

複合改良LVQニューラルネットワークによる印刷漢字認識方式の評価

7C-1

宮原景泰、
三菱電機株式会社

依田文夫
情報電子研究所

1. まえがき

近年、ニューラルネットワークを文字認識に適用する研究が盛んに進められている。しかし、これらの多くは、小規模なネットワークを用いて英数字のような少ない文字種を識別しているもので、漢字のように読み取り対象文字種が多いものに適用することは困難であった。そこで筆者らは、大規模な漢字認識に適用できる複合改良LVQニューラルネットワークによる印刷漢字認識方式を提案した⁽¹⁾。本ネットワークはLVQ2ニューラルネットワーク方式⁽²⁾をベースとしたものであり、高速に学習が収束し、それまで学習した重みの結果を損なうことなく新しい認識対象文字の追加学習を行うことができる。今回、この複合改良LVQニューラルネットワークを、デジタルニューロチップを使用して実現した実験システムを開発し、複数フォントの印刷漢字に適用したので報告する。本実験システムではオンチップでの学習が可能であり、リアルタイムで学習/認識を行うことができる。

2. 複合改良LVQニューラルネットワーク

複合改良LVQニューラルネットワークは、それぞれ独立した特徴ベクトルを処理する複数の改良LVQネットワークの出力値を統合して、最終クラスを決定するものである。以下では本ネットワークについて説明する。

2.1 改良LVQニューラルネットワーク

改良LVQニューラルネットワークの構造を図1に示す。ネットワークは3層構造であり、入力層の各ノードには入力ベクトルXの各要素が入力される。中間層の各ノードは、各文字のサブクラスに対応し、重みを介して入力層のノードと全結合している。出力層のノードは各カテゴリに対応し、関連




図1 改良LVQニューラルネットワーク

する中間層ノードのみが選択的に結合されている。出力層のノードは、中間層ノードの出力値のうち最大値を選択する。

次に本ネットワークの学習法について説明する。ここで入力ベクトルXはカテゴリCjに属し、その出力値O(X,Cj)を与える中間層ノードの重みをWcjとする。また、カテゴリCjに属さない出力ノードのうち出力値が最も大きいノードに対応するカテゴリをCi、この出力値O(X,Ci)を与える中間層ノードの重みをWciとする。この時、以下のように学習を行う。

- 1) $O(X,C_j) > O(X,C_i)$ かつ $O(X,C_j) - O(X,C_i) \leq \beta_1$ の場合
 $W_{ci}(t+1) = W_{ci}(t) - a(t)\{X - W_{ci}(t)\}$
 $W_{cj}(t+1) = W_{cj}(t) + a(t)\{X - W_{cj}(t)\}$
- 2) $O(X,C_j) \leq O(X,C_i)$ かつ $O(X,C_i) - O(X,C_j) \leq \beta_2$ の場合
 $W_{ci}(t+1) = W_{ci}(t) - a(t)\{X - W_{ci}(t)\}$
 $W_{cj}(t+1) = W_{cj}(t) + a(t)\{X - W_{cj}(t)\}$
- 3) $O(X,C_i) - O(X,C_j) > \beta_2$ の場合
 $W_{cj}(t+1) = W_{cj}(t) + a(t)\{X - W_{cj}(t)\}$

ここでtは時間(学習回数)を表わす。a(t)は正の学習係数でtの単調減少関数であり、 β_1 、 β_2 は正の定数である。

2.2 複合改良LVQニューラルネットワーク

複合改良LVQニューラルネットワークを用いた文字認識方式の構成を図2に示す。本方式では、文字パターンから文字の濃淡特徴と輪郭特徴の二種類の特徴ベクトルを抽出した後、これらの特徴ベクトルを各々の改良LVQネットワークで並列に処理する。次に個々の改良LVQネットワークの出力ノードから出力された値を、各カテゴリ毎に選択的に結合した統合判定ネットワークで、各カテゴリに対する総合出力値を求める。このうち最大の値を出力するカテゴリを認識結果とする。学習処理では、誤った結果を出力している改良LVQネットワークだけが上記学習則に基づいて重みを修正する。

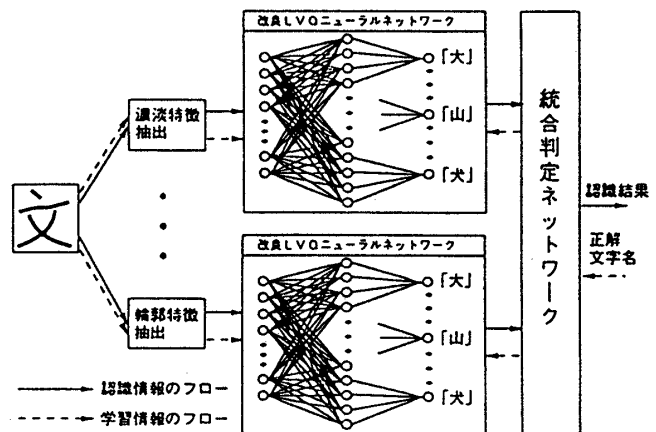


図2 複合改良LVQニューラルネットワーク

Printed Kanji Recognition System with
Multiple LVQ Neural Network
Kageyasu MIYAHARA, Fumio YODA
Computer & Information Systems Laboratory
Mitsubishi Electric Corporation

3. 実験システム

複合改良LVQニューラルネットワークの大量データによる評価を行うために、デジタルニューロチップ^①を搭載したニューロコンピュータによる実験システムを開発した。

使用したニューロチップは、1チップに64個の基本プロセッサPN(Processor Node)を格納したSIMD型デジタルニューロチップである。一つのPNは4Kbyteのローカルメモリを持ち、加算器、乗算器、論理回路、入出力バッファから構成されている。各PNは1本のブロードキャスト型入力バスと出力バス、及び隣接するPN同士を接続するプロセッサ間バスで接続され、1次元上に配置されている。(図3)

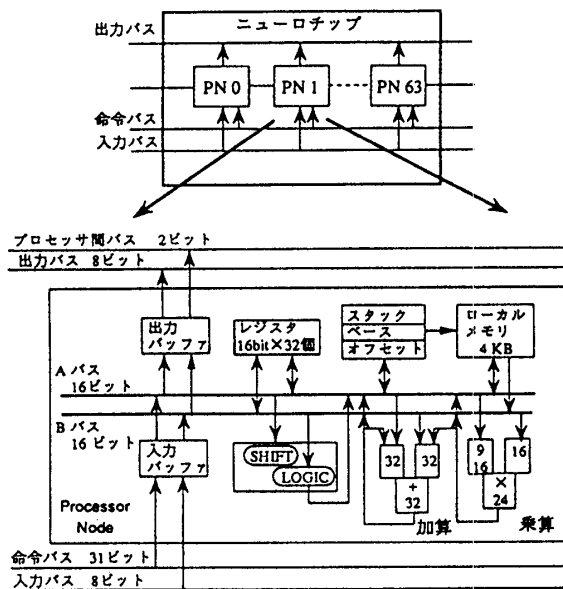


図3 ニューロチップの構成

実験システムでは、このニューロチップを4個使用しており、合計256個のPNが並列に動作する。まず64個のPNを並列動作させ文字パターンの正規化と特徴抽出を行い、次に256個のPNでネットワークの出力値を計算し候補文字の検出を行う。

改良LVQネットワークは、1つのPNに14カテゴリを割り当て、1カテゴリあたり2個の中間ノードを持つネットワークを構成することで実現した。具体的には図4に示すように、まず各PNが自らの担当する14個の出力ノードと、それに接続する28個の中間ノードの出力値を並列に計算する。複合改良LVQネットワークとしては、256個のPNに、この2つの改良LVQネットワークを構築している。




図4 PN0のノード割当

本システムでの各処理の時間は表1のとうりであり、3584字種を1秒間に約350文字処理できる。

表1 実験システムの認識処理時間

処理内容	所要時間
正規化/特徴抽出	1,601 usec
ネットワークの情報伝搬	1,126 usec
候補文字の検出	196 usec
合計	2.9 msec

4. 認識実験

JIS第1水準の印刷漢字、ひらがな、カタカナ、英字、数字、記号など約3300字種について、15種類の字形の異なったフォントを用いて認識実験を行った。15フォントのうち、11フォントの文字パターンを学習データとし、残りの4フォントを未学習データとして、K平均法で作成した重みを用いてKNN(K-nearest-neighbour)法で認識した場合と複合改良LVQニューラルネットワークの場合とを比較した。複合改良LVQネットワークの重みは、K平均法で作成した初期重みに対して学習データ(約35000パターン)で20サイクルの学習を加えたものであり、従来ワークステーションで1週間以上かかっていた学習処理を、実験システムを用いることにより18分で行うことができた。

表2に両者の結果を示す。複合改良LVQネットワークを用いることで、学習データの認識率が100%になり、さらに未学習データについても全フォントで認識率が向上していることが分かる。

表2 認識率

	KNN法	複合改良LVQ
学習データ	99.08%	100%
未学習データ	フォント1	99.63%
	フォント2	99.16%
	フォント3	99.51%
	フォント4	99.17%

5. むすび

複合改良LVQニューラルネットワークの実験システムを開発し、印刷漢字に対する効果を確認した。今後は、大量のフィールドデータによる評価を行なうと共に、本ネットワークの手書き文字への適用検討を進める予定である。

[1]依田ほか:“複合LVQニューラルネットワークによる印刷漢字認識方式の検討”,情処第43回全大,5G-5(平3), [2]Teuvo Kohonen:“The Self-Organizing Map”,Proc.IEEE,Vol.78,No.9, Sep.1990 pp.1464-1480, [3]Dan Hammerstrom,“A VLSI Architecture for High-performance,Low-Cost,On-Chip Learning”,Proc. of IJCNN,Vol.2 pp.537-544