

文字認識ニューラルネットワークの追加学習

Accessional Learning of Neural Network for Character Recognition

○東舎宏樹*, 本間経康**, 阿部健一*

○Hiroki Higashiya*, Noriyasu Honma**, Kenichi Abe*

*東北大学大学院工学研究科, **東北大学医療技術短期大学部

*Grad. School of Eng., Tohoku University, **College of Medical Sciences, Tohoku University

キーワード: ニューラルネットワーク (neural network), 追加学習 (accessional learning), 文字認識 (character recognition)

連絡先: 〒980-8579 仙台市青葉区荒巻字青葉05 東北大学大学院 工学研究科 電気・通信工学専攻 阿部研究室
東舎宏樹, Tel.: (022)217-7074, Fax.: (022)263-9289, E-mail: higashiya@abe.ecei.tohoku.ac.jp

1. はじめに

文字認識には様々な方式があるが、そのうちニューラルネットワークは非線形学習が可能であり、また学習法が確立されているという特長があるため利用されている。しかし、ニューラルネットワークには追加学習が困難であるという問題点がある。その解決策として記憶領域分割という手法が提案されているが、この手法も必要な記憶容量に無駄が発生するという欠点を抱えている。

そこで本研究では文字認識ニューラルネットワークの追加学習での必要記憶容量削減のための手法を提案し、シミュレーションによる検証を行う。

2. 文字認識ニューラルネットワークと追加学習

文字認識の手法は単純なパターンマッチングや特徴点抽出、輪郭解析など多岐に渡るが、そのうちニューラルネットワークを用いるものは、並列処理ができること、また学習法が確立されているなどの特長を有している。しかし、ニューラルネットワークはある学習を行った後に新しい学習を行おうとした場合、最初から学習をやり直さなくてはならないため追加学習が困難であると言える。その原因は、学習された文字が記憶領域にどのように分布しているか判らず、新しい学習が古い学習を破壊してしまう可能性があるためと考えられる。このことから、記憶領域が文字毎に明確に分離でき、また入力を新しく記憶するかそれとも既知の記憶パターンとして学習するかを判断できるシステムが追加学習には必要となる。

3. 追加学習可能なシステムの例とその問題点

このようなシステムの一例として「逐次記憶学習を目的とした記憶システムへの”記憶パターンの信頼度”の利用」(-芳澤,道木,大熊-1998年)のシステムを挙げる。このシステムは記憶領域を1文字毎にユニット化することにより記憶領域を分離し、また記憶領域毎に「信頼度」という尺度を導入することにより新しい文字かこれまでの文字かを区別している。

このシステムの概略を図1に示す。




図1:文字認識システムの概略

入力された文字は画素に分解され入力層に入る。入力層のニューロンは競合層の記憶ユニットそれぞれと類似度を比較し、学習の場合は一番類似度が一番高いユニットを選び出して学習を行う。新しい文字の場合はまだほとんど学習されていない記憶ユニットに学習されることになる。文字認識の場合はその記憶ユニットを出力として出す。このようにして文字認識と学習を行う。文字認識及び学習を行う記憶ユニットの選択には2つの基準で判断する。まず、入力及び各記憶ユニットをベクトルで表現し(記憶ユニットのベクトルを重みベクトル W_j とする)、入力とそれぞれの内積をとり一番大きい物を選ぶ。その際、 $|W_j|$ を信頼度として導入、そこから次式のとおり θ_{max} を定

義して、入力と記憶ユニットのなす角度が θ_{max} 以下の場合そのユニットを選択する。

$$\theta_{max} = 15 + 75e^{-7|W_j|-0.1}$$

$|W_j|$ は学習回数が多くなるほど増加するため、すでに多くの学習を行った記憶ユニットは θ_{max} が小さくなるため内積が非常に大きい文字のみ学習し、逆にほとんど学習を行っていない記憶ユニットの場合 θ_{max} が大きくなり多くの文字を学習する可能性が生まれる。重みベクトルの更新則は次の通りである。

$$\Delta W_{ji} = \eta V_j^1 (V_i^0 - V_j^1 W_{ji})$$

また競合層ユニットjの出力(=入力)

$$V_j^1 = \sum_i W_{ji} V_i^0$$

ここで V_j^0 は入力層ニューロンjの出力(=入力)、 W_{ji} は入力層のニューロンiから競合層のユニットjへの重み、 η は学習係数である。

このシステムは文字認識ニューラルネットワークでの追加学習を実現しているが、文字毎に記憶ユニットを用意する必要があるため記憶容量が膨大になる問題点がある。その問題点を解決するためのシステムを次に提案する。

4. 提案するシステム

提案するシステムの概略を図2に示す。

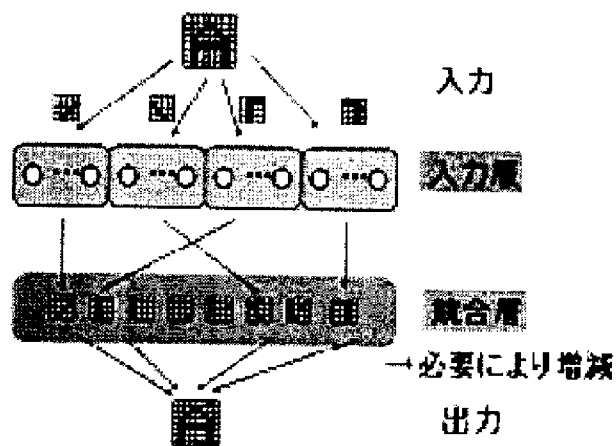


図2:提案するシステムの概略

このシステムでは入力層および競合層を分割する事により、競合層ユニットの共有を行い記憶容量を節減する。また、記憶ユニットを必要に応じ増減することにより無駄な記憶ユニットが発生することを防ぐ。

5. シミュレーション

文字認識ニューラルネットワークであることや、基本的に11の母音字母と14の子音字母の組み合わせで構成されているため文字の部分記憶が共有しやすいと考えられる点から、今回は図3の5つのハングル文字について学習および文字認識を行った。




図3:実験に使用したハングル文字

文字は $16 \times 16 = 256$ 個の2値の画素で表現し、入力層および競合層はその1/4である $8 \times 8 = 64$ 画素を1つのユニットとする。記憶ユニットは最初に1つだけ用意し、学習可能な記憶ユニットが存在しない場合新たに作り出す。記憶ユニットの初期状態は $|W_j| = 0.1$ 、また学習係数 $\eta = 0.01$ とし、1つの入力ユニットにつき50回学習を行った。その結果、全ての文字に関して正しく文字が認識された。また、最初1個だった記憶ユニットは1文字学習するたびに $1 \rightarrow 4 \rightarrow 6 \rightarrow 8 \rightarrow 11$ と増加し、無駄な記憶ユニットの発生はなかった。また、5文字学習した時点で競合域にある記憶ユニットの総画素数は704であり、これは従来のシステムで必要な画素数1280に比べて45パーセント少なくなっている。

6. おわりに

本研究では文字認識ニューラルネットワークにおける追加学習を実現すると共に、記憶容量節減のためのシステムを提案し、シミュレーションで確認した。その結果、従来の方法に比べて大きく記憶容量が節減できることを確認した。

今後の課題は、現在の入力層および記憶ユニットの形状は文字の特長に全く関係がないため、文字の特長が学習にいかされているとは言い難い。そのため、文字の特長を如何に学習に反映させていくかが今後の課題である。

参考文献:

- 1) 芳澤伸一, 道木慎二, 大熊繁: 逐次記憶学習を目的とした連想記憶システムへの「記憶パターンの信頼度」の利用, 電子情報通信学会論文誌, Vol. J81-D-II No.7, pp.1647-1655, July 1998