

# シェビシェフネットワークによる物体認識法<sup>†</sup>

生天目 章<sup>††</sup> 上田 延寿<sup>††</sup>

本論文は、ニューラルネットワークによる2次元物体の認識法について提案する。2次元物体の表現法として、メッシュ方式の離散表現ではなく、シルエットの位置情報による連続表現法を用いる。シルエットを特徴付ける複雑な形状を精度良く表現するためにシェビシェフネットワークという新しいネットワークアーキテクチャを提案する。2次元物体のシルエットの内外から抽出した位置情報を数次のシェビシェフ関数により非線形および非単調変換したデータを入力とし、その位置情報がシルエットの内側または外側のどちらに位置するかにより、出力が1と0となるいくつかの学習例を用いて学習を行う。このようなパターン識別の学習法により、2次元物体を特徴付けるシルエットの複雑な形状やシルエットの大きさ（面積）などの特徴が自動的に抽出できることを示す。また、学習に用いた標準物体の一部が欠損した物体の画像情報に対しても、学習後のネットワークは正しい識別を行い、汎化能力の高い物体認識システムが構築できることを示す。

## 1. はじめに

認識とは一度認めたものを再度認めることと一般的に定義されるが、コンピュータによる画像認識とは入力画像中から特定の物体を検出し出すことであり、画像に含まれる特徴を抽出し、抽出された特定の特徴をベースに認識が行われる。これらの研究の航空宇宙分野への応用として、移動物体の誘導や自動写真解析などがある。これらの研究には Faugeras, Hebert による距離画像解析システム<sup>1)</sup> や McKeown, Harvey, McDermott による航空写真解析システム<sup>2)</sup>、Thorpe らによる NAVAL 自動走行システム<sup>3)</sup>などがあげられる。認識において標準となる物体の形・大きさ・色などの特徴があらかじめ得られる場合は、これをモデルとして利用するモデルベースの認識法がある<sup>4),5)</sup>。本手法は前もっていくつかの標準物体の特徴をモデルとして記憶しておく、未知物体の特徴と各標準物体の特徴を比較し、入力された未知物体がどの標準物体に該当するかを認識結果として出力する。モデルベース認識システムでは、システムの効率・汎用性・認識能力といったことが問題になる。システムの効率は処理速度において問題となり、いかに効率的なモデルや比較法を用いるかによって決定される。システムの汎用性は認識対象の変化に対する対応能力のことをいい、システム構築法によって決定される。認識能力はいかに正しい認識結果が得られるかということであり、問題に対するモデルと比較法によって決定される。モデルベースに基づく認識の研究では、実際の状況にもと

づいて認識に有効な特徴をあらかじめ抽出しておき、それらを処理過程に埋め込むようなモデルと処理が一体化したハンドコンパイル法<sup>6),7)</sup> やモデルと処理を独立させたインタプリタ法<sup>8),9)</sup>、オフラインでモデルに固有な特徴を効率的な形に編集しておくコンパイル法<sup>10),11)</sup>が提案されているが、いずれも人手により認識に有効な特徴を抽出し、それらをコンピュータが処理しやすい形式で表現されている。

本論文ではニューラルネットワークを利用することにより、特徴の抽出と処理に有効な形式への表現を人が介入することなく自動的に行う方法を提案する。ニューラルネットワークを用いることにより、オフラインにおいて学習により自動的に認識に有効な標準物体の特徴を抽出し、ネットワーク内に記憶されるが、それらは解釈木ではなく、ネットワーク内のユニット間の結合重みとして表現される。認識能力は問題に対するモデルと処理の適切さによって影響をうける。モデルは各標準物体に固有であり、処理に適した形式で記憶される。処理は各問題に固有であり、同じ形式で表現されたモデルに対して有効である。本論文ではシルエット画像を認識の対象としているが、従来のニューラルネットワークアーキテクチャでは単調な非線形関数であるシグモイド関数を多層に積み重ねたニューラルネットワーク<sup>12),13)</sup>を使用していたため、複雑な形をしたシルエットをそのまま学習することができない。すなわち、単調なシグモイド関数を多層に重ねたネットワークを用いて複雑な非単調構造を十分な精度で学習することは困難である<sup>14)</sup>。そこで、複雑な形状をした物体のシルエットを少ない学習例から効率良く学習するシェビシェフネットワーク<sup>15),16)</sup>を利用した手法を提案する。シェビシェフネットワークは非単調

<sup>†</sup> Object Recognition Using Chebychev Networks by AKIRA NAMATAME and NOBUHISA UEDA (Department of Computer Science, National Defense Academy).

<sup>††</sup> 防衛大学校情報工学科

で非線形な関数であるチェビシェフ関数と単調で非線形な関数であるシグモイド関数を融合したニューラルネットワークである。そして、本論文ではチェビシェフネットワークを使って物体認識システムを構築し、その有効性をシミュレーションによって確かめる。

## 2. ニューラルネットワークによる物体認識

従来のモデルベース認識システムは標準物体が与えられると人がそれらを認識するのに効率的な特徴を考え、これを標準物体から抽出してコンピュータにモデルとして表現した。ニューラルネットワークによる認識は、その学習能力と汎化能力により各標準物体の学習例が提示されるとコンピュータが自動的に認識に有効な特徴を抽出し、適切に表現して記憶することができる。したがって、認識に必要な特徴の抽出や抽出された特徴の有効な形式による表現（内部表現）が、ニューラルネットワークの学習により自動的に行うことができる。ニューラルネットワークの認識システムを構築する場合、学習によって自動的に特徴抽出を行う。特徴の変換は同じネットワークの再学習によって自動的に行うことでもできるし、別の特徴を学習したネットワークへの交換によってもできるのでシステムの汎用性は高い。

3次元の形をした物体を対象とする場合、これをある一定方向から眺めてデジタル画像化すると2次元的な対象として表現できる。本研究では2次元画像であるシルエットを学習の対象として扱う。ここで用いる物体のシルエットは大きさが正規化されており、回転などは考えていない。また、その境界線は任意の曲線で構成された複雑な物体を対象とする。シルエットに関する情報は座標値とその座標がシルエットの内側に位置するか外側に位置するかについて示す出力値で表現する。従来、ニューラルネットワークを利用した物体認識の研究が行われてきた<sup>17)~19)</sup>。画像をメッシュ状に区切って各メッシュに入力ユニットを割り当て、認識結果を出力ユニットに割り当てる方法があり、これは特徴と処理が一体化しており、並列処理を行うために処理時間が速く効率は良いが、次のような問題点がある。

(1) 与えられた標準物体のシルエットの差に注目するので、ある標準物体に固有のメッシュに注目して認識が行われる。このため認識を行う際に固有のメッシュの情報が得られなかつたり、固有のメッシュを共有するような未知物体が入力される

と認識能力が極端に低下する。

(2) ネットワークが大規模なものになってしまふ。例えば、メッシュを画像単位にまで落とすと入力ユニットだけで数十万個が必要となり、ネットワークの規模の問題に遭遇する<sup>20)</sup>。また、NADEL<sup>21)</sup>のようにシルエット境界の曲率が極大の部分と中心を抽出し、これを写像することによって回転、拡大縮小、ノイズに強い認識法を提案しているものもある。

これに対し本システムでは、小規模なネットワークで少ない学習例から精度よく複雑なシルエットを学習するチェビシェフネットワークを用いる。チェビシェフネットワークではシルエットの座標値を入力ユニットに割り当て、認識結果を出力ユニットに割り当てるので、他の標準物体と異なるシルエットの部分のメッシュに注目するメッシュ方式のデジタル情報表現に比べてアナログ情報表現となり、小規模なネットワークでシルエットの細部まで表現することが期待できる。チェビシェフネットワークを利用してシルエットを学習することにより、ある標準物体に固有な部分に注目して特徴を抽出せず、シルエット全体からきめ細かく特徴を抽出して連続モデルとして記憶することになる。したがって、シルエットのデータの一部が欠落していたり、標準物体でない未知物体に対しても得られた情報量に応じて有効に認識を行うことができる。

## 3. チェビシェフネットワーク

チェビシェフネットワークとは、非単調・非線形関数であるチェビシェフ関数を入力ユニットに用いる多層ネットワークである。従来の単調な非線形関数であるシグモイド関数を多層に重ねる方法では学習が困難な、複雑で非線形な入出力関係をチェビシェフネットワークにより、少ない学習例で精度よく学習できる。チェビシェフネットワークは図1に示した4層ネット

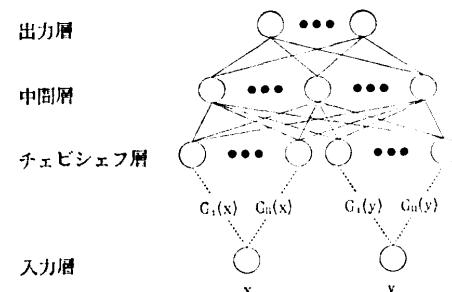


図1 チェビシェフネットワーク  
Fig. 1 The architecture of Chebychev networks.

ワークであり、入力層・チェビシェフ層・中間層・出力層から構成され、一般的な多層ネットワークとは入力層とチェビシェフ層の間で非線形変換をする点で異なる。学習はチェビシェフ層と出力層の間で逆伝播法を用いて行われ、この間のユニットはシグモイド関数を用いる。チェビシェフ層ではチェビシェフ関数により各入力値を  $n$  次まで展開した値を各ユニットに出力し、入力層とチェビシェフ層間では学習を行わない。チェビシェフ層のユニットの出力関数は、次式で表される。

$$G_n(x) = [1 + \cos(n \cdot \arccos(2 \cdot x - 1))] / 2, \\ n = 0, 1, 2, \dots, 0 \leq x \leq 1. \quad (3.1)$$

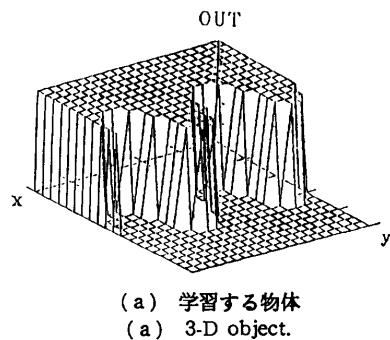
シルエットを学習するための学習例は、シルエットの境界線付近から任意に抽出する。シルエットの境界付近では、境界上のある一点から等距離で対称位置にシルエットの内側および外側からの学習例を二個一组としてシルエットの境界を挟むように抽出する。また、 $x, y$  領域の境界である縁においても学習例をいくつか設け、シルエットの外側も閉じた領域として学習させる。チェビシェフネットワークは入力値に対応して周期的に振動するチェビシェフ関数を用いるために、出力では短い周期を持って振動する関数によって合成された超曲面を形成する。

### 3.1 チェビシェフネットワークによるシルエット学習

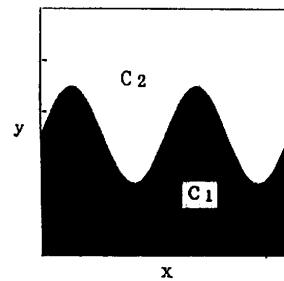
図2(a)に示すような3次元の物体を学習しようとする場合、これを上から眺めて画像化するとクラス  $C_1$  (シルエット内側領域) と  $C_2$  (シルエット外側領域) が曲線で組み合った図2(b)に示すシルエットとなる。このシルエットをチェビシェフネットワークに学習させることを考える。物体の大きさは  $0 \leq x, y \leq 1$  の領域に正規化されている。シルエットの境界は次式で表されるものである。

$$y = 0.5 + 0.2 \cdot \sin(2\pi \cdot x). \quad (3.2)$$

ここではクラス  $C_1$  に 1,  $C_2$  に 0 の出力値を割り当てて2つのクラスを識別する。ネットワークアーキテクチャを図1に示すが、入力ユニットは  $x, y$  の2個、チェビシェフユニットは入力を各々 5 次ずつ展開して 10 個、中間ユニットは 2 個、出力ユニットは 1 個である。学習例としては、図3に示すようにシルエットの境界付近から境界を挟んで 50 組 (100 個) を抽出した。○は出力 1 を、●は出力 0 を表している。チェビシェフネットワークに逆伝播法を用いて 100 回ほど学習させた。学習後に任意の  $(x, y)$  の値を



(a) 学習する物体  
(a) 3-D object.



(b) 学習するシルエット  
(b) 2-D silhouette.

図2 学習対象  
Fig. 2 The target object.

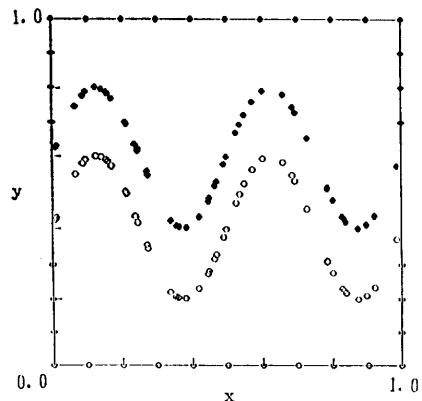


図3 図2の学習例  
Fig. 3 The positive and negative training examples for a 2-D silhouette in Fig. 2(b).

入力することによりチェビシェフネットワークが学習したシルエットを求め、それを図4(a)に示す。これより抽出された有限個の離散的学習例から、学習対象に精度よく近似している連続的シルエットが学習されていることがわかる。また、図4(a)のシルエットを3次元に復元した物体を図4(b)に示す。これより図2の学習対象の物体に近似している物体が得られていることがわかる。物体のシルエットが存在する画像には無数の点が存在し、シルエットを正確に表現しよう

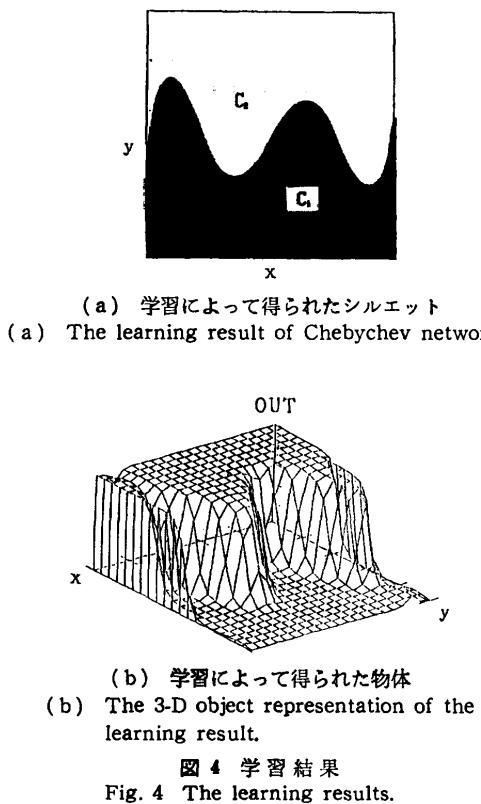


図 4 学習結果  
Fig. 4 The learning results.

とした場合は一般には無限個の点を表現しなければならないが、チェビシェフネットワークを用いることにより少数の学習例から高い汎化能力によって精度よく物体を近似できることがわかる。

### 3.2 チェビシェフネットワークの非線形変換メカニズム

チェビシェフネットワークは学習により、非線形な入出力関係を中間層-出力層間において線形分離の関係に変換する。中間層-出力層間の関係を確かめるために中間ユニットの出力値  $h_1, h_2$  を  $x$  および  $y$  軸にとり、入力座標  $(x, y)$  を  $1/50$  間隔で  $0 \leq x, y \leq 1$  の間で変化させた場合の中間ユニットの出力値とネットワークの出力ユニットとの関係を図 5 に示す。(出力ユニットの値が  $0.5$  以上ならば○、 $0.5$  未満ならば●とした。)図 3 に示された入力層と出力層間の非線形な境界で分離されるクラスの関係が、図 5 に示された中間層と出力層間では線形分離の関係に変換されていることがわかる。これは、チェビシェフ層に非単調・非線形な出力関数を持つユニットを配置したことにより、ネットワークの内部表現の獲得過程において非線形分離問題が線形分離問題に容易に変換されたことを表している。

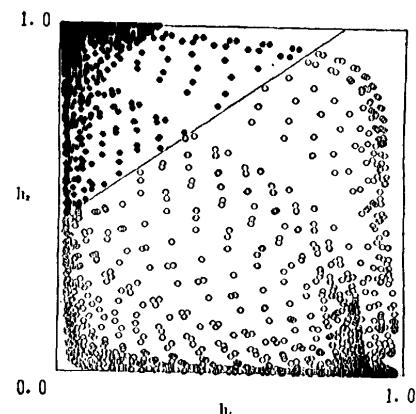


図 5 中間ユニットの出力値  $(h_1, h_2)$  とネットワーク出力値  $\{C_1(\circ), C_2(\bullet)\}$  の関係  
Fig. 5 The relation among the outputs of the hidden units  $\{h_1, h_2\}$  and the network outputs  $\{C_1(\circ), C_2(\bullet)\}$ .

### 4. チェビシェフネットワークを用いた物体認識システム

チェビシェフネットワークを使って図 6 の船 “A, B, C”を標準物体とする認識システムを考える。これらの画像は横および縦軸の大きさが  $0 \sim 1$  になるように正規化され、横軸を  $x$ 、縦軸を  $y$  とし、シルエットの内側の座標に対しては  $1$ 、外側の座標に対しては  $0$  の出力値を学習例として付与する。

#### 4.1 物体認識システムのアーキテクチャ

本論文で提案する物体認識システムは、標準物体のシルエットの学習例からシルエットの特徴を自動的に抽出し、記憶するための学習・記憶モジュールと、各標準物体の特徴と入力される未知物体の特徴を比較

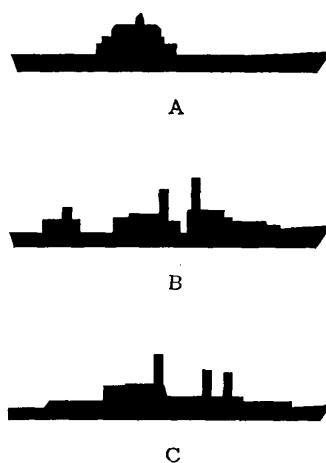


図 6 標準物体  
Fig. 6 The target silhouettes, A, B and C.

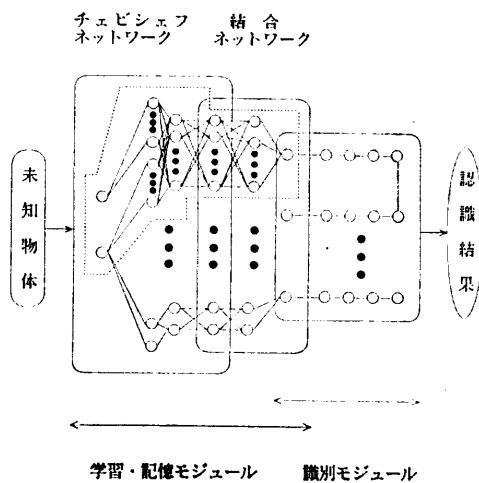


図 7 物体認識システムのアーキテクチャ  
Fig. 7 The architecture of the connectionist object recognition system using Chebychev networks.

し、未知物体がどの標準物体に類似しているかを認識結果として出力するための識別モジュールによって構成され、そのアーキテクチャを図 7 に示す。点線内はひとつの標準物体の学習・記憶モジュールに対応している。学習・記憶モジュールは複数個の Chebychev ネットワークと結合ネットワークによって構成される。Chebychev ネットワークは標準物体のシルエットをいくつかに分割した部分シルエットを学習し、部分シルエットを特徴づける形状や大きさを自動的に抽出する。結合ネットワークは、同じ標準物体の部分シルエットを学習した Chebychev ネットワークの上に階層的に構築され、部分シルエットを統合して 1 つの標準物体を表現するような学習を行う。すなわち、結合ネットワークはそれぞれの標準物体を表現し、それらは結合係数を固定することにより記憶される。識別モジュールは論理的に構築されていて、未知物体と標準物体の特徴（シルエット全体の形状や大きさ等）を比較し、最も類似した標準物体を求めるためのアルゴリズムを並列に処理するものである。

#### 4.2 部分シルエットの学習

シルエットのもつ複雑な輪郭線の非線形性を緩和する標準物体シルエットを適当な 3 個の部分シルエットに分割し、各部分シルエットごとに個々の学習例と Chebychev ネットワークを設けた（図 8）。Chebychev ネットワークの入力ユニットは 2 個、各入力は各々 4 次まで展開し、Chebychev ユニットは 8 個で、中間ユニットはそれぞれ 14, 29, 14 個、出力ユ

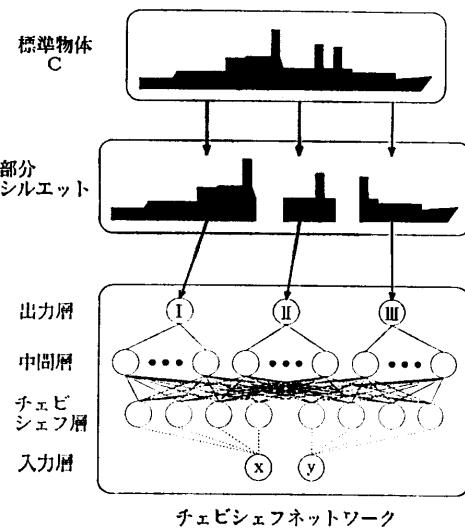


図 8 部分シルエットの学習  
Fig. 8 The training method of the target silhouette with their components.

ニットはそれぞれ 1 個とした。学習例は 101 個、86 個、85 個をそれぞれ用意し、入力には座標値 ( $x, y$ ) を用い、出力値は担当する部分シルエット内に座標があれば 1、なければ 0 とする。学習例は、物体の境界線付近と、入力座標値の境界である  $x=0, x=1, y=0$  および  $y=1$  の 4 直線上に適当に用意する。ひとつの標準物体を学習する場合は、そのシルエットを  $[0, 1]$  の大きさに正規化し、これを部分シルエットに分割する。各学習例を Chebychev ネットワークに 600~1,000 回程度学習させた。シルエットは、シルエットの輪郭曲線の極値点の位置や曲率等により特徴付けられるので、学習例はシルエットの境界線の曲率の変化率が大きい部分に留意して設けてある。学習終了後、結合係数は固定する。同様にして他の標準物体シルエットも部分シルエットごとに学習を行う。

#### 4.3 全体シルエットの学習

結合ネットワークは Chebychev ネットワークが学習した部分シルエットの特徴をひとつに結合し、標準物体全体のシルエットの特徴を表現する。結合ネットワークの入力には同じ標準物体を分割した部分シルエットを学習した複数の Chebychev ネットワークの出力ユニットが接続される。

船 “C” の標準物体シルエット全体を学習するための結合ネットワークのアーキテクチャを図 9 に示す。入力ユニットは Chebychev ネットワークの出力ユニットを用いているので 3 個、中間ユニットは 5 個とし、出力ユニットは 1 個とした。学習例はひとつの標

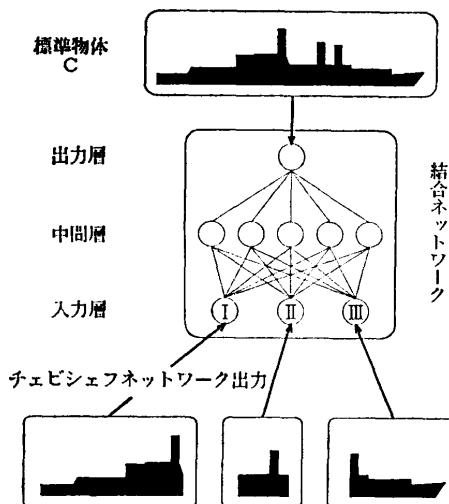


図 9 結合ネットワークのアーキテクチャ  
Fig. 9 The architecture of the connection network modules integrating three Chebychev networks.

標準物体の全体のシルエットから抽出した。入力には座標  $(x, y)$  を用い、出力には担当する標準物体シルエット内に座標があれば 1 を出力し、なければ 0 を出力するシルエット出力を用い、120 回ほど学習させた。学習が終了したら結合重みは固定する。同様にして他の標準物体のシルエットも学習する。

結合ネットワークの出力はある座標における標準物体のシルエット出力を表し、これらの集合が学習・記憶モジュールの出力となっている。この場合、船は 3 隻あるので学習・記憶モジュールの出力ユニットは 3

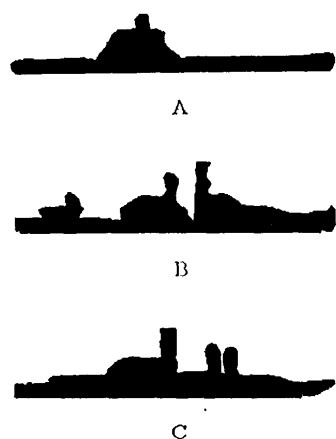


図 10 標準物体の学習結果  
(図 7 の結合ネットワークの出力値)  
Fig. 10 The learning results of Chebychev networks. The outputs of the connection network modules are plotted for each target silhouette.

個である。このような方法で各標準物体を学習・記憶するための結合ネットワークが学習したシルエットを図 10 に示す。標準物体全体のシルエットはチエビシェフネットワークにおける部分シルエットが結合ネットワークにおいて単純に結合されたものであり、部分シルエットの精度が標準物体の精度に直接影響する。

#### 4.4 識別モジュール

識別モジュールは、標準物体と未知物体のシルエットの特徴を比較し、入力された未知物体に最も類似している標準物体を認識結果として出力する。識別モジュールは検証データにもとづいて処理が行われる。検証データ  $(x_t, y_t, O_t)$  は未知物体のシルエット画像から任意に抽出され、未知物体の画像における座標  $(x_t, y_t)$  とその座標における出力値  $O_t$  で構成されており、 $t$  は  $t$  番目の検証データを表す。出力値は、検証データの座標が未知物体シルエットの内側にあれば 1、外側にあれば 0 の値をとる。 $T_0, T_1$  をそれぞれシルエットの外側と内側の検証データの総数とする。

識別モジュールは図 11 に示すように 5 種類のユニット（比較ユニット、累積ユニット、一致度ユニット、類似度ユニット、識別ユニット）から構成される。 $k$  番目の標準物体を学習した複数個のネットワークと、それらを統合した結合ネットワーク  $N_k$  に、ある座標値  $(x_t, y_t)$  を入力したときのネットワークの出力値を  $N_{kt} = N_k(x_t, y_t)$  で表し、比較ユニットの出力

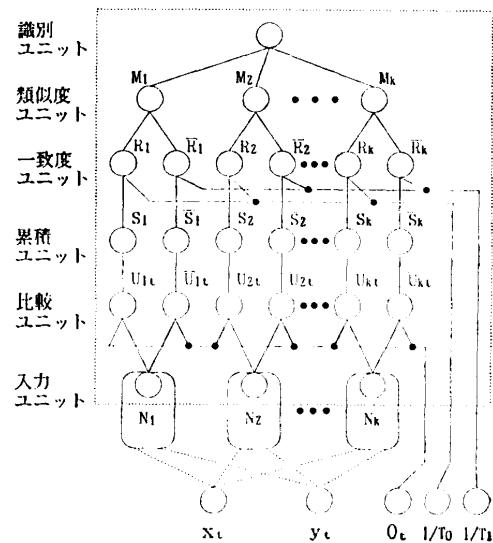


図 11 識別モジュール  
Fig. 11 The architecture of the classification network module.

関数を(4.1)式で定義する。

$$U_k(N_{kt}, O_t) = (1 - N_{kt})(1 - O_t), \quad (4.1)$$

$$U_k(N_{kt}, O_t) = N_{kt} \cdot O_t.$$

比較ユニットは、各標準物体ごとに2個配置し、未知物体と同じ座標においてシルエット内側および外側がそれぞれ一致しているかについてそれぞれのユニットで比較することにより、物体の各部を比較する。累積ユニットは比較ユニットが1を出力した回数を累積していく。比較ユニットが逐次出力する比較結果を累積することにより、物体各部の比較結果をひとつにまとめ、検証データ全体の評価を行う。累積ユニットの出力関数を(2.4)式で定義する。

$$S_k = \sum_{t=1}^{T_k} U_k(N_{kt}, O_t) \quad (4.2)$$

$$\bar{S}_k = \sum_{t=1}^{T_k} \bar{U}_k(N_{kt}, O_t)$$

一致度ユニットは累積ユニット出力をデータ総数で割った値を出力する。これにより、標準物体ごとに未知物体のシルエットの内側のデータの一致度と外側のデータの一致度を計算する。一致度ユニットの出力関数を(4.3)式で定義する。

$$R_k = S_k / T_k,$$

$$\bar{R}_k = \bar{S}_k / T_k, \quad (4.3)$$

$$0 \leq R_k, \bar{R}_k \leq 1.$$

シルエット出力0,1ごとの一致度 $R_k$ および $\bar{R}_k$ を掛け合わせた値を類似度ユニットは出力する。類似度は未知物体に対する各標準物体の類似度の指標であり、シルエット出力0,1ごとに計算された一致度を掛け合わせることにより、未知物体のシルエットが標準物体のシルエットに含まれてしまう場合やその逆の場合に小さい値が出力されるので都合が良い。未知物体ごとに検証データ数が異なる場合も正規化された値となるので、類似度の指標として有効である。類似度ユニットの出力関数を(4.4)式で定義する。

$$M_k = R_k \cdot \bar{R}_k, \quad (4.4)$$

$$0 \leq M_k \leq 1.$$

識別ユニットは最も大きい値を保持している類似度ユニットが担当する標準物体を認識結果として出力する。これにより標準物体どうしの比較を行う。識別ユニットの出力関数を(4.5)式で定義する。

$$\max(M_1, M_2, \dots, M_k). \quad (4.5)$$

## 5. シミュレーション

図7に示した物体認識システムを使って図6を標準物体としたシミュレーションを行い、本システムの有

表1 標準物体に対する検証結果  
Table 1 Classification results for test silhouettes.

未知物体	標準物体	一致度		類似度
		$R_k$	$\bar{R}_k$	
A	A	0.99	0.98	(0.97)
	B	0.66	0.95	0.63
	C	0.71	0.97	0.69
B	A	0.86	0.81	0.70
	B	0.96	0.96	(0.92)
	C	0.83	0.88	0.73
C	A	0.93	0.84	0.78
	B	0.85	0.91	0.77
	C	0.98	0.98	(0.96)

効性を確認する。

各標準物体のシルエット内外のデータを1/50間隔で抽出し、2,601個の検証データを作成し、それらを学習後の各ネットワークに提示して評価したときの一致度と類似度を表1に示す。表1は、学習例を抽出した標準物体のシルエットから得た検証データを提示されたネットワークの一致度は最大で、それぞれ0.97, 0.92, 0.96といずれも0.9以上であることを示している。逆に、自分が担当しないシルエットから得た検証データを提示された場合の一致度は0.78以下であり、本システムは最も一致度が大きい標準物体を認識結果として出力し、正しい認識結果を得た。

同じ標準物体から抽出した検証データを入力しても一致度が1にならないのは、学習において誤差が存在するためであり、その多くはシルエットの境界付近に集中している。誤りは直線の組み合わせによって構成されているシルエットの直角な部分がチェビシェフ関数が持つ非線形性のために微分可能な曲線を描いて丸められているために生じると考えられる。

## 6. 推論能力の検証

ここでは未知物体として標準物体の一部が欠損したデータが与えられた場合の物体認識システムの推論能力について検証する。欠損部分の領域に関してはシルエット出力値が不明確であることから、それ以外の領域から任意に抽出したデータを検証データとして用いる。シルエットをもとに船を認識する場合に上部構造物が認識に大きな影響を与えると考えられるので、図12に示すように標準物体の下側部分が欠損した画像

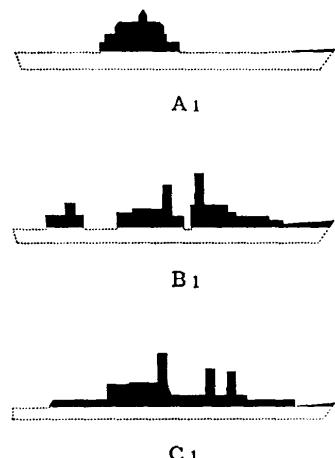


図 12 推論能力の検証に用いた画像データ  
Fig. 12 Test silhouettes.

表 2 未知物体(図 12, 13)に対する検証結果  
Table 2 Classification results for test silhouettes.

未知物体	標準物体	一致度		類似度
		$R_h$	$\bar{R}_h$	
$A_1$	A	0.97	1.00	(0.97)
	B	0.30	0.96	0.29
	C	0.42	0.98	0.41
$B_1$	A	0.56	0.83	0.47
	B	0.93	0.97	(0.90)
	C	0.64	0.90	0.58
$C_1$	A	0.87	0.87	0.76
	B	0.71	0.92	0.65
	C	0.98	0.98	(0.96)
$A_2$	A	0.99	0.98	(0.97)
	B	0.64	0.96	0.61
	C	0.69	0.95	0.65
$B_2$	A	0.86	0.81	0.70
	B	0.96	0.96	(0.92)
	C	0.83	0.88	0.73
$C_2$	A	0.90	0.81	0.73
	B	0.84	0.91	0.76
	C	0.98	0.97	(0.95)

“ $A_1, B_1, C_1$ ”を使って検証を行う。検証データは、2,090個用いた。検証結果を表2に示すが、データが欠損した物体に対しても正しい認識結果が得られていることがわかる。表1と比べると正しい標準物体に対

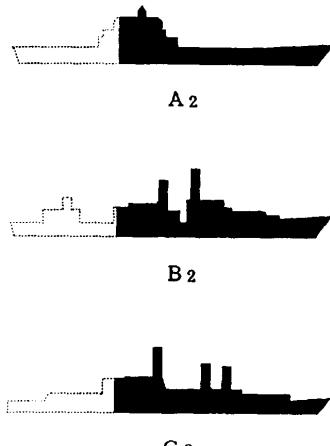


図 13 推論能力の検証に用いた画像データ  
Fig. 13 Test silhouettes.

する類似度にはほとんど変化がないが、それ以外の標準物体に対する類似度は小さくなっている。これより、船の下側は類似していることがわかり、船の認識には上部構造物の情報が有効であるといえる。次に、図13に示すようにそれぞれの船の後ろ側1/3が見えない場合“A2, B2, C2”について検証する。1,734個を検証データとして使用し、検証結果を表2に示す。この場合の類似度は図12と大差なく、正しい認識結果を得ている。これより、本システムはデータの一部が欠損した物体に対しても認識能力が大きく低下することがないことがわかる。

シルエットの一部が欠損したデータがある場合、識別モジュールでは与えられたデータの範囲内で各標準物体と未知物体のシルエットを検証データごとに比較し、どの程度類似しているかを出力して最も類似している標準物体が認識結果として出力される。このために、部分的なデータから標準物体を推論できる。識別モジュールは簡単な方法で部分的なシルエットのテンプレートマッチングを任意に抽出したデータを用いて行い、その結果を統合して認識を行っているといえる。この推論能力の検証よりメッシュ方式のように他の標準物体と異なるシルエットの部分に注目したりせず、すべてのシルエットの特徴（シルエットの形状を特徴づける極値点や曲率など）を同等に扱っていることがわかる。

## 7. おわりに

本論文ではチェビシェフネットワークという新しいネットワークアーキテクチャを用いた物体認識法を提案した。チェビシェフネットワークは、少ない学習例

から複雑な形をしたシルエットの特徴である形や大きさを自動的に精度良く抽出し、高い汎化能力を示した。三隻の船のシルエットを標準物体として用いたシミュレーションにより、学習・記憶モジュールが学習例から自動的に精度良く標準物体の特徴を抽出していることを示した。また、未知物体と標準物体を比較する識別モジュールを組み合わせる方法によって認識能力・推論能力の有効性を確かめた。本論文では全体のシルエットを三個に分割した部分シルエットを用いたが、部分シルエットをマストやデッキといった意味ごとに設けることができれば認識能力の向上が期待でき、画像理解に近づけると考えられる。

### 参考文献

- 1) Faugeras, O. D. and Hebert, M.: The Representation, Recognition and Locating of 3-D Objects, *The International Journal of Robotics Research*, Vol. 5, No. 3, pp. 27-52 (1986).
- 2) McKeown, D. M., Harvey, W. A. and McDermott, J.: Rule Based Interpretation of Aerial Imagery, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. PAMI-7, No. 5, pp. 570-585 (1985).
- 3) Thorpe, T., Hebert, M., Kanade, T. and Shafer, S.: Vision and Navigation for the Carnegie-Mellon NAVLAB, Traub, J. ed., *Annual Reviews of Computer Science*, Vol. 2, pp. 521-556, Annual Reviews Inc. (1987).
- 4) Biford, T. O.: Survey of Model-based Image Analysis Systems, *The International Journal of Robotics Research*, Vol. 1, No. 1, pp. 18-64 (1981).
- 5) Chin, R. T. and Dyer, C. R.: Model-based Recognition in Robot Vision, *ACM Comput. Surv.*, Vol. 18, No. 1, pp. 67-108 (1986).
- 6) Perkins, W. A.: Model-based Vision System for Scene Containing Multiple Parts, *Proc. 5th International Joint Conference on Artificial Intelligence*, pp. 678-684 (1977).
- 7) Horn, B. K. P. and Ikeuchi, K.: The Mechanical Manipulation of Randomly Oriented Parts, *Sci. Am.*, Vol. 251, No. 2, pp. 100-111 (1984).
- 8) Brooks, R. A.: Model-Based Three-Dimensional Interpretations of Two-Dimensional Images, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. PAMI-5, No. 2, pp. 140-150 (1983).
- 9) Brooks, R. A., Greiner, R. A. and Binford, T.: A Model Based Vision System, *Proc. of DARPA Image Understanding Workshop*, pp. 36-44 (1978).
- 10) Goad, C.: Special Purpose Automatic Programming for 3D Model-based Vision, *Proc. of DARPA Image Understanding Workshop*, pp. 94-104 (1983).
- 11) Ikeuchi, K. and Kanade, T.: Towards Automatic Generation of Object Recognition Program, *Proc. IEEE*, Vol. 76, No. 8, pp. 1016-1035 (1988).
- 12) Lippman, P.: An Introduction to Computing with Neural Nets, *IEEE ASSP Magazine*, April, pp. 4-22 (1987).
- 13) Rumelhart, D. E. and McClell, J. L. (eds.): *Parallel Distributed Processing*, MIT Press (1986).
- 14) 生天目, 木俣: ニューラルネットワークの情報表現と非線形関数の同定, 情報処理学会論文誌, Vol. 30, No. 10, pp. 1274-1280 (1986).
- 15) 生天目, 木俣: 高次関数ネットワークによるコネクション学習とその応用, 電気学会論文誌, Vol. 110-C, No. 6, pp. 376-382 (1990).
- 16) 生天目, 上田: チェビシェフネットワークによるパターン領域の識別, システム制御情報学会論文誌, Vol. 4, No. 1, pp. 28-36 (1991).
- 17) Khotanzad, A. and Lu, J. H.: Distortion Invariant Character Recognition by a Multi-Layer Perceptron and Back-Propagation Learning, *IEEE International Conference on Neural Networks*, Vol. 1, pp. 625-632 (July 1988).
- 18) Oyster, M.: Target Recognizer, *DARPA Networks*, pp. 451-455, AFCEA (1989).
- 19) Fuller, J.: Invariant Target Recognition Using Feature Extraction, *IEEE IJCNN-90-WASH-DC*, Vol. 2, pp. 595-598 (1990).
- 20) Minsky, M. and Papert, S.: *Perceptron*, expanded version, MIT Press (1988).
- 21) Seibert, M. and Waxman, A. M.: Spreading Activation Layers, Visual Saccades, and Invariant Representations for Neural Pattern Recognition Systems, *Neural Networks*, Vol. 2, No. 1, pp. 9-27 (1989).

(平成3年3月4日受付)

(平成3年10月3日採録)



生天目 章（正会員）

1973年防衛大学校卒業（応用物理学専攻）。1979年スタンフォード大学大学院博士課程修了（Ph. D.）。同年、航空幕僚監部勤務。1987～1988

年ジョージメイソン大学客員助教授。現在、防衛大学校情報工学教室助教授。人工知能、ニューラルネットワーク、意志決定工学などの研究に従事。人工知能学会、計測自動制御学会、AAAI, ACM, INNS, IEEE 各会員。



上田 延寿（正会員）

1985年防衛大学校卒業（電気工学専攻）。同年、航空自衛隊入隊。1991年、防衛大学校理工学研究科卒業。現在航空自衛隊補給本部勤務。人工知能学会会員。