

# カテゴリ重複学習による多段 BP ネットワークの構成法

田中直樹<sup>†</sup> 梶谷浩二<sup>††</sup>

BP ネットワークにおいて、学習カテゴリ数の増加にともなうネットワークの大規模化を回避するために小規模な BP ネットワークを多段階に組み合わせる方式がとられる。本論文では、所属カテゴリに近接カテゴリを付加して学習する重複学習方式を提案している。本方式では、後段のネットワークにおいてカテゴリが複数のネットワークに重複して学習され、それら複数のネットワークの出力の組合せによりカテゴリの判定を行う。これにより前段のネットワークの分類誤りを訂正することが可能となり最終的な認識率を向上させることができる。また、近接カテゴリの追加学習により、従来方式では学習されない近接カテゴリ境界の学習が可能となり、後段の BP ネットワークの認識性能の向上も期待できる。提案方式を手書き漢字認識に適用し実際に最終認識率を向上させることができることを確かめている。

## A New Hierarchical Combination of BP Networks Based on Category Duplication and Competition Principle

NAOKI TANAKA<sup>†</sup> and KOJI KAJITANI<sup>††</sup>

In this paper, a new hierarchic BP Network combination method is proposed. Generally, a combination of rough and fine classification BP networks is introduced for the recognition of a large numbers of categories instead of a large scale single BP network. In the proposed combination method, category groups of the rough classification layer are extended so as any category is allowed to be contained and learned in the more than one category groups and the final recognition result can be determined by competition of the rough and fine network outputs. Experimental result shows that the error at the rough classification stage can be corrected at the fine classification layer and that a higher total recognition rate is achieved.

### 1. はじめに

漢字認識などの多カテゴリの認識問題を BP ネットワーク<sup>1)</sup> (以下 BPnet) で学習する場合、ネットワークが大規模となり、(1) 学習時間の増大、(2) 学習の収束が容易でない、(3) 認識率が著しく低下するなどの問題点が生じる。それゆえ、通常は認識過程を多段階とし小規模な BPnet を組み合わせる方法をとる<sup>2),3)</sup>。大分類・詳細識別の 2 段階の構成を考えた場合、認識対象を大分類により候補を数十カテゴリに絞り、詳細識別で最終候補カテゴリを出力するという手順を経ることになる。この場合学習過程では、認識対象カテゴリからいくつかのカテゴリグループを生成し、大分類ネットワーク (以下、大分類 Net) でこのカテゴリグループをターゲットとする学習を行う。一方、詳

細識別ネットワーク (以下、識別 Net) ではカテゴリグループ内の識別を学習する。識別過程では、大分類 Net によりカテゴリグループが選択され、それに対応する識別 Net の最大出力となるカテゴリが最終識別結果となる。このような構成では、大分類 Net における分類結果の誤り、すなわち誤ったカテゴリグループが選択された場合、識別 Net では訂正が不可能であり、最終的な認識率は各段階の算術積となり個別の BPnet の識別性能を下まわってしまう。大分類 Net により選択される識別 Net を複数とすることも考えられるが、この場合複数の識別 Net の識別結果の選択法の問題が生じる。また、それぞれのカテゴリは単一の識別 Net でのみ学習されることになり、類似カテゴリが単一の識別 Net に属するとは限らず、類似カテゴリの境界が識別 Net において必ずしも学習されないという問題点もある。BPnet ではないが小規模なネットワークを組み合わせた多段ネットワークの代表的例として CombNET-II<sup>2)</sup> がある。CombNET-II は、大分類に相当する Stem Network と詳細分類に相当す

<sup>†</sup> 神戸大学海事科学部

Faculty of Maritime Sciences, Kobe University

<sup>††</sup> 近畿大学理工学部

School of Science and Engineering, Kinki University

る Branch Network で構成される．入力ベクトルと高い適合度を示す Stem Network のニューロンに対応する Branch Network が選択され，Branch Network の出力値と Stem Network のニューロンの出力値とを総合して最終判定を行っている．同方式は，Branch Network で学習するカテゴリ群を，Stem Network の構成時の分類結果により決定している．その結果，類似カテゴリでも Branch Network において学習されないものが存在することになる．また，パターンの変動が大きいときには，認識率が大幅に低下するとの指摘もある<sup>3)</sup>．

このような問題点を改善する方法として，谷萩らは，標本空間でのユークリッド距離が比較的近いカテゴリどうしは必ず同一の BP ネットワークで学習させる重複学習アルゴリズム<sup>3)</sup>を提案し，顔画像認識実験を通じて CombNET-II と比較して雑音を付加したときの変動に強いことを示している．しかしながら，谷萩らの報告は，少数の識別 Net によるものであり，たかだか 20 のカテゴリでの実験でしかなく，多カテゴリへの対応に関しては述べられていない．また採用した認識原理特有の性能限界も存在している．

本論文では，手書き漢字を認識対象とした多カテゴリの場合の重複学習方式について提案する．本論文で提案する方式の特徴は，ネットワークを多段構成とし，カテゴリが複数の識別 Net で重複して学習されること，複数の識別 Net の出力を論理的に組み合わせて判定を行うことである．これにより，カテゴリが単一の識別 Net でのみ学習する場合に比べて類似カテゴリとの境界が学習される機会が増加し識別性能が向上し，また，大分類段階での誤りを識別段階で訂正できるため最終認識率を大分類における正分類率よりも向上させることができる．複数のネットワークの出力を組み合わせる方式としては Mixture of Experts<sup>4),5)</sup>が知られている．同方式は，各学習器の状況に対する適用度に応じて重み付けして全体の出力を求めるものであり，効率の良いシステム構築が可能である．本提案方式では，2 層構造とし，カテゴリを陽に重複させて学習させている．さらに，その重複性を利用して識別 Net の出力を論理的に組み合わせることにより最終認識結果を得ており，「保留」という認識結果を用意し，別の識別論理で最終的な認識結果を得られる方式へと拡張できる点が特長であり，従来の方式と異なる点である．

## 2. 谷萩らの方式の性能限界

谷萩らは，小規模なネットワークを組み合わせ，カ

テゴリを複数のネットワークで学習し認識時にはそれらのネットワークを競合させる方式<sup>3)</sup>(以下，谷萩方式)を提案している．谷萩方式では，任意のカテゴリの少なくとも  $N$  (重複度パラメータ) 番目までの近いカテゴリの対がどこかのネットワークに属し，任意のカテゴリは複数のネットワークで学習される．谷萩方式は，1 層構造であるため，入力パターンはすべてのネットワークに入力され，すべてのネットワークの出力を競合させることになる．ネットワークの出力は，「他のネットワークで否定されているものを候補から外す(以下，否定原理)」ことにより候補数を絞り込む．すなわち，重複して学習されたすべてのネットワークで 1 位となったカテゴリが最終候補となる．簡単のために，各カテゴリの平均重複度を  $T$  とし，各ネットワークの誤り率を  $e$  とすると，正解カテゴリが最終候補として残る確率  $P$  は

$$P = (1 - e)^T \quad (1)$$

となりこれが谷萩方式の認識率の上限となる． $T$ ， $e$  と認識率  $P$  の関係を図 1 に示す．谷萩らの実験では，対象カテゴリが 20 カテゴリと小さいため，平均重複度は  $T = 3.15$ ，各ネットワークの平均学習カテゴリ数  $N$  が 6 カテゴリとそれぞれ少数である．そのため，各ネットワークの平均誤り率は  $e = 0.01$  程度となると推定され，最終的な認識率が 96.18% となっていると推定できる．認識対象のカテゴリ数を  $S$ ，ネットワーク数を  $K$  とすると

$$S * T = K * N \quad (2)$$

となる．平均重複度  $T$  は，最低でも  $T = 3$  程度は必要であり，カテゴリ数 300 すなわち， $T = 3$ ， $S = 300$  と仮定した場合  $K * N = 900$  となる．谷萩らの報告例のように各ネットワークでの平均学習カテゴリを  $N = 6$  とすると，ネットワーク数は  $K = 150$  にもなり現実的でない．ネットワーク数  $K$  を 50~60 程度に抑制するためには  $N$  を 30~50 程度とする必要が

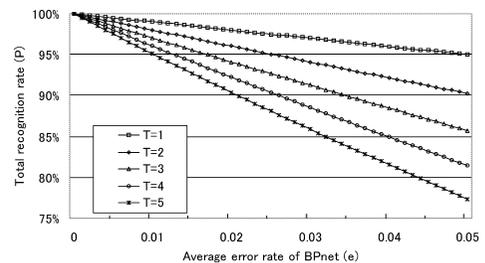


図 1 谷萩方式の認識率の  $e$ ， $T$  による変動  
Fig. 1 Recognition rate vs  $(e, T)$  of Yahagi method.

ある．前川<sup>6)</sup>は，学習方式に EXAPND 法<sup>7)</sup>を用いた 300 カテゴリーの手書き漢字認識実験で， $N = 50$ とした場合谷萩方式では認識率は 93.98%となることを報告している．このとき， $e = 0.017$ ， $T = 4$ 程度となっており，図 1 からの推定認識率 93.6%とはほぼ一致する．対象カテゴリ数がさらに増加すると， $e$ ， $T$ ともに増加し，推定認識率もさらに減少してしまうことになる．また，同方式でさらに認識率を向上させるためには学習したネットワークのいずれかで否定された場合も許容する必要があると考えられるが，否定原理に基づく同方式ではその実現は困難と考えられる．

### 3. 学習・認識アルゴリズム

#### 3.1 重複学習

本提案方式は，大分類 Net と識別 Net の 2 段階構成とする．大分類 Net ではカテゴリグループへ振り分けを行い，次に，カテゴリグループに対応する識別 Net によりカテゴリの決定を行う．すなわち各々の識別 Net は，大分類 Net の学習ターゲットであるカテゴリグループの 1 つを学習カテゴリとすることになる．ここで提案する重複学習方式では，各識別 Net での学習カテゴリ（カテゴリグループ）にその所属カテゴリの近接（類似）カテゴリを追加して学習する．すなわち各識別 Net では，本来の「学習カテゴリ」+「それらの近接カテゴリ」を学習することになり，あるカテゴリからみれば，複数の識別 Net で“重複”して学習されることになる．以下に，大分類 Net の出力ターゲットである，カテゴリグループ，識別 Net の学習グループとなる重複学習グループのそれぞれの生成法について述べる．

##### 3.1.1 クラスタリングによるカテゴリグループの生成

学習サンプルを用いて K 平均クラスタリング法によるクラスタリングを行いカテゴリグループを生成する．クラスタリングアルゴリズムは以下のとおりである．なお，クラスタリングには，学習サンプルの各カテゴリごとに平均したパターン（以下，標準パターン）を用いている．

- (1) 任意の 2 個の標準パターンをクラスタの重心の初期値とする．
- (2) 各標準パターンを，最も（ユークリッド）距離の近いクラスタに帰属させる．
- (3) 各クラスタごとに重心の再計算を行う．

(4) 重心位置が変動しなくなるまで (2)，(3) を繰り返す．

(5) クラスタ数が  $S$  個未満のとき，各クラスタの重心からの平均距離が最も遠い標準パターンを新たなクラスタの重心として追加し (2) へ戻る．

ここで得られたカテゴリグループ  $C(m)$  ( $m = 1, 2, \dots, S$ ) を初期カテゴリグループとする．

##### 3.1.2 重複学習グループの生成

上で作成した初期カテゴリグループに近接カテゴリを追加する．近接カテゴリは以下の手順で求める．

(1) カテゴリ  $i$  のカテゴリ内分散を  $\sigma^2(i)$  とし，カテゴリ  $i$  の重心と， $i$  が所属する所属カテゴリグループ  $C(k)$  の重心との距離（ユークリッド距離の 2 乗）を  $D_x(ik)$  とする．これらを用いて

$$D_x(ik) = \alpha \sigma^2(i) + D(ik) \quad (3)$$

なる距離  $D_x(ik)$  を求め，

$$\{C(j) \mid D(ij) \leq D_x(ik)\} \\ (j = 1, 2, \dots, S) \quad (4)$$

を満たすすべてのカテゴリグループ  $C(j)$  に対して，学習カテゴリとしてカテゴリ  $i$  を追加する．すなわち，カテゴリ  $i$  は  $C(k)$  と，式 (4) を満たす範囲内に重心を持つカテゴリグループに重複して所属する．近接カテゴリの追加後のカテゴリグループ（以下，追加カテゴリグループ）を  $C'(m)$  ( $m = 1, 2, \dots, S'$ ) とする．

(2) 追加カテゴリグループ  $C'(m)$  のそれぞれのグループ内の所属カテゴリ数を  $\#(C'(m))$  ( $m = 1, 2, \dots, S'$ ) とし

$$\#(C'(d)) > N \quad (5)$$

となる  $C'(d)$  について各グループの重心  $D'(d)$  からの距離が大きい追加カテゴリから順に，所属カテゴリ数が  $N$  以下となるまで削除を行う．

(3) 追加カテゴリグループ  $C'(m)$  の中で，統合後のカテゴリ数が  $N$  以下となるペアがあれば 1 つのグループに統合する．なお，式 (4) において，分散・ユークリッド距離を用いているが，他のメトリックとしても全体の性能にはあまり影響はない．統合手順は次のとおりである．

(a) グループ内のカテゴリ数が  $N$  未満のグループのみを統合候補対象とする．

(b) 統合候補のペア間において互いに重複しているカテゴリ数を求める．

(c) グループ内のカテゴリ数の多いグループから順にこれと統合可能なグループを探す．統合の条件は，統合後の各グループのカテゴリ数が  $N$  を超えないことであ

学習サンプルの分布を広げることにより BPnet の認識率を向上させる方式．

る。また、1つのグループに対して複数の統合候補が存在する場合には、(i) 統合後のグループ内のカテゴリ数が  $N$  に近い、(ii) 互いに重複するカテゴリ数が多い、候補を選択する。

- (d) (c)を統合が不可能になるまで繰り返す。統合処理終了後、統合されたにもかかわらず所属カテゴリ数の少ないグループがある場合には、別の統合候補を選択する。

これらの手順により得られたカテゴリグループ(以下、重複カテゴリグループ)を  $C''(m)$  ( $m = 1, 2, \dots, S''$ ) とする。このグループの各エントリが、それぞれの識別 Net における学習カテゴリとなる。

### 3.2 認識アルゴリズム

識別 Net の選択法による次の2つの認識アルゴリズムを用いる。

#### 3.2.1 アルゴリズム 1

- (1) 大分類 Net に入力パターンを提示し、最大出力となるグループを  $G_i$  とする。
- (2)  $G_i$  に対応する識別 Net にのみ入力パターンを提示し、最大出力となるカテゴリを認識結果とする。

#### 3.2.2 アルゴリズム 2

- (1) 大分類 Net に入力パターンを提示し、最大出力となるグループを  $G_i$  とする。
- (2)  $G_i$  に対応する識別 Net にのみ入力パターンを提示し、最大出力となるカテゴリを  $C_j$  とする。
- (3) カテゴリ  $C_j$  を学習したすべての識別 Net (Net の数を  $k$  とする) にもパターンを提示し、それぞれのネットワークで最大出力となったカテゴリ  $C'_j(l)$  ( $l = 1, 2, \dots, k$ ) の集合  $\sigma = \{C_j, C'_j(1), C'_j(2), \dots, C'_j(k)\}$  を求める。
- (4)  $\sigma$  の要素がすべて同一カテゴリであればそれを認識結果とする。そうでなければ「保留」とする。

## 4. 手書き漢字を用いた重複学習による認識実験

### 4.1 使用データ

認識実験には、ETL8-B2 の 100 カテゴリおよび 300 カテゴリを用いた。ETL8-B2 は、各カテゴリ 160 サンプルが用意されている。本実験では、160 サンプル中で、最初の偶数番号の 40 サンプルを学習用とし、

最初の奇数番号の 40 サンプルを評価用としている。

### 4.2 ネットワークおよびパラメータの設計

大分類/識別 Net への入力としては、入力サンプルの初元特徴ベクトル<sup>9)</sup>を用いた。初元特徴ベクトルとは、高次自己相関関数から得られるマスク(2次の場合マスク数は 25 となる)を文字パターンに局所的に適用するもので、文字ストロークの方向や交差部などの特徴量を反映した特徴ベクトルである。詳細は金谷ら<sup>9)</sup>を参照されたい。大分類 Net には 128 次元、識別 Net には 392 次元の初元特徴ベクトルを用いている。また、ネットワークの学習方式には EXPAND 法<sup>7)</sup>を用いている。EXPAND 法は、BPnet における未学習領域の減少を図る方式であり、BPnet の認識率を向上させることが確認されている。各種のパラメータの設計方針は次のとおりである。

- (1) 識別 Net のカテゴリ数の上限  $N$  は 100 カテゴリ以下とする。
- (2) 統合前の識別 Net の平均カテゴリ数 = (初期カテゴリグループの平均カテゴリ数  $\times$  重複度  $t$ ) である。
- (3) 初期カテゴリグループの平均カテゴリ数 = (総カテゴリ数/初期カテゴリグループ数  $S$ ) である。
- (4) 初期カテゴリグループ数  $S$  は 100 以下とする。(EXPAND 法の性能限界)
- (5) 重複度  $t = (1 \text{ サンプルに対して選択される識別 Net の数の平均})$  である。

重複度  $t$  は、認識性能を左右するパラメータとなりその議論を後述するが、3~4 程度とすることが望ましいと考えられる。重複度を 3 とした場合、(1)、(2)より初期カテゴリグループの平均カテゴリ数は 30 程度となる。さらに(3)、(4)より  $S = (\text{総カテゴリ数}/30)$  となる。またこの場合、(4)より総カテゴリ数としては約 3,000 カテゴリ程度が上限となる。それ以上の総カテゴリ数を対象とするには、大分類 Net を大分類・中分類の 2 段構成とする必要があろう。(1)のように  $N$  は EXPAND 法では実験的<sup>7)</sup>に学習カテゴリ数を 100 以下とすることが望ましいことが確かめられている。本実験では、総カテゴリ数 100 に対して  $S = 15$ 、 $N = 40$ 、総カテゴリ数 300 に対して  $S = 30$ 、 $N = 65$  としている。大分類 Net のユニット数は、100 カテゴリ  $128 \times 30 \times 15$ 、300 カテゴリ  $128 \times 60 \times 30$  (中間層のユニット数は出力層のユニット数のそれぞれ 2 倍とした)となる。識別 Net の各ネットワークのユニット数は、100 カテゴリでは  $392 \times 80 \times 40$ 、300 カテゴリでは  $392 \times 130 \times 65$  となる。重複度を規定する  $\alpha$  は、1 カテゴリあたりの平均重複度が 3~4 程度と

電総研(現産総研)により公開されている手書き文字データベース。

表 1 カテゴリグループ (100 カテゴリ)  
Table 1 A list of category group for 100 categories.

	g1	g2	g3	g4	g5	g6	g7	g8	g9	g10	g11	g12	g13	g14	g15
1	庄	以	困	遭	愛	駅	暗	円	位	印	易	歌	央	委	
2	医	依	因	運	悪	快	院	恩	言	何	引	栄	我	貨	一
3	延	移	園	演	安	機	衛	科	右	備	雨	永	改	賃	益
4	応	飲	画	遠	案		往		嘗	加	下	泳	拡	角	会
5	屋	化	回	塩	意		横		王	解	可	液			各
6	花	仮	開	温	異		億		音		河	家			革
7	確	火		過	胃		荷		害			界			
8		絵		海	員		階								
9		外			雲										
10		格			英										
11					黄										
12					夏										
13					果										
14					芽										
15					貝										
16					覚										

なるように実験的に  $\alpha = 3.0$  とした。また、個々のカテゴリの最大重複数を 5 とし、重複数が 5 を超えるカテゴリについては、それ以上の重複を抑制している。300 カテゴリではこれらの制限にもかかわらず上限  $N$  を超えるカテゴリグループが生成されている。このように、上限を超えるものについて、グループの重心からの距離が大きいカテゴリから順次削除を行うことで上限  $N$  を保つ。

#### 4.3 カテゴリグループの生成結果

100 カテゴリのクラスタリングの結果を表 1 に示す。300 カテゴリに関しても同様のアルゴリズムにより 30 個のカテゴリグループの生成を行う。大分類 Net の学習では、このカテゴリグループが出力ターゲットとなる。

#### 4.4 重複カテゴリグループの生成結果

前章で述べた重複方法による重複カテゴリグループの生成を行った。まず、カテゴリグループに近接カテゴリの追加を行っている。100 カテゴリの場合の近接カテゴリの追加後のグループを表 2 に示す。次に、グループの統合を実施した。100 カテゴリにおいては、 $\{C'(2), C'(13)\}$ ,  $\{C'(3), C'(8)\}$ ,  $\{C'(6), C'(11)\}$  がそれぞれ統合対象となった。その結果、最終的な重複カテゴリグループは  $C''(m)$  ( $m = 1, 2, \dots, 12$ ) となった。この  $C''(m)$  ( $m = 1, 2, \dots, 12$ ) のカテゴリ数の総和は 364 カテゴリとなり、したがって 1 カテゴリあたりの平均重複度は 3.64 となった。100 カテゴリの場合の  $C''(m)$  を表 3 に示す。また、300 カテゴリについては、最終的な重複カテゴリグループ数は 18 となり、それらのカテゴリ総和は 1,001 カテゴリ、平均重複度は 3.34 となった。

#### 4.5 認識実験結果

##### 4.5.1 アルゴリズム 1 による認識実験

アルゴリズム 1 を用いた認識実験結果を 100 カテゴリ、300 カテゴリそれぞれ図 2、図 3 に示す。大分類 Net (Rough Classification Network) の分類結果は、

- (1) 正分類 (Correct): 正解カテゴリが所属するカテゴリグループが選択された、
- (2) 重複分類 (Duplicate): 正解カテゴリが重複カテゴリとして追加されているカテゴリグループが選択された、
- (3) 誤分類 (Error): 上記以外 (正解カテゴリを含まないカテゴリグループ) が選択された、

となる。一方、識別 Net の認識結果は

- (1) 正認識 (Correct): 正解カテゴリを選択、
- (2) 誤認識 (Error): 正解カテゴリが選択されない、

となる。大分類 Net、識別 Net を通じての最終認識結果は、次のようになる。ただし、括弧内はそれぞれ 100 カテゴリ、300 カテゴリである (以下同様)。

- (1) 正認識: (98.35%, 95.74%)
  - (a) 正分類 正認識 (96.55%, 93.01%)
  - (b) 重複分類 正認識 (1.80%, 2.73%)
- (2) 誤認識: (1.66%, 4.26%)
  - (a) 正分類 誤認識 (0.88%, 1.47%)
  - (b) 重複分類 誤認識 (0.20%, 0.43%)
  - (c) 誤分類 (0.58%, 2.36%)

最終的な認識結果は、100 カテゴリ 98.35% (96.55 + 1.8), 300 カテゴリ 95.74% (93.01 + 2.73) となり、大分類における 97.43%, 94.48% からそれぞれ 0.92 ポイント、1.26 ポイントの改善となっている。

表 2 重複カテゴリグループ (100 カテゴリ)  
Table 2 A list of duplicate learning category group.

	g1	g2	g3	g4	g5	g6	g7	g8	g9	g10	g11	g12	g13	g14	g15
1	庄	以	困	運	愛	快	暗	円	育	位	印	易	歌	央	委
2	医	依	因	遭	惡	快	院	恩	壹	何	引	榮	我	貨	一
3	延	移	團	演	安	機	衛	科	右	価	雨	永	改	賀	益
4	応	飲	画	遠	案	以	往	惡	嘗	加	下	泳	拡	角	会
5	屋	化	回	塩	意	位	横	困	王	解	可	液	以	愛	各
6	花	仮	開	温	異	印	億	移	音	暗	河	家	依	惡	革
7	確	火	医	過	胃	飲	荷	害	困	以	界	移	安	安	愛
8	海	愛	給	雨	海	員	院	階	因	愛	印	永	安	印	案
9	惡	外	衛	暗	雲	雨	位	引	惡	飲	駅	以	飲	委	右
10	安	格	円	困	英	横	困	院	安	院	円	移	永	意	永
11	暗	位	過	意	黄	仮	胃	雨	暗	衛	応	永	液	異	廷
12	位	永		易	夏	加	遭	團	案	駅	恩	央	駅	胃	王
13	意	液		胃	果	歌	医	応	委	往	何	応	央	遭	繪
14	移	延		壹	芽	我	右	何	意	横	加	果	仮	育	
15	院	往		右	貝	解	雨	可	異	億	科	河	加	員	
16	右	応		嘗	覺	改	運	河	胃	化	花	花	花	雲	
17	運	加		英	委	開	嘗	回	遭	仮	改	我	解	嘗	
18	液	花		衛	易	拡	益	快	員	河	界	芽	快	榮	
19	益	我		益	遭		演	開	運	荷	外	改	外	英	
20	遠	快		延	医		塩	階	雲	過		貝	確	衛	
21	改			横	育		黄	貝	榮	械		外		延	
22	央	拡		黄	壹		屋		英	海		拡		演	
23	往			億	運		温		益	開		格		塩	
24	王			屋	嘗		仮		演	階		覺		往	
25	億			音	榮		何		遠	外				横	
26	恩			河	演		価		塩	拡				黄	
27	温			荷	遠		科		横	格				億	
28	荷			画	央		過		屋	確				音	
29	過			芽	王		賀		温					夏	
30	解			賀	屋		解		夏					果	
31	海			階	恩		快		果					荷	
32	繪			害	音		海		芽					芽	
33	階			確	賀		繪		賀					海	
34	格			界	開		開		貝					繪	
35				角	害		格		覺					貝	
36					角		確		角					害	
37							角							覺	

4.5.2 アルゴリズム 2 による認識実験

アルゴリズム 2 を用いた認識実験結果を 100 カテゴリ, 300 カテゴリについてそれぞれ図 4, 図 5 に示す. 大分類 Net の分類結果は, アルゴリズム 1 の場合と同様である. 識別 Net に関しては,

- (1) 正認識 (Correct): 選択された識別 Net の出力がすべて一致 (正解カテゴリ),
  - (2) 保留 (Duplicate): 選択された識別 Net の出力が一致しない (正解カテゴリを含む),
  - (3) 誤認識 (Error): 選択された識別 Net の出力に正解カテゴリが含まれない,
- となる. 大分類 Net, 識別 Net を通じての最終認識結果は,
- (1) 正認識 (97.80%, 94.85%)

- (a) 正分類 正認識 (96.15%, 92.31%)
- (b) 重複分類 正認識 (1.65%, 2.54%)
- (2) 保留 (1.53%, 2.69%)
  - (a) 正分類 保留 (0.85%, 1.28%)
  - (b) 重複分類 保留 (0.30%, 0.33%)
  - (c) 誤分類 保留 (0.40%, 1.08%)
- (3) 誤認識 (0.68%, 2.46%)
  - (a) 正分類 誤認識 (0.45%, 0.89%)
  - (b) 重複分類 誤認識 (0.05%, 0.29%)
  - (c) 誤分類 誤認識 (0.18%, 1.28%)

となる. すなわち最終認識結果は, 100 カテゴリ 97.8% (96.15 + 1.65), 300 カテゴリ 94.85% (92.31 + 2.54) となり, 大分類における 97.43%, 94.48% からそれぞれ 0.37 ポイントの改善となっている. また, 正解

表 3 統合後の重複カテゴリグループ (100 カテゴリ)  
 Table 3 A list of combined duplicate learning category group.

	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10	G11	G12
	g1	g2+ g13	g3+ g8	g4 g4	g5	g6+ g11	g7	g9	g10	g12	g14	g15
1	庄	以	困	遣	愛	駅	暗	育	位	易	央	委
2	医	依	困	運	悪	快	院	巷	何	栄	貨	一
3	延	移	園	演	安	界	衛	右	価	永	賀	益
4	応	飲	画	遠	案	以	往	嘗	加	泳	角	会
5	屋	化	回	塩	意	位	横	王	解	液	愛	各
6	花	仮	開	温	異	印	億	音	暗	家	悪	革
7	確	火	医	過	胃	飲	荷	害	困	界	安	愛
8	愛	絵	雨	海	員	院	階	愛	印	安	案	育
9	悪	外	衛	暗	雲	雨	位	悪	飲	以	委	右
10	安	格	円	困	英	横	困	安	院	移	意	永
11	暗	位	過	意	黄	仮	胃	暗	衛	永	異	廷
12	位	永	恩	易	夏	加	遣	案	駅	央	胃	王
13	意	液	科	胃	果	歌	医	委	往	応	遣	絵
14	移	延	悪	巷	芽	我	右	意	横	果	育	
15	院	往	移	右	貝	解	雨	異	億	河	員	
16	右	応	印	嘗	覚	改	運	胃	化	花	雲	
17	運	加	引	英	委	開	嘗	遣	仮	我	嘗	
18	液	花	院	衛	易	拡	益	員	河	芽	栄	
19	益	我	応	益	遣	引	演	運	荷	改	英	
20	遠	快	何	延	医	外	塩	雲	過	貝	衛	
21	塩	改	可	横	育	下	黄	栄	械	外	延	
22	央	拡	河	黄	巷	可	屋	英	海	拡	演	
23	往	歌	快	億	運	河	温	益	開	格	塩	
24	王	確	階	屋	嘗	械	仮	演	階	覚	往	
25	億	印	貝	音	栄	永	何	遠	外		横	
26	恩	駅		河	演	円	価	塩	拡		黄	
27	温	央		荷	遠	応	科	横	格		億	
28	荷	解		画	央	恩	過	屋	確		音	
29	過			芽	王	何	賀	温			夏	
30	解			賀	屋	科	解	夏			果	
31	海			階	恩	花	快	果			荷	
32	絵			害	音		海	芽			芽	
33	階			確	賀		絵	賀			海	
34	格			覚	界		開	貝			絵	
35				角	害		格	覚			貝	
36					角		確	角			害	
37							角				覚	

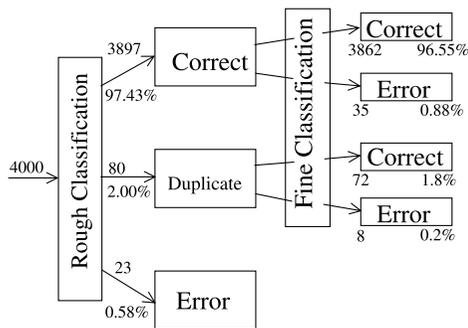


図 2 アルゴリズム 1 による認識実験結果 (100 カテゴリ)  
 Fig. 2 Experimental result of algorithm 1 for 100 categories.

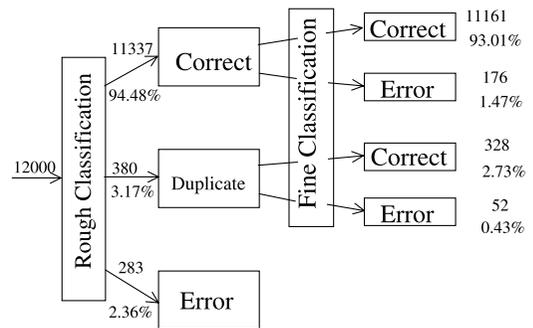


図 3 アルゴリズム 1 による認識実験結果 (300 カテゴリ)  
 Fig. 3 Experimental result of algorithm 1 for 300 categories.

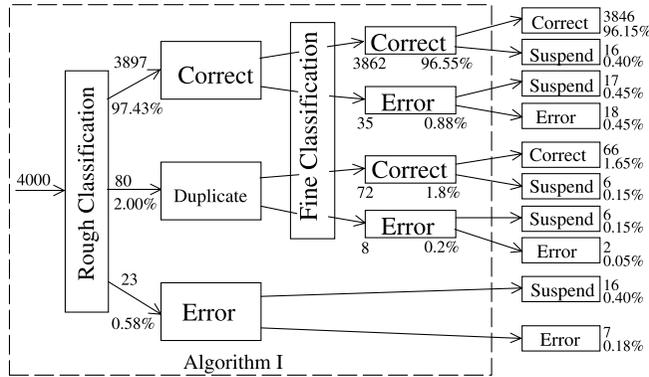


図 4 アルゴリズム 2 による認識実験結果 (100 カテゴリ)  
 Fig. 4 Experimental result of algorithm 2 for 100 categories.

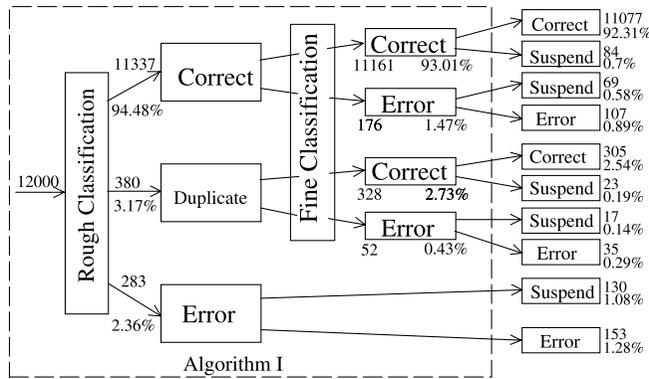


図 5 アルゴリズム 2 による認識実験結果 (300 カテゴリ)  
 Fig. 5 Experimental result of algorithm 2 for 300 categories.

となる可能性のある保留については、100 カテゴリ 1.53% (0.40 + 0.45 + 0.15 + 0.15 + 0.40), 300 カテゴリ 2.69% となっている。これら保留となったものに関しては、重み付き距離判別法<sup>10)</sup>によりおよそ 96% ~ 99% が正認識となることを確かめている。したがって、保留となったものの中で最低でも 100 カテゴリで 1.46%, 300 カテゴリでは 2.58% が正認識となる。これを正認識に加えると、100 カテゴリ 99.26%, 300 カテゴリ 97.43% の認識率が期待できることになり、300 カテゴリの場合、2 章で述べた谷萩方式の 93.98% と比較して大きな改善となる。

4.5.3 重複度  $t$  に関する検討

重複度  $t$  については本実験では 3.5 程度としているが、次のような議論が可能である。重複学習しない場合の大分類 Net の誤分類率を  $e_1$  とし、重複学習した場合の重複分類率、誤分類率をそれぞれ  $e_1 l(t)$ ,  $e_1(1 - l(t))$ , 識別 Net 数を  $M$  とすると

$$P(\text{正分類}) = (1 - e_1) \tag{6}$$

$$P(\text{重複分類}) = e_1 l(t) \tag{7}$$

$$P(\text{誤分類}) = e_1(1 - l(t)) \tag{8}$$

なる。重複分類とは、大分類 Net において正解カテゴリが属す識別 Net ではなく、残りの  $M - 1$  個の識別 Net 中の正解カテゴリを重複学習している  $t - 1$  個の識別 Net の 1 つが選択されることである。すなわち、 $l(t)$  は、

$$\frac{t - 1}{M - 1} \leq l(t) \leq 1 \quad (1 \leq t \leq M) \tag{9}$$

を満たす  $t$  の増加関数となる。さらに、識別 Net の誤認識率を  $e_2$  とすると

アルゴリズム 1 の場合、

$$P(\text{正認識} | \text{正分類}) = (1 - e_2) \tag{10}$$

$$P(\text{正認識} | \text{重複分類}) = (1 - e_2) \tag{11}$$

$$P(\text{誤認識} | \text{正分類}) = e_2 \tag{12}$$

$$P(\text{誤認識} | \text{重複分類}) = e_2 \tag{13}$$

となり、

$$P(\text{正認識}) = (1 - e_1(1 - l(t)))(1 - e_2) \tag{14}$$

となる。  $t$  の増加とともに  $e_1(1 - l(t))$  が減少し、 $P(\text{正$

平均誤り率、学習カテゴリ数  $S$  に依存し重複度  $t$  には直接依存しない。

認識率) が向上することが分かる．

アルゴリズム 2 の場合

$$P(\text{正認識} | \text{正分類}) = (1 - e_2)^t \quad (15)$$

$$P(\text{正認識} | \text{重複分類}) = (1 - e_2)^t \quad (16)$$

$$P(\text{保留} | \text{正分類}) = 1 - e_2^t - (1 - e_2)^t \quad (17)$$

$$P(\text{保留} | \text{重複分類}) = 1 - e_2^t - (1 - e_2)^t \quad (18)$$

$$P(\text{保留} | \text{誤分類}) > \left(1 - \prod_{k=1}^{t-1} \frac{M-t-k}{M-k}\right) \cdot (1 - e_2) \quad (19)$$

$$P(\text{誤認識} | \text{正分類}) = e_2^t \quad (20)$$

$$P(\text{誤認識} | \text{重複分類}) = e_2^t \quad (21)$$

$$P(\text{誤認識} | \text{誤分類}) < 1 - \left(1 - \prod_{k=1}^{t-1} \frac{M-t-k}{M-k}\right) (1 - e_2) \quad (22)$$

となり，

$$P(\text{正認識}) = (1 - e_1(1 - l(t)))(1 - e_2)^t \quad (23)$$

$$P(\text{保留}) > (1 - e_1(1 - l(t)))(1 - e_2^t - (1 - e_2)^t) + e_1(1 - l(t)) \left(1 - \prod_{k=1}^{t-1} \frac{M-t-k}{M-k}\right) \cdot (1 - e_2) \quad (24)$$

$$P(\text{誤認識}) < (1 - e_1(1 - l(t)))e_2^t + e_1(1 - l(t)) \cdot \left(1 - \left(1 - \prod_{k=1}^{t-1} \frac{M-t-k}{M-k}\right) (1 - e_2)\right) \quad (25)$$

となる．

$t$  の増加とともに  $l(t)$  は大きくなり  $e_2^t$ ,  $\prod_{k=1}^{t-1} \frac{M-t-k}{M-k}$  は十分小さくなるため

- (1) アルゴリズム 1 と比べて正認識率が若干低下する．
- (2)  $P(\text{誤認識} | \text{誤分類}) \simeq e_2$  となり,  $P(\text{誤分類})$  も小さくなるため  $P(\text{誤認識})$  はかなり小さくなる．

これらのことから  $t$  は  $P(\text{正認識} | \text{正分類})$  があまり減少しない範囲で十分に大きくとることが望ましい．しかし,  $t$  の増加は, 識別 Net 数の増加および保留判定時の候補カテゴリ数を増加させるため適度な範囲にとどめる必要がある．保留判定の場合, 上述のように候補カテゴリ間で重み付き距離判別法により最終的にカテゴリを決定するが, 候補カテゴリが多数となるとこの判定法の適用が難しくなる．今回の実験での重複度では, 保留の場合の候補カテゴリ数がほとんど 2 程

度に抑えられており妥当な値となっているものと考えられる．なお, 脚注でも触れたが, 個々の識別 Net は独立した BPNet であり, その認識性能 (誤り率  $e_2$ ) は主に, 学習カテゴリ数  $S$  に依存し, 重複度  $t$  には直接依存しない．しかしながら, 大分類 Net において正分類となるものと重複分類となるものでは入力データの品質が異なる (正分類となるものが高品質) ことが多いため, 正分類となったデータと重複分類となったデータでは識別 Net の誤り率は異なり, たとえば式 (10), (11) は一般に

$$P(\text{正認識} | \text{正分類}) \geq (1 - e_2) \quad (26)$$

$$P(\text{正認識} | \text{重複分類}) \leq (1 - e_2) \quad (27)$$

となり本実験でもその傾向が見られる．正分類と重複分類との間でのデータ品質の差異については被験データに依存するため定量的にとらえることが困難であり, 上記の議論ではその差異がないものとしている．

## 5. む す び

本論文では, 識別 Net における重複学習方式を提案し, 手書き文字認識に適用し大分類 Net の分類効率を上回る最終認識率を得られることを確認した．今後は,

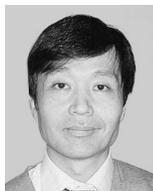
- (1) 保留となったサンプルの別アルゴリズムを用いた判定実験,
- (2) 認識対象カテゴリを数千のオーダとした場合のネットワークの構成法などの検討,

などが課題として残されている．上記 (1) に関してはすでに上述の結果が得られており別稿で報告予定である．(2) に関しては, 多カテゴリとする場合についてのそれぞれのパラメータの設定について言及した．多カテゴリとした場合, 大分類 Net での分類率が低下することが予測されるが, 本方式の特徴である識別 Net での訂正がより有効に機能することが期待できる．また, 重複学習した各識別 Net の最大値が一致しないための保留も増加するものと推測されるが, 上で述べた判定法での対処が可能である．

## 参 考 文 献

- 1) Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: Learning Internal Representations by Error Propagation, Chap.8 of *Parallel Distributed Processing, Vol.1*, Rumelhart, D.E. and McClelland, J.L. (Eds.) Foundation (1986).
- 2) 堀田健一, 岩田 彰, 松尾啓志, 鈴村宣夫: 大規模ニューラルネット CombNET-II, 信学論 (D-II), Vol.J75-D-II, No.3, pp.545-553 (1992).
- 3) 谷萩隆嗣, 高野裕昭: カテゴリーを組み合わせた

- ニューラルネットワークによる顔画像認識, 信学論 (D-II), Vol.J77-D-II, No.11, pp.2151-2159 (1994).
- 4) Duda, R.O., Hart, P.E. and Stor, D.G.: *Pattern Classification*, John Wiley and Sons, Inc. (2001).
- 5) Avnimelech, R. and Intrator, N.: Boosted Mixture of Experts: An Ensemble Learning Scheme, *Neural Computation*, Vol.11, pp.483-497 (1999).
- 6) 前川智義: ニューラルネットワークによるカテゴリ重複グループの学習とその文字認識への応用, 近畿大学大学院理工学研究科修士論文, 平成 7 年度 (1996).
- 7) 田中直樹, 是枝利明, 井上 健, 梶谷浩二: カテゴリの分布を考慮したバックプロバゲーションネットワークの学習法, 信学論 (D-II), Vol.J81, No.2, pp.293-300 (1998).
- 8) 荒井正之, 奥田健三, 渡辺博芳, 宮道尋一: 追加学習が可能な大規模ニューラルネットワーク Honeycomb ネット III, 信学論 (D-II), Vol.J80-D-II, No.7, pp.1955-1963 (1997).
- 9) 金谷利旭, 田中直樹, 梶谷浩二: 高次自己相関関数とニューラルネットワークによる図形の特徴抽出とその文字認識への応用, 信学技報, NC93-72, pp.33-40 (1994).
- 10) 田中健司: 修正初元特徴ベクトルによる類似文字識別, 近畿大学理工学部電気電子工学科卒業研究, 平成 16 年度 (2005).
- (平成 18 年 6 月 6 日受付)  
(平成 18 年 12 月 7 日採録)



田中 直樹 (正会員)

昭和 32 年生。昭和 61 年大阪大学大学院工学研究科通信工学専攻博士課程修了。同年近畿大学助手。平成 2 年神戸商船大学 (統合により現神戸大学海事科学部) 助教授。平成 4~5 年ワシントン大学客員助教授。パターン認識・画像処理等の研究に従事。工学博士。電子情報通信学会会員。



梶谷 浩二

昭和年生。昭和 44 年大阪大学大学院工学研究科通信工学専攻博士課程修了。同年近畿大学講師。昭和 50 年同大学助教授。昭和 58 年同大学教授。論理回路, パターン認識等の研究に従事。工学博士。電子情報通信学会会員。