

5 N-6 並列多段ニューラルネットワークによる手書き漢字の分類

江刺家公也†, 荒井 正之‡, 王 晉申†, 奥田 健三†

†:宇都宮大学 ‡:帝京大学

1 はじめに

ニューラルネットを用いた文字認識の研究が今日広く行なわれている^[1]。われわれは、小学校学習漢字の全996文字を対象とし、ベクトル量子化ニューラルネット（以下VQネット）を用いて漢字を大分類の後、誤差逆伝搬法を用いた階層型ネットにより認識を行うネットワークを構築し、考察を進めてきた。特にVQネットを2層構造にすることにより、学習時間が単層VQネットに比較し約23%と大幅に短縮され、更に分類数の均等化にも寄与することを明らかにした^[2]。

今回は分類率の向上を目指し、2層構造のVQネットを並列に配置したネットワークを構築し、実験、考察を進めた。入力特徴ベクトル、累積分類率、学習時間について報告する。

2 ネットワーク構成

ネットワークの構成を図1に示す。2層構造のVQネットにおいて分類を行い、階層型ネットにより認識を行うネットワークを並列に配置する。累積分類率、認識率の向上を目指して、相補性の高い入力特徴ベクトルを用いた。

第1層のVQネットにおいて、入力データがどのニューロンと最適整合するかをユークリッド距離を用いて求め、最適整合したニューロンに大分類される。次に最適整合となった第1層ニューロンと接続する第2層VQネットに入力データを入力し、第1層と同様に最適整合した第2層のニューロンに更に細かく分類される。最後に第2層ニューロンと接続する第3～5層の誤差逆伝搬による階層型ネットにより認識させる。

3 入力特徴ベクトル

今回用いた入力特徴ベクトルは、大局的方向寄与度密度特徴（以下GDCD）と局所的方向寄与度密度特徴（以下LDCD）である^[3]。GDCDは文字を複数方向から走査し、各走査時に白点から黒点に変わるもの黒点の方向寄与度を4方向成分別に計数し、1次元座標軸に投影する。次に各投影軸を適当に区間分割し、各区

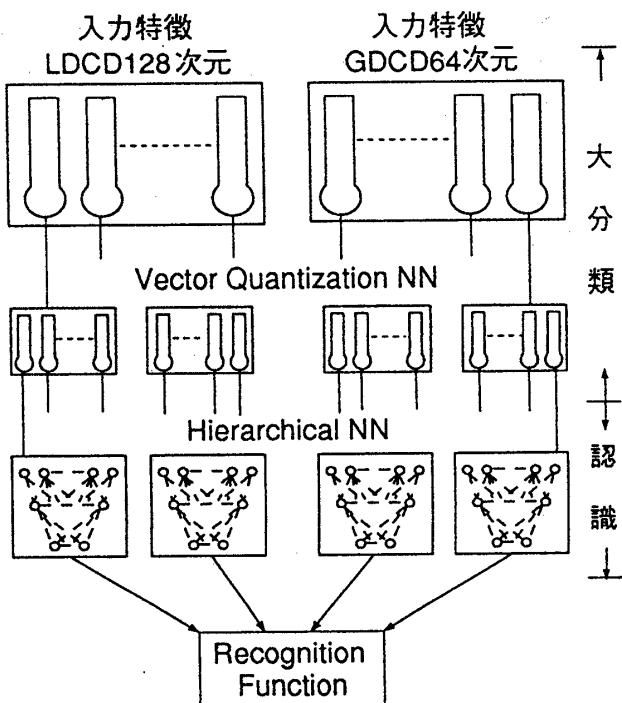


図1 ネットワーク構成

間ごとに平均して方向寄与度密度を求ることにより得られる。4方向の場合は128次元、2方向の場合は64次元となる。LDCDは文字を8×8の粗メッシュ領域に等分割し、各粗メッシュ領域内で方向寄与度密度を2方向から求めることにより得られ128次元となる。入力特徴ベクトルを抽出するための前処理としてノイズ除去、正規化を施した。

4 実験

ネットワーク構造において、単層構造とは2次元格子状に $10 \times 10 = 100$ 個のニューロンを配置したVQネットである。2層構造とは第1層目に2次元格子状に $3 \times 3 = 9$ 個のニューロンを配置し、第2層目は第1層の各ニューロンの分担するカテゴリー数の約1/10のニューロンを1次元に配置したネットワークで

ある。そして並列構造とは2層構造を並列に配置した、図1のネットワークである。

先に述べたシステムをワークステーション(MIPS Magnum 3000)上でC言語を用いて試作し実験を行った。データは電総研作成のETL 9の一部を使用し、学習30サンプル、未学習10サンプルを用意した。学習のための入力ベクトルには学習データ30サンプルの特徴ベクトルの平均値を使用した。学習係数などのパラメータ、学習回数は予備実験で最も分類率の良かった値を用いた。

4.1 累積分類率

これまでの実験結果により、入力特徴ベクトルとしてLCD 128次元が優れていることを明らかにした^[3]。それ故、並列構造に用いるもう1つの入力特徴ベクトルとして、LCD に対し高い相補性を持つと考えられるGDCDを選定した。2層構造においてGDCDの64次元と128次元の累積分類率は、表1に示す様に累積9位までみた場合ほとんど差がなく、処理時間を考慮すると64次元で良いと思われる。

以上より入力特徴ベクトルとして単層構造、2層構造にはLCD 128次元を用い、並列構造にはLCD 128次元とGDCD 64次元を用いた。これらの累積分類率を表2に示す。

表1 GDCDによる累積分類率(単位:%)

次元数	64次元		128次元	
	学習	未学習	学習	未学習
累積3位	89.13	86.80	90.09	87.88
累積6位	95.17	93.57	95.62	94.03
累積9位	97.23	96.15	97.36	96.41

表2 構造別累積分類率(単位:%)

構造		単層	2層	並列
特徴		LDCD128	LDCD128	LDCD128 GDCD64
学習	累積6位	93.09	84.75	89.18
	累積12位	97.28	92.14	95.17
	累積18位	98.60	-	97.23
未学習	累積6位	90.94	81.75	86.80
	累積12位	96.39	90.37	93.57
	累積18位	97.93	-	96.15

表において2層構造、並列構造の場合、第1層で第3位分類率までとり、第2層において累積分類率を適用する。累積12位分類率を例に挙げると、2層構造

は第2層において4位まで、並列構造は2層において2位までを候補とすることになる。また並列構造の場合、入力特徴ベクトル LCD 128次元、GDCD 64次元を入力するネットワークをそれぞれ独立に実行し、どちらかが正分類していれば良いとした。

表2をみると2層構造に対し並列化の効果が認められる。また構造別累積分類率は単層構造が最も優れており、次いで並列構造が良い。累積18位分類率で比較した場合、学習データで単層構造98.60%、並列構造97.23%となり、未学習データで単層構造97.93%、並列構造96.15%となる。これらの差は学習データで約1.4%、未学習データで約1.8%であった。

4.2 学習時間

学習に要した時間を表3に示す。ここで学習時間はCPU時間を用いた。2層構造の第1層、第2層合計学習時間は248秒、並列構造の合計学習時間は378秒であった。単層構造における学習時間1145秒に対し、2層構造は約22%、並列構造は約33%となる。並列構造は並列処理が可能で、その場合は2層構造の学習時間と同じになり、更に短縮される。

表3 構造別学習時間(単位:秒)

構造	1層時間	2層時間	合計時間
単層構造	1145	-	1145
2層構造	110	138	248
並列構造	168	210	378

5 まとめ

本稿では、VQネットを2層化したネットワークモデルを並列に配置し、相補性が高いと考えられる入力特徴ベクトル LCD 128次元と、GDCD 64次元を入力することにより、累積18位において分類率が学習97.23%、未学習96.15%となり、文献[3]に比較し大幅に向上することを明らかにした。しかし、単層構造と比較すると若干劣る結果となった。学習時間は単層構造と比較すると約33%に短縮された。今後の課題として、更なる累積分類率の向上が挙げられ、入力特徴ベクトルに検討を加え他の組み合わせでの実験などが必要である。

参考文献

- [1] 岩田,他:大規模ニューラルネット Comb NET-II,信学技報,NC90-34,1990
- [2] 萩田,他: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 D,J66-D,6,pp722-729,1983
- [3] 奥田,他:多段ニューラルネットワークによる手書き漢字の分類,情報処理学会第43回全国大会,5G-8,1991