

## ファジィ推論アーキテクチャに基づくニューラルネットのVTRテープ走行系調整工程への適用

高木, 英行  
松下電器産業株式会社中央研究所

鈴木, 規之  
松下電器産業株式会社FA技術研究所

<https://hdl.handle.net/2324/4377861>

---

出版情報 : Journal of Japan Society for Fuzzy Theory and Systems. 3 (4), pp.810-818, 1991-11-15. Japan Society for Fuzzy Theory and Intelligent Informatics  
バージョン :  
権利関係 :




**論文**

# ファジイ推論アーキテクチャに基づくニューラルネットのVTRテープ走行系調整工程への適用<sup>†</sup>

高木 英行<sup>\*1</sup> 鈴木 規之<sup>\*2</sup>

ファジイ推論アーキテクチャに基づくニューラルネット(NARA)を現実世界の問題に適用し、性能を評価する。システムの初期設計時の安全性を保持しつつ適応性を実現するためには、論理性と学習機能の2点をシステムに併せ持たせることが必要であることを述べる。そして論理性をニューラルネット(NN)の構成に反映させたNARAがこの条件を満たし得るシステムであることを述べる。評価実験はVTRテープ走行系の自動調整を行なうルールベースシステムの入出力データを用い、従来の単一NNとNARAとの性能比較を行なった。この結果、1653個の学習データに対して2.2%の認識誤りを1.4%に、1653個の未学習データに対して4.6%の認識誤りを3.9%に減少させることができた。さらに、ファジイ論理導入の評価、認識誤り傾向の解析、現行システムとの比較評価などについて考察した。最後に適応化実現の研究に於ける本論文の位置付けと今後の展開を示す。

**キーワード：**ニューラルネット、ファジイ制御、融合化技術、工場自動化、応用

## 1. はじめに

生産工程では各種ロボットの導入で自動化が図られ、生産性の向上のみならず品質の均等化に大いに貢献している。しかしながら最終検査工程では熟練者による官能検査に頼る場合がまだ多く、自動化が遅れている。この理由の1つは、不良品のパターンは極希にしか起きてないので、不良品パターンをすべて事前に用意することができないことによる。このような場合、単なるパターンマッチングでは対応できない。不良品パターンの不足に対しては論理で補う必要がある。このような例として、ルールベースシステムをVTRテープ走行系の検査・調整工程へ適用しこの工程の自動化が図られている<sup>[1]</sup>。

自動化の次の課題は、適応化である。生産現場

では生産機種を切り替えた場合、検査・調整の制御ルールを修正する必要が生じる。現在では、ルールベースシステムの開発者がこの修正を行なっているが、敏速な対応をするためには、現場での生産者が機種の違いによる判定誤りのサンプルを学習データとして自動調整装置に提示するだけで徐々に検査・調整ルールが自動的に修正される学習型自動調整が望まれる。このような学習型機能の実現としてニューラルネット(NN)の導入が数多く検討されている<sup>[2]</sup>。しかし、一から学習し直すのでは時間効率が悪いばかりでなく、本来の設計と異なったルール・論理が生じる恐れがあり、安全性からも問題がある。つまり学習機能だけでなく初めに設計した論理性の大枠が保持できる機能も必要である<sup>[3]</sup>ので、ルールベースシステムを単に通常のNNに置き換えるだけでは問題がある。

本論文ではこの将来実現すべき学習による自動調整への取りかかりとして、論理性をファジイ推論アーキテクチャで表わし得、かつNNの学習機能も持つ、NARA (Neural-networks designed on Approximate Reasoning Architecture<sup>[4]</sup>)

<sup>†</sup> Application of Neural-networks designed on Approximate Reasoning Architecture to the Adjustment of VTR Tape-Running Mechanisms

Hideyuki TAKAGI and Noriyuki SUZUKI

\*1 松下電器産業株式会社 中央研究所  
Central Research Laboratories, Matsushita Electric Industrial Co., Ltd.

\*2 松下電器産業株式会社 FA技術研究所  
FA Engineering Laboratory, Matsushita Electric Industrial Co., Ltd.

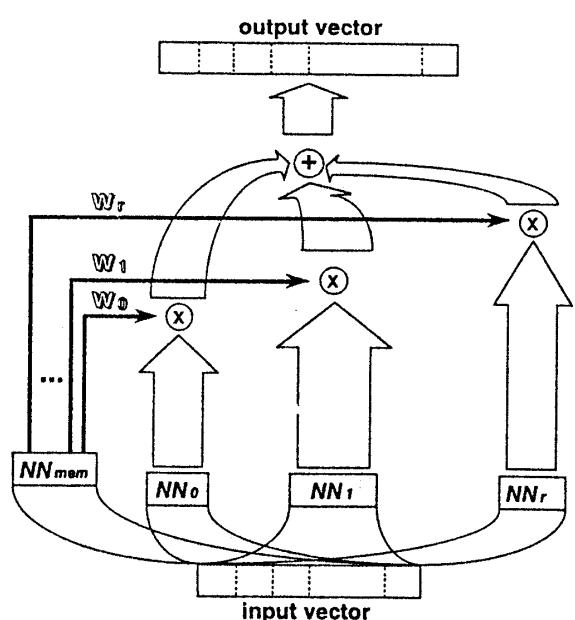
を取り上げる。NARAを本論文で初めて具体的課題に適用して通常のNNとの性能比較を行うことで、将来の適応性実現に向けた第一歩としての導入手法の有効性を示す。

## 2. ファジイ推論アーキテクチャに基づくNN<sup>[4]</sup>

NARAは構造化NNの一種で、IF-THEN形式のファジイ推論ルールに基づいて複数のNNが構成されたものである。**Fig.1** にNARAの一般的構造を示す。**Fig.1**において、 $NN_{mem}$ が複数のルールの前件部に相当し、各ルールのメンバーシップ値を出力する。その他のNNは各ルールの後件部に相当する。例えばn番目のルールは次のように表わされる。

$$\text{IF } \vec{x} \text{ is } A_n, \quad \text{THEN } \vec{y}_n = N_n$$

ここで、 $\vec{x}$ は入力ベクトル、 $\vec{y}_n$ はn番目のルールの出力ベクトル、 $A_n$ は入力特徴量パラメータ空間上のn番目のルールに相当するサブ空間でファジイ集合で表わされる。 $N_n$ は**Fig.1**の $NN_n$ の出力層からの出力ベクトルである。入力ベクトル $\vec{x}$ がサブ空間 $A_n$ に帰属する度合 $W_n$ は、 $NN_{mem}$ の出力層の(n-1)番目のユニットが出力する。



**Fig.1** Neural-networks designed on Approximate Reasoning Architecture

次にNARAの長所と残された課題について述べる。長所はIF-THEN形式に従ってNN内部を解析することによって、性能改善のための手がかりが得易い点にある。通常のNNでは獲得した論理が重み係数という形で分散して表現されているため、性能改善をするための手がかりが得にくいという問題があった。それに対しNARAは、前件部や各ルールの後件部に対応するNNが部品としてシステム全体を構成しているので、ファジイ推論ルールに従ってシステムを解析することによってどのNNが問題であるかを特定することができる。従ってその問題の部分のNNのみに対策を施すことによって、他の部分の特性を変えることなく全体の性能を向上させることができる。これは論理を直接的に表現できないという従来のNNの課題をクリアできる可能性を持っていることを意味する。さらに全体を一から学習し直さず特定の部分のみ修正できるということは、基本的な制御ルールの大筋を保持しながら、生産機種切り替えに伴う部分的な違いを学習機能で修正するという、適応性を実現できる可能性を持っている。

一方課題としては、文献[4]で人工的な問題に対して適用し原理的な性能の可能性が示されているだけで、現実の課題に対してまだ適用されていない点にある。本論文は具体的課題に対するNARAの最初の適用を示すものである。

## 3. NARAの適用システム

### 3.1 VTRテープ走行系の調整

テープと磁気ヘッドとの位置関係を一定に保つために、テープ走行系規制ポストの自動位置調整システムが実現されている<sup>[1]</sup>。本論文ではこのルールベースシステムのデータを用いて、NARAの評価を行なう。

初めにVTRテープ走行系調整について説明する。従来、熟練者は走行させたテープの規制状態を、規制ポスト付近のテープのたわみ量を目視することで判断し、そのたわみ量が所定の状態になるまで調整ドライバーを微妙にコントロールしながら回していた。この熟練者の検査・調整作業に

おける「目視官能判断」をルールベースシステムに置き換えることで、検査・調整工程の自動化が実現された。

Fig.2 に調整部の構成を示す。縞パターンを描いたボードに光を当てるとその縞パターンはテープ表面に投影する。視覚認識装置はテープに投影された縞パターンのゆがみをCCDカメラで入力し、画像処理で解析して規制ポスト付近のテープのたわみ情報を抽出する。調整アクチュエータは傾斜ポストの角度とたわみ情報を基づいて傾斜ポストの角度を変化させ、規制状態の調整を行う。

### 3.2 テープたわみパターンからの特徴抽出

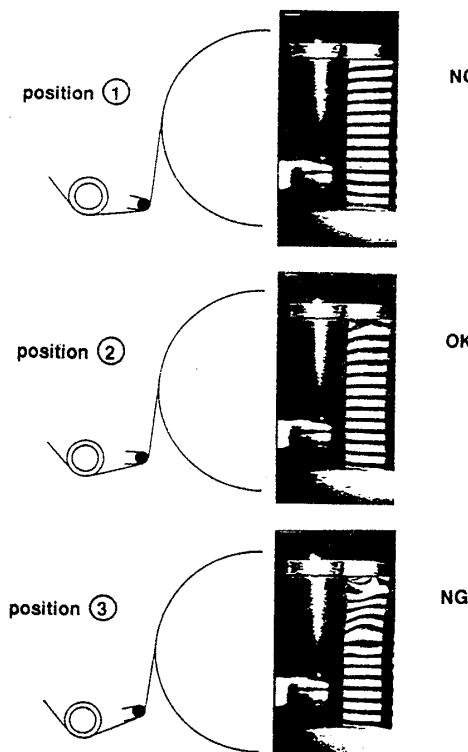


Fig.3 Relationship between the position of inclined base unit and warping pattern on video tape

Fig.2 のCCDカメラで得られたたわみの縞パターンをFig.3 に示す。規制ポストの規制がかかり過ぎ(ポジション1)ても規制が足りなく(ポジション3)ても調整が必要で、ポジション2の丁度良い規制状態になるよう調整する。特徴量の抽出は、Fig.3 の入力パターンに対し、Fig.4 に示す10本のたわみ検出ライン上で、縞パターン間の距離(ピッ

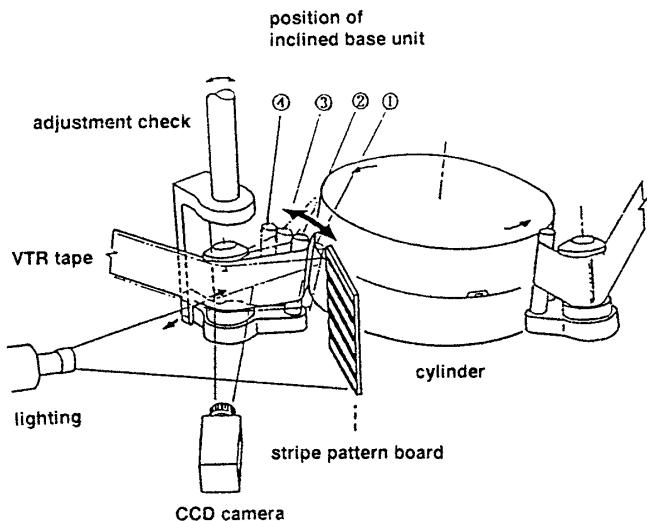


Fig.2 Adjustment part of VTR tape-running mechanisms

チ)を計算することから始める。次に、縞パターンピッチ長が標準であるかどうかを分類する。ここで標準ピッチ長とは、ゆがみがなく縞パターンが等間隔に並んでいる部分の縞と縞との幅のことである。標準ピッチより長いピッチおよび短いピッチがテープの2次元的分布(Fig.4)上でどのように分布しているかという情報から、テープたわみの境界・大きさ・重心位置・面積など6種類のたわみ特徴量を算出する。この6次元データが実験システムへの入力になる。

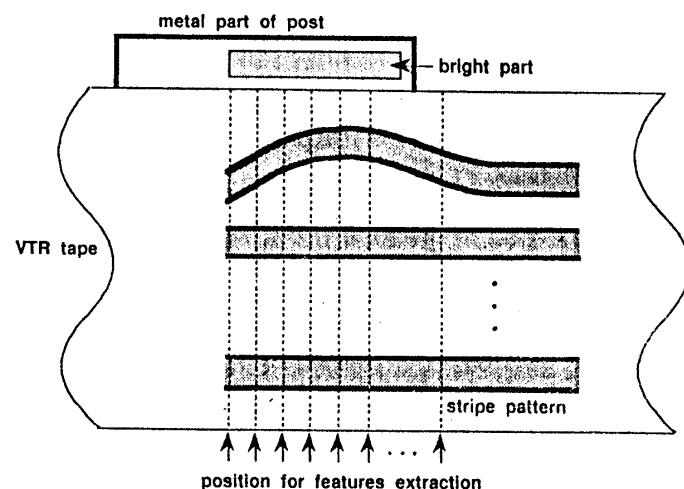


Fig.4 Detection of tape warping pattern

### 3.3 ルールベースシステムによる自動調整<sup>[1]</sup>

熟練者は縞パターンを10種類程度に分類し、良好の判定と調整を行なっている。そこで熟練者の縞パターン分類と3.2で求めた6次元特徴空間での入力ベクトルの分布との対応をルールで記述し、各縞パターンに対応した傾斜ポストの調整量を制御量として出力するファジィ制御ルールを設計する。この現行のルールベースシステムでは後件部が定数である推論法<sup>[5]</sup>を修正した方法を用いているが、詳細は文献[1]に譲る。この現行システムの出力が4.の実験システムの教師データとなる。

このVTRテープ走行系の自動調整装置は、現在当社VTR製造ラインで実稼働中である(Fig.5とPhoto.1)。現実のVTRは、同じ縞パターンに対して同じ調整量で傾斜ポストを調整しても、必ずしも同じ状態に調整されない場合がある。これはVTRデッキの個体差によるものである。そこで実運用上では、大きく規制ポストを動かして一気に調整するのではなく、調整が収束するよう少しづつ調整を繰り返して個体差の影響が調整に大きく及ぼないようにしている。そして最大3回まで自動調整を繰り返すシステムになっている。

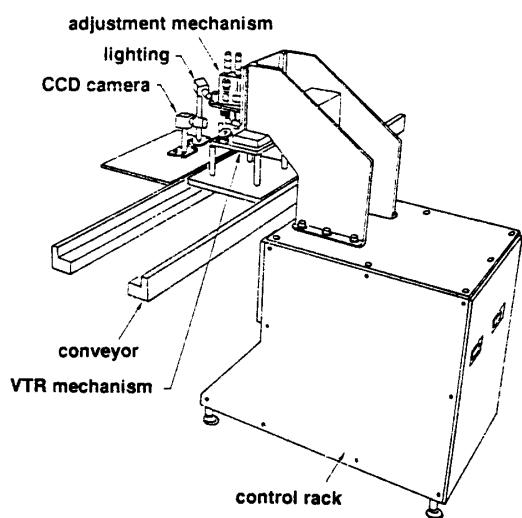


Fig.5 Outline of VTR mechanisms adjustment machine

## 4. VTRテープ走行系調整へのNARAの応用

### 4.1 NNモデルと学習データ

3.で述べた実用システムのデータを用い、NARAの有効性を検討する。

実稼働中の3.のシステムから6次元の入力パターンと調整が成功した時に認識した縞パターンを3306組読みだし、NARAに適用した。これらのデータの奇数番目の1653組を学習用に、偶数番目の1653組を評価用に用いた。この6次元ベクトルが入力データである。この収集データの中には10パターンすべてが含まれているわけではなく、極めて特異な2種類の縞パターンが含まれていなかった。そこでNNが識別すべき縞パターンを8種とし、NARAと通常のNNの最終出力ベクトル次元数も8とした。

NNはすべて3層のfeed-forward型でback-propagationで学習した。各NNの入力層ユニット数は入力特徴量の個数の6であるが、出力層ユニット数は4.2で述べるクラスタリングによって分類されるクラスタ数とパターン数で決まる。中間層ユニット数は性能に依存するので、4.2以降の実験・評価では中間層ユニット数を変化させて評

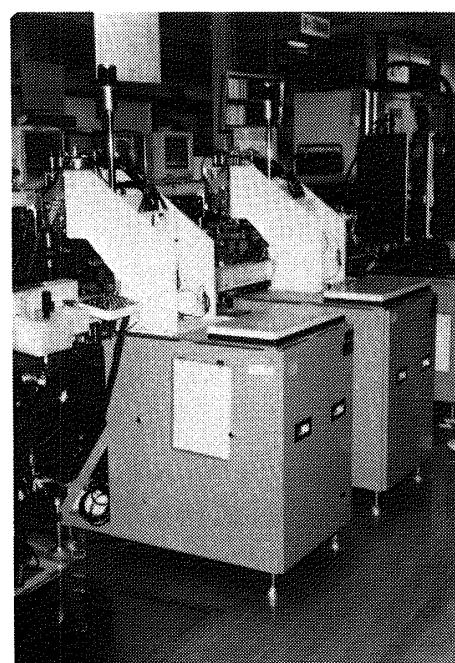


Photo.1 VTR mechanisms adjustment machines that are running in VTR assembly line

価する。そして、未学習データに対して最も認識誤りが小さい値を示した時の性能値を最適性能値と呼ぶことにし、この性能値で評価する。中間層ユニット数はこの最適性能値を示す個数を後述表記する。

#### 4.2 認識実験

##### (a) 従来の単一NNによる認識実験

入力層ユニット数6個、出力層ユニット数8個のNNに1653組の入力パターンを学習データに、認識した縞パターンを教師データにして学習した。中間層ユニット数を16個～24個の間に変化させた結果、Table 5のモデルサイズの時に、Table 4の最適性能値が得られた。

##### (b) NARAによる認識実験

学習データと未学習データと一緒にしてクラスタリングした結果、クラスタの重心間距離<sup>[6]</sup>はTable 1に示すように、大きく2つのクラスに分離されることが判った。そこで、Fig.1の後件部を2つにした(つまり2つのファジィ推論ルールで構成される)NARA(NARA1と呼ぼう)を用いて実験を行なった。

認識率は次のように定義する。NN<sub>mem</sub>の認識率は、NN<sub>mem</sub>の識別結果が2つのクラスのうちクラスタリングで決められた正しいクラスであったかどうかで判定する。初めに未学習データも含めてクラスタリングをしているので、NARAの学習に使わなくてもNN<sub>mem</sub>の未学習データに対する認識率を求めることができる。NN<sub>0</sub>とNN<sub>1</sub>の認識率はクラスタリングで分けられた2つのクラスそれぞれの中での縞パターン識別率で表わす。後述の(c)のNN<sub>mem1</sub>・NN<sub>10</sub>・NN<sub>11</sub>や(d)の実験も同様である。

4.2(a)と同じく中間層ユニット数を7個～17個の間に変化させた結果、Table 5のモデルサイズの時に、Table 4の最適性能値が得られた。なお、Table 1の数値は樹形図<sup>[6]</sup>の枝に相当しているので、各クラスタに対して1つの距離値のみ示してある。

Table 1 Distance between centroids of clusters

| cluster number | 2                  | 3                 | 4                 | 5                 | 6                | 7                |
|----------------|--------------------|-------------------|-------------------|-------------------|------------------|------------------|
| distance       | 289.0 <sup>2</sup> | 30.8 <sup>2</sup> | 29.8 <sup>2</sup> | 11.4 <sup>2</sup> | 6.9 <sup>2</sup> | 1.2 <sup>2</sup> |
|                | 8                  | 9                 | 10                | 11                | 12               | 13               |
|                | 8.0 <sup>2</sup>   | 5.8 <sup>2</sup>  | 10.0 <sup>2</sup> | 5.3 <sup>2</sup>  | 7.4 <sup>2</sup> | 2.1 <sup>2</sup> |

##### (c) NARAの解析と改良

NARAの特長は2.で述べたように内部解析が従来の単一のNNに比較して容易であり、性能向上を図り易い点にある。そこで(b)の内部解析を行い性能の向上が可能かどうかを調べる。(b)のNARA1は前件部に相当するNN<sub>mem</sub>と、後件部に相当するNN<sub>0</sub>とNN<sub>1</sub>から構成されている。この3つのNNの認識性能を個々に検討した結果、Table 2のNARA1に示すように、3つの中ではNN<sub>1</sub>(第2のファジィ推論ルールの後件部に相当)の認識性能が他に比べて若干低いので、ここに改善の可能性がないかを検討する。

Table 2

Recognition rate (%) of each NN composing NARA  
(TRD: training data, UTD: untraining data)

|                    | NARA1 |      | NARA2         |      |
|--------------------|-------|------|---------------|------|
|                    | TRD   | UTD  | TRD           | UTD  |
| NN <sub>mem</sub>  | 99.6  | 98.2 | same as NARA1 |      |
| NN <sub>0</sub>    | 98.7  | 97.1 | same as NARA1 |      |
| NN <sub>1</sub>    | 98.1  | 95.6 |               |      |
| NN <sub>mem1</sub> |       |      | 99.9          | 98.2 |
| NN <sub>10</sub>   |       |      | 98.6          | 95.6 |
| NN <sub>11</sub>   |       |      | 98.4          | 96.1 |

第2のルールが適用されるデータをさらにTable 1のクラスタリング結果で調べてみるとさらに2つ(すなわち、全学習データからみると3つのクラス)に分けることが次に取り得る方法であることが分かる<sup>[4]</sup>。この時3つのファジィ推論ルールに相当するNNを組合せる方法として、並列にルールを並べる方法と、多段に並べる方法が考えられる。NARAではすべての前件部を1つのNN<sub>mem</sub>が表わすので、ルールの並列化を採用する

と、追加ルールだけでなく、 $NN_{mem}$ も学習し直さなければならぬ。更に、 $NN_{mem}$ の学習し直しでファジィ分割領域の形状が変わり得るので、結局後件部のすべてのNNも再学習が必要になる。本研究は単に認識性能を向上させることだけに主眼があるのでなく、1. で述べたような安全性を確保した適応学習を目指しているので、全NNの再学習が必要なこのルールの並列化は問題がある。そこで入力ベクトルがルール2に属していると $NN_{mem}$ が判断したら、さらに2つのルールの後件部に相当する $NN_{10}$ と $NN_{11}$ が多段推論することに相当するよう、Fig.6 のように接続することにした。これをNARA 2と呼ぼう。このNARA 2を用いて認識実験をした。

NARA 1の場合、 $NN_0$ と $NN_1$ の値がメンバーシップ値で重み付けられた後対等に加算される。しかし、NARA 2では旧 $NN_1$ に相当するFig.6 の波線部が2つのNNの出力の和であり、Fig.6 上部の最終的な加算器で単純に加算すると1つの $NN_0$ より2つのNNの加算である波線部の影響が強くなってしまう。そこで、Fig.6 のように各加算後に正規化しておく。なお、本実験の場合は最大値を出力する縞パターン番号が分かればよいので、最終段の正規化は必ずしも必要ではない。

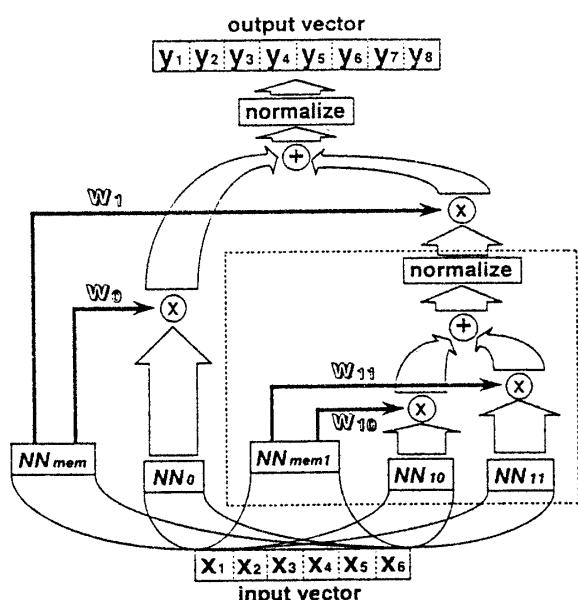


Fig.6 Production type NARA system

4.2(a)と同じく中間層ユニット数を7個~17個の間で変化させた結果、Table 5のモデルサイズの時に、Table 4の最適性能値が得られた。本実験のデータの場合、2つのルール構造にしても3つのルール構造にしても性能は変わらなかった。個々のNNの性能をTable 2に示す。

#### (d) ファジィ論理と2値論理の性能比較

NARAがファジィ推論ルールに基づくのは、前件部に相当する $NN_{mem}$ が入力特徴パラメータ空間をファジィ分割するからである。この $NN_{mem}$ の出力層ユニットの中で最大の出力をするユニット出力値を1、その他のユニット出力を0に強制修正することで、「2値論理推論アーキテクチャに基づくNN」を構成し、NARAとの性能を比較する。実験にはTable 4に示した最適性能値を示すNARA 1とNARA 2を用いて行なった。結果をTable 3に示す。2値論理の推論ルールに基づくNNをNARAと略記するのはおかしいが、便宜上Table 3ではNARAをファジィ論理にした時と2値論理にした場合という表現をとっている。

Table 3 Error rate of fuzzy logic and two-value logic  
( FL: fuzzy logic      2L: two-value logic )

|                 | NARA1 |      | NARA2 |      |
|-----------------|-------|------|-------|------|
|                 | FL    | 2L   | FL    | 2L   |
| training data   | 1.6%  | 1.5% | 1.4%  | 1.5% |
| untraining data | 3.9%  | 4.2% | 3.9%  | 4.1% |

#### 4.3 実験結果と考察

##### (a) NARAと通常のNNとの認識性能評価

4.2の実験結果をTable 4に、Table 4の実験結果を示したモデルサイズをTable 5に示す。データ数が1653個もあることから、Table 4の結果是有意差があり、NARAは通常の大きな1つのNNよりも認識性能が高いと考えられる。通常のNNとNARAとの違いは、IF-THEN形式のルール構造に基づいてNNが構成されているかどうかにある。各々の中間層のユニット数を調整して最適性能値で比較しているので、通常のNNとNARAとの性能差は、ファジィ推論ルールという論理構造をNNに反映したかどうかの違いである。

**Table 4** Error rate of each model

|                 | ordinary NN | NARA1 | NARA2 |
|-----------------|-------------|-------|-------|
| training data   | 2.2%        | 1.6%  | 1.4%  |
| untraining data | 4.6%        | 3.9%  | 3.9%  |

**Table 5** Model sizes of neural networks that compose each model

|             |             | unit number of          |                         |                         |
|-------------|-------------|-------------------------|-------------------------|-------------------------|
|             |             | input layer             | hidden layer            | output layer            |
| ordinary NN |             | 6                       | 22                      | 8                       |
| NARA1       | $NN_{mem}$  | 6                       | 9                       | 2                       |
|             | $NN_0$      | 6                       | 13                      | 8                       |
|             | $NN_1$      | 6                       | 17                      | 7                       |
| NARA2       | $NN_{mem}$  | same as<br><i>NARA1</i> | same as<br><i>NARA1</i> | same as<br><i>NARA1</i> |
|             | $NN_0$      |                         |                         |                         |
|             | $NN_{mem1}$ | 6                       | 15                      | 2                       |
|             | $NN_{10}$   | 6                       | 13                      | 7                       |
|             | $NN_{11}$   | 6                       | 13                      | 5                       |

### (b) ファジィ論理と2値論理との比較評価

各々1653個の学習データと未学習データを用いたので、Table 3の実験結果には±0.1%弱の実験誤差が含まれていると考えられる。このことから、NNへファジィ論理を導入する場合と2値論理を導入する場合とでは、学習データに対しては両者に有意差は無いものの、未学習データに対してはファジィ論理の導入がシステム全体の性能向上に寄与していると言える。これは学習データ分布の形状と未学習データの分布形状が多少異なっていた場合、サブ空間境界面に幅がある方(サブ空間がファジィ集合で表わされる方)が未学習データの誤認識救済に役立つという説明<sup>[3]</sup>に合った実験結果である。4.2(d)の実験では、NARAの $NN_{mem}$ を共通にして出力を処理するかどうかでファジィ論理と2値論理の比較をした。つまり、入力特徴パラメータ空間が分割されている形状は全く同じで、分割されたサブ空間の境界面傾斜のみが異なる実験条件で評価した。従ってTable 3の性能差は、論理に関係しない分割形状の影響は全くなく、分割されたサブ空間がファジィ集合かクリスピ集合かの違いによるものである。このサブ空間の境界面傾斜を如何にNNで制御するかで

更に性能差が生じると考えられるが、これはNNとファジィ理論との融合化技術における今後の課題である<sup>[3]</sup>。

### (c) 認識誤り傾向の解析

次にTable 4の認識誤りの解析をしてみた。通常のNNをNARA 1に置換した時の認識誤りの状況をTable 6(a)に、通常のNNをNARA 2に置換した時の認識誤りの状況をTable 6(b)に示す。通常のNNが起した認識誤りのうちNARAの導入で学習データに対して5~6割、未学習データに対して4割程回復している。しかし割合は少ないものの新規の認識誤りも生じている。この割合はエラーの回復の割合より少ないのでTable 3の性能向上が図られたわけであるが、入力特徴パラメータ空間の分割というルールベースシステムの本質の所で新規の認識誤りが生じていると思われる所以、更に性能を向上させるためには、前述の分割空間の境界面傾斜の制御(これはメンバーシップ関数の設計に関わる)等を通じて今後検討して行く必要がある。

**Table 6**

Analysis of misrecognition of each model

(a) When NARA1 is used instead of an ordinary NN,

|                 | the error number has been reduced | newly added | unchanged |
|-----------------|-----------------------------------|-------------|-----------|
| training data   | 18                                | 8           | 18        |
| untraining data | 32                                | 20          | 44        |

(b) When NARA2 is used instead of an ordinary NN,

|                 | the error number has been reduced | newly added | unchanged |
|-----------------|-----------------------------------|-------------|-----------|
| training data   | 22                                | 9           | 14        |
| untraining data | 33                                | 22          | 43        |

**(d) NARAの現行システムへの適用の有効性検討**

本論文の目的は通常のNNとNARAの性能差を、現実世界の応用問題を通じて比較しNARAの有効性を示すことにある。現在稼働中のVTRテープ走行系調整用ルールベースシステムと性能を比べることが主目的ではないが、NARAを現行システムに導入する場合について多少考察を加えてみる。

システムの評価には、縞パターンの認識率、1回で調整ができる自動調整化率、最大3回までの試行を許す最終システムの自動調整化率がある。現行システムでは、最終システムの自動調整化率のみが評価されており、NARAでは最適認識率のみが評価されている。このように、比較できる共通の評価数値がないことと、既にシステムが稼働中なため評価のためだけに製造ラインを止めることができないため、結論を出すことは早計であるが、次のような期待ができる。すなわち、現行システムが、(1)良品の縞パターンを10種類中1種類ではなく3種類としていること、(2)最大3回までの試行を許し、自動調整化率を高める設計になっていること、(3)規制ポストの移動調整量を少な目にして調整回数を増えてでも必ず収束させることに主眼を置いた設計になっていることを考慮すれば、NARAの最適認識率96.1%と(1)～(3)を組み合わせた最終システムは十分実用に耐える性能

を示すものと期待できる。

**(e) NARAの性能改善について**

Table 1のクラスタ間距離、および、Table 4のNARA1とNARA2の性能を比較すれば、今回のデータに対しては2つのファジィ集合に対応したルール構造にすることで十分である。Table 1のクラスタ間距離だけでも入力空間が大局的に見ると2つに分かれていることが判るが、2.で述べたようにこの分割数を増やしてもNARAは対応可能である。3つに分けたNARA2で評価実験し、NARA1と同等の性能しか示さないことを確認できたからこそ、Table 1の数値を勘案して、今回のデータに対しては2つのルール構造に基づいてNNを構成することで十分であると結論付けられたと言えよう。従来のNNではこのような構造に柔軟性を持たせることが大変困難である。

文献[4]の原理的性能の確認、および、本論文の現実世界の問題への適用で、構造化NNは従来の単一NNより認識性能が高いことが示されたが、認識性能の向上率をみると文献[4]のような劇的な効果は表れていない。これは適用課題が極端な非線形性を持っておらず、従って従来の単一NNでもかなり対応ができたためと考えられる。

**5. 結論**

本論文ではVTRのテープ走行系調整という具体的な課題に対してNARAを適用評価した。その結果、従来のNNに比べ認識性能が高いことが示された。NARAの基本的思想は論理構造をNNへ組み込むことである。本論文はNARAというモデルを用いて、この論理構造の組み込みがNNの性能向上に有効であることを現実の課題に適用して示した。さらに、NNへファジィ論理を導入した場合と2値論理を導入した場合の比較検討、通常のNNとNARAを用いた場合の認識誤りの傾向の検討、現行VTRテープ走行調整システムとの性能比較、などを行なった。

適応性を持った自動化工程の実現の観点からみると、本論文は認識性能面における構造化NNの有効性の証明という第1段階に位置付けられる。

第2段階として取組むべき課題は、NNの学習機能を活かして1.で述べた適応性の実現を図ることである。その後、システムが持つ論理性の大枠を維持したまま環境に応じた論理の部分的な修正、すなわちシステムの安全性も保証される適応性を実現する最終段階へと研究が展開されていくことになる。

### 謝 辞

本論文での実験データの収集にご協力頂きました、当社ビデオ事業部の岡社員と藤原課長、FA技術研究所の岡橋主担当、中央研究所電子機器基礎研究所の木室長に感謝いたします。

### 参考文献

- [1] 鈴木, 岡橋, 岡, 藤原：“ファジィ推論を用いたテープ走行系調整用視覚認識装置”，第6回ファジィ・システム・シンポジウム, pp.415-418 (1990.9)
- [2] 高木英行：“あいまいさと知識情報処理”，システム／制御／情報, Vol.34, No.5, pp.263-273 (1990)

---

### 著者紹介

---



高木 英行 (たかぎ ひでゆき)

松下電器産業株式会社 中央研究所  
電子機器基礎研究所

昭56年九州芸術工科大学修士課程情報伝達専攻終了。同年松下電器産業株式会社入社。同社中央研究所において、Cコンパイラ・音声WPの開発、および音声認識・聴覚モデル等の研究を経て、現在、神経回路網・ファジィ理論等の研究に従事。平成3年よりカリフォルニア大学バークレー校客員研究員。工学博士。昭63電子情報通信学会篠原記念学術奨励賞受賞。日本音響学会、電子情報通信学会、日本ファジィ学会、神経回路学会、IEEE, INNS(国際神経回路網学会)各会員。

- [3] H.Takagi: "FUSION TECHNOLOGY OF FUZZY SYSTEM AND NEURAL NETWORKS, AND ITS STRONG POINTS AND PROBLEMS", Proc. Sino-Japan Joint Meeting on Fuzzy Sets and Systems, D 1-6, pp.1-4, International Academic Publishers, (Oct. 1990)
- [4] 高木, 香田, 小島：“ファジィ推論アーキテクチャに基づくニューラルネット”，日本ファジィ学会誌, Vol.3, No.1, pp.131-144(1991)
- [5] M.Braae and D.A.Rutherford: "Fuzzy relations in a control setting", Kybernetes, Vol.7, pp.185-188 (1978)
- [6] 奥野, 久米, 芳賀, 吉澤：“(改訂版)多変量解析法”, 日科技連(1981)

(1990年12月1日 受付)

(1991年1月29日 再受付)

[問い合わせ先]

Dr.Hideyuki TAKAGI  
Computer Science Division  
University of California at Berkeley  
Berkeley, CA 94720 U.S.A.  
TEL <+1>510-642-8015  
FAX <+1>510-642-5775  
e-mail : takagi@cs.berkeley.edu



鈴木 規之 (すずき のりゆき)

松下電器産業株式会社 FA技術研究所

昭62東京工業大学工学部制御工学科卒業。同年松下電器産業株式会社入社。同社生産技術部門において、パターン認識・画像計測等のロボットビジョンの研究および画像処理装置の開発に従事。