

PDP モデルによる
手書き漢字と平仮名の区別

Distinction between Hand-written Kanji and Hiragana
Characters Using a PDP Model

梅田三千雄
Michio UMEDA

大阪電気通信大学 工学部
Faculty of Engineering, Osaka Electro-Communication University

Abstract This paper discusses a new distinction system between hand-written Kanji and Hiragana characters using a PDP model. In this system, two different types of features are extracted from character patterns. One is a Hough transformed feature which consists of 40, 78 or 156 elements. Another is a local direction contributivity (LDC) feature which consists of 64 or 256 elements. A 3-layered artificial neural network based on a parallel distributed processing model is utilized for the distinction. The experimental result shows that the correct distinction rate is above 99% for learned characters data and is about 95% for unlearned characters but same category data. But, the rate is less than 90% for unlearned Kanji category data.

1. まえがき

我々が日常の情報伝達に使用している日本語は、表意文字である漢字と表音文字である仮名とが混在した、世界でも珍しい言語である。このうち、漢字は表意文字であるがゆえに、文字種が非常に多く、その形も一般に複雑なのが特徴である。また、漢字は、そのストロークに直線成分が多く含まれるのも特徴である。これに対して、仮名は万葉仮名に端を発した表音文字で、幾多の歳月を経て今日のような字形になっている。仮名でも、特に、平仮名は曲線成分が比較的多く含まれるストロークで構成されるのが特徴である。

このような漢字と平仮名が混在した日本語文書において、もし漢字と平仮名の区別が可能となれば、機械による文字認識は新たな展開をすることも考えられる。例えば、平仮名に対しては、膨大な文字種から成る漢字を認識対象から除外することができるため、少数の文字種を対象にして、より詳細で複雑な処理を導入することも可能となる。一方、漢字に対しては、漢字の偏や旁、冠、脚などの構造情報を着目して、つまり構造解析的手法を導入することにより、人間の行う文字認識に極めて近いシステムを実現することも可能となるであろう。

漢字仮名混じり文を対象にして、漢字と平从名を

区別しようとする研究は、これまでにほとんど例がない。関連する研究として、美濃らによる印刷文書を対象とした9か国文字の分類の研究が報告されている[1]。この論文は、MOLD理論で定義された66種類の合法パターンを用いて、その頻度分布とともに特徴抽出し、ハングル文字やギリシャ文字、アラビア文字、漢字、ローマ文字、日本文字（漢字仮名混じり文字）など、9種類の文字から成る印刷文書を類別しようとしたものである。結果として、全体では約93%の正答率が得られるものの、漢字と日本文字との区別が難しく、正答率も70%前後にまで低下することが報告されている。なお、漢字と日本文字との区別において、特に平从名に存在するストロークの曲線性が重要であると指摘していることは極めて興味深い。

本報告では、漢字と平从名におけるストロークの直線性や曲線性の違いに着目して、文字パターンの特徴抽出を行うことにより、手書き漢字と平从名の区別を試みる。具体的には、画像処理において、直線検出の方法として提案されているHough変換[2]と、手書き漢字認識において、文字の直線性に着目した効率のよい特徴として提案されている局所方向寄与度特徴[3]を用いて、ストロークの直線性や曲線性の違いなどの特徴抽出を行う。次に、これ

らの特徴量を入力として、誤差逆伝搬法で学習させた多層型の並列分散処理モデル（PDPモデル）を利用することにより、手書きの漢字と平仮名の区別が可能となるかどうかについて検討する。

2. 手書き文字の特徴抽出

手書き漢字と平仮名の区別には、文字ストロークの直線性や曲線性の違いに着目して、特徴抽出するのが有効であろう。ここでは、次の二つの方法をもとに、その特徴抽出を試みる。一つは、画像処理や画像理解において、直線を検出する有力な方法として提案されている、Hough変換の手法を応用したものである。もう一つは、手書き漢字認識において、比較的高い認識精度の得られる特徴として提案されている、局所方向寄与度特徴である。

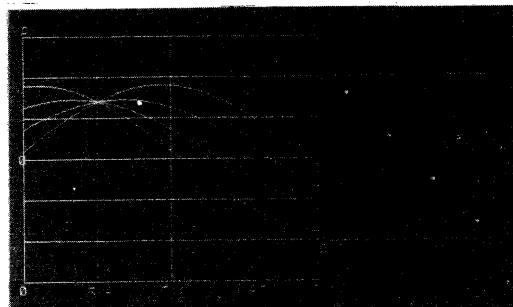
2. 1 Hough変換による特徴抽出

一般に、Hough変換による直線の検出では、 $(x-y)$ 平面における特徴点を

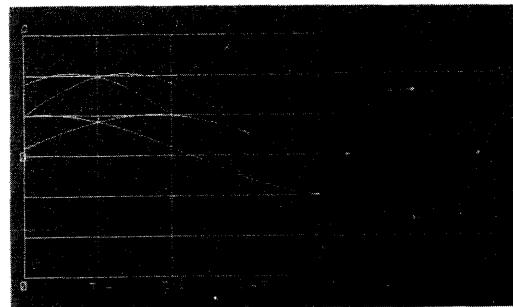
$$\rho = x \cos \theta + y \sin \theta \quad (1)$$

によって、 $(\rho-\theta)$ 平面に写像し、その軌跡が集中する要素を求ることによって行われる。

特徴点で表された手書き文字パターンに対して、このHough変換を施すと、例えば、図1(a)に示すように、直線上の各点に対する写像は $(\rho-\theta)$



(a) 直線上の点に対して



(b) 曲線上の点に対して

図1 特徴点群に対するHough変換の例

平面のある点で極めて大きなピークをもつ分布となる。これに対して、図1(b)に示すように、曲線上の各点に対する写像は、ピークが分散し、その値も小さくなることがわかる。この性質を利用して、Hough変換によって、文字パターンの直線性や曲線性の違いを抽出することができよう。

ここでは、次のようにしてHough変換による文字パターンの特徴抽出を行う。

まず、手書き文字パターンを細線化する。細線化には、Hilditchの方法を用いた。この方法によって細線化した手書き漢字パターンの例を図2に示す。この細線化パターンは、8-連結での接続関係を保存した、線幅1のパターンとなる。したがって、細線化パターンの任意の隣接する2点に着目すると、その接続関係には、図3に示すような4つの場合がある。ここで、例えば、図3(a)の2点に対して、式(1)に基づくHough変換を行うと、 $(\rho-\theta)$ 平面での2つの軌跡は、 $\theta=0^\circ$ のある ρ の値でのみ交差することになる。そこで、この2点に対しては、2つの軌跡が交差する、 $\theta=0^\circ$ での該当する ρ にのみ投票することとする。同様に、図3(b)の2点に対しては、軌跡が交差する、つまりこの2点を通る直線を表す、 $\theta=45^\circ$ での該当する ρ にのみ投票する。図3(c)、(d)の2点に対しても、同様に、 $\theta=90^\circ$ と 135° での該当する ρ にのみ投票する。

一方、大きさ1の正方領域に含まれる各点について、Hough変換を行うと、これに対応する ρ の変域は、 $\theta=0^\circ$ では $\rho=0 \sim 1$ 、 $\theta=45^\circ$ では $\rho=0 \sim \sqrt{2}$ 、 $\theta=90^\circ$ では $\rho=0 \sim 1$ 、さらに $\theta=135^\circ$ では $\rho=-1/\sqrt{2} \sim 1/\sqrt{2}$ までと

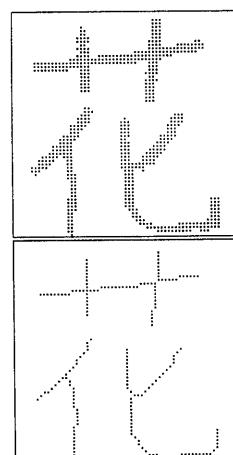


図2 細線化パターンの例

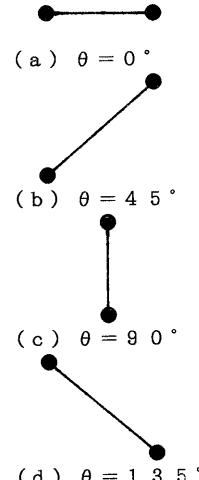


図3 隣接点の接続関係

なる。したがって、 64×64 画素から成る手書き文字パターンを、 $x, y = 0 \sim 63$ の座標系で表現して Hough 変換を施し、 ρ の値を 8 画素刻みで粗くまとめて投票すると、40 次元の特徴量が抽出される。同様に、 ρ の値を 4 画素刻みで粗く投票すると 78 次元、2 画素刻みでは 156 次元の特徴量が各々得られる。図 2 に示した文字パターンに対して、 ρ を 4 画素刻みで抽出した 78 次元の特徴量の例を図 4 に示す。

2. 2 局所方向寄与度特徴の抽出

手書き漢字認識では、ストロークの方向性に着目した特徴を抽出するのが有効であることが知られている。ストロークの方向性を抽出し、しかも比較的高い認識精度の得られる特徴の一つに、局所方向寄与度特徴（以下、LDC 特徴と呼ぶ）がある。ここでは、この LDC 特徴を用いて、手書き漢字と平仮名の特徴抽出を行うことにする。

LDC 特徴は、方向寄与度特徴を発展させ、次のようにして抽出することができる。

方向寄与度特徴は、図 5 に示すように、文字内のある黒点 Bにおいて、8 方向に触手を伸ばして求められる黒点の連結長 l_i ($i = 1, 2, \dots, 8$) を用いて、

$$d_m = \frac{l_m + l_{m+4}}{\sqrt{\sum_{j=1}^4 (l_j + l_{j+4})^2}} \quad (2)$$

で定義される。

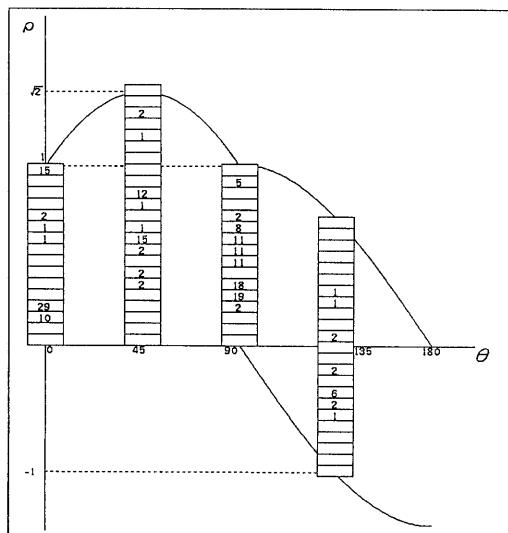


図 4 Hough 変換特徴の抽出例(78 次元)

64×64 画素で表される手書き文字パターンのすべての黒点において、式(2)によって定義される方向寄与度特徴を求め、これを 4×4 個に分割したまたは 8×8 個に分割した小領域に含まれる全黒点についての平均を算出することにより、LDC 特徴を抽出することができる。したがって、 4×4 個の小領域に分割すると 64 次元、 8×8 個の小領域に分割すると 256 次元の特徴量が抽出される。手書き漢字と平仮名に対する LDC 特徴の抽出例を図 6 に示す。曲線のストロークが多く含まれる平仮名に対しては、斜め方向の成分が大きく抽出されることがわかる。

3. PDP モデルによる区別システム

抽出した二つの特徴量による手書き漢字と平仮名の区別には、図 7 に示すような、並列分散処理モデル (PDP モデル) を使用した。この PDP モデルは、入力層、中間層、出力層の 3 層から成る階層型ネットワークである。入力層には、手書き文字から抽出した 2 種類の特徴、つまり Hough 変換特徴または LDC 特徴が入力される。入力層のユニット数は、特徴量の次元数に一致させた。したがって、Hough 変換特徴では、40、78 または 156 ユニットとなる。一方、LDC 特徴では、64 または 256 ユニットとなる。中間層のユニット数は、

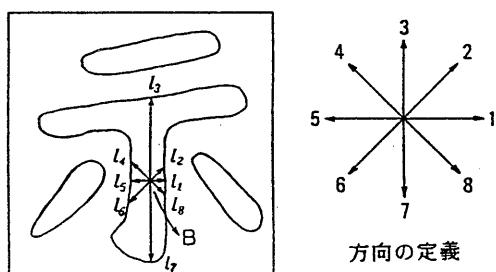


図 5 方向寄与度特徴の定義

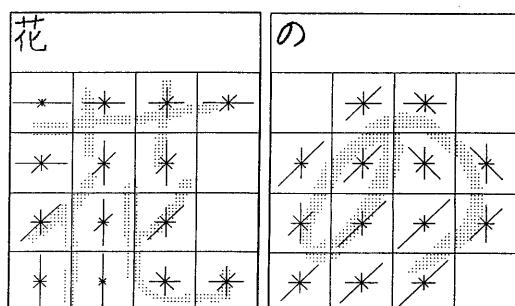


図 6 局所方向寄与度特徴の抽出例(64 次元)

8、16または24個とした。出力層は2ユニットで構成し、漢字と平仮名に対応させた。

この処理モデルでは、層内および層を飛び越えたユニット間の接続はないものとし、かつ各層間では全てのユニットは接続されているものとした。つまり、信号が下層から上層に向かって一方的に伝達されるフィードフォワード型ネットワークである。

また、このネットワークの学習には、誤差逆伝搬法と呼ばれる、教師ありの学習則を用いた。学習による重みの変更は、

$$\Delta \omega_{n+1} = -\eta \partial E / \partial \omega + \alpha \Delta \omega_n \quad (3)$$

において、学習定数 η と安定化定数 α を適当に固定し、重み ω を学習のたびごとに変更していく、逐次修正により学習を行った。

4. 漢字と平仮名の区別実験

4.1 実験条件

PDPモデルによる手書き漢字と平仮名の区別には、電総研で作成され、公開されている手書き漢字データベースETL8[4]を使用した。このデータベースは、75文字の平仮名と881文字の教育漢字について、各文字160人分のパターンが3巻の磁気テープに納められている。

ここでは、次のようにして、PDPモデルによる学習と区別実験を行った。

まず、75文字の平仮名を平仮名セットと呼ぶこ

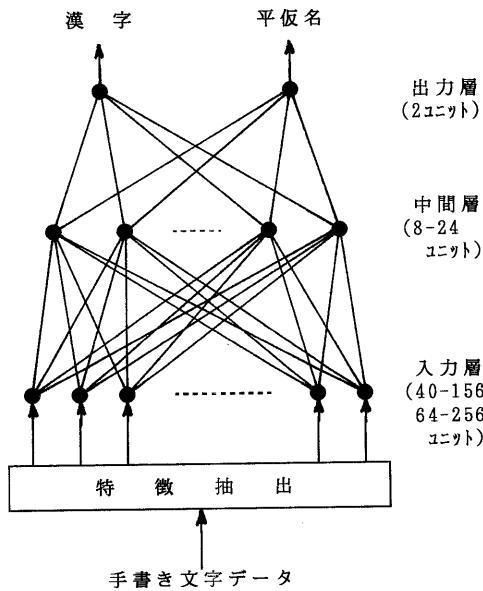


図7 PDPモデルによる区別システム

とにし、これと同数の漢字を各巻の先頭から順に、表1のように取り出して漢字セット1、2、3とした。漢字は、50音順に配列されているので、これによって字形についてはランダムに75文字が選択されると仮定した。また、各文字データは、160個のうち、先頭から100個だけを使用した。このうち、奇数番目のデータを学習に用いる学習データセットとし、偶数番目のデータは学習に使用しない未知データセットとした。

平仮名と対する漢字セットの違いによって、逆伝搬法に基づく学習により、3種類のネットワークを作成した。つまり、漢字セット1、2、3に対応したネットワーク1、2、3である。例えば、表1のように、平仮名セットと漢字セット1に含まれる150文字を対象に、それらの奇数番目のデータを用いて作成されるネットワークをネットワーク1とする。ネットワーク2、3についても同様である。

学習回数は、合計7500文字のデータに対する学習を1回として、いずれの場合とも、重みの逐次修正により、400回まで行った。

4.2 学習した文字セットの区別実験結果

Hough変換特徴を用いて作成した、3種類の

表1 学習に用いた文字セットとネットワークの種類

(平仮名セット)	
あいうえおかぎぎくぐけけこごさざじすすせせぞぞ ただぢぢつづてとどなにぬねのはばばひびふぶぶ へべべほほぼまみむめもややゆゆよよらりるれろわをん	
(漢字セット1)	
愛悪庄安暗案以位依頼委意易異移胃遺医育一老印員因引 飲院右爾運雲營榮永冰英術益駅門園延演遠塩央往応横 王黃億屋恩温音下化坂何加可夏家科果歌河火花荷謀貨	
(漢字セット2)	
故湖五午後誦譲護交候光公功効厚口向后孝工幸広康校構 港皇耕考航行講鉛高号合告国毅黒今根混左差查再最妻才 採済災祭細菜際在材罪財坂作昨策刷察殺雜三參山散產算	
(漢字セット3)	
蒂待態貨退隊代台大第題達谷单炭短團断男談知地池置築 竹茶着中忠昌柱注虫著貯丁帳張朝町陽調長鳥直賃通低 停定底庭弟堤程敵の適鉄典天展店転点伝田電徒登都努度	
(ネットワークの種類)	
1	(平仮名セット)+(漢字セット1)
2	(平从名セット)+(漢字セット2)
3	(平从名セット)+(漢字セット3)
	の奇数 番目の データ で作成

表2 Hough変換特徴による区別実験結果

特微量元素の次元数	中間層の個数	ネットワークの種類	正答率(%)		
			漢字	平仮名	平均
40	8	1(学習)(未知)	93.3 91.8	96.2 94.1	94.7 92.9
		2(学習)(未知)	92.1 90.0	96.9 93.9	94.5 92.0
		3(学習)(未知)	92.5 90.8	94.8 93.1	93.6 92.0
	16	1(学習)(未知)	97.4 94.4	97.0 93.3	97.2 93.8
		2(学習)(未知)	97.4 94.8	97.1 93.0	97.2 93.9
		3(学習)(未知)	94.9 93.0	95.6 93.0	95.2 93.0
	24	1(学習)(未知)	98.3 95.3	98.0 94.3	98.1 94.8
		2(学習)(未知)	99.4 94.3	99.3 94.2	99.3 94.2
		3(学習)(未知)	96.1 92.4	98.3 95.2	97.2 93.8

ネットワークによる手書き漢字と平仮名の区別実験の結果を表2に示す。

Hough変換特徴は、投票する ρ の画素刻みの粗さによって、40、78または156次元の特徴量となる。入力層のユニット数は、各々の特徴量に対応させて設定した。また、中間層のユニット数は8、16、24の3通りについて実験した。

表において、学習データセットに対する結果とは400回の学習によって作成した各ネットワークに改めて学習文字セットを入力して、区別させたときの正答率である。また、未知データセットに対する結果は、学習に使用しなかったデータセット、つまり同じ文字セットの偶数番目のデータを入力としたときの正答率を示したものである。

この結果より、まず特徴量の次元数に関しては、40から78にすると、学習データセットに対する正答率は高くなるものの、未知データセットに対する正答率はほとんど向上しない。さらに、78から156にすると、学習データセットに対してはほとんど差がないものの、未知データセットに対してはむしろ正答率が低下することがわかる。これは、投票する($\rho - \theta$)平面での画素刻みを細かくしすぎると、分布のピークが分散し、ストロークの直線性や曲線性などを表す特徴量がぼけてしまうことによるものであろう。

特徴量の次元数	中間層の個数	ネットワークの種類	正答率(%)		
			漢字	平仮名	平均
78	8	1(学習)(未知)	96.9 92.0	97.1 91.9	97.0 91.9
		2(学習)(未知)	98.1 93.6	96.9 91.7	97.5 92.6
		3(学習)(未知)	97.1 93.4	96.7 92.0	96.9 92.7
	16	1(学習)(未知)	99.1 94.7	99.0 93.3	99.1 94.0
		2(学習)(未知)	99.5 93.6	99.6 93.9	99.5 93.8
		3(学習)(未知)	99.6 94.0	99.7 92.7	99.6 93.3
	24	1(学習)(未知)	99.9 94.5	99.8 92.7	99.9 93.6
		2(学習)(未知)	99.8 95.1	99.8 93.7	99.8 94.4
		3(学習)(未知)	99.8 93.8	99.9 94.1	99.9 94.0

特徴量の次元数	中間層の個数	ネットワークの種類	正答率(%)		
			漢字	平仮名	平均
8	16	1(学習)(未知)	98.8 92.1	98.0 88.4	98.4 90.2
		2(学習)(未知)	98.1 91.9	97.9 88.3	98.0 90.1
		3(学習)(未知)	96.8 89.7	98.7 92.8	97.7 91.3
156	24	1(学習)(未知)	99.8 92.5	99.6 90.7	99.7 91.6
		2(学習)(未知)	99.8 92.2	99.8 91.4	99.8 91.8
		3(学習)(未知)	96.3 90.5	97.9 91.2	97.1 90.9
		1(学習)(未知)	99.9 92.0	99.8 91.0	99.8 91.5
		2(学習)(未知)	99.9 92.1	99.9 91.8	99.9 91.9
		3(学習)(未知)	99.9 ₇ 90.7	99.9 ₅ 90.8	99.9 ₆ 90.7

次に、中間層のユニット数に関しては、8個から16個、24個へと増やすと、学習データセットに対する正答率は確実に向かうものの、未知データセットに対しては、16個から24個に増加しても正答率はわずかにしか向上しない。これは、中間層のユニット数を増加させても、このネットワークの汎化能力には限界があることを示している。

また、未知データセットに対する正答率は、学習データセットと比較して2~9%近くも低下する。例えば、78次元の特微量で、中間層のユニット数を24個に設定すると、学習データセットに対しては、3種類のネットワークの平均で99.9%となり、未知データセットに対しては94.0%の正答率となる。この差は、手書きによる文字パターンの変形に基づくものであろう。

次に、LDC特徴を入力として作成した、ネットワークによる区別実験の結果を表3に示す。

LDC特徴は、分割ができる小領域の数により64または256次元の特微量として抽出される。中間層のユニット数は、ここでも8、16、24の3通りとし、学習回数は400回とした。

この結果より、LDC特徴の次元数に関しては、64から256に増やすと、学習および未知データセットに対して、正答率はどちらも向上することがわかる。しかし、学習データセットについては、どの中間層のユニット数の場合でも、99%以上にまで向上するのに対して、未知データセットについては、ユニット数が少ないと、正答率は高くなるが、多くするとほとんど差がなくなる。

また、中間層のユニット数に関しては、64次元の特徴では、8個から16個、24個へと増やすにしたがって、学習および未知データセットに対してとも正答率は向上する。しかし、256次元の特徴では、中間層のユニット数を増加させても、正答率はほとんど向上しないことがわかる。256次元の特微量を用いると、入力層のユニット数が多くなるため、たとえ少ない中間層のユニット数のときでも層間の結合は膨大になる。そこへ、新たに中間層のユニットを追加して、結合を増やしても、パターンの学習能力や文字変形の吸収能力などは向上せず、限界であるといえよう。

学習と未知データセットに対する正答率は、学習データセットに対しては、Hough変換特徴よりも低くなるものの、未知データセットに対しては、わずかに高くなる。つまり、LDC特徴の方が両者の差が小さくなることがわかる。例えば、256次元の特微量を用いて、中間層のユニット数を24個に設定すると、学習データセットに対しては、3つのネットワークの平均で99.4%となり、未知データセットに対しては95.5%の正答率となる。

表3 LDC特徴による区別実験結果

特微量元素 の 次元数	中間 層の 個数	ネットワーク の 種類	正答率 (%)		
			漢字	平仮名	平均
64	8	1(学習) (未知)	95.5 94.2	93.9 92.1	94.7 93.1
		2(学習) (未知)	95.8 94.1	97.0 94.6	96.4 94.3
		3(学習) (未知)	95.1 93.9	94.9 93.2	95.0 93.6
	16	1(学習) (未知)	97.9 94.6	98.1 94.8	98.0 94.7
		2(学習) (未知)	98.2 95.6	98.4 95.2	98.3 95.4
		3(学習) (未知)	95.3 92.0	98.3 96.1	96.8 94.1
	24	1(学習) (未知)	98.9 96.1	98.6 94.6	98.7 95.3
		2(学習) (未知)	98.7 95.5	99.5 96.2	99.1 95.9
		3(学習) (未知)	97.0 93.7	99.5 96.2	98.2 94.9

特微量元素 の 次元数	中間 層の 個数	ネットワーク の 種類	正答率 (%)		
			漢字	平仮名	平均
256	8	1(学習) (未知)	99.5 97.1	98.9 93.8	99.2 95.4
		2(学習) (未知)	98.9 95.4	99.4 95.1	99.2 95.2
		3(学習) (未知)	98.7 95.9	99.2 94.3	98.9 95.1
	16	1(学習) (未知)	99.2 96.2	99.0 94.3	99.1 95.3
		2(学習) (未知)	99.3 96.9	99.1 94.7	99.2 95.8
		3(学習) (未知)	99.2 95.9	99.2 94.6	99.2 95.2
	24	1(学習) (未知)	99.4 96.4	99.2 94.7	99.3 95.6
		2(学習) (未知)	99.5 96.6	99.6 95.4	99.5 96.0
		3(学習) (未知)	99.3 95.9	99.4 93.9	99.4 94.9

これより、LDC特徴は、文字パターンの学習能力において、Hough変換特徴より少し劣るもののが手書きによる文字変形に対する吸収能力においてはむしろ優れていることがわかる。

4. 3 未学習漢字セットの区別実験結果

これまでの実験では、学習に用いた平仮名セットと対にする漢字セットの違いによって、異なる3種類のネットワークを構成し、学習に用いたのと同じ文字データセットに対して、その区別能力を明らかにしてきた。

ここでは、この3種類のネットワークを用いて、どのネットワークにおける学習にも使用しなかった漢字、つまり未学習漢字セットに対して、これらのネットワークがどの程度の区別能力を備えているかについて検討する。

表4 未学習漢字セットに対する区別実験結果
(Hough変換特徴)

特微量元素の次元数	中間層のユニット数	ネットワークの種類			
		1	2	3	平均
40	8	80.9	79.4	82.9	81.1
	16	86.3	84.6	84.4	85.1
	24	85.4	85.1	82.5	84.4
78	8	84.1	85.0	86.4	85.2
	16	85.3	84.7	86.2	85.4
	24	86.0	85.5	85.6	85.7
156	8	84.9	84.8	81.0	83.6
	16	84.1	84.6	83.9	84.2
	24	84.2	84.5	84.3	84.3

(LDC特徴)

特微量元素の次元数	中間層のユニット数	ネットワークの種類			
		1	2	3	平均
64	8	87.3	84.3	85.7	85.8
	16	86.1	85.3	83.2	84.9
	24	87.0	84.7	85.0	85.5
256	8	89.5	85.4	88.5	87.8
	16	88.5	89.1	89.0	88.9
	24	88.7	88.2	89.7	88.9

教育漢字881文字のうち、どのネットワークの学習にも使用しなかったものは656文字になる。これらの文字について、データベースの先頭から各100個、合計65600個の漢字データを対象として、3種類のネットワークに入力したときの、つまり未学習漢字セットに対する正答率、およびその平均を表4に示す。

これより、Hough変換特徴を用いて作成したネットワークでは、最も高い場合でも、その正答率は平均で85.7%にすぎない。一方、LDC特徴を用いると、これよりはわずかに良くなるものの、高々88.9%で、90%にも達しないことがわかる。この結果は、学習データセットに対する正答率と比べて10%以上、未知データセットに対しても数%以上も低下してしまうことを示している。つまり、PDPモデルを用いて、手書き漢字と平仮名を区別させるには、漢字に対してもできるだけ多くのものを学習しておく必要があるといえよう。

次に、各々の特微量を学習して作成した3種類の異なるネットワークを用いて、未学習漢字セットを3つのネットワークに同時に投入し、その出力結果の多数決によって、手書き漢字を区別させたときの

表5 多数決による未学習漢字セットの区別結果

特徴の種類	特微量の次元数	中間層のユニット数		
		8	16	24
Hough変換特徴	40	83.8	87.9	87.1
	78	88.0	88.2	88.1
	156	87.3	86.9	86.8
LDC特徴	64	88.6	87.4	87.7
	256	90.0	90.7	90.6

表6 正答率の低い未学習漢字

正答率(%)	(Hough変換特徴) 78次元・16個	(LDC特徴) 256次元・16個
50~40	形犬士始市拾人打八水 秒米歩迷令	拾川然俗燈燃必力令
40~30	修述女状仁多二燃半比 必本浴立六	犬士七修十人多冬
30~20	七十水念不夕	形刃冷
20~10	求心木力	女少夕
10~0	小少冷	小心

実験結果を表5に示す。

これより、異なる漢字を学習した3種類のネットワークを用いて、それらの出力結果の多数決で区別させても、単独のネットワークで区別させるときと比べて、正答率は1~2%ほどしか向上せず、最も高いものでも、90%をわずかに上回る程度の正答率に留まることがわかる。つまり、学習していない漢字の区別は難しく、手書き漢字ができるだけ正確に漢字だと判断させるためには、区別すべき漢字のすべてを学習させておくことが不可欠であるということができるよう。

3種類の異なるネットワークの出力結果の多数決によって、未学習漢字セットを区別させても、その正答率が50%にも達しなかった漢字を表6に示しておくる。Hough変換特徴の例は、78次元の特微量で、中間層が16個の場合(正答率88.2%)である。LDC特徴の例は、256次元で中間層が16個の場合(正答率90.7%)である。

これより、正答率の低い未学習漢字には、平仮名のようにストローク数が少なくて、簡単な漢字や、曲線になることの多い斜め方向のストロークが目につく漢字が多く含まれていることがわかる。

5. むすび

漢字と平仮名におけるストロークの直線性や曲線性の違いに着目して、それらの特徴を抽出し、かつPDPモデルを用いて、手書き漢字と平仮名の区別に関する可能性について検討した。

特徴の抽出には、二つの方法を用いた。一つは、画像処理でよく利用されるHough変換を応用したものである。このHough変換特徴は、細線化した文字パターンの隣接する2点の関係を($\rho - \theta$)平面に写像し、投票することによって求められる。このとき、投票する画素刻みの粗さによって、この特徴は40または78、156次元の特微量として抽出される。もう一つは、手書き漢字認識においてよく用いられるLDC特徴である。LDC特徴は、方向寄与度によってストロークの方向性を抽出し、その局所的な分布の違いを特徴とするものである。この特徴は、分割する小領域の違いによって、64または256次元の特微量として抽出される。

抽出した特微量による手書き漢字と平仮名の学習と区別には、並列分散処理モデル(PDPモデル)を使用した。このPDPモデルは、3層のフィードフォワード型階層ネットワークであり、その学習には誤差逆伝播法を用いた。中間層のユニット数は8、16または24個とし、合計400回の学習によりネットワークを構成した。

このネットワークを用いて、学習文字セットと未学習漢字セットに対する区別実験を行った。

その結果、次のようなことが明らかになった。

1) Hough変換特徴を用いると、学習データセットに対して99.9%、未知データセットに対して94.0%の正答率が得られる。しかし、画素刻みを細かくしても区別能力には限界がある。

2) これに対して、LDC特徴を用いると、学習データセットでは99.4%、未知データセットでは95.5%の正答率が得られ、学習と未知データセットに対する正答率の差は、Hough変換特徴のときよりも小さくなる。

3) これらのネットワークに、学習には使用しなかった未学習漢字セットを区別させると、正答率は極めて低く、89%を越えない。つまり、より正確な区別には、すべての文字に対して学習することがほしい。

4) 3種類の異なるネットワークの出力結果の多数決によって未学習漢字を区別させても、正答率は1~2%ほどしか向上しない。正答率の極めて低い漢字は、平仮名のような簡単なものや、斜め方向の線分の多く含まれるものなどである。

これより、Hough変換特徴とLDC特徴のどちらを用いても、学習した文字セットに対する区別はかなり可能となるが、未学習漢字に対する能力は低く、より正確な区別には、すべての文字の学習が不可欠であることが明らかになった。

今後は、1)すべての漢字を学習したネットワークの作成と、その区別能力の定量化、2)より高い能力を有する新しい特徴の探索と、それによる区別の可能性、などについて検討していく。

謝辞

本研究に際し、実験に協力して戴いた本学昨年度卒研生の竹田善広君(現、三菱電機(株))並びに本年度卒研生の政岡靖久君に深謝する。また、データを提供して戴いた電総研の関係各位に深く感謝する。なお、本研究の一部は文部省科研費(一般研究(C)No.02680033)によるものである。

参考文献

- [1]松瀬、美濃、坂井：“合法パターン頻度分布に基づく9か国文字の類別”，信学技報、PRU83-9, pp.65-72 (1983.5).
- [2]松山、與水：“Hough変換とパターンマッチング”情報処理、Vol.30, No.9, pp.1035-1046(1989.9).
- [3]萩田、内藤、増田：“大局的・局所的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.J65-D, No.6, pp.722-729(1983-6).
- [4]森、山本、山田、斎藤：“手書き教育漢字のデータベースについて”，電総研彙報、Vol.43, No.11-12, pp.60-81(1979.11-12).

盛光印刷所