入力データの特徴を抽出するファジィネットとそのサイン認識への応用

非会員 渡 辺 成 (名古屋大)

正 員 古 橋 武 (名古屋大)

正 員 内 川 嘉 樹 (名古屋大)

Fuzzy Net Extracting Features of Input Data and its Application to Signature Recognition

Shigeru Watanabe, Non-member, Takeshi Furuhashi, Member, Yoshiki Uchikawa, Member
(Nagoya University)

This paper presents a new neural network structure from which features of input data can be extracted easily. The basic structure is a two-layer perceptron and each unit in the input layer has a fuzzy membership function. The input space is divided into fuzzy sub-spaces by the membership functions and the new type of neural network has an ability of nonlinear mapping. The new neural network can handle some deformations of input data with the fuzzy divisions. The structure of the new network is very simple and the features of input data are easily known from the connection weights of the learned network. The authors call the neural network Fuzzy Net. A basic experiment of signature recognition is done using the fuzzy net. The capability of the new network in feature extraction is verified.

キーワード：ファジィネット，サイン認識

1. はじめに

近年、手書き文字認識に関する研究が盛んになされている。オンライン認識は文字の形状のほかに、筆圧、筆速など認識に利用できる情報が多く実用化が進んでいる。これに対して、オフラインの手書き文字認識は、利用できるデータが文字の形状のみであるため、技術的に難しく、認識率の高いシステムの実現が困難になっている。

著者らは、オフラインの手書き文字認識の一種であるサイン認識システムの構築を目指して研究を進めている。サインの認識のためにはサインの筆者の個人性特徴を把握する必要がある。個人性特徴を明確に把握できれば、認識性能を向上させる手法を検討できるのみならず、認識システムの処理効率の向上を図ることも可能となり、実用的なオフラインサイン認識システ

ムの実現を期待できる。また、人間がサインの真偽を判断する場合の支援を行うことも可能である。

手書き文字の個人性特徴に注目した文字認識の研究は以前から報告されている⁽¹⁾⁽²⁾。また、手書き文字から筆者識別を行う研究例も報告されている⁽³⁾。しかし、従来の研究では、個人性特徴を我々にわかりやすい形で自動抽出する手法は示されていない。

ニューラルネットワークにより、文字認識知識を自動獲得する研究が近年盛んになされている^{(4)~(12)}。特に手書き文字は筆者による文字の変形が大きく、認識のためのルールの獲得が困難であるため、ニューラルネットワークが積極的に応用されている^{(5)(8)~(10)}。しかし、ニューラルネットワークにより獲得される認識知識はネットワーク内に分散記憶されるために、文字のどの特徴がとらえられているのか解析することが困難である。活字文字の認識においては、直線成分の特

微量を検出するニューラルネットワークモデル⁽⁴⁾、漢字の「へん」、「つくり」、「かまえ」などの特徴をとらえるベクトル量子化ニューラルネットワーク(LVQ)と、複数の3層BP形のニューラルネットワークを併用するCombNET⁽⁷⁾が提案されている。しかし、文献(4)のネットワークは文字の特徴量を各層の発火ニューロンの出力値の総和としていて、認識知識として利用できるかどうかは疑問である。また文献(7)では、自己組織化アルゴリズムにより入力データの大分類をLVQにより行う手法が示されているが、大分類された入力データにおいてどの特徴が重視されているかを知ることはできない。一方、手書き文字の筆者による変形をファジィデータとしてとらえ、ファジィ推論を用いることでオンライン入力文字の認識性能を向上させる研究の報告例もある⁽¹¹⁾⁽¹²⁾。

本論文では、入力データの特徴を学習後のネットワークから容易に把握できる新しい構成のニューラルネットワークを提案する。本ネットワークは単純パーセプトロンの構成を基本とし、入力層の各ユニットはファジィ推論におけるメンバシップ関数を内部関数にもつ。このメンバシップ関数により本ネットワークの入力空間はファジィ分割され、本ネットワークは非線形写像能力を有する。また、入力空間がファジィ分割されることで、手書き文字のような入力データの変形を吸収できると期待される。本ネットワークは従来の3層BPタイプのネットワークと比較して構成が極めて簡単であり、学習後の結合荷重から入力データにおいて重視された特徴を容易に知ることができる。著者らは、本ネットワークをファジィネットと呼ぶ。

本論文では、ファジィネットをオフラインのサイン

認識に適用し、本ネットがサインの筆者の個性特徴を抽出できる可能性を有することを示す。

2. ファジィネット

図1に提案するファジィネットの構成を示す。本ネットワークは2層パーセプトロンを基本構成とする。図は n 入力1出力のファジィネットの例を示す。入力層の各ユニットはファジィ推論におけるメンバシップ関数を内部関数にもつ。図の例では、各入力データ $I_1, \dots, I_n$ に対してそれぞれSmall, Medium, Bigの3つのメンバシップ関数が用いられている。メンバシップ関数の詳細を図2に示す。横軸は正規化された入力データであり、縦軸がグレード値である。グレード値は入力データに対して図示のようにメンバシップ関数の値として与えられる。入力層の各ユニットの出力値 O_{ij} ($i=0 \sim n, j=1, 2, 3$)はそれぞれのメンバシップ関数のグレード値であり、それぞれのグレード値に結合荷重 w_{ij} ($i=0 \sim n, j=1, 2, 3$)を掛け、出力層のユニットの入力としている。

出力層のユニットは(1)式で表されるシグモイド関数 f を内部関数にもつ。

$$f(s) = \frac{1}{1 + e^{-s}} \dots\dots\dots (1)$$

ただし、 s : 本ユニットの入力の総和

このシグモイド関数は出力ユニットの入力値の総和に対してスレッショルドの働きをする。この関数の値が出力層のユニットの出力値となり、同時にファジィネットの出力となる。得られた出力と教師信号との誤差を用いて、結合荷重 w_{ij} を(2)式に示すデルタルールにより更新する。

図1 ファジィネット
Fig. 1. Fuzzy net.

図 2 メンバシップ関数
Fig. 2. Membership functions.

$$\left. \begin{aligned} \Delta w_{ij}(t+1) &= \eta(y - o)f'(s)o_{ij} + \alpha \Delta w_{ij}(t) \\ w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}(t+1) \end{aligned} \right\} \dots\dots\dots (2)$$

ここで、 Δw_{ij} : 結合荷重の変量, y : 教師信号, o : ネットの出力, f' : シグモイド関数の導関数, o_{ij} : 入力層の第 ij 番目のユニットの出力, η : 学習率, α : 慣性係数

本ネットワークは 2 層パーセプトロンの構成となっているが、ファジィ分割された各部分入力空間ごとに結合荷重が割り当てられているので、非線形写像能力を有する。また、簡単なネットワーク構成であるために、学習後の結合荷重の大小からどの部分領域のデータ(入力データの特徴)が重視されたかを知ることができる。ただし、簡単なネットワーク構成としたことの代償として、入力パターンの判別能力は線形ではないことを付言しておく。

3. サイン認識への応用

オフラインサイン認識に本論文で提案するファジィネットを適用する。サインの認識のためにはサインの筆者の個性特徴を把握する必要がある。そこで、サインデータをファジィネットに学習させて、サインに含まれる個性特徴を自動抽出する手法について検討する。今回は、サインデータの前処理にストローク密度⁽¹⁴⁾を用い、この値をファジィネットの入力とした。

本論文ではサインデータは書類上の所定の罫線上に書かれたものを対象とする。従って、サインの傾きは筆者によっていつも一定に保たれていると仮定する。サインの大きさは書類によってばらつくものとする。

〈3・1〉 ストローク密度特徴 図 3 はサインを 4 方向から走査し、ストローク密度特徴を求める例を示す。(a) 水平方向・(b) 垂直方向・(c) 右斜め 45° (+ 45°) 方向・(d) 左斜め 45° (-45°) 方向にサインを走査し、それぞれに対してストローク密度特徴を求め

図 3 走査方法
Fig. 3. Scanning method.

図 4 ストローク密度特徴の縮約と規格化
Fig. 4. Reduction and normalization of stroke density feature.

ている。ここで、ストローク密度は走査時に横切る文字データの濃度などが用いられる。また、走査の方向は以上の 4 方向に限らず任意の方向が可能であるが、本論文では基本的な 4 方向について個性特徴の抽出を行う。それぞれの密度特徴は単位長さ当たりの走査線の本数を増やせば、より詳細なものが得られる。しかし、サインのように一般に横長に書かれる手書き文字においては、特に垂直方向のストローク密度特徴のデータ数が著しく多くなってしまふ。そこでデータ数を削減し、規格化する手法を図 4 に示す。サインデータはイメージスキャナにより取り込む。まず、走査線の幅をデータのドット単位とし、ストローク密度特徴を求める[図 4(a)]。そして、得られたストローク密度の重心を求め、その重心に対して左右対称に等間隔で密度特徴を分割し、各間隔ごとに、その間に含まれる密度の和を求めた。ただし、分割の間隔(width)は重心を中心として左右にストローク密度の和が総和の 90% になるところまでの長さのうち、長いほうを所定の数で割ることにより決める。このようにすれば、ス

図5 サインデータとストローク密度特徴の例
Fig. 5. An example of signature and stroke density features.

トローク密度特徴の分割は雑音の影響を受けにくくなる。得られたストローク密度をストローク密度の総和で規格化する。 I_i ($i=1\sim n$)は得られたストローク密度特徴でこれをファジィネットの入力とする。

図5にサインとそのストローク密度特徴の例を示す。被験者が紙の上に記入した“Watanabe”というサインをイメージスキャナでワークステーションに取り込み、そのストローク密度特徴を求めた結果である。ストローク密度特徴は、上から順に水平方向、垂直方向、右斜め45°(+45°)方向、左斜め45°(-45°)方向の走査結果である。各方向の走査は、それぞれ上から下、左から右、左斜め上から下、下から右斜め上に行っている。この例では、ストローク密度特徴の数をそれぞれ25個とし、データ数を大きく削減している。

〈3・2〉実験と検討 本ファジィネットにより、サインの個人性特徴の抽出を行う簡単な実験を行った。あらかじめ、被験者の一人が“Watanabe”というサインを紙に書き、これを正例とした。他の5人の被

験者に正例を提示し、それを見ながら極力似たサインを書くことを依頼した。

図6は得られた正例および負例の例を示す。得られたサインは正例として12例、負例として92例であり、これらを学習用データとした。各例のストローク密度特徴を求め(ただし、分割数を25個とした)、水平方向、垂直方向、右斜め45°(+45°)方向、左斜め45°(-45°)方向のストローク密度特徴をそれぞれ別々のファジィネットに入力して学習を行った。教師信号は正例に対して1、負例に対して0とした。結合荷重の初期値はすべて0とした。学習は正負の104例の出力誤差の二乗和が0.1以下になった時点で終了した。このとき、正例の入力に対して各ファジィネットの出力は0.9以上、負例に対しては0.2以下であった。

図7は学習後の結合荷重を示す。左側から順にそれぞれ水平方向、垂直方向、右斜め45°(+45°)方向、左斜め45°(-45°)方向のストローク密度特徴に対する結合荷重である。横軸は図5の各ストローク密度特徴に対応し、縦軸は結合荷重の大きさである。上段がSmall(S)のメンバシップ関数の結合荷重であり、中段がMedium(M)の、下段がBig(B)のメンバシップ関数のそれである。また、水平方向のストローク密度特徴については荷重の最大値の75%のレベルを破線で示している。サインの個人性特徴は結合荷重の分布にとらえられていると思われる。ここでは、大きな結合荷重をもつストローク密度特徴に注目してみる。

図8は図6のサインの例について水平方向のストローク密度特徴を示す。左側が正例のストローク密度特徴であり、右側が負例のそれである。太線のストローク密度特徴は、対応するSmall, Medium, Bigの結合荷重のいずれかが前述の75%のレベルを超えている。また、図9は、図8の太線のストローク密度特徴のストロークの中心線をサインに重ねて示す。上側のストロークから順に、Medium(M), Medium(M), Small(S), Medium(M)とBig(B)の結合荷重が大きいことに対応する。それぞれ図示したストローク線の周辺の文字の密度が中くらい(M), 中くらい(M), 小さい(S), 中くらい(M)または大きい(B)ということが正例の主な特徴としてとらえられている。ストローク密度特徴がSmall, MediumもしくはBigであるかは負例のストローク密度特徴との相対的な関係によって決まるので、一番上のストローク線ではMediumであることが特徴としてとらえられているが、負例のストローク密度特徴はそれよりも小さな値となっている。実際、このストローク線に対するMediumのメンバシップ関数のグレード値は0.40、負例で0.36であっ

図 6 サインの正例と負例
Fig. 6. Examples of true/false signature.

図 7 結合荷重
Fig. 7. Weights.

図 8 ストローク密度特徴
Fig. 8. Stroke density feature.

図 9 サインの特徴
Fig. 9. Feature of signature.

図 10 単純パーセプトロン
Fig. 10. Perceptron.

た。同様に、図 9 の例では上から 2 番目のストローク線では、正例においては Medium である (Medium のグレード値が 0.84) のに対して、負例では Small (Medium のグレード値が 0.48) となっている。

入力層にメンバシップ関数を使わない単純パーセプトロン (図 10) により学習を行った場合を比較のために示す。ストローク密度特徴は 25 分割 ($n=25$) とした。学習後の認識結果は、正例のデータでは 12 例のうち

4例が四つのいずれかにおいて低い値が出力され、負例のデータでは92例のうち21例において高い値が出力され、正しくは判別できなかった。本ファジィネットは単純パーセプトロンと同様に線形判別能力しかもたないが、各入力ユニットにメンバシップ関数を用いることで認識性能が向上していることがわかる。

更に本ファジィネットは、密度が大きい(Small), 中くらい(Medium), 小さい(Big)という入力データの特徴をとらえることができる。単純パーセプトロンにおいては、ストローク密度特徴の分割数を増やせば、認識性能をある程度向上させることは可能であるが、ストローク密度が小さい, 中くらいなどを特徴としてとらえる能力はない。

4. ま と め

本論文では、入力データの特徴を学習後のネットワークから容易に把握できるファジィネットを提案し、本ネットをオフラインサイン認識に適用し、その有効性を実験によって示した。

今回は入力データとして単純なストローク密度特徴を使ったため、サインの曲がりやはねなどの特徴を明確にとらえることはできなかったが、入力データの前処理の工夫により、より多くの特徴をとらえることが可能となる。今後は有効な前処理の方法について検討していきたい。また、前処理の結果に応じてストローク線の走査方向・本数の決定方法および複数のファジィネットの出力から真偽判定をする方法などについてつめていきたい。

また今回は、本ファジィネットにより入力データの特徴抽出が可能であることを重点に検討したが、今後は本ネットの認識率についてより詳細な検討をしていく予定である。

(平成4年11月2日受付)

文 献

- (1) 内藤・増田:「個人性に注目した手書き漢字認識」, 信学論(D), **J67-D**, 480 (昭59-4)
- (2) 尺良・金子・淀川:「2次統計量の線分スペクトル分解—テクスチャ性からの手書き文字個人性情報の抽出—」, 同上(D), **J67-D**, 488 (昭59-4)
- (3) 野沢・竹下・掛布:「人間による筆者識別と計算機による筆者識別—反復記入手書き文字の場合—」, 電子情報通信学会パターン認識・理解研究会, p.9 (平3)
- (4) 梅野・枇杷木:「文字パターン認識における自己組織化を利用した特徴量の検出」, 信学論(D), **J69-D**, 1443 (昭61-10)
- (5) 木村:「誤差および出力変動を最小化する学習アルゴリズムとその低品質手書き漢字認識への応用」, 同上(D-II), **J73-D-II**, 840 (平2-6)

- (6) 加藤・丹・江島:「英数字認識に対するフィードフォワード形PDPモデルの比較検討」, 同上(D-II), **J73-D-II**, 1249 (平2-8)
- (7) 岩田, 他:「大規模4層ニューラルネット(Comb NET)」, 同上(D-II), **J73-D-II**, 1261 (平2-8)
- (8) 森:「PDPモデルによる手書き漢字認識」, 同上(D-II), **J73-D-II**, 1268 (平2-6)
- (9) 大友・石谷・原:「神経回路モデルを用いたオンライン手書き漢字認識」, 同上(D-II), **J73-D-II**, 1275 (平2-6)
- (10) 大友, 他:「神経回路モデルを用いた手書き漢字の2段階認識法」, 同上(D-II), **J74-D-II**, 158 (平3-2)
- (11) 田守, 他:「ファジィ推論を応用したオンライン手書き文字認識手法」, 同上(D-II), **J74-D-II**, 166 (平3-2)
- (12) 大森:「ファジィ推論による実時間手書き漢字認識」, 同上(D-II), **J72-D-II**, 369 (平元-3)
- (13) D. E. Rumelhart: Parallel Distributed Processing (1986) The MIT Press
- (14) 内藤・小森・淀川:「手書き漢字認識のためのストローク密度特徴」, 信学論(D), **J64-D**, 757 (昭56-8)

渡 辺 成 (非会員)

平成4年3月名古屋大学工学部卒業。
現在, 同大学大学院工学研究科博士課程
前期課程に在学中。ファジィ・ニューロ
によるサイン認識に関する研究に従事。

古 橋 武 (正員)

昭和60年3月名古屋大学大学院博士課程修了。同大学工学部助手, 平成2年12月同助教授, 現在に至る。工学博士。主として, 制御システム・エキスパートシステムにおける知識獲得技術の確立を目指して, ファジィニューラルネットワークによる知識獲得, ファジィ推論による知識獲得に関する研究に従事。

内 川 嘉 樹(正員)

昭和44年名古屋大学大学院博士課程満了。60年同大学工学部教授, 現在に至る。工学博士。主として, ニューラルネットワーク, ファジィ理論, 遺伝アルゴリズムなどを利用したシステム技術の基礎および産業への応用に関する研究を行っている。61年日本電子顕微鏡学会論文賞受賞。応用物理学会東海支部長。