ファジィネットによるオフラインサイン認識

非会員 渡辺 成 (名古屋大)
 正員 古橋 武 (名古屋大)
 非会員 小幡 賢三 (日本電装株式会社)
 正員 内川 嘉樹 (名古屋大)

An Off-Line Signature Recognition Using a Fuzzy Net

Shigeru Watanabe, Non-member, Takeshi Furuhashi, Member (Nagoya University),
 Kenzo Obata, Non-member (Nippondenso Co., Ltd.), Yoshiki Uchikawa, Member (Nagoya University)

This paper presents a method of off-line signature recognition using feature strokes and a fuzzy net. For getting feature strokes a pre-processing of signature data is studied. The pre-processing consists of a thinning method and a method of extracting feature strokes from an original signature and corresponding strokes from new signatures. The structure of fuzzy net is a simple perceptron and each unit in the input layer has a fuzzy membership function. From the connection weights of the trained network, it is easy to know which features of input data are important for signature recognition, i.e. the personal characteristics of the signatures are known from the fuzzy net. An experiment is done to show the feasibility of the new method.

キーワード：サイン認識, ファジィネット, ニューラルネット

1. はじめに

筆者らは、サインの照合システムの構築を目指して研究を進めている[1][2]。サインの自動照合システムはセキュリティシステムを中心に潜在的なニーズが高まっている。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することができれば、認識性能を向上させる手法を検討することができるのみならず、認識システムの処理効率の向上を計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。

一方、手書き文字を認識する手法に関する研究が盛んになされている。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[3][4]。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[5]。しかし、従来の研究では、個人性特徴を我々に判りやすい形で自動抽出する手法は示されていなかった。

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。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[6]~[9]。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、文字のどの特徴が捉えられているのか解析することが困難である。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。

手書き文字の筆者による変形をファジィデータとして捉え、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[10]。

筆者らは、これまでに学習後の結合荷重からサインの個人性特徴を抽出できるファジィネットを提案してきた[1][2]。ファジィネット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ーシップ関数を内部関数に持つ。このメンバー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、サインのような入力データのぶれ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。このファジィネットを用いて文献[1]ではオンラインのサインデータのもつ個人性特徴を周波数領域における特徴として抽出する手法を提案した。また、文献[2]ではオフラインのサインデータのもつ個人性

特徴をストローク密度特徴から抽出する手法を提案した。しかし、ストローク密度特徴は人間がサインを認識する際に注目していると予想される特徴とは、ずれが大きいという問題があった。

本論文では、オフラインのサインデータから自然な個人性特徴を自動抽出する新しい手法を提案する。本手法では、データの前処理として、線分における長さ・傾き・曲がりなどから特徴線分を選び出し、これらの特徴データをファジィネットに入力することにより、サインの個人性特徴を抽出するものである。実験を行い、本手法がサインの個人性特徴抽出に有効であることを示す。

2. 前処理

サインデータの前処理は、抽出される個人性特徴、認識率などの優劣を決定する。本稿では、自然な個人性特徴の抽出を目指して、サインデータの前処理の基礎的検討を行う。

図1 細線化手法

図 1: Thinning method

<2.1> 細線化 スキャナーで取り込まれたオフラインのサインデータは、1,0(点がある、ない)の画素情報であり、ここから細線化により線分情報を抽出する。本稿では簡単のために左から右、上から下にサインの画像データを走査した際に生じるサインの影を細線化情報として抽出する(図1)。ただし、得られる線分が幅1ドットとなるように影をつける。この様子を図2に示す。この手法は簡単であるために計算時間が少なくすむ。また、サインの個人性特徴をほぼ保持していることから、自然な個人性特徴抽出の基礎的検討には十分と考えられる。ただし、かすれたサインデータやにじんでばやけたサインデータからは正確な細線化は困難であるので、検討が必要であることを付言しておく。図3(a),(b)はそれぞれスキャナーで取り込まれたサイン、細線化されたサインの例を示す。細線化して得られた画素データから図2(a)のような端点判別用のスリットを利用して端点を探し(図3(c)の■印)、端点から端点までを一つの線分とする。ただし、端点の探索は左から右へと行い、線分の2つの端点のうち左側の端点の位置のx座標の

図2 線分データ

図 2: Stroke data

図3 線分データの抽出例

図 3: An example of extracting stroke data

降順に線分データをシステムに取り込んでいくこととする。本手法では、細線化処理が線分分割として機能し、端点抽出もスムーズに行うことができる。得られた線分データは、サインのぶれにより毎回少しずつ異なることが予想されるが、このぶれは後述のように、ファジィネットの学習時にデータを正規乱数であることおよびファジィネットによる入力空間のファジィ分割により吸収できると期待している。

<2.2> 線分データ さて、サイン認識は、現状、人間によって行われている。サイン認識に際して人間はどのような特徴に注目しているのだろうか。本論文では、前節の細線化によって得られた線分データから極力自然な次の要素を取り出し、人間が注目しているであろうサインの特徴抽出を目指す。

図4 曲がり

図 4: Curve

1. 重心位置 (X_c, Y_c)
2. 長さ (L)
3. 曲がり (S_{top}, S_{bottom})
4. 傾き (θ)

ここで曲がりは図4(a)に示すように線分の各端点を結ぶ直線 l と線分データが囲む面積 S_{top}, S_{bottom} により定義する。また、傾き θ は線分 l と水平線とのなす角度である。得られたデータを以下の手法により正規化する。重心の位置 X_c, Y_c はそれぞれ細線化して得られたサインの左右・上下の幅(図5(c) $X_{left} \sim X_{right}, Y_{top} \sim Y_{bottom}$)で正規化し、長さ L は細線化後のサインから得られたすべての線分のなかで最も長い線分の長さ(L_{max})で正規化して、それぞれ $\hat{X}_c, \hat{Y}_c, \hat{L}$ と表す。また、曲がりは線分 l の一部 a を斜辺にもつ直角二等辺三角形(図4(b))の面積 $S_{triangle}$ で正規化し、 $\hat{S}_{top}, \hat{S}_{bottom}$ とする。このようにして得られた曲がりのデータは、その線分がどのくらい鋭く曲がっているかを表す。傾きは $-\pi/2 \sim \pi/2$ で正規化し、 $\hat{\theta}$ と表す。以上の処理により、1つの線分データから $(\hat{X}_c, \hat{Y}_c, \hat{L}, \hat{S}_{top}, \hat{S}_{bottom}, \hat{\theta})$ の6つのパラメータを得ることができる。

<2.3> 特徴線分 一つのサインデータから多くの線分データが得られる。これら全てをサイン照合に用いれば高い正答率を実現できると期待される。しかし、多くのデータを用いることは、ファジィネットの規模を大きくし、大きなメモリ容量を必要とする。本論文では基礎検討として、長さもしくは曲がりの大きな線分データを選び出して特徴線分とし、これらの線分から個性特徴の抽出を行う。

正例(本人が書いたサイン)の1つを基本サインとし、そこから特徴線分を選び出した結果を図5(a)に示す。なお、特徴線分を選ぶ基準は次のようにしている。

1. $\hat{L} \geq 0.6$
2. $\hat{L} \geq 0.3 \cap (\hat{S}_{top} \geq 0.6 \cup \hat{S}_{bottom} \geq 0.6)$
3. $\hat{L} \geq 0.3 \cap (\hat{S}_{top} \geq 0.3 \cap \hat{S}_{bottom} \geq 0.3)$

上記の基準により図5(a)の例では10個の線分が選ばれている。先に述べたように左から右に線分を探索しているの左から順に番号がついている。

特徴線分はサインデータごとに少しずつ異なり、他のサ

Watanabe

(a)正例 (基本サイン)

Watanabe

(b)正例

Watanabe

(c)負例

図5 特徴線分

図 5: Feature strokes

インデータから基本サインと同じ位置の特徴線分が選ばれるとは限らない。そこで他の正例サインや負例サイン(他人が書いたサイン)からは基本サインで選ばれた各特徴線分に対して式(2)の値 Δ を最小にする線分をそのサインの特徴線分として選び出す。

$$\Delta = |\hat{X}_c - \hat{X}'_c| + |\hat{Y}_c - \hat{Y}'_c| + |\hat{L} - \hat{L}'| + |\hat{S}_{top} - \hat{S}'_{top}| + |\hat{S}_{bottom} - \hat{S}'_{bottom}| + |\hat{\theta} - \hat{\theta}'| \quad (2)$$

ここで基本サインの各パラメータをそれぞれ $\hat{X}_c, \hat{Y}_c, \hat{L}, \hat{S}_{top}, \hat{S}_{bottom}, \hat{\theta}$ として、その他のサイン(正例・負例)の各パラメータを $\hat{X}'_c, \hat{Y}'_c, \hat{L}', \hat{S}'_{top}, \hat{S}'_{bottom}, \hat{\theta}'$ とした。(2)式には線分データの重心位置に関する項があり、選ばれた線分の相対位置は基本サインとおおよそ同じになっている。さらに、線分間の相対位置を考慮して該当するものがその位置に見当たらない場合はその線分に対応するデータはないとしてすべて0.0とする。結果を図5(b),(c)に示す。(b)は他の正例サインで、(c)は負例サインを示す。

3. ファジィネット

図6は本論文で用いるファジィネットの構成を示す。各入力ユニットは三角形のメンバーシップ関数を内部関数に持つ。図6の例ではSmall, Medium, Bigの3つのメンバーシップ関数を用いられている。メンバーシップ関数の詳細を図7に示す。ネットの入力 $I_1 \sim I_n$ は図5(a),(b),(c),(d)に示したサインの各特徴線分のパラメータのうち長さ・曲がり・傾き $(\hat{L}, \hat{S}_{top}, \hat{S}_{bottom}, \hat{\theta})$ を用いる。

本論文の例では $n = 4(\text{パラメータ}) \times 10(\text{特徴線分})$ である。各線分のパラメータをSmall, Medium, Bigのメンバ

図6 ファジィネット

図 6: Fuzzy Net

図7 メンバシップ関数

図 7: Membership functions

シップ関数の入力とし、それぞれのグレード値に結合荷重 w_{ij} ($i = 1 \sim n, j = 1, 2, 3$) を掛け、出力ユニットの入力としている。出力ユニットは (3) 式で表されるシグモイド関数 f を内部関数に持つ。

$$f(s) = \frac{1}{1 + e^{-s}} \quad (3)$$

ただし、 s は出力ユニットの入力の総和である。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ュホルドの働きをする。この関数の値がファジィネットの出力値になる。ネットの教師信号は入力のサインデータが本物 (正例) であれば 1、偽物 (負例) であれば 0 を与える。結合荷重 w_{ij} は (4) 式に示すデルタルールにより更新する。

$$\left. \begin{aligned} \Delta w_{ij}(t) &= \eta(y - o)f'(s)o_{ij} + \alpha\Delta w_{ij}(t-1) \\ w_{ij}(t) &= w_{ij}(t-1) + \Delta w_{ij}(t) \end{aligned} \right\} \quad (4)$$

ここで、 Δw_{ij} は結合荷重の変更量、 y は教師信号、 o はネットの出力、 f' はシグモイド関数の導関数、 o_{ij} は入力層の第 ij 番目のユニットの出力、 η は学習率、 α は慣性係数を示す。

なお、本ファジィネットは基本的には単純パーセプトロンの構成をしている。したがって、 N 個の結合荷重を決定するには N 個の互いに独立なデータがあればよい。しかし、本研究ではサインの持つ個性特徴の抽出を目的としているので、できるだけ多くの正・負例データをファジィネット

に提示することで、その個性特徴が学習により獲得されることを期待している。そこで、上記のようなデルタルールにより結合荷重を更新することにする。

入力ユニットが Small, Medium, Big の 3 つのメンバシップ関数を持つのは、サインの個性特徴が長さ・曲がり・傾きの中大小いずれにあるのかを抽出するためである。ネットワークの学習後の結合荷重において、ある線分の長さ $\hat{L}$ の Big のメンバシップ関数に対する結合荷重 w が大きい場合には、その線分の長いことがサインの正例の特徴としてとらえられていることを意味し、Medium のメンバシップ関数に対する結合荷重 w が大きければ線分の長さが中くらいであることが正例の特徴であることを意味する。入力ユニットのメンバシップ関数の種類数を増やせば、より詳細な個性情報を抽出できるが、本人のサインであつても毎回少しずつ異なることを考えれば 3 つ程度が妥当と思われる。ただし、今後詳細に検討していきたい。

4. 実験と検討

本ファジィネットによりサインの個性特徴の抽出実験を行った。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。そして、他の 13 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いてもらうことにした。図 8 は正例及び負例の例を示す。

得られたサインは正例として 11 例、負例として 89 例であった。正例のうち 3 例、負例のうち 10 例の計 13 例を学習用に残り 87 例を評価用とした。正例 3 例のうち 1 例を基本サインとして細線化し、線分データを得る。その各線分からパラメータ $\hat{X}_c, \hat{Y}_c, \hat{L}, \hat{S}_{top}, \hat{S}_{bottom}, \hat{\theta}$ を取り出す。各パラメータのうち長さ $\hat{L}$ と曲がり $\hat{S}_{top}, \hat{S}_{bottom}$ に注目して特徴線分を抽出する。今回は “Watanabe” というサインに対して 10 個の線分を抽出した。他の正例サインや負例サインは前述の方法により、基本サインの各線分に対応する線分を抽出して、それらから各パラメータを得た。正例データ 11 例のうち、1 例において特徴線分として抽出された線分データが基本サインのそれらと少しずつ違ってしまっていたが、それは評価用データとした。正例 3 例、負例 10 例の学習データはさらに正規分布に従う乱数を用いて各パラメータをふ

図9 結合荷重

図 9: Connection Weights

図8 サインの正例と負例

図 8: True and False Signatures

り、正例データ (57 個)、負例データ (49 個) を作成し、ファジィネットの学習用に用いた。ただし、乱数の標準偏差を正例では規格幅の 10%、負例では同 50% とした。また単なる乱数も負例データ (7 例) として作成した。総計 126 個のデータをファジィネットに学習させた。学習データは前述のように結合荷重の数により多ければ多い程よいが、ここでは簡単のために結合荷重 120 個より少し多い数とした。なお、オリジナルの正例を 3 個に限定したのは、実運用に際して登録サインの数は少ない方が好ましいと思われるからである。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全て 0 付近として学習を開始した。学習は正負の 126 例の出力誤差の 2 乗和が 0.05 以下になった時点で終了した。この時点で学習データの出力は正例で 0.95 以上、負例で 0.25 以下となった。

学習後のネットワークに評価用のサインを入力して認識をする際に、ファジィネットの出力が 0.8 以上のものを正例、0.5 以下のものを負例、0.5 ~ 0.8 のものを判定不能と設定した。その結果、正例サインは 8 例のうち、4 例が正例、1 例が負例、3 例が判定不能となった。一方負例サインは 76 例が負例、3 例が判定不能となった。正例判定には厳しい結果となったが、サイン照合の正答率の向上には、特徴線分の数を 10 個からもっと増やすこと、ファジィ分割数の検討

図10 個人性特徴

図 10: Personal characteristics

及びメンバーシップ関数のチューニング等が挙げられる。

図 9 は (a) 長さ $\hat{L}$, (b) 曲がり $\hat{S}_{bottom}$, (c) 曲がり $\hat{S}_{top}$, (d) 傾き $\hat{\theta}$ に対する学習後の結合荷重を示す。縦軸は結合荷重の大きさである。それぞれ、上段が Small のメンバーシップ関数の結合荷重であり、中段が Medium の、下段が Big のメンバーシップ関数のそれである。また、それぞれについて荷重の最大値の 70% のレベルを破線で示してある。このレベルより大きな結合荷重をもつ入力をサインの個人性を表す代表的パラメータとして捉えてみる。その特徴パラメータを図 10 に示す。図 10(a) が正例、図 10(b) が負例である。各特徴は長さ $L(\square)$ 、曲がり $S_{top}, S_{bottom}(\triangle, \nabla)$ 、傾き $\theta(\diamond)$ を区別して示してある。例えば図 10 では “e” の下の部分が中くらいであることが正例の特徴として抽出されていることがわかる。また、“b” の下の部分の曲がりの鋭いことが抽出されていることも示している。また、これらの特徴はサインにおいてバランスよくそろっていることに意味があり、いくつかの特徴が一致していても正例のサインとはなり得ない。

5. まとめ

本研究では、オフラインのサインデータから自然な個人性特徴を自動抽出する手法を提案した。サインデータから線分データを抽出する前処理の手法を検討し、実験を行っ

て本手法により個人性特徴の抽出が可能であることを示した。

今回は、線分パラメータとして長さ・曲がり・傾きのデータを用いて実験を行ったが、今後は線分間の関係(相対位置・相対角度)などを考慮してより詳細な検討を進めていく予定である。また、特徴線分の抽出法についても、対応する線分を安定して抽出できる方法を検討していきたい。

文 献

- (1) 渡辺, 古橋, 内川: “ファジィネットによるサイン認識の基礎的研究”, 第8回ファジィシステムシンポジウム講演論文集 pp. 173 - 176(1992).
- (2) 渡辺, 古橋, 内川: “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”, 電気学会論文誌, 113-C, 7, pp. 543 - 548(1993).
- (3) 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, 4, pp. 480 - 487(1984).
- (4) 尺長, 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-”, 信学論(D), J67-D, 4, pp. 488 - 495(1984).
- (5) 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, pp. 9 - 16(1991).
- (6) 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”, 信学論(D-II), J73-D-II, 6, pp. 840 - 847(1990).
- (7) 岩田, 他: “大規模4層ニューラルネット(Comb NET)”, 信学論(D-II), J73-D-II, 8, pp. 1261 - 1267(1990).
- (8) 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”, 信学論(D-II), J73-D-II, 8, pp. 1275 - 1280(1990).
- (9) 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”, 信学論(D-II), J74-D-II, 2, pp. 158 - 165(1991).
- (10) 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”, 信学論(D-II), J74-D-II, 2, pp. 166 - 174(1991).

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率を目指して, 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。

小幡 賢三 (非会員) 昭和55年3月明治大学工学部電気工学科卒業。同年、松下電器産業株式会社入社。以来情報機器、音響機器の開発に従事。現在、日本電装株式会社にて、情報機器の開発に従事。電子情報通信学会、日本音響学会、各会員。

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, ファジィ推論, 遺伝的アルゴリズムなどを利用したシステム技術の基礎及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。