

任意に回転したパターンと回転角度を認識する複写学習モデル

須崎 健一[†] 荒屋 真二[†] 中村 良三^{††}

本論文は、基本パターンを学習するだけで、任意に回転したパターンと回転角も認識できる複写学習モデルを提案する。従来モデルは、前処理として、回転パターンを生成もしくは数学的な処理で回転に不变な特徴量を抽出し、それらを可変ネットで学習している。したがって、学習前に膨大な処理が必要である。複写学習モデルは、まず、3層ネットの一部分を用いて基本パターンだけを学習し、次に、得られた結果を未使用の部分ネットに、ある規則に従って複写する。学習後は、すべての部分ネットを用いて入力パターンの認識処理を行う。提案モデルは従来モデルと比べ、以下の利点をもつ。(1)ネットワーク構造が簡素で規模が小さい。(2)学習ならびに認識速度が速い。(3)回転角度の認識も可能である。また、複写学習モデルは複写手法を工夫することで、回転・位置ずれ・スケール変換を受けたパターンにも適用できる。

A Copy-Learning Model for Recognizing Randomly Rotated Patterns and Their Angles

KENICHI SUZAKI,[†] SHINJI ARAYA[†] and RYOZO NAKAMURA^{††}

This paper proposes a Copy-Learning neural net model that can recognize rotated patterns at various angles. With the conventional neural net model, it took a large volume of processing prior to learning by the neural net to recognize a pattern rotated at various angles. Copy-Learning model eliminates this pre-processing. This model introduces a new Copy-Learning mechanism different from conventional models. The proposed model combines three types of processing: first, it learns only the standard patterns by using a part of the 3-layer neural net; secondly, it rotates the values of obtained weights and biases and copies them into an unused part of the net. After copy learning, all parts of the network are used to recognize unknown input patterns. Compared with the conventional model, the proposed model has the following merits. (1) The scale of the net is small and the structure is simple. (2) The speed of learning and recognizing is fast. (3) The information of the rotation angle can be obtained. If the Copy-Learning method is extend, it would be applicable to pattern recognition involving scale-change, translation and rotation transformations.

1. まえがき

位置ずれ、回転、拡大縮小などの変換を受けたパターンの認識は、文字認識システムをはじめ、各種の産業分野においても、重要性が増している。特に、任意に回転したパターンを認識することは、多くの分野から要請があるにもかかわらず、現在でも技術的に難しい問題とされている。ニューラルネットで回転を認

識する手法としては、取り扱う回転パターンのすべてを学習させる方法^{1)~3)}と、フーリエ変換、モーメント不変性などの数学的な前処理によって回転不变な特徴量を抽出し、それを記憶させる方法⁴⁾に大別できる。しかし、いずれの方法でも、正方メッシュ上に表現されたパターンが任意の回転を受けたとき、それらのパターンを前処理なしで認識できるネットモデルは実現されていない。本論文は、従来モデルとは全く異なる手法、つまり取り扱う回転パターンのすべてを学習させるような Widrow らの手法や数学的な前処理も行わず、小規模なネットと簡単な学習法で、任意の回転パターンが認識できる複写学習モデルを提案する。

複写学習モデルとは、3層ネットの一部分だけを用いて、基本パターンだけを通常の誤差逆伝播(BP)法で学習し、得られた重みとバイアスの値を、未使用の

[†] 福岡工業大学工学部情報工学科

Department of Communication and Computer Engineering, Faculty of Engineering, Fukuoka Institute of Technology

^{††} 熊本大学工学部電気情報工学科

Department of Electrical Engineering and Computer Science, Faculty of Engineering, Kumamoto University

部分ネットに、ある規則に基づいて複写し、ネット全体で任意の回転パターンを認識するものである。複写学習モデルには、すでに、位置ずれならびに 90 度ごとの回転パターンが認識できるモデル⁵⁾とそのモデルを拡張して任意に回転したパターンも認識できるモデル⁶⁾がある。しかし、これらのモデルは回転の影響が除去されておらず、汎化力も明らかではなかった。そこで、提案するモデルは、回転の影響を完全に除去するために、正方の基本入力メッシュを任意に回転させ、回転前と後のメッシュの重なり面積比から、複写すべき重みを算出し、未使用の部分ネットに複写する手法を用いた。その結果、複写学習モデルの認識時では、基本パターンと任意の回転パターンの出力値が完全に一致する不变性が部分ネット上に生成された。また、本モデルが何度ごとの複写を行えば、その間の未学習パターンも認識できるかということも明らかにした。

本論文は、従来モデル^{1)~3)}との性能比較を行い、提案モデルが、ネット規模が小さく、構造も簡素で、学習ならびに認識時間も大幅に短縮されることを示す。また、従来モデルでは不可能だった角度の認識も可能なことを示す。以下、2 章では提案モデルのネット構造と学習法を示す。3 章では提案モデルと従来モデルの実験について示す。4 章では実験結果を基に従来モデルと性能比較を行い、提案モデルの有効性を示す。5 章はまとめと今後の課題を示す。

2. 複写学習モデル

2.1 ネットワーク構造

ここでは、任意の回転パターンが認識できる複写学習モデルとして、図 1 のような 20 度ごとのモデルを取り上げる。なお、図 1 のモデルですべての回転パターンが認識できることについては、3.2 節にて述べる。図 1 の入力層 IN は、 N^2 個のユニットからなり、入力パターンを表現するための $N \times N$ の正方メッシュに対応する。隠れ層と出力層は、18 個のユニットグループに分かれ、それぞれ 20 度ごとの回転角に対応する。各隠れ層 H_i ($i=0, 1, \dots, 17$) のユニット数 L は、記憶させたいパターン数に依存する。各出力層 O_i ($i=0, 1, \dots, 17$) のユニット数 M は、基本パターン数に等しい。IN から H_i の一つのユニットグループへの結合の重みを WH_i ($i=0, 1, \dots, 17$) とする。

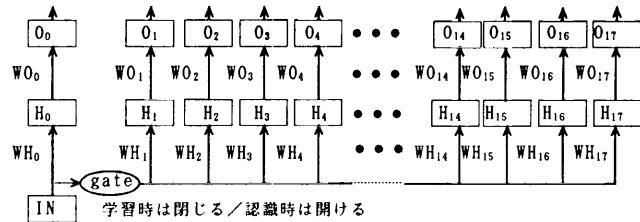


図 1 20 度ごとの回転パターンを認識する複写学習（並列認識）モデル
Fig. 1 The Copy-learning/parallel-recognizing model recognizing rotated pattern at 20° intervals.

(a) 基本入力メッシュ (b) 回転メッシュ
(a) basic input mesh (b) rotation mesh

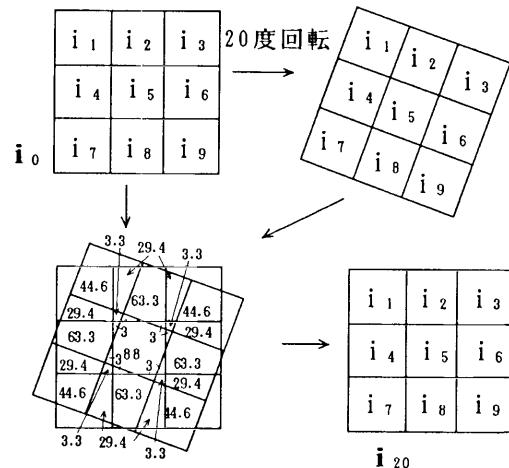


図 2 基本入力メッシュと回転メッシュの重ね合わせ
Fig. 2 Weight superimpose between basic input mesh and rotation mesh.

る。 WH_i は $N^2 \times L$ 次元のベクトルとなる。 H_i から O_i への結合の重みを WO_i ($i=0, 1, \dots, 17$) とする。 WO_i は $L \times M$ 次元のベクトルとなる。 H_i と O_i のユニットグループの各バイアスベクトルを、それぞれ BH_i , BO_i ($i=0, 1, \dots, 17$) とする。

2.2 複写学習法

学習時は図 1 のゲートが閉じられ、IN, H_0 , および O_0 からなる部分ネットが、BP 法により基本パターンだけを学習する。

次に、以下の手順 [S1], [S2] で複写を行う。なお、複写の手法をわかりやすく説明するため、 $N=3$, $L=1$ とし、図 2 のような基本入力メッシュを右 20

度回転させ、回転前と後のメッシュの重なり具合を示したもの用いる。なお、同図(c)の各数値は回転後のメッシュが基本入力メッシュに対してどれだけ重なっているかを面積比で表したものである。ここで、基本パターンを i_0 、 r 度の回転パターンを i_r と表す。 i_0 と i_r は共に N^2 次元の縦ベクトルとなる。ここで扱

$$\begin{aligned} \mathbf{T}_{20} = & \begin{vmatrix} .446 & .000 & .000 & .294 & .000 & .000 & .000 & .000 & .000 \\ .294 & .633 & .000 & .033 & .030 & .000 & .000 & .000 & .000 \\ .000 & .294 & .446 & .000 & .000 & .000 & .000 & .000 & .000 \\ .000 & .000 & .000 & .633 & .030 & .000 & .294 & .033 & .000 \\ .000 & .030 & .000 & .030 & .880 & .030 & .000 & .030 & .000 \\ .000 & .033 & .294 & .000 & .030 & .633 & .000 & .000 & .000 \\ .000 & .000 & .000 & .000 & .000 & .000 & .446 & .294 & .000 \\ .000 & .000 & .000 & .000 & .030 & .033 & .000 & .633 & .294 \\ .000 & .000 & .000 & .000 & .000 & .294 & .000 & .000 & .446 \end{vmatrix}, \quad i_0 = \begin{vmatrix} i_1 \\ i_2 \\ i_3 \\ i_4 \\ i_5 \\ i_6 \\ i_7 \\ i_8 \\ i_9 \end{vmatrix} \end{aligned}$$

ここで、 \mathbf{T}_{20} は図 2(c)から求めたもので、“回転パターン生成行列 (N^2 行 N^2 列)”と呼ぶ。 \mathbf{T}_{20} の行は図 2(a)の基本入力メッシュの i_1, i_2, \dots, i_9 に対応し、列は同図(b)の回転メッシュの i_1, i_2, \dots, i_9 に対応する。 \mathbf{T}_{20} の算出を図 2(c)から述べる。1 行目は、基本入力メッシュの i_1 は回転メッシュの i_1 と i_4 の二つが重なっているため、その面積比から、1 列に 0.446 と 4 列に 0.294 を定める。それ以外の列は重なりがないため 0 とする。2 行目では、基本入力メッシュの i_2 に対して、回転メッシュの i_1, i_2, i_4, i_5 が重なり、1, 2, 4, 5 列に 0.294, 0.633, 0.033, 0.030 を定める。以下 9 行目まで、図 2(c)の面積比から行列の各要素を決める。なお、回転パターンは基本入力メッシュからはみ出さないようなフォントを用いる。したがって、図 2(c)の両メッシュが重ならない部分は切り捨てる。

上記の方法で \mathbf{T}_{20} を求め、式(1)の演算を行えば、20 度回転したパターンが生成される。なお、 \mathbf{T}_{20} は基本入力メッシュと 20 度回転したメッシュ間に對してのみ成り立つもので、40 度回転には利用できない。すなわち、 r 度の回転に対して、 $i_r = \mathbf{T}_r \cdot i_0$ は成り立つが、 $2 \cdot r$ 度の回転パターンに対して、 $i_{2r} = \mathbf{T}_{2r} \cdot i_0$ は成り立たない。したがって、回転角度(r)が変われば、再度、 \mathbf{T}_r を算出しなければならない。しかし、0 ~ 90 度間の \mathbf{T}_r を算出するだけでよい。それ以降の回転角度に対しては、90 度ごとの回転ならびに複写(パターンの重みの転送のみで、回転パターンの生成が可能⁵⁾、また、入力層と隠れ層間の重みを転送するだけで複写が可能⁵⁾ が利用できるからである。

う回転パターンは図 2(c)に示すようなメッシュの重なりの面積比から算出したものである。 r 度回転したパターンは、式(1)で表される。

$$i_r = \mathbf{T}_r \cdot i_0 \quad (1)$$

$N=3, r=20$ とすると、

$$i_0 = \begin{vmatrix} i_1 \\ i_2 \\ i_3 \\ i_4 \\ i_5 \\ i_6 \\ i_7 \\ i_8 \\ i_9 \end{vmatrix}$$

図 3(a)(b) は、 10×10 のメッシュで表した基本パターンと 100 行 100 列の \mathbf{T}_{20} を用いて作成した 20 度ごとの回転パターンの一例である。

[S1] 学習で得られた \mathbf{WH}_0 の重みを式(2)を用いて未使用の \mathbf{WH}_i へ複写する。

$$\mathbf{WH}_i = \mathbf{R}_r \mathbf{WH}_0 \quad (i=1) \quad (2)$$

$N=3, r=20$ とすると、

$$\mathbf{R}_r = (\mathbf{T}_{20}^{-1})^T$$

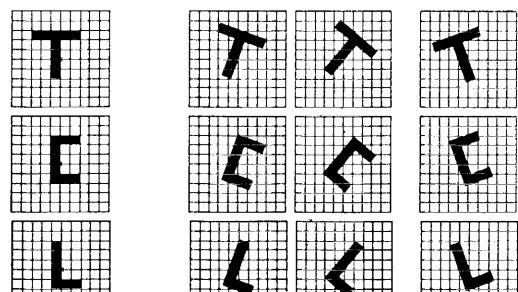
ここで、 \mathbf{R}_{20} は \mathbf{T}_{20} の逆行列を転置したもので、“回転複写行列 (N^2 行 N^2 列)”と呼ぶ。 \mathbf{R}_r の算出については、2.3 節にて説明する。

[S2] 次に、 $\mathbf{WO}_0, \mathbf{BH}_0$ ならびに \mathbf{BO}_0 を、式(3)~(5)のように複写する。

$$\mathbf{WO}_i = \mathbf{WO}_0 \quad (i=1, 2, \dots, 17) \quad (3)$$

$$\mathbf{BH}_i = \mathbf{BH}_0 \quad (i=1, 2, \dots, 17) \quad (4)$$

$$\mathbf{BO}_i = \mathbf{BO}_0 \quad (i=1, 2, \dots, 17) \quad (5)$$



(a) 基本パターン
(a) standard patterns
(b) 20°ごとの回転パターン
(b) rotate patterns at 20° intervals

図 3 実験で用いたパターン
Fig. 3 Character patterns used in experiment.

一方、認識時には図1のゲートが常に開かれており、ネット全体で入力パターンを処理する。出力層の各ユニットグループのうち、一つのユニット出力値が1に近く、残りすべてが0に近い値が出力されたユニットグループが正しい認識結果を示す。以下、このような出力パターンを“逆T字形出力”と呼ぶ。入力パターンの回転角度が $20 \cdot i$ ($i=1, 2, \dots, 17$) 度ならば、出力層のユニットグループ O_i に逆T字形出力が現れ、回転角度がわかる。

また、複写学習モデルは、出力層を1個にして、入力層と隠れ層間に、18個のゲートを設ければ、逐次的な処理で回転パターンの認識ができる。このようなモデルを逐次認識モデル⁵⁾と呼ぶ。このモデルは式(5)の複写が不要で、ネット規模も小さくできるが、平均認識時間は長くなる。

ここで、複写学習を用いて、任意に回転したパターンを認識する方法としては、部分ネットごとに20度ごとの回転パターンを学習させることでも可能である。しかし、この場合は、学習ごとに回転パターンを逐次生成するか、あるいはメモリから逐次読み出すか、いずれも手間がかかり、18倍の学習負荷も負わなければならない。これも基本パターンが少なければよいが、多くなれば膨大な学習パターン数と学習時間要する。

2.3 回転複写行列の算出

複写学習モデルの各部分ネットは式(3)～(5)のようにネット条件と同じにしている。このようなネットで、回転パターンを認識するためには、基本パターンを入力したときの隠れユニット H_0 の入力積和 S_0 と $r (=20 \cdot i)$ 度の回転パターンを入力したときの H_i ($i=1, 2, \dots, 17$) の入力積和 S_r を等しくなるようにしなければならない。式(2)で導入した \mathbf{R}_r は、 $S_0=S_r$ の条件から算出したものである。 \mathbf{R}_r の算出法を以下に示す。

基本パターン \mathbf{i}_0 を入力した場合の H_0 への S_0 は、

$$S_0 = \mathbf{W} \mathbf{H}_0^T \cdot \mathbf{i}_0 \quad (6)$$

であり、 r 度の回転パターン \mathbf{i}_r を入力した場合の H_i ($i=1, 2, \dots, 17$) への S_r は、

$$S_r = \mathbf{W} \mathbf{H}_i^T \cdot \mathbf{i}_r \quad (7)$$

である。ここで、式(7)に(1), (2)を代入すると、 S_r は、

$$\mathbf{R}_r^T \cdot \mathbf{T}_r = \mathbf{E} \quad (\mathbf{E}: \text{単位行列}) \quad (8)$$

のときに、 S_0 と等しくなる。したがって、式(8)から、 \mathbf{R}_r は、

$$\mathbf{R}_r = (\mathbf{T}_r^{-1})^T \quad (9)$$

となる。この \mathbf{R}_r を導入した複写学習モデルは、 r 度回転したパターンを提示したときの出力値と基本パターンを提示したときの出力値が完全に一致する。

2.4 追加学習

複写学習モデルは、[S1] と [S2] の複写だけでは、テストパターンと複写学習を受けたパターン間の重なりが大きい（ハミング距離で3以下程度）場合には、誤認識をすることがある。例えば、“M”と“N”的パターンは、どちらか一方を回転させれば、重なりが大きくなる。誤認識が発生する要因としては、本来、ネットワークに正しく認識すべきパターンと、誤認識したパターンとの区別が十分に学習されていないからである。したがって、誤認識が発生したならば、そのネットワーク状態から、次の追加学習^{5), 6)}を行う。

誤認識したパターンのどちらか一方を、基本パターンに含めて再度、 \mathbf{IN} , H_0 , O_0 の部分ネットを用いて、BP 学習を行う。このとき、追加したパターンに対する教師パターンは、出力層 O_0 の複数のユニットに対して、なるべく0に近い値を与える。追加パターンが複数あれば、教師パターンも重ならないように与える。追加の学習が完了すれば、再度、[S1] と [S2] の複写を行う。このような処理を施した複写学習モデルは、誤認識を完全に解消できる。追加学習の実験結果とその効果については、文献 5), 6) に譲る。

なお、回転を受けたパターンが、他のパターンと完全に重なる場合の学習と認識については、4章にて考察する。

3. シミュレーション実験

3.1 実験内容と目的

[実験1] 複写学習モデルが何度ごとに複写学習を行えば、その間の未学習の回転パターンも認識できるかを調べる。これにより、本モデルの汎化力が明らかになり、任意の回転パターンも認識できるネットモデルが実現できる。

[実験2] 比較のため、従来モデルとして Widrow らのスクランブルモデル^{1), 2)}と制約付き3層 BP モデル³⁾に90度ごとの回転パターンの学習ならびに認識テストを行う。

実験では 10×10 の正方メッシュで表現された図3のようなパターンを用いた。実験はニューラルネットワークシミュレータ SunNet を用いて S-4/EC 上で行った。パラメータとしては、学習率 0.25, モーメ

ンタム 0.9, 重みとバイアスの初期値の分散を 0.5 とした。学習完了判定は、全訓練パターンに対して、平均誤差自乗が 0.001 以下に達したときとした。

3.2 実験結果

実験では、学習（基本）パターン数が 26 個で、認識テストとして、任意の 5 文字を選び、それらのパターンを 10 度ごとに回転させたものを用いた。実験 1 の認識結果の一例を表 1 に示す。表 1 は、20 度ごとの回転複写行列をそれぞれ算出して、各回転角の複

表 1 10° ごとの回転パターンの出力結果

Table 1 The results of output of the rotated patterns at 10° intervals.

| 提示 パターン (°) | 出力層の出力値 | | | 出力層ユニット グループ O _i (角度) O _i (0°) * |
|---------------------|--------------------|--------------------|--------------------|---|
| | O _i [T] | O _i [C] | O _i [L] | |
| L (0°) | .0067 | .0071 | .9723 | O ₀ (0°) * |
| | .0067 | .0066 | .9320 | O ₁ (20°) |
| L (10°) | .0067 | .0250 | .9263 | O ₂ (40°) |
| | .0066 | .0075 | .9312 | O ₀ (0°) |
| L (20°) | .0067 | .0066 | .9658 | O ₁ (20°) |
| | .0066 | .0087 | .9403 | O ₂ (40°) |
| L (30°) | .0067 | .0104 | .9497 | O ₀ (0°) |
| | .0067 | .0071 | .9723 | O ₁ (20°) * |
| L (40°) | .0066 | .0066 | .9200 | O ₂ (40°) |
| | .0067 | .0271 | .8800 | O ₁ (20°) |
| L (50°) | .0067 | .0184 | .9649 | O ₂ (40°) |
| | .0066 | .0066 | .9693 | O ₃ (60°) |
| L (60°) | .0067 | .0014 | .9131 | O ₁ (20°) |
| | .0066 | .0071 | .9723 | O ₂ (40°) * |
| L (70°) | .0066 | .0079 | .9563 | O ₃ (60°) |
| | .0067 | .0066 | .9100 | O ₁ (20°) |
| L (80°) | .0067 | .0066 | .9358 | O ₂ (40°) |
| | .0066 | .0066 | .9700 | O ₃ (60°) |
| L (90°) | .0067 | .0650 | .9442 | O ₂ (40°) |
| | .0066 | .0071 | .9723 | O ₃ (60°) * |
| R (0°) | .0066 | .0066 | .9693 | O ₄ (80°) |
| | .0067 | .0050 | .9290 | O ₂ (40°) |
| R (10°) | .0067 | .0075 | .9658 | O ₃ (60°) |
| | .0066 | .0066 | .9633 | O ₄ (80°) |
| R (20°) | .0067 | .0250 | .9312 | O ₃ (60°) |
| | .0066 | .0071 | .9723 | O ₄ (80°) * |
| R (30°) | .0066 | .0066 | .9543 | O ₅ (100°) |
| | .0067 | .0250 | .9444 | O ₃ (60°) |
| R (40°) | .0067 | .0071 | .9606 | O ₄ (80°) |
| | .0066 | .0066 | .9574 | O ₅ (100°) |

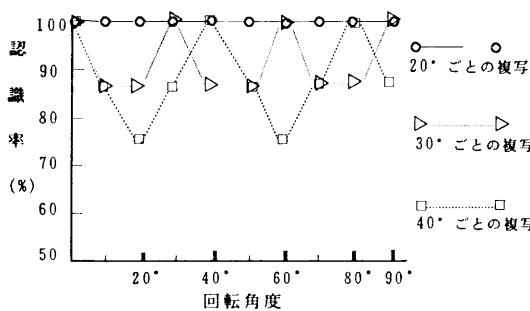


図 4 回転角度と平均認識率の関係

Fig. 4 Relationship between average recognition rate and rotation angle.

写を行い、10 度ごとの回転パターンを提示したときの出力値を表したものである。*印の O_i は複写したパターンに対する認識結果であり、すべて同じ値を示している。これは 20 度ごとの回転複写が完璧に実行されていることを示している。また、10, 30, 50, 70, 90 度の未学習パターンに対しても、汎化力は現れ、ほぼ “L” のパターンと認識できる。

図 4 は、20 度ごと、30 度ごと、ならびに 40 度ごとの回転複写を行い、その間の回転パターンに対する平均認識率を示したものである。未学習の回転パターンに対する認識判定は、出力値の最大値が入力パターンの回転角度に最も近い出力ユニットグループ O_i に現れたときを O_i 周辺の回転パターンを “認識” したとし、現れなかった場合を “誤認識” したとした。また、複写角度の中間に相当する回転パターンを提示したときは、両方の O_i のいずれかに最大値が現れた場合を、認識と判定した。なお、認識率は、ネットワークの初期条件を 5 回変更して実験を行い、その平均値とした。

図 4 から、複写する回転角度は、約 20 度ごとの複写で 0~90 度間の未学習パターンもほぼ認識できることがわかった。90 度~360 度間も図 4 と同様の結果が得られた。なお、複写学習モデルは基本パターンを学習後、回転複写を行い、基本パターンを提示した時点で誤認識が発生する場合がある。このときは、2.4 節で述べた追加学習を行い、誤認識を完全に解消してから、回転複写を行った。しかし、次回からの学習の際に、入力フォントやネットワークの初期条件を変えなければ、初めから追加学習に必要なパターンを学習パターンに含めて学習すればよいため追加学習は不要となる。

また、複写角度が 20 度より小さくなると、汎化能力が強く現れ、未学習パターンに対して、2 カ所以上の O_i に大きな出力値が発生し、認識率は 90~80% 程度に低下した。また、追加学習で認識率の向上を試みたが、改善されなかった。

次に、実験 2 の認識結果は、文献 3) にて報告しているので、その結果を基に次章にて比較検討する。

4. 性能比較

複写学習モデルと従来モデルを比較する。公平な比較を行うため、従来モデルとしては、提案モデルと同様に数学的な前処理を行わず、回転パターンを直接に取り扱っている Widrow らのモデル^{1),2)} と、著者ら

表 2 各ニューラルネットワークモデルの比較
Table 2 Comparison of respective neural network models.

| 項目 | 複写学習モデル | | Widrow らの スクランブルモデル | 制約付き 3 層 BP モデル |
|----------------------|------------------------|-----------------------|---|-----------------------|
| | 並列認識 | 逐次認識 | | |
| ユニット数 入力層 | $N^2 : 25$ | $N^2 : 25$ | <固定ネット> $N^2 : 25$ 2 層 $4N^2 : 100$ 3 層 $N^2 : 25$ | $N^2 : 25$ |
| 隠れ層 出力層 | $4L : 16$ $4M : 40$ | $4L : 16$ $M : 10$ | <可変ネット> 4 層 $L : 4$ 5 層 $M : 10$ | $4L : 16$ $M : 10$ |
| ユニット合計 | 81 | 51 | 164 | 51 |
| 結合数 | 560 | 560 | 2,740 | 560 |
| 基本パターン数 (訓練パターン数) | 10 (10) | 10 (10) | 10 (40) | 10 (40) |
| 追加パターン数 | 3 | 3 | — | — |
| 平均学習 完了時間 (s) | 4.3 | 4.3 | 338 | 28 |
| 追加学習時間 (s) | 0.5 | 0.5 | — | — |
| 複写時間 (s) | 1.0 | 1.0 | — | — |
| 平均認識時間 (ms) | 1 | 4 | 1,611 | 16 |
| 回転角度認識 | 出力層 O_i から可能 | ゲートの切り 替えから可能 | なし | なし |

が提案した制約付き 3 層 BP モデル³⁾を取り上げる。これらのモデルに共通する点は、あらかじめ想定された回転パターンを認識する部分ネットを採用していることである。例えば、Widrow らのモデルでは、固定ネットの 1 層と複数に分割された 2 層間で、制約付き 3 層 BP モデルでは、入力層と複数に分割された隠れ層間で、それぞれ用いられている。すなわち、前者は学習前に、後者は学習時に利用したものである。両モデルに対して、複写学習モデルは任意の回転パターンに対応できるようにするために、学習後に部分ネットを利用したものといえる。

従来のモデル^{1)~3)}は、パターンを正方メッシュで表現する限りでは、90 度ごとの回転だけしか扱えない。したがって、複写学習モデルでも、90 度ごとの回転に限定して性能評価を行う。表 2 に各モデルの比較を示す。ここで、Widrow らのモデルの特徴は文献 1)~3) に譲る。従来モデルは学習に多大な時間を要するので、表 2 では、 N を 5 とし、基本パターン数を 10 個とした。また、隠れユニット数 L は、各モデルの学習が最も早く完了したときのものを用いた。

表 2 から、複写学習モデルの学習時間が大幅に短縮されている。その理由は、従来モデル^{1)~3)}では、基本

パターンから 90 度ごとの回転パターンを混合させて、それらをすべての部分ネットを用いて学習しているからである。それに比べ、複写学習モデルでは一部分のネットだけを用いて、基本パターンだけを学習しているからである。このように複写学習モデルは、90 度ごとの回転に限定しただけでも、格段に優れている。

さらに、従来モデルでは、回転を受けると他のカテゴリに完全に重複するパターン、たとえば “<, ^, >, √” の記号は 90 度ごと回転すると、四つのカテゴリに属するので、学習は大きな値の平均自乗誤差を残したままになる。このときの認識時の出力値は、いずれのパターンでも 0.25 となる。このような低い値では、回転を受けると他のカテゴリに重複するという事前情報がない限り、認識の判別すら困難である。これに比べて、複写学習モデルは基本パターンだけを学習するため、学習は収束し、認識時には 1 に近い出力値が得られる。しかし、回転角度の認識は不可能となる。このような状況では、文脈などを考慮しない限り、人間でも正しい認識は不可能であり、複写学習モデルと同様に可能性のあるカテゴリを列挙することしかできない。

5. まとめ

本論文は、基本パターンを学習するだけで、それらが任意に回転を受けたパターンとその回転角も認識できる複写学習モデルを提案し、実験によりその有効性を示した。実験から、任意の回転パターンを認識するためには、約 20 度ごとの複写学習モデルを実現しておけばよいことがわかった。

Widrow らのモデル¹⁾では、位置ずれ・回転・拡大縮小、すなわち相似変換がメッシュ単位ならびに 90 度単位であるのに対し、複写手法は、基本メッシュと回転メッシュの重なった面積比を用いているため、任意の相似変換を受けたパターンに対しても容易に適用できることが予想される。任意の相似変換を受けたパターンを認識するモデルを構築するのが、今後の課題である。

謝辞 本研究は平成 5 年度文部省科学研究費の補助によった。

参考文献

- 1) Widrow, B., Winter, R. G. and Baxter, R. A.: Layered Neural Nets for Pattern Recognition, *IEEE Trans. Acoust., Speech & Signal Process.*, Vol. ASSP-36, No. 7, pp. 1109-1118 (1988).
- 2) 福見, 細川, 大松: ニューラルネットワークによる位置ずれ・回転に不变なパターン認識システム, 電学論 C, Vol. 110-C, No. 3, pp. 148-155 (1990).
- 3) 荒屋, 須崎, 麻生: 回転パターンを学習認識するニューラルネットワーク, 電学論 C, Vol. 111-C, No. 5, pp. 202-208 (1991).
- 4) Carpenter, G. A. and Grossberg, S.: The ART of Adaptive Pattern Recognition by a Self-organization Neural Network, *IEEE Computer*, Vol. 21, No. 3, pp. 77-88 (1988).
- 5) 須崎, 荒屋, 中村: 位置ずれ・回転パターンを認識するニューラルネットワーク, 情報処理学会論文誌, Vol. 34, No. 11, pp. 2277-2281 (1993).
- 6) Suzuki, K., Araya, S. and Nakamura, R.:

A Copy-Learning Model for Recognizing Patterns Rotated at Various Angles, *Trans. IEICE*, Vol. E 76-A, No. 7, pp. 1207-1211 (1993).

- 7) 須崎, 荒屋, 中村: ニューラルネットワークによる回転パターンの学習認識, 電学論 C, Vol. 112-C, No. 9, pp. 561-567 (1992).

(平成 5 年 12 月 15 日受付)

(平成 6 年 3 月 17 日採録)

須崎 健一 (正会員)



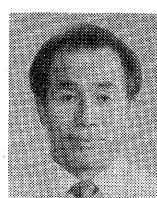
昭和 47 年日本大学理工学部電気工学科卒業。昭和 52 年東京電機大学大学院修士課程修了。昭和 47 年防衛大学校助手。昭和 55 年福岡工業大学講師。平成元年同助教授。ニューラルネットの研究に従事。電子情報通信学会、電気学会各会員。

荒屋 真二 (正会員)



昭和 47 年東北大学工学部通信卒業。同年三菱電機(株)入社。昭和 60 年福岡工業大学助教授。平成元年同教授。工学博士(東大)。人工知能の研究に従事。昭和 57 年電気学会論文賞受賞。電気学会、電子情報通信学会、人工知能学会、IEEE 各会員。

中村 良三 (正会員)



昭和 39 年防衛大学校応用物理専攻卒業。昭和 43 年熊本大学大学院電気工学専攻修士課程修了。中部電力(株)を経て、昭和 50 年熊本大学工学部勤務。現在、同工学部電気情報工学科教授。工学博士。データ構造とアルゴリズムの設計と解析、計算機言語、推論処理などに興味を持つ。電子情報通信学会、電気学会各会員。