢字が入ることを抑えるため、自己増殖法のしきい値 R_{th} を適切に選ぶ。2)第2学習過程では非類似文字の混入を避けるため step 1 を設置し、入力漢字を今の所属ニューロンから外し、その最適整合ニューロンを求め直す。3)上記の1)と2)のいずれかを実施すると、自己増殖法の均等性を損なうことになる。良い分類を求めながら、分類均等性をも保つためにわれわれは淘汰 step 6 を新設し、ニューロンのポテンシャル下限値 (G_{low}) の設定により、その値未満のニューロンを淘汰する。増殖淘汰学習は2つの学習過程からなり、そのパラメータの定義およびアルゴリズムを以下に示す。

2.2 増殖淘汰学習アルゴリズム

n : 入力ベクトルの次元数

K : 学習サンプル総数

X_k : k 番目の入力ベクトル ($k=1, 2, \dots, K$)

M_i : i 番目のニューロン、またはその参照ベクトル

g_i : ニューロン i の内部ポテンシャル (サンプル数)

G_{up} : g_i の上限、 G_{up} を超えると分裂を起こす

G_{low} : g_i の下限、 G_{low} 未満のニューロンを淘汰

R_{th} : 新しいニューロンを生成するときのしきい値

v : 生成されたニューロン数

[第1学習過程]:

この学習過程は1回のみ実施し、初期のベクトル量子化ネットを生成する。

step 0: ニューロンが存在していない初期状態である。

step 1: 入力ベクトル X_k ($k=1$) を第1番目のニューロンとする。

$$v=1 \quad (1)$$

$$g_1=1 \quad (2)$$

$$M_1=X_1 \quad (3)$$

各入力ベクトル X_k について以下の step 2~step 5 を繰り返す。

step 2: 入力 X_k の所属するニューロン M_i を単純類似度⁷⁾により求める。

$$\text{sim}(\mathbf{X}_k, \mathbf{M}_c) = \max_i \{\text{sim}(\mathbf{X}_k, \mathbf{M}_i)\} \quad (4)$$

$$\text{sim}(\mathbf{X}_k, \mathbf{M}_i) = \frac{(\mathbf{X}_k, \mathbf{M}_i)^2}{|\mathbf{X}_k|^2 \cdot |\mathbf{M}_i|^2} \quad (5)$$

[ここで平方根の計算に比べて平方の計算時間が短いので、式(5)を採用した。またこの式(5)と文献4)の式(4)のいずれを用いても、分類率は同じであることを確認している.]

もし $\text{sim}(\mathbf{X}_k, \mathbf{M}_c) \geq R_{th}$ ならば、step 3 へ進む。そうでなければ、step 5 へ進む。

step 3: \mathbf{X}_k をニューロンに加え、ポテンシャルを増やし、ニューロンを修正する。

$$g_c^{(new)} = g_c^{(old)} + 1 \quad (6)$$

$$\mathbf{M}_c^{(new)} = \mathbf{M}_c^{(old)} + \frac{\mathbf{X}_k - \mathbf{M}_c^{(old)}}{g_c^{(new)}} \quad (7)$$

もし $g_c^{(new)} > G_{up}$ ならば、step 4 へ行く。もし $g_c^{(new)} \leq G_{up}$ ならば、step 2 に戻る。

step 4: 1つのニューロンを2つに分裂する。まずニューロン \mathbf{M}_c を用いて次式で与えられる超平面を作る。

$$A \cdot (\mathbf{X} - \mathbf{M}_c) + a_0 = 0 \quad (8)$$

A, a_0 乱数で与える。この超平面によってニューロン \mathbf{M}_c に属する入力ベクトル群 ($G_{up} + 1$ 個) を $\mathbf{M}_c^{(new)}$ と $\mathbf{M}_v^{(new)}$ に2分する。この2分割が偏りを生じる場合、 A, a_0 を変えて、偏りがなくなるまで分割を繰り返す。

$$v^{(new)} = v^{(old)} + 1 \quad (9)$$

$$\mathbf{M}_c^{(new)} = \frac{1}{g_c^{(new)}} \sum_i \mathbf{X}_{ci} \quad (10)$$

$$\mathbf{M}_v^{(new)} = \frac{1}{g_v^{(new)}} \sum_j \mathbf{X}_{cj} \quad (11)$$

ただし、

$$|g_c^{(new)} - g_v^{(new)}| \leq 1 \quad (12)$$

$$\mathbf{X}_{ci} \neq \mathbf{X}_{cj} \quad (13)$$

$$\{\mathbf{X}_{ci}\} + \{\mathbf{X}_{cj}\} + \{\mathbf{X}_c\} \quad (14)$$

step 2 に戻る。

step 5: 新しくニューロン \mathbf{M}_v を生成する。

$$v^{(new)} = v^{(old)} + 1 \quad (15)$$

$$g_v^{(new)} = 1 \quad (16)$$

$$\mathbf{M}_v^{(new)} = \mathbf{X}_k \quad (17)$$

step 2 に戻る。

[第2学習過程]:

この過程では、反復学習により生成されたベクトル量子化ネットの最適化を図る。学習サンプルの入力を繰り返し、ベクトル量子化ネットを学習させる。各ニューロンのポテンシャルが変化しなくなったら、学習

が収束したと見なす。

step 0: 毎回学習前に $k=1$ とする。

各入力ベクトル \mathbf{X}_k について以下の step 1~step 6 を順次繰り返す。

step 1: 入力文字 \mathbf{X}_k を現所属ニューロン \mathbf{M}_b から取り除く。すなわち、この文字をどのニューロンにも属しないようにする。 \mathbf{M}_b のポテンシャルを g_b とすると、 \mathbf{M}_b, g_b は次のように修正される。

$$g_b^{(new)} = g_b^{(old)} - 1 \quad (18)$$

if ($g_b^{(new)} > 0$) then

$$\mathbf{M}_b^{(new)} = \mathbf{M}_b^{(old)} - \frac{\mathbf{X}_k - \mathbf{M}_b^{(old)}}{g_b^{(new)}} \quad (19)$$

else $\mathbf{M}_b^{(new)} = 0$

step 2: 入力文字 \mathbf{X}_k の最適整合ニューロン \mathbf{M}_c を決める (第1過程の step 2 と同じゆえ略)。

もし $\text{sim}(\mathbf{X}_k, \mathbf{M}_c) \geq R_{th}$ ならば、step 3 へ進む。そうでなければ、step 5 へ進む。

step 3: \mathbf{X}_k を最適整合ニューロン \mathbf{M}_c に投入し、 \mathbf{M}_c, g_c を修正する (第1過程の step 3 と同じゆえ略)。

もし $g_c^{(new)} > G_{up}$ ならば、step 4 へ行く。もし、 $g_c^{(new)} \leq G_{up}$ ならば、step 6 へ行く。

step 4: ニューロン分裂によりニューロンを増殖し (第1過程の step 4 と同じゆえ略)、step 6 へ行く。

step 5: 新しくニューロン \mathbf{M}_v を生成して (第1過程の step 5 と同じゆえ略)、step 6 へ行く。

step 6: step 1 で修正されたニューロン \mathbf{M}_b のみに対して、ポテンシャルをチェックし、 $g_b^{(new)} < G_{low}$ ならば、 \mathbf{M}_b を淘汰する。まず、 $\mathbf{M}_b^{(new)}$ に属していた $g_b^{(new)}$ 個の文字 \mathbf{X}_b を $\text{sim}(\mathbf{X}_b, \mathbf{M}_c)$ によりおのおの最適整合するニューロン \mathbf{M}_c に移動し、 $g_b^{(new)}$ が0になるまで繰り返す。第 v 番目のニューロン \mathbf{M}_v のすべての内容を $\mathbf{M}_b^{(new)}$ に移すことにより、 \mathbf{M}_b を淘汰する。その後ニューロン数を1だけ減らす。すなわち、

$$g_b^{(new)} = g_b^{(old)} \quad (20)$$

$$\mathbf{M}_b^{(new)} = \mathbf{M}_v^{(old)} \quad (21)$$

$$v^{(new)} = v^{(old)} - 1 \quad (22)$$

$k \neq K$ ならば、 $k=k+1$ として step 1 へ行く。 $k=K$ ならば、収束判定を行う。収束条件を満たさなければ、step 0 へ行き、収束条件を満たせば、学習を終了する。

2.3 増殖淘汰分類法

増殖淘汰分類法により学習サンプルを学習させ、学習終了時に生成されるニューロン数と各ニューロンに

含まれるおのおのの漢字を記憶する。1ニューロンが1グループを表し、すべてのニューロンにより全字種がニューロン数と同数のグループに分類される。

分類時に入力漢字がどのニューロンと最適整合するかを求め、このニューロンに記憶された幾つかの漢字に入力漢字が含まれれば、正分類とする。

この分類法は G_{up} により分類されるグループ数を制御でき、 G_{low} により分類均等性を図ることができる。 G_{up} を大きくすれば、生成されるグループ数 v が少なくなる。 G_{up} と v の間の関係が次の式でほぼ近似できる。

$$v = \frac{K}{(G_{up} + G_{low})/2} = \varepsilon \cdot \frac{K}{G_{up}} \quad (23)$$

K は学習サンプル総数である。 ε は G_{low} により異なり、例えば $G_{low} = G_{up}/4$ の場合、 $\varepsilon = 8/5$ となる。また G_{up} を超えるときニューロンを2つに分裂するため、 G_{low} は $1 \leq G_{low} \leq G_{up}/2$ を満たす整数である。

3. 分類ネットとその構成法

増殖淘汰法、自己増殖法と自己組織化法はともに、生成されたニューロンにより全字種を幾つかのグループに分割する分類法であり、1つのニューロンに入った漢字群を1グループと見なす。これらの分類法は全字種をクラスタリングし、シングルテンプレートを作り、単純類似度を用いるマッチング法と考えられる。約1,000字種の手書き漢字分類に適用した実験において、上記の3つの分類法では増殖淘汰法の分類率、分類均等性などは自己組織化法、自己増殖法に比べて改善された。しかし、1グループに所属する漢字群が1ニューロンで表され、かつ手書き漢字のパターン変動が大きいため、分類率を大幅に向上するにはまだ不十分である。さらに手書き漢字分類率を向上するために、われわれは1つのグループに複数ベクトルを持たせる分類ネットを考案した。

3.1 分類ネットの構成法

分類ネットの構成には2つの方法があると考えられる。1つは全字種のすべての学習サンプルを自己増殖学習アルゴリズムで学習させ、分類ニューラルネットを作成する(分類ネット1)⁹⁾。この構成法では、1) 字種が多く、学習サンプル数が多い場合には膨大な学習時間が必要である。2) 同字種のサンプルが文字パターン変動のために幾つかのグループに分類されることがあり、分類後の識別BPネットの構成が複雑になる。したがって、われわれはもう1つの構成法(分類ネット2)

を工夫した。

この方法は次の3つの手順による。まず、増殖淘汰法により全字種を幾つかのグループに分ける。次に、各グループについて増殖淘汰学習を行い、各グループを表す複数ベクトルを生成する。最後に、すべてのグループにおいて生成したベクトルを要素とする全字種の分類ネットを構成する。われわれの分類ネットは1) ネットの作成時間が短い、2) 1字種が1グループにしか属しないという利点がある。

後述の予備実験の結果の表4によれば、自己増殖法の分類率が低いので、分類ネット2の構築にはそれを用いても、増殖淘汰法に比べてより高い分類率が得られるとは考えられない。なお、同表4によって、自己組織化法は学習時間が長く、分類均等性も悪いために、分類ネット2の構築には良い方法とは思われない。この2つの方法に対して分類率が高く、分類均等性がよい増殖淘汰法を用いて分類ネットを構築する方法がよいと考えられる。分類ネット2の構成について以下に説明する。

3.1.1 分類ネットのグルーピング

各字種の学習サンプルの平均特徴ベクトルを入力データとし、増殖淘汰分類法により学習させる。生成されるニューロン数をグループ数とし、同じニューロンに属する幾つかの漢字を同一のグループに配分し、全字種を幾つかのグループに分類する。こうしたグループ内の漢字は形が似ており、統計的に共通な性質を持つ。すなわち、同グループ内の漢字が同じニューロンに最適整合するため互いに近づき、逆に異グループに属する漢字は互いに遠ざかるので、分類率の向上に寄与できる。分類されたグループ数を v とする。

3.1.2 グループ内での複数ベクトルの生成

同グループ内のすべての字種の学習サンプルを入力データとし、再び増殖淘汰分類法により学習させる。生成される幾つかのニューロンをグループ内のベクトルとする。第 i グループにおいて j 個のニューロンが生成されるとすると、グループ i に属する複数ベクトルは次のように表される。

$$M_{i1}, M_{i2}, \dots, M_{ij}$$

増殖淘汰法で学習する際、 G_{up} の値により生成されるベクトル数が異なる。この作成方式ではグループに属する字種数の多少に応じ、字種数の多いグループにベクトルが多く作成される。

3.1.3 分類ネットの構築

各グループに番号を付け、同グループの複数ベクトル

ルに同じグループ番号を与える。すべてのベクトルを1次元の配列に置き、全字種の分類ネットとする。分類ネットの構造を図1に示す。max は入力漢字と1グループにおける複数ベクトルのうち、整合度の最大値をとることを意味する。

3.2 分類ネットの分類法

分類ネットの分類法はマルチテンプレート識別法と異なる。マルチテンプレート識別⁹⁾は1字種を1グループとする場合であるが、分類ネットの分類は幾つかの字種を1グループとする場合である。ここで、われわれの分類ネットの分類方式は、まずグルーピング時各字種の所属グループを正解グループとする。次にある漢字サンプルが入力される時、分類ネットのベクトルとの整合度を計算し、最大整合ベクトルの所属グループが正解グループと同じであれば、このサンプルは正分類されたとする。具体的な分類方法を次に述べる。

[分類方式]:

この分類方式では、入力漢字 X_k が入力されると、まずおのおのグループにおいて最適整合ベクトル M_{ci} を計算し、このグループの最適整合値とする。次にすべてのグループの最適整合値において最も大きい値を持つグループ c を求め、このグループを分類結果とする。すべてのグループのうち、整合度が最も大きいグループが正解グループと同じであれば、正分類とする。また、正分類されるサンプル数がサンプル総数に占める割合を分類率と定義する。

$$\text{分類率} = \frac{\text{正分類サンプル数}}{\text{サンプル総数}} \quad (24)$$

4. 手書き漢字分類実験

われわれの漢字分類実験では、小学校学習漢字 996 字種を分類対象として、電総研作成の ETL-9B デー




図1 分類ネット
Fig. 1 Classification Net.

タベースの手書き漢字を40セット(41番~80番)取り、大小・位置の簡単な正規化を施し、LDCD 特徴128次元¹⁾により特徴抽出を行う。そのうち30セット(41番~70番)を学習サンプル、10セット(71番~80番)を未学習サンプルとする。学習には学習サンプルを用い、分類には未学習サンプルを使用する。実験には SONY NWS-5000 ワークステーションを使う。

4.1 増殖淘汰分類法

本節では、996 字種の手書き漢字の分類実験を行い、分類率や分類均等性などについて自己増殖法、自己組織化法および増殖淘汰法を評価する。実験において、各字種の 30 サンプルを平均したものを学習サンプルとする。

4.1.1 自己増殖法と増殖淘汰法の比較

自己増殖法と増殖淘汰法について分類実験を行った。その結果を表1に示す。候補字数は同じ、グループ数はほぼ同じ場合、増殖淘汰法の分類率が7%向上できることがわかった。また自己増殖法において R_{th} の値を0から1まで0.1ずつ変化させた分類実験において、 $R_{th}=0.7$ で分類率は57.3%と少し上がったが、分類されたグループ数は148に増加し、各グループの字数は1から15の間にはばらついた。これは、入力漢字の最適整合ニューロンとの整合度がしきい値 R_{th} を超えないためグループが多く生成されたのである。増殖淘汰法では、第2過程の step 6 を設定したため、字種数が G_{low} 未満のグループを淘汰し、分類均等性を保っている。また step 1 を施したため、分類されたグループにおいて類似漢字が多くなり、分類率もさらに向上した。増殖淘汰法の第2学習過程において step 1, step 6 を設置したために、 R_{th} の値の変化による分類率の変化は1%未満であった。そこで以下の実験では第2過程において $R_{th}=0$ とした。

自己増殖法と増殖淘汰法により分類された漢字グループの一部を表2に示す。増殖淘汰法を用いると、自己増殖法で分類した漢字グループから非類似漢字を

表1 自己増殖法と増殖淘汰法の比較
Table 1 Comparison of self-growing and self-growing/sifting methods.

| 学習法別 | | 自己増殖法 | 増殖淘汰法 |
|---------|----|----------------------|-------------------------|
| 実験条件 | 共通 | $G_{up}=15, 100$ 回学習 | |
| | 相違 | $R_{th}=0$ | $R_{th}=0.7, G_{low}=5$ |
| 分類率 (%) | | 55.1 | 62.1 |
| 組内字分布 | | 5~15 | 5~15 |
| グループ数 | | 102 | 104 |

取り除くのに役立つことがわかったが、非類似漢字が完全に取り除かれていないこともある。これは漢字を構成する部分構造のおおのが複数のグループに類似する場合があるためと、手書き漢字のパターン変動があるためと考えられる。

4.1.2 増殖淘汰法の均等性と学習特性

$G_{up}=15, R_{th}=0.7$ の条件で G_{low} の変化による分類結果を表3に示す。自己増殖法に比べ、いずれの場合も分類率は高い。しかし G_{low} を大きくするにつれて、分類率が少しずつ低下していく傾向がある。また実験によって $G_{low} \geq 5$ の場合 100 回まで学習させても収束しないが、学習 10 回の結果に比べ分類率はほとんど変わらない。

$G_{up}=15, G_{low}=4$ と $R_{th}=0.7$ の条件で学習回数による分類結果を図2に示す。32回で学習が終了した。また 10 回学習以降分類率がほとんど変わらず、10 回で学習を打ち切ってもよいと考えられる。

表 2 分類された漢字グループ例
Table 2 Example of characters in classified groups.

| No. | 自己増殖法 |
|-----|--------------------|
| 1 | 開闢開闢開, 閉問門周同, 用 |
| 2 | 貨質貧資質, 賞貨質貧質, 背骨算 |
| 3 | 域磁城織職, 成以確地池, 燃破八班 |
| 4 | 丸九乳北乱, 犬元光七先, 悲亡 |
| 5 | 紀純絶総能, 犯礼化兆 |

| No. | 増殖淘汰法 |
|-----|-----------------|
| 1 | 開闢開闢開, 閉問門 |
| 2 | 貨質貧資質, 賞貨質貧質, 背 |
| 3 | 域磁城織職, 成械減識 |
| 4 | 丸九乳北乱, 礼化花兆犯 |
| 5 | 紀純絶総能, 紙終給統統 |

表 3 増殖淘汰法における G_{low} の効果
Table 3 The effect of G_{low} in self-growing/sifting classification method.

| G_{low} | 最小候補字数 | 100 回学習分類率 (%) | 分類されたグループ数 | 収束回数 |
|-----------|--------|----------------|------------|------|
| 1 | 2 | 62.5 | 127 | 29 |
| 2 | 2 | 62.4 | 128 | 40 |
| 3 | 3 | 62.2 | 122 | 26 |
| 4 | 4 | 62.2 | 113 | 32 |
| 5 | 5 | 62.1 | 104 | — |
| 6 | 6 | 61.2 | 99 | — |
| 7 | 7 | 60.5 | 94 | — |
| 8 | 8 | 59.7 | 88 | — |

4.1.3 3つの分類方法の比較

上記 4.1.2 項の実験において、 $G_{low}=5$ の条件での増殖淘汰法および自己増殖法と自己組織化法についての分類実験結果を表4に示す。増殖淘汰法では、自己増殖法に比べて分類率が7% 向上し、自己組織化法に比べて分類率が約1% 向上し、かつ分類均等性や学習時間などがかなりよく、3つの分類法において最も優れている。

4.2 分類ネットによる分類

上記の実験結果より印刷漢字の分類に用いられた自己組織化法、自己増殖法、増殖淘汰法をそのまま手書き漢字の分類に用いるのは適当でないことがわかった。本節では3章で述べた2つの分類ネットにより分類実験を行う。そのうち分類ネット2の実験において、グルーピング時には4.1節の平均学習サンプルを使い、分類ネット作成時には全学習サンプルを用いる。

4.2.1 分類率とベクトル数の関係

グルーピング時、 G_{up} を小さくすればグループ内の字種数が少なくなり、BP ネットの識別率の低下を防




図 2 学習回数による分類結果
Fig. 2 Classification rate vs. number of learning times.

表 4 各分類方法の比較
Table 4 Comparison of classification methods.

| 分類方法別 | | 増殖淘汰法 | 自己増殖法 | 自己組織化 |
|---------|-----------|-------|-------|-------|
| 実験条件 | G_{up} | 15 | 15 | 10*10 |
| | G_{low} | 5 | — | — |
| | R_{th} | 0.7 | 0.0 | — |
| | 学習回数 | 10 | 5 | 80 |
| グループ数 | | 104 | 102 | 100 |
| 最大候補字数 | | 15 | 15 | 27 |
| 最小候補字数 | | 5 | 5 | 1 |
| 相対学習時間 | | 2 | 1 | 18 |
| 分類率 (%) | | 62.1 | 55.1 | 61.3 |

げる。ここで $G_{up}=15$, $G_{low}=4$ の条件で 113 グループが生成された。

分類ネット作成時、 $G_{low}=G_{up}/4$ と設定し、 G_{up} の値を変化させることにより、ベクトル数の違う分類ネット 2 を構成した。分類率が G_{up} により変化する様子を図 3 に示す。 G_{up} を小さくすることによって分類ネット 2 のベクトル数が増加し、分類率が向上する。

実験によって $G_{up}=20$ の場合、分類ネットの分類率は 83.5% であり、表 4 の増殖淘汰法に比べ、分類率が 20% 以上高くなった。また G_{up} が減少するにつれて分類率曲線は一定値に近づく。例えば、 $G_{up}=10$ の場合分類率は 84.4% であり、 $G_{up}=20$ の場合に比べ、1% 未満上がったが、ベクトル数とその 2 倍となった。これは、1 字種あたり 30 サンプルの手書き漢字によるパターン変動を $G_{up}=20$ 程度のベクトル数ではほぼ吸収できたものと考えられる。

4.2.2 分類率と分類均等性の関係

グルーピング時分類均等性に及ぼす G_{low} の効果を表 3 に示した。分類ネット 2 における分類率と均等性の関係を調べるため、表 3 のグルーピングに対して、同じベクトル数を持つ分類ネットを次の方法で生成する。グループにおける 1 字種あたり 30 サンプルの平均を計算し、求めた平均サンプルをグループ内の 1 つの参照ベクトルとする。そうすれば、表 3 における G_{low} 値のいずれの場合に対しても 996 個の参照ベクトルを持つ分類ネットが生成できる。これらの分類ネットの分類結果を表 5 に示す。この表によれば、 G_{low} が変化しても分類率はほとんど変わらない。したがって、 $G_{low}=1\sim 8$ 間の値を任意に選択することができ、 G_{low} を大きく選ぶことにより、BP ネットの数を削減するのに有効である。

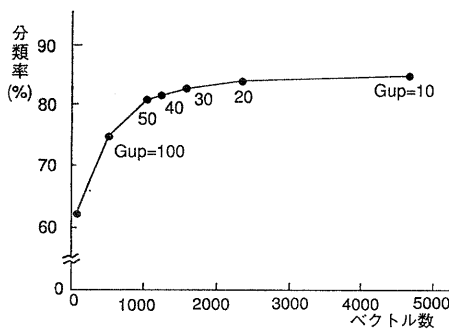


図 3 ベクトル数による分類結果
Fig. 3 Classification rate vs. number of vectors.

4.2.3 分類ネット構成法の比較

最大候補字数を同じにする条件で分類ネット 1 と分類ネット 2 について実験を行う。この条件を満たすため分類ネット 1 においてグループあたり最大字種数のしきい値 $h_{th}=15$ 、分類ネット 2 においてグルーピング時の $G_{up}=15$ とする。比較実験の結果を表 6 に示した。ベクトル数がほぼ同程度の場合分類ネット 2 では分類率と学習時間が共に優れていることがわかった。また分類ネット 2 ではグループ数が少なく、1 字種が 1 グループのみに属するので、グループ内の漢字識別に対する BP ネットの構築が非常に簡明になる。

また、グルーピング時 G_{up} を 15 とし、同程度の参照ベクトル数を持つ場合では、分類ネット 2 の構築に自己増殖法を用いれば、その分類率は増殖淘汰法を用いるのに比べて 4% 低下した。なお、分類ネット 2 の構築において、自己増殖法は学習時間が長く、分類均等性が悪いので、検討対象から外した。

4.3 まとめおよび考察

4.3.1 増殖淘汰法について

- 1) 自己増殖法を改良することによって、増殖淘汰法により分類率を向上できることを明らかにした。
- 2) パラメータの設定により、分類されるグループ内の字種数を $G_{up}\sim G_{low}$ の間に抑えることができた。
- 3) 増殖淘汰法は自己増殖法に比し分類率が高く、自

表 5 分類ネットにおける G_{low} の効果
Table 5 The effect of G_{low} on classification network.

| G_{low} | 最小候補字数 | 分類率 (%) | グループ数 |
|-----------|--------|---------|-------|
| 1 | 2 | 81.3 | 127 |
| 2 | 2 | 81.2 | 128 |
| 3 | 3 | 80.9 | 122 |
| 4 | 4 | 81.3 | 113 |
| 5 | 5 | 81.2 | 104 |
| 6 | 6 | 81.1 | 99 |
| 7 | 7 | 81.1 | 94 |
| 8 | 8 | 81.4 | 88 |

表 6 分類ネットの比較
Table 6 Comparison of classification networks.

| ネット構成法 | 分類ネット 1 | 分類ネット 2 |
|---------|-------------|-------------|
| 実験条件 | $h_{th}=15$ | $G_{up}=15$ |
| 分類率 (%) | 77.5 | 82.4 |
| 相対生成時間 | 50 | 1 |
| ベクトル数 | 1421 | 1597 |
| グループ数 | 1421 | 113 |
| 候補字数 | 1~15 | 4~15 |

己組織化法に比べ学習時間は短く、分類均等性がよく、3つの分類法において最も優れている。

4.3.2 分類ネットについて

1) 分類ネット生成時の G_{up} の値を小さくすることにより、グループ内のベクトルが多く作成され、分類ネットの分類率が大幅に向上した。これは、各グループが類似漢字からなり、グループ間の漢字があまり似ていないので、分類率が高くなったと考えられる。

2) 分類される漢字が1グループにしか属しないので、認識用のBPネットの構成と学習が容易である。またすでに提案された分類ネット1に比べ学習時間も著しく少なくなった。

5. 手書き漢字認識実験

5.1 認識システム構成

996字種の漢字を認識するために、図4に示す認識システムを構築した。これは分類ネット、BPネットおよび識別関数 f からなる。この認識システムの動作を次に記す。

- まず漢字パターンが入力される時分類ネットの各ベクトルとの最大整合度を計算し、各グループごとに整合度の最大値 SM を求める。

- 次に SM の高い順に幾つかのグループを選び、そのグループに接続しているBPネットの最大出力を計算し、その値を SB で表す。

- 最後に選ばれる各グループについて識別関数 f を計算し、 f の最大値を持つグループにおいてBPネットの最大出力ニューロンに対応づけられる漢字を認識結果とする。また f を使わない場合、 SM 最大の1グループを選び、それに接続しているBPネットの識別結果をシステムの認識結果とする。ここで識別関数 $f^{10),11)}$ は次の式である。

$$f = \gamma \cdot SM + (1 - \gamma) \cdot SB \tag{25}$$

5.2 認識実験および結果

手書き漢字認識率をさらに向上するために、768次元の外郭方向寄与度特徴 (P-DC)²⁾を用いる。他の実験条件は4章に使ったものと全く同じである。実験結果を表7に示した。ただし、3層BPネットにおいて入力ニューロン数は768、中間ニューロン数は16、出力ニューロン数はグループの字種数に等しい。認識関数を使う場合候補グループ数を2とした。

分類では107グループが作成され、95.2%の分類率が得られた。107グループのBPネットについておの

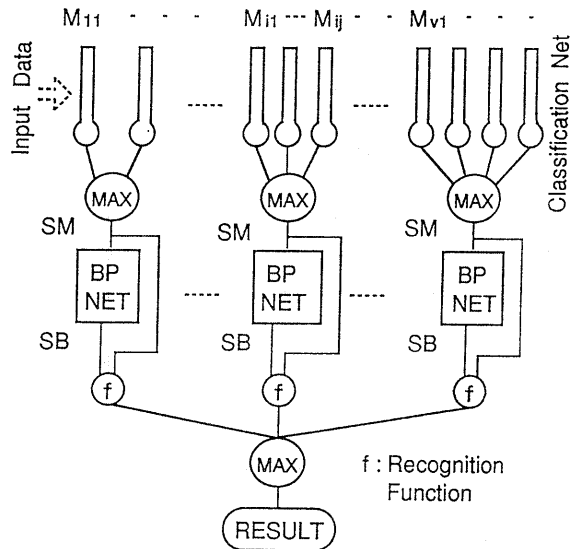


図4 認識システムの構成
Fig. 4 Constitution of Recognition System.

表7 996字種の漢字認識結果
Table 7 Recognition results of 996 characters.

| 実験項目 | 条件 | 結果 (%) |
|-----------|---|--------|
| 全字種の分類率 | グルーピング: $G_{up}=15, G_{low}=4$ ネット生成: $G_{up}=20, G_{low}=5$ | 95.2 |
| グループ平均識別率 | 3層BPネット: 768-16-字数 $\eta=0.2, \alpha=0.5$ | 97.5 |
| 全字種の認識率 | f 不使用 | 93.1 |
| | f を使用, $\gamma=0.95$ | 93.6 |

おのの識別率を求め、その平均は 97.5% となった。全字種の認識率では、識別関数を使わない場合 93.1% で、識別関数を使用した場合、 γ の増加とともに認識率は向上し、 $\gamma=0.95$ で、認識率は 93.6% に達し、その後 $\gamma > 0.95$ では減少する。

一方、図3に示した分類率の変化と同様に、参照ベクトル数がある値以上になると、さらにそれを増加させても、全字種の認識率はそれほど向上しない。例えば、ネット生成時の $G_{up}=10$ として、表7における参照ベクトル数を約2倍にしても、全字種の認識率は 93.4% とわずか 0.3% の向上に過ぎない。これに比べて識別関数 f を使う方はベクトル数を増加せずに、認識率を 0.5% 向上できる。この意味で識別関数 f を導入するのは効果的である。

また、P-DC 特徴を用いた増殖淘汰法の分類率は 74.7% で、これに比べ分類ネット2の分類率は特徴抽出法にかかわらず、約0%2向上できることがわかった。

6. む す び

手書き漢字を認識するために combNET-II を改良したことにより、われわれは増殖淘汰法、分類ネット、BP ネットと認識関数を用いた多字種の手書き漢字の認識法を考案した。この認識方法は分類と認識との2段階からなる。分類では、増殖淘汰法によって全字種を幾つかのグループに分類し、次に1グループあたり複数参照ベクトルを作成し、分類ネットを構成した。識別では、グループに分類された比較的少数の漢字認識のためのBP ネットを作成した。識別関数により分類ネットとBP ネットを結び、認識システムを構築し、996字種の手書き漢字の認識実験を行った。自己組織化法、自己増殖法と増殖淘汰法において、増殖淘汰法の分類率、分類均等性および学習時間などが優れていることを明らかにした。1グループに1ベクトルのみを持つ自己組織化法や自己増殖法などの分類法に比べ、分類ネット2が手書き漢字のパターン変動に優れた分類能力を持っていることを確かめた。また本文で提案した認識システムにP-DC特徴を用いた場合、996字種の手書き漢字認識率は93.6%に達した。

今後多字種漢字グルーピングの最適化のため、増殖淘汰法分類法の学習アルゴリズムの探究、また計算量の低減のため、分類ネットのベクトル数の削減などを図って行きたい。

謝辞 この研究は宇都宮大学工学部情報工学科の卒業生の加藤宏光君、元小出浩一君の協力によって得られたものである。付記して謝意を表する次第である。

参 考 文 献

- 1) 萩田紀博, 内藤誠一郎, 増田 功: 大局的・局所方向寄与度密度特徴による手書き漢字認識方式, 信学論, Vol. J66-D, No. 6, pp. 722-729 (1983).
- 2) 萩田紀博, 内藤誠一郎, 増田 功: 外郭方向寄与度特徴による手書き漢字の識別, 信学論, Vol. J66-D, No. 10, pp. 1185-1192 (1983).
- 3) 岩田 彰, 当麻孝志, 松尾啓志, 鈴木宣夫: 大規模4層ニューラルネット CombNET, 信学論, Vol. J73-D-II, No. 8, pp. 1261-1267 (1990).
- 4) 堀田健一, 岩田 彰, 松尾啓志, 鈴木宣夫: 大規模ニューラルネット ComNET-II, 信学論, Vol. J75-D-II, No. 3, pp. 545-553 (1992).
- 5) Kohonen, T.: The Self-Organizing Map, *Proc. of The IEEE*, Vol. 78, No. 9, pp. 1464-1480 (1990).
- 6) 斐 東善, 森下哲次, 蕪山幸和, 伊崎保直, 山本栄一郎: 手書き漢字認識におけるテンプレート複数化の検討, 信学技報, PRL 81-42, pp. 49-56 (1989).

- 7) 飲島泰蔵: パターン認識理論, 森北出版 (1989).
- 8) 魏 回, 北村 正, 岩田 彰, 鈴木宣夫: CombNET-II による中国 1000 単語音声認識, 信学論, Vol. J75-D-II, No. 4, pp. 689-696 (1992).
- 9) 出本 浩, 横塚志行, 木田博巳: LVQを用いた手書き漢字認識辞書作成方式の検討, 信学技報, PRU, 91-154, pp. 63-68 (1991).
- 10) 王 晋申, 加藤宏光, 元小出浩一, 荒井正之, 奥田健三: 複数参照ベクトルによる手書き漢字分類法, 電子情報通信学会 1993 年春季大会論文集, D-548 (1993).
- 11) 加藤宏光, 元小出浩一, 王 晋申, 荒井正之, 奥田健三: 手書き漢字認識用ニューラルネットの認識関数, 電子情報通信学会 1993 年春季大会論文集, D-549 (1993).

(平成5年3月19日受付)

(平成5年11月11日採録)



王 晋申 (正会員)

1958年生。1983年北京航空学院情報卒業。1991年宇都宮大学大学院情報修了。同大学助手を経て、現在名古屋工業大学に所属。文字認識、ニューラルネットワークなどの研究

に従事。



荒井 正之 (正会員)

1958年生。1981年東京理科大学理工学部経営工学科卒業。1992年宇都宮大学大学院工学研究科生産・情報工学専攻博士後期課程入学(社会人特別選抜)。1989年4月帝京大学理工学部助手、現在に至る。ニューラルネットワーク、パターン認識などの研究に従事。著書「BASIC入門テキスト」(共著, オーム社), 「モデム設計と応用技法」(共著, トリケップス社)など, 電子情報通信学会会員。



奥田 健三 (正会員)

1927年生。1952年早稲田大学卒業。工学博士。(株)日立製作所, 宇都宮大学工学部情報工学科教授を経て、1993年より作新学院大学経営学部教授。主たる研究テーマは知識工学, 事例ベース推論, ニューロ・コンピューティング, ファジィ理論の応用, 電力系統工学。電気学会, 電子情報通信学会, IEEE 各会員。