

単純再帰結合型ネットワークを用いた テンプレートマッチング方式による 文字認識ニューラルネットワーク

篠 沢 佳 久^{†1}

本論文においては、オフライン手書き文字画像を対象としたテンプレートマッチング方式によるニューラルネットワークの改良を試みる。筆者らはテンプレートマッチング方式による文字画像の認識をニューラルネットワークによって行う手法を提案してきた。これは入力層にテンプレートの文字パターンと未知文字パターンを入力し、同じ文字種であれば発火し、異なった文字種であれば発火しないように動作をするニューラルネットワークを用いて実現している。本論文においては、認識率の向上を図るためテンプレートと未知文字パターンの2つの画像の全領域間におけるマッチングではなく、文字画像の局所領域における構造や特徴に考慮し、局所領域間ごとの類似性から認識結果を求める手法を提案する。これは、テンプレートと未知文字パターンを局所的な領域に分割し、対応する領域間ごとでマッチングを行い、それぞれの領域間ごとの類似性から認識結果を求めることが可能なニューラルネットワークを単純再帰結合型ネットワークを用いて構築し、その学習方法を提案する。そして産業技術総合研究所提供の文字画像データベース ETL9B、3,036 字種を対象としたニューラルネットワークを構築した結果、認識率の向上を示すことができた。

Neural Networks which Consist of Simple Recurrent Networks for Character Recognition by Template Matching

YOSHIHISA SHINOZAWA^{†1}

Neural networks which recognize offline handwritten characters based on template matching have been proposed. A character pattern can be recognized with neural networks which activate as follows. In recognition, a template pattern and an unknown pattern are input into the input layers of a neural network at same time. When two patterns are same kind, an output unit is fired, but when these are different, it is not fired. We improve neural networks based on tem-

plate matching between all the regions of a template pattern and an unknown pattern. We propose simple recurrent networks which recognize character patterns with similarities between partial regions of a template pattern and an unknown pattern. A template pattern and an unknown pattern are divided into some partial regions and each partial region is input into simple recurrent networks. Simple recurrent networks calculate similarities between partial regions of two patterns and recognize the unknown pattern. We propose how to learn simple recurrent networks and construct neural networks for ETL9B. The results obtained from our experiments show an increased recognition rate of character patterns.

1. ま え が き

手書き文字認識の研究は古くから行われており、今日に至るまでさまざまな認識方法が考案されている。字体が書き手によって異なり、筆順情報を利用できないオフライン手書き文字認識の研究はパターン認識の分野において最も困難な課題の1つである。日本で使用されている文字、特に漢字は偏や旁などの部首と非部首から構成されているものが多数ある。そのため「休」と「体」もしくは「明」と「暗」といった例のように任意の部首と非部首の構成がその文字の特徴となっており、その構成要素の組合せの相違が文字画像を認識するうえで有効な場合もある。そこで文字画像から1画1画（ストロークと呼ぶ）を抽出した後、ストロークの位置情報や接続情報を用い、局所的に特徴となりうる部首や非部首を抽出し、その形状や構成要素から文字画像を認識する手法（ストローク構造解析法）の研究がされてきた¹⁾。しかしオフライン文字画像からストローク1画1画を厳密に抽出することは困難であるため、ストローク構造解析法は主としてオンライン文字認識において適用され、オフライン文字認識においては文字画像全体から文字固有の特徴を抽出し、その特徴を認識に利用する研究（パターン整合法）が主流となっている²⁾。

文字画像認識の代表的な手法の1つとしてテンプレートマッチング方式³⁾があげられる。これは、まず認識対象となる文字種において、標準となるべき文字画像（テンプレートと呼ぶ）から任意の特徴をあらかじめ抽出しておく。そして認識したい文字画像（未知文字パターンと呼ぶ）からも同様に特徴を抽出し、あらかじめテンプレートから抽出しておいた特徴との距離（もしくは類似度）を求める。そしてすべてのテンプレートとの距離を求めた

^{†1} 慶應義塾大学理工学部管理工学科

Faculty of Science and Technology, Keio University

後、最も距離の短いものを認識結果とする総当たり方式である。この方式では日本語のように認識対象となる文字種が多い場合、全字種との距離を求める必要があるため、多くの計算量を必要とする。そのため**大分類・詳細認識**の手法が利用されてきた。

大分類・詳細認識とは、まずはじめに認識したい未知文字パターンに対しておおまかに分類を行い、文字候補の数を絞り込む（**大分類**）。そして次に大分類によって絞り込まれた文字候補の中からさらに詳細な認識を行い、最終的に候補を1つに絞り込む（**詳細認識**）という2段階による認識方法である。大分類においては計算量が少なく済むように簡単な（特徴数の少ない）特徴およびユークリッド距離のような識別関数を使用し、一方で詳細認識においては大分類で使用したものよりも複雑な特徴およびより精度の高い識別関数を使用する。

その他の手法としてニューラルネットワークを用いた認識^{4)–5)}も多く考案されている。ニューラルネットワークを利用した場合、学習用の事例（学習文字パターンと呼ぶ）を適切に提示することにより、異なった文字種のカテゴリを厳密に分類できる識別関数を生成できるためである。しかしこれは比較的、少ない文字種を認識対象とした小さな規模の場合であり、認識対象となる文字種が増加するにつれてニューラルネットワークの規模も大きくする必要があり、学習が困難になるという問題が生じてしまう。そのため単一のニューラルネットワークで数千種類の文字種を認識対象とするのは困難である。そこで大分類・詳細認識の手法を導入し、大分類もしくは詳細認識において機能的に異なるニューラルネットワークを利用することで上記の問題を解決している^{6)–11)}。これは大分類によって複数の文字種が属しているカテゴリに候補を絞り込んだ後、詳細認識においては各カテゴリ内の文字種を認識対象としたニューラルネットワークを構築する方法^{6)–8)}や詳細認識においてはニューラルネットワークでの認識対象を1字種のみとする方法^{9)–10)}、さらには2つの文字種を判別（二者択一）するニューラルネットワークを利用する方法¹¹⁾などさまざまな手法が提案されている。

一方で、筆者らはテンプレートマッチング方式による認識をニューラルネットワークで実現する手法を提案してきた¹²⁾。これは、テンプレートとなる文字種と認識したい未知文字パターンの特徴をニューラルネットワークに同時に入力したとき、この2つの文字パターンが同字種である場合は出力層が発火し、異なる場合は発火しないような動作をするニューラルネットワークを構築することで実現している。すなわち、上記のような動作をするニューラルネットワークを文字種分用意することによって、各ニューラルネットワークは対応した文字種のテンプレートとして動作することになる。

また文字パターンの構造をニューラルネットワークの構造に反映させ、効果的に学習を行うことによって認識率を向上させようとする試みもある¹³⁾。これは出力層に漢字の部首と非部首を対象としたニューロンを配置し、ある任意の部首を対象とした出力層のニューロンに対しては、中間層そして入力層へとつながる結合を制限し、ネットワークの内部結合を局所結合化することによって、文字の構造上の特徴を利用し、効果的に学習しようとする試みである。このように漢字は局所的な領域において構造的な特徴があり、局所領域ごとの特徴を利用することによって認識率の向上が期待できる¹⁴⁾。

そこで本論文においては、上述したニューラルネットワークを用いたテンプレートマッチング方式による認識方法を改良し、テンプレートと未知文字パターンの2つの画像の全領域間におけるマッチングではなく、局所領域間ごとの類似性から認識結果を求める手法を提案する。これは文字画像の局所領域における構造や特徴に考慮するため、テンプレートと未知文字パターンを局所的な領域に分割し、対応する領域間ごとでマッチングを行い、それぞれの領域間ごとの類似性から認識結果を求めることが可能なニューラルネットワークを単純再帰結合型ネットワークを用いて構築することで実現する。このようにマッチングする領域を局所的な範囲とすることによって、より精度の高い識別関数を構築でき、認識率の向上も期待される。そして産業技術総合研究所提供の文字画像データベース ETL9B、3,036 字種を対象とした認識実験を通してその有効性を評価する。

2. 提案モデルの構造

2.1 テンプレートマッチング方式の導入

ニューラルネットワーク（以下ネットワークと略す）を用いたテンプレートマッチング方式による文字パターンの認識方法について説明する¹²⁾。認識対象の文字種が N 個の場合、 N 個のネットワークを用意し、各ネットワークと任意の1字種とを対応づける。すなわち任意のネットワークはあらかじめ定められた1字種のみを認識を行う。図1に例として、「あ」を認識対象としたネットワークの構造を示す。

図1に示すようにネットワークの構造は、入力層、中間層、出力層の3層から構成される階層型のフィードフォワード構造とする。出力層のニューロンの個数は1個、中間層のニューロンの個数は任意とする。入力層には、そのネットワークで処理する文字種のテンプレートとなる文字パターン（図1の場合は「あ」である）から抽出した特徴と認識すべき未知文字パターンから抽出した特徴を同時に入力する。入力層において、テンプレートの文字パターンの特徴を入力する部分を比較対象部、未知文字パターンの特徴を入力する部分を




図 1 ネットワークの構造
Fig. 1 Structure of neural networks.

認識対象部と呼ぶ。したがって、入力層のニューロン数は2つの文字パターンの特徴数分必要となる。

そして認識対象部に入力した未知文字パターンがテンプレートと同じ文字種である場合は、出力層が発火し（図1左図）、異なった文字種である場合は、発火しない（図1右図）ようにネットワークを動作させる。すなわち文字種 i ($i = 1, 2, \dots, N$) を認識対象とするネットワークにおいては、文字種 i のテンプレートの特徴ベクトル T_i と未知文字パターンの特徴ベクトル x を入力した場合、 T_i と x が同じ文字種の場合は発火し、異なった文字種の場合は発火しないように教師信号 t_i を与え、ネットワーク内の結合係数を調整（学習）し、式 (1) のような動作をする識別関数 F_i を構築する。

$$F_i(T_i, x) = \begin{cases} 1.0 & \dots x \in i \\ 0.0 & \dots x \notin i \end{cases} \quad (1)$$

未知文字パターンを認識する場合、図2に示すように各文字種ごとに上記のような動作をするように学習したネットワークを N 個用意する（図2には「あ」「い」…「お」を認識対象としたネットワークを示している）。各ネットワークにおいて、対応した文字種のテンプレートと未知文字パターンの特徴を入力層に入力し、同時に N 個のネットワークを動作させる。そして出力層の発火が最も大きなネットワークで対象としている文字種を認識結果とする。手書き文字においては、書き手によって字体が多様である。そのため同一文字種に対して複数の字体の異なる文字パターンをテンプレートとして利用し、学習させるこ




図 2 テンプレートマッチング方式によるニューラルネットワークでの認識
Fig. 2 Recognition of character patterns with neural networks.




図 3 文字パターンのブロックへの分割
Fig. 3 Division of a character pattern into partial regions.

とによって字体の異なる文字パターンにも対応可能となり、認識率の向上が期待できる。

2.2 部分領域ごとのマッチング方式への拡張

1章で述べたように漢字は偏や旁などから構成されており、文字の構造や構成要素の組合せ、すなわち局所的な領域内における特徴に着目した認識を行うことによって認識率の向上が期待される。そこで本論文においては、前節で述べたニューラルネットワークによるテンプレートマッチング方式を拡張し、テンプレートの文字パターンと未知文字パターンの全領域をマッチングさせるのではなく、局所領域における特徴に考慮するためテンプレートと未知文字パターンを局所的な領域に分割し、対応する領域間ごとにマッチングを行い、それぞれの領域間ごとの類似性から認識結果を求める手法を提案する。

図3に示すように文字パターン x を任意の大きさの局所的な領域（ブロックと呼ぶ）

$\{x_1, x_2, \dots, x_d\}$ に分割する (分割数 d). ここでのブロックは文字 (特に漢字) の偏や旁に該当するものと考え微小領域ではなく, ある程度の大きさを持つものとする (図 3 の場合, 分割数 d は 4 とし, その大きさは文字パターンの半分としている).

テンプレートの文字パターン T_i と未知文字パターン x においても, それぞれを同じ分割方法でブロック $\{T_{i1}, T_{i2}, \dots, T_{id}\}$, $\{x_1, x_2, \dots, x_d\}$ に分割し, 各ブロック T_{ij} と x_j ($j = 1, 2, \dots, d$) との類似性から認識結果を求めることができるように下記の 2 点から前節で述べたネットワークの改良を試みる.

(1) 出力層のニューロンの増加

(2) ネットワークの内部結合の再帰結合化

まず (1) 出力層のニューロンの増加から説明する. 2.1 節で説明したネットワークの場合, 文字種 i を対象としたネットワークにおいては文字パターンの全領域 T_i と x を入力していたが, 提案モデルにおいては位置的に対応したブロックを組合せ, $(T_{i1}, x_1), (T_{i2}, x_2), \dots, (T_{id}, x_d)$ という順番でネットワークに入力する. これは, テンプレートの文字パターンのブロック T_{ij} を入力層中の比較対象部に, 未知文字パターンのブロック x_j を認識対象部に入力し, 局所領域 T_{ij} と x_j との類似性を求めるためである. そして 2.1 節のネットワークと同様に出力層のニューロンを 1 個とした構造とする場合, 2 つのブロック T_{ij} と x_j が同じ文字種 i の同一の構成要素であるときは出力層のニューロンが発火し, それ以外の場合は発火しないように動作をするネットワークを構築することになる (式 (2)).

$$F_i(T_{ij}, x_j) = \begin{cases} 1.0 & \dots x_j \text{ が文字種 } i \text{ の } j \text{ 番目のブロックの場合} \\ 0.0 & \dots \text{上記の条件以外の場合} \end{cases} \quad (2)$$

しかしこのネットワークを用いて出力層を発火させる学習を行う場合, 異なった d 個のブロックの組合せの入力に対して, 出力層のニューロンをいずれも発火するように処理しなければならないため, ネットワークの学習が困難となる. 出力層のニューロンを 1 個の構造としたまま用いる場合であれば, 1 字種につき分割数 d 個分のネットワークを用意し, 各ネットワークについては文字種 i の j 番目のブロックと対応づけ, ブロック T_{ij} の認識処理を行うことができるようにすればよい. しかしこの場合, $N \times d$ 個のネットワークの学習が必要となる.

そこで本論文においては, 上記の問題を単一のネットワークで解決するため, 出力層については, 分割数 d 個分のニューロンを用意し, j 番目のニューロンは j 番目に入力する 2 つ




図 4 ネットワークへの各ブロックの入力

Fig. 4 Input of divided partial regions to neural networks.

のブロック T_{ij} と x_j との類似性を処理するものに対応づける (図 4 には「暗」を認識対象としたネットワークの構造と動作を示す. 図 4 中の上図は未知文字パターンとして「暗」を, 下図は「明」を入力した場合のネットワークの動作状況を示している).

すなわち図 4 の上図に示すように, 文字種 i を対象としたネットワークにおいて, テンプレート T_i と未知文字 x のブロックを組み合わせ, $(T_{i1}, x_1), \dots, (T_{id}, x_d)$ という順番でネットワークに入力する. そして j 番目に入力するブロック T_{ij} と x_j が文字種 i の同一の構成要素である場合は, 出力層の j 番目のニューロンのみを発火させ, それ以外は発火させないように教師信号 t_{ij} を与え, ネットワークを学習する. 一方で図 4 の下図に示すように, テンプレートと異なる文字種のブロックを入力している場合は, 出力層のいずれのニューロンも発火させない (式 (3)).

$$F_i(T_{ij}, x_j) = \begin{cases} \underbrace{(0, \dots, 0, 1, 0, \dots, 0)^t}_{j-1} \cdots x \in i \\ \underbrace{(0, \dots, 0, 0, 0, \dots, 0)^t}_{d-j-1} \cdots x \notin i \end{cases} \quad (3)$$

このような構造とすることによって、前節のネットワークと比較して、入力層のニューロン数の削減につながり、複数の異なった特徴を併合した場合においても、入力層は一定の個数で済む。

2.3 ネットワークの再帰結合化

次に(2)ニューラルネットワークの内部結合の再帰結合化について説明する。図4のネットワークの場合、各ブロックの入力情報を独立して学習している。すなわちテンプレートの文字パターンを構成するブロックと同一かどうかを学習しているだけであり、 $\{x_1, x_2, \dots, x_d\}$ が同じ文字の構成要素であることを学習していない。たとえばテンプレート T_i とテンプレートと異なる文字種 x の学習において、 j 番目のブロックが同じ形状である場合、すなわち (T_{ij}, x_j) は出力層を発火させるための入力 (T_{ij}, T'_{ij}) (T'_{ij} はテンプレートと同じ文字種 i の j 番目のブロック) と類似した入力となるが、出力層を抑制するように学習しなければならない。これは部分領域を対象とする提案手法においては、当然のことながら生じてしまう問題であり、これを解決するためには、その他の領域も含めて対象としなければならないという矛盾が生じてしまう。

そこでこの問題を解決するために、入力情報 (T_{ij}, x_j) から出力層の発火状況を学習するうえで、それ以前の入力情報 (T_{ik}, x_k) ($k = 1, 2, \dots, j-1$) を残しておき、利用することにする。過去に入力した情報をネットワーク内部に蓄積する方法の1つとして、ネットワークの再帰結合化(単純再帰結合型ネットワーク^{15),16)})があげられる。単純再帰結合型ネットワークにおいては、構造上、ネットワークへの入力を入力層と文脈層に分ける。入力層についてはこれまで述べてきたのと同様に外部入力を受けける一方で、文脈層については中間層と同数のニューロンを用意し、直前の中間層の値を文脈層へフィードバックさせる。この中間層から文脈層へのフィードバックにより過去に入力された情報が文脈層に蓄積されることになる。

そこで前述の問題を解決するため、提案モデルにおいても単一のネットワークの構造を再帰結合型とする(図5)。図5に示すように、ネットワークの入力部には入力層だけでなく、中間層と同数のニューロンを文脈層に配置する。各文字種ごとで、入力層はこれまでと同様にテンプレートと未知文字パターンの2つのブロックを入力し、文脈層については直前の




図5 ネットワークの再帰結合化

Fig. 5 Simple Recurrent Networks.




図6 提案するネットワークでの文字パターンの認識

Fig. 6 Recognition of character patterns with proposed neural networks.

中間層の状態をコピーし、式(3)と同様な動作をするようにネットワークを学習する。この文脈層へのコピーによって、以前の入力情報が蓄積されることになり、 x_j を学習するうえで x_1 から x_j は同じ文字種のブロックという情報が残ることになる。すなわち、このような構造とすることによって、上記の例であげた (T_{ij}, x_j) は (T_{ij}, T'_{ij}) と類似した入力ではあるが、文脈層の値を合わせると異なる入力情報となり、部分領域を対象としながら前述の問題を解決できるものと考えた。

未知文字パターンを認識する場合、学習済みの再帰結合型のネットワークを N 個用意する(図6)。そしてすべてのネットワークに各テンプレート T_i と未知文字パターン x のブ

ロック $(T_{i1}, x_1), (T_{i2}, x_2), \dots, (T_{id}, x_d)$ を順番に入力する. そのたびに中間層の値を文脈層にコピーしたうえで, 各ネットワークを動作させ, 出力層の発火状況 o_{ij} ($j = 1, 2, \dots, d$) を求めた後, 教師信号 t_{ij} との誤差自乗和 $\sum_{j=1}^d (o_{ij} - t_{ij})^2$ を求め, その値が最も小さいネットワークで対象としている文字種を認識結果とする. また以上のようなネットワーク構造とすることにより, 文字画像の切り出し処理において, 切り出す領域の対象をブロック単位とすることによって, 文字画像の切り出し処理と認識処理を行うことも期待できる¹⁷⁾.

3. 提案モデルの学習方法

3.1 抑制用パターンの選択方法

次に提案モデルの学習方法について述べる. 認識対象の文字種が N 個の場合において, 各ネットワークの学習を行う際, 発火用パターン (出力層を発火させる学習文字パターン) の対象はそのネットワークで処理する文字種 1 個であり, 抑制用パターン (出力層を抑制する学習文字パターン) の対象は残り $N - 1$ 個の文字種となる. しかし抑制用パターンとして $N - 1$ 個の文字種を学習で使用するのは, 学習に必要な計算量から考慮すると大きな問題となる. そこで, テンプレートの文字パターンと類似している (特徴空間上で位置的に近い関係にある) 文字パターンのみを抑制用パターンとして使用する¹⁰⁾. これは, テンプレートの文字パターンと類似している文字パターンとの識別面を適切に構築することができれば, 類似していない文字パターンとの区別がつくものと考えられるからである. そこでテンプレートと類似している文字種のみを選ぶために, あらかじめユークリッド距離などを用いて大分類を行っておく. そして大分類の結果からその上位候補に列挙された文字候補のみを抑制用パターンの対象として考慮する. たとえば平仮名の 71 文字を認識対象とし, 未知文字として「あ」を認識することを想定する. 文字パターン「あ」から任意の特徴を抽出し, ユークリッド距離によって認識を行った結果, 第 1 候補から順に『お あ う よ な』というような順番の認識結果になったとする. この結果から上位候補の「お」「う」「よ」「な」という文字パターンは「あ」と類似しているということから, 文字種「あ」を対象としたネットワークにおいてはこれらを抑制用パターンとして利用する.

3.2 学習方法

任意のネットワークにおいて発火用パターンを用いて学習する場合は, 図 7 に示すように (図 7 は「暗」を対象としたネットワーク), 入力層の比較対象部にはそのネットワークで対象としたテンプレートの文字パターンのブロックを, 認識対象部にもテンプレートと同じ文字種のブロックを順次入力し, 対応する出力層のニューロンのみを発火させるように学




図 7 提案するネットワークでの学習

Fig. 7 Learning of character patterns with proposed neural networks.

習する (図 7 左図). 一方で抑制用パターンを用いて学習する場合は, 認識対象部には大分類の結果から決めた抑制用パターンの文字種のブロックを入力し, 出力層のすべてのニューロンを発火させないようにネットワークの学習を行う (図 7 右図). 個々のネットワークの学習にはバックプロパゲーションアルゴリズム (誤差逆伝播アルゴリズム)¹⁸⁾を用いる. 下記にネットワークの学習アルゴリズムを示す.

抑制用パターンの決定

- (1) 学習文字パターンを用いて大分類を行い, 各文字種 i ($i = 0, 1, 2, \dots, N$) において第 P 候補までに出現する文字候補の集合 C_i (文字種 i は除く) を求める. 文字候補数を c_i 個とする. 文字種 i を認識対象としたネットワークにおいては, その抑制用パターンを C_i に属する文字パターンとする. N 個のネットワークに対して以下の (2) から (13) を繰り返す.

文字パターンのブロックへの分割

- (2) 文字種 i のテンプレート T_i と抑制用パターン $x \in C_i$ を d 個のブロック $\{T_{i1}, T_{i2}, \dots, T_{id}\}, \{x_1, x_2, \dots, x_d\}$ に分割する.

発火用パターンを用いた学習

- (3) 文字種 i を対象とするネットワークにおいて中間層のすべてのニューロンを初期化する (0 とする). $j = 0$ とする.

- (4) 入力層の比較対象部にテンプレートの文字パターンブロック T_{ij} , 認識対象部にテンプレートと同字種の文字パターンブロック T'_{ij} (発火用パターン) を入力する. 出力層の j 番目のニューロンのみを発火させ, 他のニューロンは発火しないように教師信号 t_{ij} を与える.
- (5) 中間層のニューロンの値を文脈層へとコピーする.
- (6) ネットワークを動作させ, 出力層のニューロンの発火状況 o_{ij} を求める. 教師信号と出力値の誤差自乗和 $\sum_{j=1}^d (t_{ij} - o_{ij})^2$ を計算し, 教師信号と同様な出力をするようにバックプロパゲーションアルゴリズムを用いて, ネットワーク内の結合係数を調整する.
- (7) $j = j + 1$ とし, j が分割数 d 以下であれば (4) へ戻る. そうでなければ $j = 0$ とし, (8) 以下の抑制用パターンを用いた学習を行う.

抑制用パターンを用いた学習

- (8) すべてのネットワークにおいて中間層を初期化する.
- (9) 入力層の比較対象部にテンプレートの文字パターンブロック T_{ij} , 認識対象部に抑制用パターン $x \in C_i$ のブロック x_j を入力する. 出力層のすべてのニューロンを発火しないように教師信号 t_{ij} を与える.
- (10) 中間層のニューロンの値を文脈層へとコピーする.
- (11) (6) と同様にネットワークを動作させ, 教師信号と同様な出力をするようにバックプロパゲーションアルゴリズムを用いて, 結合係数を調整する.
- (12) $j = j + 1$ とし, j が分割数 d 以下であれば (9) へ戻る. そうでなければ $j = 0$ とし, c_i 個の抑制用パターンの学習が終了するまで (8) から (12) を c_i 回繰り返す.
- (13) 誤差自乗和の総和が収束するまで (3) から (12) を繰り返す. 誤差自乗和が収束した場合は, 学習を停止し, (2) に戻り別の文字種を対象としたネットワークの学習を行う.

4. 認識実験

4.1 実験条件

提案モデルの有効性を評価するために認識実験を行う. 認識実験には産業技術総合研究所提供の文字画像データベース ETL9B, 3,036 字種を利用した. ニューラルネットワーク構築のため学習文字パターンとして 1 字種につき最初の 1 セット目の 40 パターンを利用し, 認識実験で利用する未知文字パターンとして 2 セット目の 40 パターンを利用した. すなわ

表 1 文字パターンの大分類の結果

Table 1 Classification rate with Euclidean distance.

候補数 P	学習文字	未知文字
第 1 候補	95.08%	92.47%
第 5 候補	99.14%	98.62%
第 10 候補	99.42%	99.07%

ちテンプレートの文字パターンおよび抑制用パターンとして 1 字種につき 40 パターンの学習文字を利用する.

それぞれの文字パターンについては, 前処理として 64×63 の大きさの原画像に対し, 非線形正規化処理¹⁹⁾ を施し 48×48 の大きさにした後, 196 次元 (大きさは 14×14) の輪郭線特徴²⁰⁾ を抽出した. そして抽出した特徴を利用して大分類を行い, 各文字種 i ごとに第 P 候補までに出現する文字種の頻度を調べた後, その集合 C_i を抑制用パターンの候補として決定し, ネットワークの学習に用いる. 大分類にはユークリッド距離を用いた. すなわち未知文字パターンの特徴ベクトル $x^t = (x_1, x_2, \dots, x_{196})$ と文字種 i のテンプレートの特徴ベクトル (この場合は 1 字種につき 40 個の学習文字パターンから抽出した特徴ベクトルの平均を用いる) $T_i^t = (a_{i1}, a_{i2}, \dots, a_{i196})$ としたとき, 2 つの文字パターン間のユークリッド距離 d_i は, 式 (4) のように求めることができる.

$$d_i = \sum_{j=1}^{196} (x_j - a_{ij})^2 \quad (4)$$

そこで抑制用パターンを決定するため, 抽出した特徴を用いてユークリッド距離による大分類を行った. その結果を表 1 に示す. 表 1 より, 学習文字パターンの第 10 候補までの分類率が 99.4% に達していることから, 抑制用パターンの対象を第 10 候補までに出現した文字種とした. そして候補数 $P = 10$ の場合, 1 字種につき抑制用パターンの個数は平均 97.3 文字であった.

ネットワークへ入力する局所領域については, 文字パターンから抽出した特徴を図 3 に示す位置情報のとおりに 4 つのブロックに分割し, これを利用する. 1 つのブロックの大きさは 112 (図 3 の左図のブロック (x_1, x_2) の大きさは 8×14 , 右図の場合 (x_3, x_4) は 14×8) とした. 各ネットワークの構造は以下のとおりである. 入力層のニューロンの個数は使用するブロックの特徴数が 112 なので 2 倍の 224 個となる. 1 字種につき 4 個のブロックを入力するため, 出力層は 4 個となる. 文脈層と中間層については 4.2 節で述べる. また

学習の高速化のため、中間層を等しく2つに分け、入力層の比較対象部と認識対象部をそれぞれ別々の中間層と結合させた構造（局所結合化¹³⁾）とした（局所結合化の影響については考察において述べる）。出力層と中間層、文脈層と中間層とは全結合のままである。ネットワークへの入力時において、入力層へ入力する2つのブロックの特徴と文脈層にコピーされる値（直前の中間層の値）については、それぞれの総和が1となるように入力値を正規化している。学習方法はモーメント法²¹⁾を使用した（モーメント係数は0.9）。学習時のパラメータの設定はすべての実験で同一とした。

4.2 提案モデルでの認識結果

前節で述べた実験条件のもとで提案モデルの学習を行った。提案モデルの有効性を評価するため、下記の条件で学習したネットワークとの比較を行う。

(1) 出力層のニューロンが1個のネットワーク

出力層のニューロン数をブロックの分割数 d 個としたときの影響を調べるため、出力層のニューロンが1個のネットワークの場合との比較を行う。この場合、2.2節で述べたように出力層以外は提案モデルの構造と同様であり、文字種 i のテンプレート $\mathbf{T}_i$ と学習文字 $\mathbf{x}$ において対応するブロックごとに組み合わせ、 $(\mathbf{T}_{i1}, \mathbf{x}_1), (\mathbf{T}_{i2}, \mathbf{x}_2), \dots, (\mathbf{T}_{id}, \mathbf{x}_d)$ という順番で入力する。そして文字種 i の j 番目のテンプレートのブロック $\mathbf{T}_{ij}$ を比較対象部に入力した際は、テンプレートと同じ文字種 i の j 番目のブロック $\mathbf{T}'_{ij}$ を認識対象部に入力したときのみ、出力層のニューロンを発火させ、それ以外の入力の場合は発火させないように学習を行う。

(2) 再帰結合化していないネットワーク

ネットワークの再帰結合化の影響を調べるため、中間層から文脈層へのフィードバックのないネットワークとの比較を行う。この場合、入力部には文脈層は存在しない。

(3) 抑制用パターンをランダムに学習した場合

抑制用パターンの候補に大分類の結果を利用する場合の影響を調べるため、大分類の結果を利用せず、学習ごとに残りの3,035字種からランダムに選択し学習対象とした場合と比較する。提案モデルにおいて文字種 i を対象としたネットワークを学習する場合、 c_i 個の抑制用パターンを利用していることから、条件を同じとするため、残り3,035字種の中からランダムに c_i 個の文字種を抑制用パターンとして選択し、学習に利用する。

上記の(1)から(3)の方法において、すべてのネットワークの中間層と文脈層のニューロン数を32個と固定し、学習回数（学習方法(3)から(12)の繰返し回数）を100回、200

表2 提案モデルにおける認識結果

Table 2 Recognition rate with proposed neural networks.

	学習回数	100 回	200 回	300 回
提案モデル	学習文字	99.39%	99.39%	99.40%
	未知文字	92.63%	92.62%	92.63%
(1) 出力層が1個の場合	学習文字	99.36%	99.37%	99.37%
	未知文字	90.65%	90.67%	90.60%
(2) 再帰結合なしの場合	学習文字	99.40%	99.40%	99.41%
	未知文字	92.03%	91.98%	91.98%
(3) ランダムに学習した場合	学習文字	98.71%	99.05%	99.18%
	未知文字	92.25%	92.77%	92.83%
ユークリッド距離	学習文字		95.08%	
	未知文字		92.47%	

回、300回と増やしていった場合の認識結果を表2に示す。認識時に入力層の比較対象部に入力するテンプレートとしては、学習時に利用した40個の学習文字パターンの中からランダムに1個を選択し入力している。表2には、各方法による学習文字パターンと未知文字パターンに対する認識率を示す。

表2より、ランダムな文字種を選択し、これを抑制用パターンの対象として学習した場合を除いて、いずれの方法においても学習回数が100回で認識率はほぼ一定となっている。また学習文字パターンに対しては、ユークリッド距離による結果と比較して、すべての方法において認識率の向上が見られる。しかし未知文字パターンに対しては、出力層が1個のネットワークの場合、学習回数が200回において認識率が90.67%と1.8%の低下が見られた。また再帰結合化していないネットワークの場合も、学習回数が100回において認識率が92.03%と0.44%の低下が見られ、汎化性が低下してしまった。一方で提案モデルの場合、学習回数が100回において認識率が92.63%となり、再帰結合のない場合と比較して0.6%、出力層が1個の場合と比較して1.96%の認識率の向上が図れたことから、提案モデルにおける出力層のニューロンの増加およびネットワークの再帰結合化の効果がみられる。

またランダムな文字種を抑制用パターンの対象として学習した場合、学習回数100回においては、学習文字パターンに対しては98.71%、未知文字パターンに対しては92.25%となり、提案モデルと比較して認識率の低下が見られた。さらに学習回数を増やし、回数を300回とした場合は学習文字パターンに対しては99.18%、未知文字パターンに対しては92.83%という認識結果が得られた。この結果より、抑制用パターンにランダムな文字種を利用する場合、最終的には高い精度の結果が得られたが、より多くの学習回数が必要ことが分かる。

表 3 中間層と文脈層のニューロン数を変えた際の認識結果
Table 3 Recognition rate in increasing units in hidden layers.

	ニューロン数	16 個	32 個	48 個	64 個
提案モデル	学習文字	99.38%	99.39%	99.40%	99.39%
	未知文字	92.24%	92.63%	92.62%	92.55%
(1) 出力層が 1 個の場合	学習文字	99.26%	99.36%	99.38%	99.38%
	未知文字	88.33%	90.65%	91.44%	91.76%
(2) 再帰結合なしの場合	学習文字	99.39%	99.40%	99.39%	99.40%
	未知文字	91.64%	92.03%	92.07%	92.11%

そこで以下の実験では、学習回数は 100 回と固定し、学習に利用する抑制用パターンについては大分類の結果を用いる。

次に中間層と文脈層のニューロン数の影響について調べるため、ニューロン数を 16 個、32 個、48 個、64 個としてネットワークの学習を行う。その結果を表 3 に示す。表 3 には、提案モデル、出力層が 1 個のネットワーク、再帰結合化していないネットワークにおいて、中間層と文脈層のニューロン数を変化させ学習した場合の学習文字パターン、未知文字パターンに対する認識率を示している。

表 3 より、提案モデルにおいては、ニューロン数が 32 個で認識率はほぼ一定となることが分かる。出力層が 1 個のネットワークの場合、出力層が増えるにつれ、未知文字パターンに対する認識率が向上する傾向にある。再帰結合化していないネットワークの場合においても、出力層が増えるにつれ、微増する傾向にある。中間層が 32 個の場合、提案モデルにおいて未知文字パターンに対する認識率は 92.63%である。一方で中間層を 64 個と 2 倍に増やした場合においては、出力層が 1 個の場合は 91.76%、再帰結合がない場合は 92.11%であり、中間層の増加の影響よりも、提案モデルにおける効果が見てとれる。

4.3 ブロック数を増加した場合

次に入力に利用するブロックの影響について調べるため、図 3 に示した以外のブロックの分割方法について検討する。文字パターンのブロックへの新たな分割方法を図 8 に示す。

図 3 および図 8 に示す 12 種類のブロックをネットワークへの入力情報として用いる。1 つのブロックの大きさはすべて 112 とした。まず入力するブロック数を 4 個 (x_1, x_2, x_3, x_4 を利用)、8 個 ($x_1, x_2, \dots, x_8$)、12 個 ($x_1, x_2, \dots, x_{12}$) と増やしネットワークの学習を行った。出力層のニューロン数も入力するブロック数と同数とするため、4 個、8 個、12 個と増やしていった。その他のネットワークの構造および学習条件は 4.1 節で述べたとおりである。中間層と文脈層のニューロン数は表 3 の結果より 32 個と固定する。その結果




図 8 文字パターンのブロックへの分割その 2

Fig. 8 Division of character patterns into partial regions.

表 4 ブロック数を増やしたときの認識結果

Table 4 Recognition rate in increasing partial regions.

ブロック数	学習文字	未知文字
4 個 (x_1, x_2, x_3, x_4)	99.39%	92.63%
8 個 ($x_1, x_2, \dots, x_8$)	99.40%	93.75%
12 個 ($x_1, x_2, \dots, x_{12}$)	99.41%	94.09%

を表 4 に示す。表 4 には入力するブロック数を増やした場合、学習文字パターンと未知文字パターンに対する認識率を示す。

表 4 より、学習文字パターンに対してはブロック数を増やしても大きく変化は見られないことが分かる。一方で未知文字パターンに対してはブロック数を 8 個とした場合、認識率は 93.75%となり、ブロック数が 4 個の場合と比較して 1.12%の向上が見られた。さらにブロック数を 12 個とした場合は、認識率は 94.09%となり 1.46%の向上が見られ、入力するブロック数の増加にともない汎化性が向上していることが分かる。そして局所的に特徴が異なる文字パターンに対する認識結果の例として、平仮名において濁点、半濁点の付く文字と付かない文字（「は」、「ば」、「ぼ」など 45 文字）の結果を取り上げる。濁点、半濁点の付く平仮名において、局所的に異なる領域は、図 3、図 8 中の $x_2, x_3, x_6, x_8, x_{10}, x_{12}$ のブロックである。分割数を 4, 8, 12 と増やした場合、これら 45 文字の未知文字パターンに対する認識率は 88.0%, 89.1%, 89.9%と向上していった。これは分割数が増加すると比較対象となる局所領域も増え、より精度の高い識別関数の構築が可能となるためである。

次に入力するブロックの種類による影響についての認識実験を行う。入力するブロック数を 4 個と固定したうえで異なったブロックを組み合わせ、ネットワークの学習を行った。入力するブロックの組合せは (x_1, x_2, x_3, x_4)、(x_5, x_6, x_7, x_8)そして ($x_9, x_{10}, x_{11}, x_{12}$)とした。各ネットワークの出力層のニューロン数は 4 個である。その結果を表 5 に示す。表 5 には入力情報として利用したブロックごとの学習文字パターンと未知文字パターンに

表 5 利用したブロックの影響

Table 5 Recognition rate in using different partial regions.

入力に利用したブロック	学習文字	未知文字
(x_1, x_2, x_3, x_4)	99.39%	92.63%
(x_5, x_6, x_7, x_8)	99.38%	92.67%
($x_9, x_{10}, x_{11}, x_{12}$)	99.38%	92.65%

対する認識率を示す。

表 5 より、入力に利用したブロックの組合せにかかわらず、学習文字パターンおよび未知文字パターンに対する認識率は同程度であり、その組合せに大きく依存していないことが分かる（いずれのブロックの大きさも 112 である）。したがって、より複数の局所領域において、テンプレートとの詳細な識別関数を構築し、最終的な認識結果を求めることによって認識率の向上を図れることが分かった。

5. 考 察

本論文の提案手法について考察する。認識時、提案モデルにおいて入力するテンプレートについては 1 字種につき 40 個用意した学習文字パターンの中からランダムに選択し利用している。そのため利用するテンプレートによって認識率にばらつきが生じると考えられる。そこで入力情報としてブロック数を 12 個利用して学習したネットワーク（4.3 節）を用いて未知文字パターンの認識を 10 回繰り返して行ったところ、平均認識率は 94.09%、標準偏差は 0.128 となり、選択されるテンプレートによって認識率に大きな差は生じなかった。

本論文で提案するニューラルネットワークの構造上の利点として、使用する特徴数よりも入力層のニューロン数が少なく済むという点があげられる。これは複数の異なる特徴を併合して利用した場合でも、各特徴ごとで分割するブロックの大きさをすべて同じ大ききとすれば、入力層のニューロン数は一定のままで済むため、複数の異なる特徴の併用に容易に拡張できる。

しかし入力情報として利用するブロック数を増やすと認識率も向上する一方で、認識時に必要な計算量も増加する。すなわちブロック数が d 個の場合、2.1 節で説明したネットワークと比較してほぼ d 倍の計算量が必要となる。本論文においては、ネットワークの局所結合化を行うことによって、単一のネットワークに必要な学習および認識時における計算量の削減を図っている。局所結合化の影響について考察するため、4.2 節で行った評価実験において、中間層と入力層を全結合化したネットワーク（中間層と文脈層のニューロン数を 32

表 6 全結合化した場合の各モデルの認識結果

Table 6 Recognition rate with neural networks which have all to all connections.

	局所結合型		全結合型	
	学習文字	未知文字	学習文字	未知文字
提案モデル	99.39%	92.63%	99.39%	92.81%
(1) 出力層が 1 個の場合	99.36%	90.65%	99.34%	91.56%
(2) 再帰結合なしの場合	99.40%	92.03%	99.39%	92.19%

表 7 提案モデル（全結合型）においてブロック数を増やしたときの認識結果

Table 7 Recognition rate with neural networks which have all to all connections in increasing partial regions.

ブロック数	局所結合型		全結合型	
	学習文字	未知文字	学習文字	未知文字
4 個	99.39%	92.63%	99.39%	92.81%
8 個	99.40%	93.75%	99.40%	93.89%
12 個	99.41%	94.09%	99.40%	94.23%

個、学習回数を 100 回と固定）で学習を行った結果を表 6 に示す。また 4.3 節で行った評価実験においても、同様に中間層と入力層を全結合化したネットワークを用いて分割数を増やし、学習を行った結果を表 7 に示す。

表 6 および表 7 より、それぞれの方法において全結合化したネットワークを用いた方が認識率は高いことが分かる。表 6 の結果については、表 2 と同様な傾向の結果が得られており、全結合化したネットワークを用いた場合においても、提案モデルの有意性が見てとれる。また表 7 の結果についても、表 4 と同様に、分割数の増加によって認識率の向上を図れることが分かる。以上のようにネットワークの全結合化を図ることによって、学習において調整可能なパラメータが増えるため、より詳細な識別関数の構築が可能であり、認識率の向上につながる。しかし、一方で学習および認識時に必要な計算量が増加する。提案モデルにおいて、出力層が 4 個、中間層と文脈層が 32 個として、中間層と入力層が全結合している場合、1 ネットワークの総結合数は 8,320 個 ($4 \times 32 + 32 \times (112 + 112 + 32)$) であり、局所結合化した場合の総結合数は 4,736 個 ($4 \times 32 + 16 \times 112 \times 2 + 32 \times 32$) となる。局所結合化を図ることによって、認識率は多少低下するが、総結合数を減らすことができ、必要な計算量の大幅な削減をすることが可能であるため、本論文においては局所結合化したネットワークを利用した。

また 1 章で述べたように、計算量を削減する手法としては、大分類・詳細認識型の認識方

表 8 大分類・詳細認識による結果

Table 8 Recognition rate with rough classification and detail recognition.

候補数 P	未知文字
2	94.24%
3	94.59%
4	94.72%
5	94.78%
6	94.82%
7	94.86%
8	94.87%
9	94.90%
10	94.89%
ユークリッド距離	92.47%
提案手法	94.09%

法を利用するのが一般的である。すなわちまず大分類ではユークリッド距離を識別関数として使用して文字候補を P 個に絞り込む。そして次に絞り込まれた P 個の文字候補を対象としたネットワークのみを使用して詳細認識を行い、1 つに候補を絞り込むという方式である。この場合、大分類で P 個に絞られた候補に対して、式 (5) に示すようにユークリッド距離による結果とネットワークの出力結果の積 Sim_i が最小となる候補を認識結果とする。

$$Sim_i = \sum_{j=1}^{196} (x_j - a_{ij})^2 \times \sum_{j=1}^d (o_{ij} - t_{ij})^2 \quad (5)$$

そこで表 4 より、最も高い認識率の得られたブロック数が 12 個を入力対象としたネットワークに対して大分類・詳細認識を行った。その結果を表 8 に示す。表 8 には、大分類で絞り込む候補数 P を変化させたときの未知文字パターンに対する認識率を示す。

表 8 より、最も高い認識率としては $P = 9$ において 94.90% が得られた。2.1 節で述べた全領域を比較対象としたテンプレートマッチング方式と部分領域を比較対象としたテンプレートマッチング方式に改良した提案手法とを比較する。文献 12) の実験結果と比較して、利用した特徴や実験条件などが異なるため一概にはいえないが、ユークリッド距離を用いた認識による 92.47% から詳細認識に提案手法を用いた大分類・詳細認識による 94.90% への向上 (文献 12) の場合、92.17% から 93.33% へ向上) を図ることができた。これは複数の局所的な領域ごとにおいて、テンプレートとの識別関数を構築することによって各局所領域ごとの認識精度も高まり、最終的な認識結果を向上することができたためである。全領域を

比較対象とするテンプレートマッチング方式を改良した提案手法の有効性を示すことができた。

6. む す び

本論文においては、オフライン手書き文字画像を対象としたテンプレートマッチング方式によるニューラルネットワークを改良し、文字画像を局所領域に分割した後、対応する領域ごとでテンプレートマッチングを行い最終的な認識結果を求めることができるように、個々のニューラルネットワークとしては単純再帰結合型ネットワークを用いて学習および認識を行う手法を提案した。そして文字画像データベース ETL9B, 3,036 字種を対象としたネットワークの学習を行い、認識実験を行った結果、認識率の向上が図れることを確認できた。今後は認識時に利用するブロックの形状や大きさの影響について調べるとともに、複数の特徴を併合した認識方法の考案などさらなる改良を行い、認識率の向上を図っていく予定である。

謝辞 本研究を行う際に、貴重な手書き文字データベースを提供していただきました産業技術総合研究所の皆様には感謝いたします。

参 考 文 献

- 1) 森 健一：パターン認識，電子情報通信学会 (1988).
- 2) 藤澤浩道：企業研究者から見た文字認識の進歩と課題と将来，電子情報通信学会技術研究報告，PRMU2003-247, pp.93-100 (2004).
- 3) 酒井幸市：デジタル画像処理入門，CQ 出版社 (2006).
- 4) 羅 四維，岩根典之，山崎晴明：人工神経網による手書き漢字の認識方法，情報処理学会論文誌，Vol.30, No.8, pp.962-969 (1989).
- 5) 朱 小燕，山内康一郎，神保孝志，梅野正義：階層的ニューラルネットワークを用いた手書き文字認識，電子情報通信学会論文誌，Vol.J73-D-II, No.1, pp.54-61 (1990).
- 6) 岩田 彰，當麻孝志，松尾啓志，鈴木宣夫：大規模 4 層ニューラルネット CombNET，電子情報通信学会論文誌，Vol.J73-D-II, No.8, pp.1261-1267 (1990).
- 7) 堀田健一，岩田 彰，松尾啓志，鈴木宣夫：大規模ニューラルネット CombNET-II，電子情報通信学会論文誌，Vol.J75-D-II, No.3, pp.545-553 (1992).
- 8) 荒井正之，奥田健三，宮道壽一：Honeycomb ネット II による多字種の手書き漢字認識，電子情報通信学会論文誌，Vol.J77-D-II, No.9, pp.1708-1715 (1994).
- 9) 猿田和樹，加藤 寧，安倍正人，根元義章：排他的学習ネット (ELNET) を用いた手書き文字認識の細分類手法，電子情報通信学会論文誌，Vol.J79-D-II, No.5, pp.851-859 (1996).

- 10) Saruta, K., Kato, N., Abe, M. and Nemoto, Y.: High Accuracy Recognition of ETL9B Using Exclusive Learning Neural Network-II (ELNET-II), *IEICE Trans.*, Vol.E79-D, No.5, pp.516-522 (1996).
- 11) 石井 力, 和泉勇治, 加藤 寧, 根元義章: ニューラルネットワークを用いた二者択一方式の手書き文字認識システム, 電子情報通信学会論文誌, Vol.J83-D-II, No.3, pp.988-995 (2000).
- 12) 篠沢佳久, 大駒誠一: テンプレートマッチングによるオフライン手書き文字認識ニューラルネットワークの作成, 情報処理学会論文誌, Vol.42, No.1, pp.16-25 (2001).
- 13) 大友照彦, 大槻恭士, 楊 青, 石谷幹夫, 原 健一: 局所結合型神経回路網モデルによる手書き漢字の効率的認識法, 情報処理学会論文誌, Vol.35, No.6, pp.1091-1100 (1994).
- 14) 白石知之, 田中英彦: 漢字の階層的構造を用いた部分要素への分割による類似文字弁別手法, 情報処理学会第 51 回全国大会, Vol.2, pp.173-174 (1995).
- 15) Elman, J.L.: Finding Structure in Time, *Cognitive Science*, Vol.14, pp.179-211 (1990).
- 16) Elman, J.L.: Distributed representations, simple recurrent networks and grammatical structure, *Machine Learning*, Vol.7, pp.195-224 (1991).
- 17) 田中規之, 重田和夫, 志水英二: リカレントネットワークによる文字認識, 電子情報通信学会総合大会, D-2-16 (2001).
- 18) Rumelhart, D.E. and McClelland, J.L.: *Parallel Distributed Processing*, Vol.1, MIT Press (1986).
- 19) 山田博三, 齊藤泰一, 山本和彦: 非線形正規化法の改良, 電子情報通信学会総合大会, D-439 (1988).
- 20) 孫 寧, 安倍正人, 根元義章: 改良型方向線素特徴量および部分空間法を用いた高精度な手書き文字認識システム, 電子情報通信学会論文誌, Vol.J78-D-II, No.6, pp.922-930 (1995).
- 21) 中野 馨: 入門と実習ニューロコンピュータ, 技術評論社 (1988).

(平成 19 年 11 月 1 日受付)

(平成 20 年 7 月 1 日採録)



篠沢 佳久 (正会員)

1994 年慶應義塾大学理工学部管理工学科卒業。1996 年同大学大学院理工学研究科管理工学専攻前期博士課程修了。1999 年同専攻後期博士課程修了。博士 (工学)。機械学習, パターン認識に興味を持つ。現在, ニューラルネットワークを用いた言語獲得および情報リテラシー教育におけるグループウェア構築の研究に従事。電子情報通信学会会員。