

(19) 日本国特許庁 (J P)

(12) 特 許 公 報 (B 2)

(11) 特許番号

特許第3328953号  
(P3328953)

(45) 発行日 平成14年9月30日(2002.9.30)

(24) 登録日 平成14年7月19日(2002.7.19)

(51) Int.Cl. <sup>7</sup>	識別記号	F I
G 0 6 N 3/00	5 4 0	G 0 6 N 3/00 5 4 0 A
G 0 6 F 9/44	5 5 4	G 0 6 F 9/44 5 5 4 L

請求項の数 3 (全 18 頁)

(21) 出願番号	特願平4-132897	(73) 特許権者	591018497 山川 烈 福岡県飯塚市大字幸袋781番地300
(22) 出願日	平成4年5月25日(1992.5.25)	(72) 発明者	山川 烈 福岡県飯塚市大字幸袋781番地300
(65) 公開番号	特開平5-324599	(74) 代理人	100075258 弁理士 吉田 研二 (外1名)
(43) 公開日	平成5年12月7日(1993.12.7)	審査官	久保 光宏
審査請求日	平成11年5月24日(1999.5.24)		

最終頁に続く

(54) 【発明の名称】 非線形シナプスニューロン、そのデバイス及びそれを用いた予測方法

1

(57) 【特許請求の範囲】

【請求項1】 サンプリングされた時系列信号を受け入れる直列接続された遅延手段と、前記遅延された時系列信号のそれぞれに所望の重み付けを与えるための複数の非線形シナプス手段と、各非線形シナプスの出力を加算する加算手段と、を含み、前記非線形シナプス手段は、入力信号レベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数手段と、各メンバシップ関数手段に接続され対応するメンバシップ関数のグレードで学習の度合いが定められる複数の可変重み付け手段と、を含むことを特徴とする非線形シナプスニューロン。

2

【請求項2】 サンプリングされた時系列信号を受け入れる直列接続された遅延回路と、前記遅延された時系列信号のそれぞれに所望の重み付けを与えるための複数の非線形シナプス回路と、各非線形シナプスの出力を加算する加算器と、を含み、前記非線形シナプス回路は、入力信号レベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数回路列と、各メンバシップ関数回路に接続され対応するメンバシップ関数のグレードで学習の度合いが定められる複数の可変重み付け回路と、を含むことを特徴とする非線形シナプスニューロンデバイス。

10

【請求項 3】 サンプリグされた時系列信号を受け入れ所定量の遅延を与え、前記遅延された時系列信号のそれぞれに非線形シナプスで所望の重み付けを与え、複数の非線形シナプスの出力を加算してサンプリグ時刻先における所望の時刻の時系列信号の値を予測する予測方法であって、

前記非線形シナプスは、前記サンプリグされた時系列信号に基づいて、当該入力信号がレベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数のグレードに応じて可変重み付けを与えたことを特徴とする非線形シナプスニューロンを用いた予測方法。

【発明の詳細な説明】

【0001】

【産業上の利用分野】本発明は非線形シナプスニューロン、特に音声信号、画像信号等の信号予測を効果的に実行するための非線形シナプスニューロンに関するものである。

【0002】

【従来の技術】人間の脳を真似たネットワークを電気的な信号処理として用いるニューラルネットワークがパターン認識、信号処理あるいは知識処理等に利用され、脳のニューロンに対応したユニットが複数個複雑に接続され、各ユニットの動作及びユニット間の接続形態を適当に定めることによってパターン認識機能、知識処理機能を実行することができる。

【0003】これらのニューラルネットワークはネットワークの構造からパターン伝送型と自動伝送型に分類され、前者は入力パターンをある出力パターンに変換するネットワークを形成し、また後者は入力パターンに最も近いパターンを出力するネットワークを形成する。

【0004】前記パターン伝送型ニューラルネットワークでは、各ユニット（ニューロン）を入力層、中間層、出力層に階層化し、各ユニットは入力層から出力層に向け接続され、この結果、入力ユニットと出力ユニットとは独立している。そして、演算機能や画像情報は各ユニット間の接続形態や接続の強さとして記憶され、得られた出力と望ましい出力との差を用いて結合の強さが任意に変化される。このときの結合の強さは結合係数あるいはシナプスの重みとして所定のパラメータを形成している。

【0005】一方、自動伝送型ニューラルネットワークにおいては、入力ユニットと出力ユニットとは共通であり、ネットワーク内の全てのユニットが互いに相互接続され、前記結合の強さ（シナプスの重み）は似通った入力パターンを識別するために用いられている。

【0006】このようなニューラルネットワークによってパターン認識が行われるが、周知のように、このニューラルネットワークを効果的に作動させるためには、バ

ックプロパゲーション等として知られる学習アルゴリズムが用いられ、前述したパターン認識、音声認識、音声合成、信号処理あるいは知識処理等の広範囲の信号予測適用分野でニューラルネットワークを作用させるためには、このバックプロパゲーション等の学習が極めて効果的である。

【0007】通常、ニューラルネットワークは、入力層、中間層そして出力層という階層構造をとり、この中間層は隠れ層として知られており、パターン伝送型ニューラルネットワークにおいては、学習過程において入力データの処理（前向き）と逆に学習のデータを入力したときに結果のエラーを減らすように（後ろ向き）シナプス結合の記述を変え、これが収束するまで学習アルゴリズムを繰返す。

【0008】従って、従来において、バックプロパゲーションアルゴリズム等の学習機能が付加されたニューラルネットワークにて各種のパターン認識その他の信号予測が成果をあげている。

【0009】

20 【発明が解決しようとする課題】しかしながら、このような従来におけるニューラルネットワークでは、最適予測作用を行うために、多数回の学習作用を必要とし、このためにパラメータが多い場合には学習自体に多大な時間が費やされるという問題があった。

【0010】即ち、従来一般的なニューラルネットワークにおいては、入力層と中間層及び中間層と出力層との間は全てのシナプス間が結合され、この結果、学習に必要な演算回数が極端に増大するという問題があった。

30 【0011】例えば、入力層に5素子、中間層に6素子そして出力層に7素子のニューラルネットワークを想定すると、入力層と中間層との間で30個の結合組み合わせ数が生じ、同様に中間層と出力層間には42個の結合組が必要となる。

【0012】従来のネットワークにおいては、各シナプスは線形特性を有しており、この結果、前記全ての組み合わせを同時に機能させながら学習を行う必要があり、この結果、前記想定した比較的単純なネットワークにおいても、その全組み合わせ数が1260個の組み合わせ数となり、このような多数の結合組に対して所望のパラメータを設定するために、多大の演算時間が必要となっていた。

【0013】本発明は上記従来の課題に鑑みなされたものであり、その目的は、少ない回数での学習によってシナプスの結合係数を最適値に設定収束することができる高速学習型であり、かつ、極めて高い予測精度の非線形シナプスニューロン、そのデバイス及びそれを用いた予測方法を提供することにある。

【0014】

50 【課題を解決するための手段】上記目的を達成するために、本発明は、本発明に係る非線形シナプスニューロン

5

及びデバイスは、複数の入力信号のそれぞれに所望の重み付けを与えるための複数の非線形シナプス手段（回路）と、各非線形シナプスの出力を加算する加算手段（器）と、を含み、前記非線形シナプス手段（回路）は、入力信号  $x$  に対して可変重み係数  $(a_0, a_1, a_2, \dots, a_n)$  を有する非線形関数  $\{f(x) = a_0 + a_1 x + a_2 x^2 + a_3 x^3 \dots a_n x^n\}$  で示される可変関数手段（回路）、を含むことを特徴とする。

【0015】また、本発明に係る非線形シナプスニューロン及びデバイスは、複数の入力信号のそれぞれに所望の重み付けを与えるための複数の非線形シナプス手段（回路）と、各非線形シナプスの出力を加算する加算手段（器）と、を含み、前記非線形シナプス手段（回路）は、入力信号レベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数手段（回路）と、各メンバシップ関数手段（回路）に接続され対応するメンバシップ関数のグレードで学習の度合いが定められる複数の可変重み付け手段（回路）と、を含むことを特徴とする。

【0016】更に、本発明に係る非線形シナプスニューロン及びデバイスは、サンプリングされた時系列信号を受け入れる直列接続された遅延手段（回路）と、前記遅延された時系列信号のそれぞれに所望の重み付けを与えるための複数の非線形シナプス手段（回路）と、各非線形シナプスの出力を加算する加算手段（器）と、を含み、前記非線形シナプス手段（回路）は、入力信号レベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数手段（回路）と、各メンバシップ関数手段（回路）に接続され対応するメンバシップ関数のグレードで学習の度合いが定められる複数の可変重み付け手段（回路）と、を含むことを特徴とする。

【0017】更に、本発明に係る非線形シナプスニューロン及びデバイスは、空間的に異なる座標位置の複数の信号のそれぞれに所望の重み付けを与えるための複数の非線形シナプス手段（回路）と、各非線形シナプスの出力を加算する加算手段（器）と、を含み、前記非線形シナプス手段（回路）は、入力信号レベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数手段（回路）と、各メンバシップ関数手段（回路）に接続され対応するメンバシップ関数のグレードで学習の度合いが定められる複数の可変重み付け手段（回路）と、を含むことを特徴とする。

【0018】

【作用】従って、本発明によれば、複数の入力信号のそれぞれに非線形シナプスで所望の重み付けを与え、各非線形シナプスの出力を加算し、前記非線形シナプスは、入力信号  $x$  に対して可変重み係数  $(a_0, a_1, a_2, \dots, a_n)$  を有する非線形関数  $\{f(x) = a_0 +$

6

$a_1 x + a_2 x^2 + a_3 x^3 \dots a_n x^n\}$  で示される可変関数を有するので、各非線形シナプスの結合係数は、他のシナプスとは独立して決定され、その学習時においても各シナプスの重み付けは極めてわずかな回数、例えば入力信号を変化させた数回の学習によって収斂し、誤差値を少なくして高精度の結合係数を設定することが可能となる。

【0019】また、本発明によれば、複数の入力信号のそれぞれに非線形シナプスで所望の重み付けを与え、各非線形シナプスの出力を加算し、前記非線形シナプスは、入力信号がレベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数のグレードに応じて可変重み付けを与えたので、各非線形シナプスの結合係数は、他のシナプスとは独立して決定され、その学習時においても各シナプスの重み付けは極めてわずかな回数、例えば入力信号を変化させた数回の学習によって収斂し、誤差値を少なくして高精度の結合係数を設定することが可能となる。

【0020】更に、本発明によれば、サンプリングされた時系列信号を受け入れる所定量の遅延手段を与え、前記遅延された時系列信号のそれぞれに非線形シナプスで所望の重み付けを与え、各非線形シナプスの出力を加算し、前記非線形シナプスは、入力信号がレベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数のグレードに応じて可変重み付けを与えたので、各非線形シナプスの結合係数は、他のシナプスとは独立して決定され、その学習時においても各シナプスの重み付けは極めてわずかな回数、例えば入力信号を変化させた数回の学習によって収斂し、誤差値を少なくして高精度の結合係数を設定することが可能となる。

【0021】更に、本発明によれば、空間的に異なる座標位置の複数の信号のそれぞれに非線形シナプスで所望の重み付けを与え、各非線形シナプスの出力を加算し、前記非線形シナプスは、入力信号がレベルに応じて区間分けされ、順次前件部の一部が重複して並列接続された複数の相補型メンバシップ関数のグレードに応じて可変重み付けを与えたので、各非線形シナプスの結合係数は、他のシナプスとは独立して決定され、その学習時においても各シナプスの重み付けは極めてわずかな回数、例えば入力信号を変化させた数回の学習によって収斂し、誤差値を少なくして高精度の結合係数を設定することが可能となる。

【0022】

【実施例】以下、本発明に係る非線形シナプスニューロン、そのデバイス及びそれを用いた予測方法について実施例に基づいて詳細に説明する。

【0023】図1には、本発明に係る非線形シナプスニューロンの好適な実施例が概略的な全体図として示され、このニューロンは4つのシナプス10-1~10-

4を有し、これらの各シナプスは本発明において非線形シナプスからなることを特徴とする。

【0024】各非線形シナプス10には、その入力端子11-1~11-4に信号x<sub>0</sub>, x<sub>1</sub>, x<sub>2</sub>, x<sub>3</sub>が供給され、非線形シナプス10において各複数の信号xのそれぞれに所望の重み付けが与えられる。

【0025】そして、各非線形シナプス10の出力は、\*

$$y = f_0(x_0) + f_1(x_1) + f_2(x_2) + f_3(x_3) \quad (1) \text{式}$$

従って、本発明において、各シナプスはその入出力関係が非線形となり、この結果、時系列信号あるいは空間信号からシステムを同定する場合に、システムの非線形性が強い場合においても、本発明の非線形シナプスを用いることによって高精度の非線形近似を行うことが可能となる。

【0027】従って、本実施例において、各非線形シナ

$$f(x) = a_0 + a_1 x + a_2 x^2 + a_3 x^3 + \dots + a_n x^n \quad (2) \text{式}$$

従って、上記(2)式の係数a<sub>n</sub>の値を学習によって定めれば、信号に最適な非線形シナプスを設定することができる。

【0030】以下に、前述したいずれかの非線形シナプ

$$f(x) = a_0 + a_1 x + a_2 x^2 + a_3 x^3 + a_4 x^4 \\ = a_0 + x [ a_1 + x \{ a_2 + x ( a_3 + a_4 x ) \} ] \quad (3) \text{式}$$

そして、この(3)式は、図2の縦属接続された積和回路にて構成することができる。

【0032】即ち、図2に示した非線形シナプス10は4個の縦属接続された積和回路13-1~13-4を含み、各積和回路13はそれぞれ乗算器14及び加算器15からなる。積和回路13-1において、乗算器14-1は信号xと前段の積和回路13-2から得られた出力f<sub>(1)</sub>(x)が供給されており、この両信号の乗算出力が加算器15-1において係数a<sub>0</sub>と加算されている。

【0033】同様に、順次各積和回路13は前段出力f<sub>(n)</sub>(x)と信号xとの積算値に各係数a<sub>n</sub>を加算する構成からなる。

【0034】従って、この図2に示した非線形シナプス回路により、前述した(3)式が実現されていることが理解される。

【0035】勿論、このような非線形シナプス10の回路は、IC回路から構成してもよく、またこれをソフトウェアで実現してもよい。

【0036】以上のようにして、本発明において非線形シナプス10を構成すると、図1における各シナプス10はそれぞれ独立して構成され、もはや従来のニューラルネットワークのように、全ての信号に対して線形シナプス群をネットワーク状に組み合わせる必要がなくなり、これによって前述した各シナプス10の結合係数a<sub>n</sub>を学習することが極めて容易となる。

【0037】図2から明らかなように、各縦属接続された積和回路13はその下流側、即ち積和回路13-1の

\* 加算手段12に供給され、各出力が加算された後出力端子19から出力信号yとして出力される。前記各非線形シナプス10において、その内容は可変関数f<sub>0</sub>, f<sub>1</sub>, f<sub>2</sub>, f<sub>3</sub>で示され、この結果、非線形シナプスニューロンの入出力関係は次式で与えられる。

【0026】

プス10の可変関数f(x)を学習によって定めれば信号xに対して極めて高精度に予測信号yを得ることができる。

【0028】本実施例において、前記シナプス10の可変関数f(x)は以下の(2)式に示される多次多項式によって表わされる。

【0029】

ス10の構造を更に詳細に説明する。

【0031】前記(2)式は4次可変関数として考えると以下の(3)式にて表わされる。

係数a<sub>0</sub>が定数成分の決定に係わり、順次高次シナプス係数a<sub>n</sub>が信号の高次成分を表わすこととなる。この結果、本実施例においては、順次定数成分から高次成分に向かって各シナプス係数を学習によって定めることが好適であり、これによって少ない回数により簡単に各係数を最適値に決定することができる。

【0038】a<sub>0</sub>~a<sub>4</sub>の5個の係数を定めるには、図3に示すような(x<sub>1</sub>, y<sub>1</sub>), (x<sub>2</sub>, y<sub>2</sub>), ..., (x<sub>5</sub>, y<sub>5</sub>), (x<sub>6</sub>, y<sub>6</sub>), ...と5個以上のデータが必要である。これは、(3)式において、a<sub>0</sub>~a<sub>4</sub>の全ての係数を決定するのに、(x, f(x))に関する5個のデータを(3)式に代入し、a<sub>0</sub>~a<sub>4</sub>に関する5元連立方程式を解くことに類似している。5個未満の(x, f(x))のデータでは全てのa<sub>0</sub>~a<sub>4</sub>が決定できないのである。

【0039】以下に、(x<sub>1</sub>, y<sub>1</sub>), (x<sub>2</sub>, y<sub>2</sub>), ..., (x<sub>6</sub>, y<sub>6</sub>)の6個のデータを用いた学習によってa<sub>0</sub>~a<sub>4</sub>を決定する手順について述べる。

【0040】(1)まず、係数a<sub>1</sub>~a<sub>4</sub>を0に設定する。

【0041】(2)  $\sum_{i=1}^6 (y_i(t) - y_i)^2$  (i=1~6)を計算する。

【0042】(3)  $\frac{\partial}{\partial a_n} \sum_{i=1}^6 (y_i(t) - y_i)^2$  / a<sub>n</sub>(t) = 0ならばa<sub>n</sub>(t+1) = a<sub>n</sub>(t) - G,  $\frac{\partial}{\partial a_n} \sum_{i=1}^6 (y_i(t) - y_i)^2$  / a<sub>n</sub>(t) < 0ならばa<sub>n</sub>(t+1) = a<sub>n</sub>(t) + Gとする。但し、ここでGは定数。

【0043】(4) a<sub>n</sub>(t+1)における  $\sum_{i=1}^6 (y_i(t+1) - y_i)^2$  (t)より小さければ(例えば図4の曲線①上のBの

ように)、この  $a_n(t+1)$  を  $a_n(t)$  として上記(2)に戻る。もし、 $\sigma^2(t+1)$  が  $\sigma^2(t)$  より大きければ(例えば図4の曲線②上のCのように)、上記(3)におけるGを半分にして(3)を実行する。このとき  $\sigma^2(t+1)$  はDとなる。このようにして得た  $a_n(t+1)$  における二乗平均誤差  $\sigma^2(t+1)$  が  $\sigma^2(t)$  よりも小さくなるまで何度もGを半減する。かくして、 $\sigma^2(t+1)$  が、図4中のEのようにAよりも低くなるまで続ける。以下(3)に戻る。

【0044】(5)上記(3)、(4)を繰り返し、 $|\sigma^2(t+1) - \sigma^2(t)|$  がある値より小さくなったら、その  $a_n(t)$  の学習は一時停止し、次は  $a_{n+1}(t)$  について(2)~(5)と同様の学習を行なう。

【0045】(6)  $a_0 \sim a_4$  の値を一通り学習で定めると、1回の学習が終了したとみなす。

【0046】(7)  $\sigma^2(t)$  がある値以下になるまで、上記(2)~(6)を繰り返す。

【0047】実験によれば、前記所望のシナプス係数  $a_0 \sim a_n$  を求めるために、数回の学習で十分に高精度の学習が可能であった。また、3次多項式を満たす5個のデータ  $(x_1, y_1), (x_2, y_2), \dots, (x_5, y_5)$  を用いて、上記の方法で  $a_0 \sim a_4$  を求めたところ、当然のことながら  $a_4 = 0$  となった。

【0048】以上のようにして、非線形シナプスの各結合係数を多次多項式モデルで同定すれば所望の入力信号に対して高精度の予測値を得ることができる。

【0049】なお、本実施例において、図2中の積和回\*

$$X = (x_0, x_1, x_2, x_3)$$

各非線形シナプス10への入力信号  $x_0 \sim x_3$  の集合を入力ベクトル  $X_i$  と呼ぶ。この入力ベクトル  $X_i = (x_0, x_1, x_2, x_3)$  は時系列信号  $X$  を初期値から順に遅延素子20を通して各非線形シナプス10の入力端子に供給される。

【0056】従って、図6の入力ベクトルと動作モードとの関係を用いて本実施例における学習動作と予測動作とを説明する。

【0057】符号101で示される状態では、入力ベクトルは  $X_0$  から  $X_2$  までが入力された状態で、この3ステップでは、各遅延回路20に対して、4個の遅延回路20全てを動作することができず、実際のモードにおいては予備動作として取り扱われる。即ち、本実施例においては各非線形シナプス10の結合係数を求めるための

$$\sigma_k^2 = (y_{k+1} - \hat{y}_{k+1})^2$$

(5)式において、 $y_{k+1}$  は時刻  $k+1$  における時系列信号であり、また  $\hat{y}_{k+1}$  は時系列信号が入力された時の予測値を示す。

【0061】本実施例において、十分に使用可能な誤差  $\sigma_k$  を得るまでの収斂学習回数は数回で十分であった。従って、本発明によれば、従来のニューラルネットワークに比してその学習回数が著しく減少していることが理

\* 路13に用いられている乗算器14-1や加算器15-1は高精度である必要はない。すなわち、非線形性の高い乗算器や加算器であっても、これを含めた形で、学習により、次数( $a_n$ の数)や係数  $a_0 \sim a_n$  を定め、 $\sigma^2$  を小さくすることができる。このことは、デバイスを構成する際に極めて都合がよい。

【0050】本発明において、このような入力信号としては、時系列信号あるいは空間的な信号として取り扱うことができ、以下に時系列信号を入力信号として処理する場合の本発明の他の実施例を説明する。

【0051】本実施例において、本発明の非線形シナプスニューロンは遅延素子との組み合わせによってダイナミカルシステムの同定が行われる。

【0052】図5にはこのような非線形シナプスニューロンの好適な実施例が全体的な概略図として示されている。

【0053】図5においてサンプリングされた時系列信号  $y_n$  は入力端子21から直列接続された実施例においては4個の遅延回路20-1~20-4に入力される。

【0054】従って、前記入力信号  $y_n$  は順次各遅延回路20を通して1サンプリング周期ごとに順次非線形シナプス10-1~10-4に供給されることとなる。従って、本実施例によれば、4個の時系列信号がサンプリングされて入力されたとき、全ての非線形シナプス10が機能することとなる。

【0055】いま、4個の時系列信号  $X$  が以下の(4)式で与えられたとき、

$$(4)式$$

学習動作は図6において入力ベクトル  $X_3$  から  $X_{n-1}$  までの複数回において行われ、この時にはいずれも4個の入力信号  $x_0 \sim x_3$  が各遅延回路20から非線形シナプス10に供給されている。

【0058】従って、前述した図2で示したように、これらの各入力信号に応じて各シナプス10の結合係数  $a$  を求めることができる。この状態は図6において符号102で示されている。

【0059】本実施例においては、符号102で示される  $X_3$  から  $X_{n-1}$  までの各入力ベクトルに対して順次学習が進められ、 $k$  番目の入力ベクトル  $X_k$  に対して、本実施例の学習は以下に示す(5)式の評価関数が極小になるように行われる。

$$【0060】$$

$$(5)式$$

解される。

【0062】図6の符号103は前述した学習によって各非線形シナプス10の結合係数が決定された後に、入力ベクトル  $X_n$  が入力端子21に供給されたときの1サンプリング時刻先の予測動作を示しており、入力ベクトル  $X_n$  は各非線形シナプス10によって所望の重み付与えられ、その加算値が  $x_{n+1}$  として求められてい

10

20

30

40

50

る。

【0063】従って、入力ベクトル $X_n$ を順次時系列信号のサンプリング入力信号とすることによって常に1時刻先の予測値を正確に得ることが可能となる。

【0064】また、1サンプリング時刻より更に先の予測を行うためには、図6の符号104で示されるように、入力ベクトル $X_n$ に対してその出力である $y_{n+1}$ 、 $y_{n+2}$ 、 $y_{n+3}$ ...を順次入力端子21へ戻し、本発明に係る非線形ニューロンを繰り返し動作させ\*

$$f(x) = 2 - 2x^2 + x^4$$

すなわち、上記(6)式は、前述した(2)式の各係数 $a$ が以下の値である多次多項式からなることが理解される。

【0068】

- $a_0 = 2$
- $a_1 = 0$
- $a_2 = -2$
- $a_3 = 0$
- $a_4 = 1$
- $a_5 = 0$

図7には、前記多次多項式が実線で示され、この時系列信号を本実施例における非線形シナプスニューロンにて同定した結果を以下に示す。

【0069】図7には、前記実線で示される(6)式の多次多項式に標準変量 $G = 0.01$ 、学習回数200回で本実施例を用いて学習したときの同定された関数が破線で示されている。なお、この標準変量 $G$ は、各学習時における係数 $a$ の標準的な変化幅を示す。図7から明らかのように、この関数は元の実線で示された時系列信号とほとんど重なってしまい、前述した条件における本実施例の同定が極めて高精度で行われていることが理解される。

【0070】なお、前記学習に用いられたデータは8個のサンプリングデータであり、以下にその座標値を示す。

【0071】

- $(-1.0, 1.0)$

$$f(x) = 2 - 2x^{2.5} + x^{3.5}$$

図10の実線は、本実施例で取り扱う入力信号を示し、このように非整数指数を有する入力信号に対しても、本実施例によれば、整数指数をもった非線形関数のシナプス手段によって破線で示されるように極めて近似したシステム同定が可能なが理解される。

【0077】この第2の実験によれば、5個のサンプリングデータを用い、1000回学習して前述した破線のシステム同定結果が得られている。

【0078】図11は平均二乗誤差の平方根が学習によっていかなる減少挙動を示すかを示し、急峻な誤差減少が示されている。

【0079】更に、図12は、本実施例において学習し

\*ることにより、所望の将来予測値を得ることが可能となる。

【0065】前述した本実施例に係る非線形シナプスニューロンにて実際の時系列信号の同定を行った例を以下に説明する。

【0066】いま、1つの非線形シナプスについての学習シミュレーションを行うために、以下の(6)式で示す時系列信号を考える。

【0067】

(6)式

- $(-0.8, 1.1296)$
- $(-0.5, 1.5625)$
- $(-0.1, 1.9801)$
- $(0.0, 2.0)$
- $(0.2, 1.9216)$
- $(0.4, 1.7456)$
- $(1.0, 1.0)$

図8は本実施例における学習過程をエラー(2)の学習とともに誤差が修正されている様子を示し、平均二乗誤差の平方根が学習回数とともに急速に減少しており、誤差1%となるのに116回の学習で十分なことを示す。

【0072】また、図9には、本実施例で用いた多次多項式の係数 $a_0 \sim a_5$ の学習による収束状態を示しており、実験で用いた200回の学習によってほぼ各係数が収束していることが理解される。

【0073】ここで、 $G = 0.01, 0.1, 1.0$ のいずれの場合も、各係数の収束状態は同様であったが、その学習時間はもちろん $G$ の大きい順に高速化していた。

【0074】図10~12は、本実施例を用いて更に他の時系列係数をシステム同定した場合の例を示す。

【0075】この実験では、以下の(7)式に示される非整数指数の多次多項式をシステム同定することもできることを示す。

【0076】

(7)式

たときの非線形シナプスの非線形関数係数 $a_0 \sim a_5$ がどのように収束するかを示しており、1000回の学習によってほぼ各係数が所定値に収束している様子が理解される。

【0080】以上説明した各実施例においては、非線形シナプスの重み付けは多次多項式によって定められていたが、このような非線形シナプスは本発明において、ファジィルールを用いて表現することも可能である。

【0081】図13には本発明のファジィ理論を用いた好適な実施例が示され、前述した図1のニューロン構造の非線形シナプス10をメンバシップ関数手段と重み付け手段とによって構成した実施例が示されている。図に

20

30

40

50

において、非線形シナプス 10 - 4 のみが例示されているが、他の非線形シナプス 10 - 1, 10 - 2, 10 - 3 も同様に複数のメンバシップ関数手段とこれに対応して設けられた複数の重み付け手段とから構成されている。

【0082】図 13 において各非線形シナプス 10 はレベルの数を 5 個とした非線形シナプス  $f(x)$  の構造からなり、並列接続された 5 個のメンバシップ関数回路 30 - 1 ~ 30 - 5 に入力信号  $x$  が供給される。これらの各メンバシップ関数回路 30 は、図 14 中の  $\mu_1 \sim \mu_5$  にみられるように順次前件部の一部が重複して並列接続され、更に隣接する 2 個のメンバシップ関数が互いに相補型に構成されている。

【0083】従って、入力信号  $x$  はその値にかかわらず、5 個のメンバシップ関数回路 30 のうち 2 個のメンバシップ関数によってのみそのグレードが定められ、更に両グレードの総計値は常に「1」となるような相補型に設定されている。

$$f(x) = w_j \mu_j(x) \quad (j=0 \sim 4)$$

(8) 式から、各重み  $w$  はこれに対応するメンバシップ関数のグレード  $\mu$  に依存することが理解される。

【0089】前述したメンバシップ関数  $\mu$  と入力信号  $x$  との関係が図 14 に示されている。図 14 において、入力信号  $x$  は最小値  $x_{\min}$  と  $x_{\max}$  との間を変動し、時刻  $t$  に従った時系列信号を形成している。

【0090】信号レベル  $x$  を実施例においては  $x_0 \sim x_4$  で区切られた 4 区間に分け、図において  $x_{01}, x_{12}, x_{23}, x_{34}$  に区分けする。

【0091】そして、メンバシップ関数回路 30 のメンバシップ関数は前記区間ごとに隣接するメンバシップ関数が互いに相補型にそのグレード総計を常に「1」とするようにメンバシップ関数が設定される。この結果、メンバシップ関数  $\mu_1$  は実線で示されるように区間  $x_{01}$  に対してのみ与えられる。そして、メンバシップ関数  $\mu_2$  は区間  $x_{01}$  と  $x_{12}$  において、同様にメンバシップ関数  $\mu_3$  は区間  $x_{12}$  と  $x_{23}$ 、メンバシップ関数  $\mu_4$  は区間  $x_{23}$  と  $x_{34}$  について表れ、メンバシップ関数  $\mu_5$  は区間  $x_{34}$  についてのみ与えられている。

【0092】従って、いずれの信号レベル値においても 2 個のメンバシップ関数のみが相補的に機能してそれらのグレード総計は常に「1」となり、例えば時刻  $t_1$  においては、メンバシップ関数  $\mu_2$  と  $\mu_3$  とが働く。

【0093】そして、この時刻定  $t_1$  においては、他の 3 個のメンバシップ関数  $\mu_1, \mu_4, \mu_5$  は全て「0」であるため、これらのメンバシップ関数のグレードにて度合いが定まる重み付けは機能しないことが明らかである。従って、時刻  $t_1$  においては、メンバシップ関数  $\mu_2, \mu_3$  のグレードに応じて重み付け  $w_2$  と  $w_3$  とが学習し、その他の  $w_1, w_4, w_5$  の学習は行われない、

$$w(t_1) = \{w_2 \times \mu_2(t_1) + w_3 \times \mu_3(t_1)\} / \{\mu_2(t_1) + \mu_3(t_1)\}$$

\* 【0084】従って、このメンバシップ関数のグレードにより各メンバシップ関数回路 30 に接続されている重み付け回路 31 - 1 ~ 31 - 5 の重みは対応するメンバシップ関数のグレードでその学習の度合いが定められることとなる。

【0085】実施例において、重み付け回路 31 の出力は加算器 32 を経て前述した加算器 12 に供給されるが、本発明においては、必ずしも非線形シナプス 10 内の加算器 32 は設ける必要がない。即ち、重み付け回路 31 の各出力を直接加算器 12 へ供給しても同様の効果が得られるからである。

【0086】図 13 の構造において、入力  $x$  に対する各グレード  $\mu$  に重み  $w$  を乗じた値の総和が非線形シナプス 10 の入出力関係を示す。

【0087】従って、この非線形シナプス  $f(x)$  の入出力関係は、以下の(8)式にて示される。

【0088】

(8) 式

これは、区間  $x_{12}$  の全てにおいて同様であり、区間  $x_{12}$  ではそれぞれのメンバシップ関数にて定まるグレード  $\mu_2, \mu_3$  の度合いに応じた重み  $w_2, w_3$  のみの学習が行われることとなる。他の区間においても、同様の作用が得られる。

【0094】本発明において互いに隣接するメンバシップ関数をその前件部において重複させ、相補型に用いることにより、前述したように全てのレベルにおいてグレードの総数は「1」となり、この結果、重み付け加算をした後のデータをそのまま非線形シナプス 10 の出力として用いることができるという利点がある。即ち、仮にこれらのグレード統計値が「1」でない場合には、加算後に割り算その他のディファジフィケーションを行う必要があり、回路あるいは処理システムを著しく複雑にするが、本発明においては前記相補型メンバシップ関数を用いることによってこのような不都合を確実に防止することができる。

【0095】図 15 には、前記時刻  $t_1$  における非線形シナプス 10 - 3 の重み付け係数を求める手順が示されている。

【0096】時刻  $t_1$  における入力信号値は  $x(t_1)$  で示され、このときの励起されるメンバシップ関数は  $\mu_2$  と  $\mu_3$  であり、これら各メンバシップ関数  $\mu_2, \mu_3$  のそれぞれのグレードは  $\mu_2(t_1)$  及び  $\mu_3(t_1)$  で示される。従って、これらのグレードに合わせて、それぞれ重み  $w_2, w_3$  の比率が定まり、その平均が  $w(t_1)$  として求められる。

【0097】(9) 式は前記相補型メンバシップ関数から平均的に求められた重み  $w(t_1)$  を示す。

【0098】

$$= w_2 \times \mu_2 ( t_1 ) + w_3 \times \mu_3 ( t_1 )$$

( 9 ) 式から明らかなように相補型メンバシップ関数を用いることによって本発明によれば、分母が常に「 1 」となり後段において割り算器等のデフジャジフィケーションを必要とすることがない。

【 0 0 9 9 】 以上のようにして、本発明によれば、ファジィ推論を用いて非線形シナプスの重み付けを決定することができ、前述した多次多項式と同様に各非線形シナ\*

$$y_{n+1} = f ( y_n ) + a y_{n-1} + b y_{n-2}$$

すなわち、

$$y_{n+1} = f ( y_n ) + p_n + q_n$$

$$p_{n+1} = a y_n$$

$$q_{n+1} = b p_n = b y_{n-1}$$

なる関係を有する。

【 0 1 0 2 】 図 1 6 において、時系列信号は 0 ~ 4 9 の 5 0 個のデータで示され、縦軸の X の値は ± 3 . 0 の間をカオス的に変動する。

【 0 1 0 3 】 従って、本発明においては、このような従来予測不能な時系列信号に対して非線形シナプスを用いてわずかな回数の学習により予測可能であることを示す。

【 0 1 0 4 】 本実施例を用いた実験においては、図 1 6 のカオス的な信号を 1 ~ 5 次の各モデルで同定した。

【 0 1 0 5 】 図 1 7 はこの 1 ~ 5 次までの 5 個の本発明に係る非線形シナプスニューロンが示されている。

【 0 1 0 6 】 そして、図 1 8 にはこれらの 5 個のニューロンによって図 1 6 におけるカオス的な信号を同定したときの平均二乗誤差が示されている。

【 0 1 0 7 】 図 1 8 から明らかなように、図 1 6 のダイナミカルシステムは 3 次の時系列信号であるが、ニューロンで同定する時の各次数のマッピング関数は折れ線近似となるので、3 次ニューロンモデルよりも 4 次及び 5 次ニューロンモデルの方が高次シナプスで補正できるために、良好な結果が得られていることが理解される。図 1 9 ~ 2 3 には前述した 5 次ニューロンモデルによって 3 次の時系列信号をシステム同定するときの各次のマッピング関数が示されている。各図において、実線は図 1 6 のカオス的な信号を作るのに用いた 3 次ダイナミカルシステムの各次数におけるマッピング関数を示し、破線は 5 次ニューロンモデルで同定した場合の各次のマッピング関数を示す。

【 0 1 0 8 】 図 1 9 ~ 2 3 により明らかなように、本実施例によれば、3 次のダイナミカルシステムを 5 次ニューロンモデルで同定しているため、3 次までの折れ線近似誤差が 4 次及び 5 次の非線形シナプスで補正可能であることを示す。

【 0 1 0 9 】 図 2 4 には 5 次ニューロンモデルにおける予測動作が示され、前述したごとく重み付け学習された 5 次ニューロンモデルを用いて、順次入力信号で学習をし、係数を更新しながら、将来発生する時系列信号の予

( 9 ) 式

\* プスはそれぞれ独立しているため、これらの重み付けを定めるための学習回数は極めて僅かでもよく、簡単に最適なシナプスの重み付け決定を行うことができる。

【 0 1 0 0 】 図 1 6 には 3 次のダイナミカルシステムで作られたカオス的な信号が示され、この時系列信号は以下の ( 1 0 ) 式で示される。

【 0 1 0 1 】

( 1 0 ) 式

10 測を行っている。

【 0 1 1 0 】 この予測は、現在の入力信号より 1 時刻先でもあるいは所定の任意の将来時刻における予測でもよい。

【 0 1 1 1 】 図 2 4 に示した予測値 ( 破線 ) は、図 1 6 のカオス的な信号を再掲した実線で示す真の値に対する 1 時刻先の予測値を示す。従って、図 2 4 から、本実施例によれば、従来予測不能であったカオス的な信号に対しても十分追従する予測作用を行えることが理解される。

20 【 0 1 1 2 】 図 2 5 は前述したように重み付け学習をしてシステム同定した本実施例における 5 次のニューロンモデルに出力から入力へのフィードバックを施し、固定的に与えられた 5 個の時系列信号からその後発生する予測値を順次予測した状態を示すものであり、前記図 2 4 と同様に実線が真の値、そして破線がフィードバックから得られた将来の予測値を示す。

【 0 1 1 3 】 この図 2 5 における予測は現在与えられている 5 個の時系列信号のみから将来に渡る予測作用を行うものであり、図 2 4 と異なり、先の予測ほど誤差を含むことは当然である。

30 【 0 1 1 4 】 しかしながら、このような将来予測に対しても、図 2 5 からは少なくとも 5 ~ 1 0 同時刻先の予測に対しては極めて一致度の高い予測作用が得られていることが理解される。

【 0 1 1 5 】 図 2 6 から図 2 9 にはそれぞれ本実施例を用いた時の学習時におけるゲイン定数 を変化させたときの学習回数と平均二乗誤差との関係を示す。

【 0 1 1 6 】 実施例においては、 を以下の 4 種類にして実験したところ、

$$= 0 . 0 2$$

$$= 0 . 2$$

$$= 0 . 5 6$$

$$= 0 . 5 7$$

= 0 . 2 の時に極めて良好なシステム同定が行われていることが理解される。

【 0 1 1 7 】 即ち、ゲイン定数 を 0 . 2 に設定したとき最も早く学習が完了し、図 2 7 から明らかなように、1 0 回程度の学習回数で十分に高精度の同定が行われ、従来と比し 1 0 0 ~ 1 0 0 0 分の 1 程度の極めて僅かな回数で本発明における非線形シナプスニューロンがシステム同定できることを示す。



【0118】また、ファジィ推論によって定められた非線形シナプス10は前述した多次多項式による非線形シナプスと同様に、入力される複数の時系列信号から順次、次の時刻あるいは将来の所定時間先の時刻における値を順次予測することができ、入力時系列信号を順次更新することによって常に所定量先の予測値を得ることができる。

【0119】また、一定数の入力信号をシステム同定済のニューロンモデルに供給すれば、順次先の時刻を予測することができる。即ち、入力信号は一定時刻において固定しているが、次の時刻の予測値を出力した時にこれを入力端子にフィードバックし、次々にこのフィードバックされた予測値を用いながら、更に先の将来における予測値を順次更新することができる。

【0120】ファジィ推論による非線形シナプスを用いた場合においても、実験によれば5～10回の学習によって十分な高精度でシステムを同定することができ、従来の線形シナプスによる同定と異なり、極めて短時間で学習を完了することができる利点がある。

【0121】また、本発明による非線形シナプスニューロンはその入力信号として時系列信号ばかりでなく、空間信号も処理可能であり、この与えられた空間の外の予測値を得る場合にも用いることができる。

【0122】図30にはこのような空間的な信号の一例が示されており、 $x$ 軸方向に等間隔で分布した $x_1 \sim x_5$ 、そして、 $x_7$ が既知である。この場合、本発明に係る非線形シナプスニューロンに $(x_1, x_2, x_3, x_4)$ における $y$ の値 $(y_1, y_2, y_3, y_4)$ を入力し、出力 $y$ が $y_7$ となるように前記各非線形シナプス10の $f(x)$ を学習で求める。勿論、通常の既知データとしては、前述した4個のデータ $y$ のみではなく、 $y_1 \sim y_{50}$ の多数のデータを4個ずつシリアルに入力して前記学習を行うことが好適である。

【0123】このようにして、システム同定が行われ、次に $(x_2, x_3, x_4, x_5)$ の $y$ の値 $(y_2, y_3, y_4, y_5)$ を入力すると本発明に係る非線形ニューロンからは座標 $x_8$ に対応する値 $y_8$ を予想することが可能である。

【0124】このようにして、本発明によれば、時系列信号ばかりでなく、空間的な信号を用いて未知の座標を外挿することができる。

【0125】

【発明の効果】以上説明したように、本発明によれば、非線形シナプスの重みを多次多項式あるいはファジィ推論にて求め、これらのシナプスは互いに干渉することなく互いに独立した構成から成るので極めて簡単に少ない学習回数で所望の重み付けあるいは結合係数を得ることが可能となり、特に、本発明の多次多項式及び本発明における相補型メンバシップ関数を用いた非線形シナプスによれば、簡単な構造によって極めて確度の高い予測を

行えるという利点がある。

【図面の簡単な説明】

【図1】本発明に係る非線形シナプスニューロンの全体的な構成を示す説明図である。

【図2】本発明における非線形シナプスを多次多項式で構成した実施例を示すブロック回路図である。

【図3】多次多項式からなる非線形シナプスの重み付け係数を求めるための平均二乗誤差を最小にする説明図である。

10 【図4】多次多項式からなる非線形シナプスの重み付け係数と平均二乗誤差の関係を示すグラフの上で $a_n(t)$ から $a_n(t+1)$ を求める説明図である。

【図5】本発明において、時系列信号を複数の遅延回路を介して非線形シナプスに並列的に入力するニューロンの好適な実施例を示す説明図である。

【図6】本発明における重み付け学習動作及び予測動作を示す説明図である。

20 【図7】本発明に係る非線形シナプスニューロンを用いてシステム同定したときの入力信号とシステム同定した結果とを示す説明図である。

【図8】本実施例を用いてシステム同定したときの平均二乗誤差の収束状態を示す説明図である。

【図9】同じく本実施例を用いてシステム同定したときの多次多項式の各係数の収束状態を示す説明図である

【図10】本実施例を用いて非整数指数を有する入力信号をシステム同定したときの入力信号とシステム同定結果を示す説明図である。

30 【図11】この実施例でのシステム同定時の平均二乗誤差の収束状態を示す説明図である。

【図12】本実施例を用いたシステム同定における多次多項式の各係数の収束状態を示す説明図である。

【図13】本発明に係る非線形シナプスニューロンにファジィ推論を用いた場合の好適な実施例を示す説明図である。

【図14】図13に示した実施例の相補型メンバシップ関数を示す説明図である。

【図15】図13に示した実施例における相補型メンバシップ関数と重み付け係数との関係を示す説明図である。

40 【図16】本発明に係る非線形シナプスニューロンでシステム同定を行うためのカオスの信号を示す説明図である。

【図17】本発明の非線形シナプスニューロンを用いて図16のカオスの信号をシステム同定するための1次～5次のニューロンモデルを示す説明図である。

【図18】図17に示した各次ニューロンモデルによるシステム同定時の平均二乗誤差を示す説明図である。

【図19】前記システム同定時における1次のマッピング関数を示す説明図である。

50 【図20】システム同定時における2次のマッピング関

数を示す説明図である。

【図 2 1】システム同定時における 3 次のマッピング関数を示す説明図である。

【図 2 2】システム同定時における 4 次のマッピング関数を示す説明図である。

【図 2 3】システム同定時における 5 次のマッピング関数を示す説明図である。

【図 2 4】システム同定された本実施例における非線形シナプスニューロンに順次時系列信号を供給して 1 時刻先を予測する時の真の信号と予測信号との関係を示す説明図である。

【図 2 5】本実施例におけるニューロンモデルを用いて特定時刻における時系列信号を用いて順次予測値をフィードバックしながら将来の予測を行う時の真の信号と予測信号との関係を示す説明図である。

【図 2 6】学習時のゲイン定数を 0.02 とした時の学習回数と誤差との関係を示す説明図である。

【図 2 7】学習時のゲイン定数を 0.2 とした時の学\*

\* 習回数と誤差との関係を示す説明図である。

【図 2 8】学習時のゲイン定数を 0.56 とした時の学習回数と誤差との関係を示す説明図である。


【図 2 9】学習時のゲイン定数を 0.57 とした時の学習回数と誤差との関係を示す説明図である。

【図 3 0】本発明を空間信号に用いた場合の外挿予測作用を示す説明図である。


【符号の説明】

- 1 0 非線形シナプス
- 1 1 入力端子
- 1 2 加算器
- 1 3 積和回路
- 1 4 乗算器
- 1 5 加算器
- 1 9 出力端子
- 2 0 遅延回路
- 3 0 メンバシップ関数回路
- 3 1 重み付け回路


【図 1】




【図 2】




【図 3】




【図 5】




【図 15】




【図14】




【図4】




【図7】




【図8】




【図16】



【図 9】




【図 2 7】




【図 6】

	入力ベクトル	動作モード
	$X_1$	
101	$X_0 = (y_0, *, *, *)$ $X_1 = (y_1, y_0, *, *)$ $X_2 = (y_2, y_1, y_0, *)$	予備動作
102	$X_0 = (y_3, y_2, y_1, y_0)$ $\vdots$ $X_k = (y_k, y_{k-1}, y_{k-2}, y_{k-3})$ $\vdots$ $X_{n-1} = (y_{n-1}, y_{n-2}, y_{n-3}, y_{n-4})$	学習動作
103	$X_n = (y_n, y_{n-1}, y_{n-2}, y_{n-3})$	一時刻先の予測動作
104	$X_{n+1} = (y_{n+1}, y_n, y_{n-1}, y_{n-2})$ $X_{n+2} = (y_{n+2}, y_{n+1}, y_n, y_{n-1})$ $X_{n+3} = (y_{n+3}, y_{n+2}, y_{n+1}, y_n)$	繰り返し予測動作


【図10】




【図11】



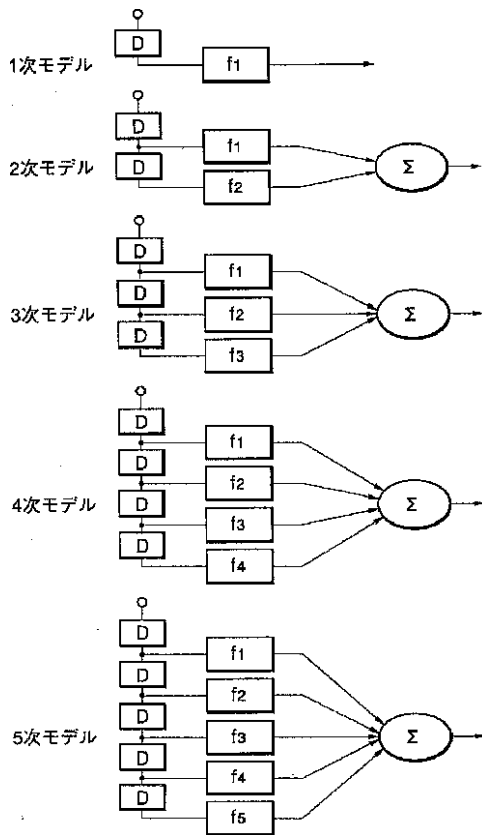
【図12】




【図13】



【図17】




【図19】





【図18】

非線形シナプス数	1	2	3	4	5
平均二乗誤差	0.739	0.275	0.149 × 10 <sup>-2</sup>	0.104 × 10 <sup>-2</sup>	0.147 × 10 <sup>-3</sup>


【図30】





【図 20】





【図 24】





【図 21】




【図 22】




【図 2 3】




【図 2 5】



【図 2 6】




【図 2 8】





【図 2 9】



## フロントページの続き

- (56) 参考文献 特開 平 3 - 125257 ( J P , A )  
 特開 平 2 - 201586 ( J P , A )  
 特開 平 5 - 128086 ( J P , A )  
 特開 平 2 - 93708 ( J P , A )  
 特開 平 3 - 218558 ( J P , A )  
 特開 平 3 - 268055 ( J P , A )  
 特開 平 2 - 162459 ( J P , A )  
 特開 平 3 - 95664 ( J P , A )  
 特開 平 6 - 35707 ( J P , A )  
 村井伸浩・他, 「ニューラルネットワーク予測モデルによる時系列の非線形性の抽出」, 電子情報通信学会技術研究報告, 日本, 社団法人電子情報通信学会・発行, 1992年 3月18日, Vol. 91, No. 529 ( NC91 - 98 ~ 131 ), pp. 237 - 244  
 和多田淳三・他, 「ファジィ時系列モデルとその予測問題への応用」, 日本経営工学会誌, 日本, 1983年, Vol. 34, No. 3, pp. 108 - 186, ( J S T 資料番号: F0241B )  
 Gupta, M. M. ; Qi, J., "Synaptic and somatic learning and adaptation in fuzzy neural systems", Proc. of 1991 IEEE International Joint Conference on Neural Networks, 1991年, Vol. 1, pp. 875 - 880, ( I N S P E C Accession Number : 4254100, I S B N : 0 - 7803 - 0227 - 3 )

- (58) 調査した分野(Int.Cl.<sup>7</sup>, DB名)  
 G06N 1/00 - 7/08  
 G06G 7/60  
 G06F 9/44  
 G05B 13/00 - 13/04  
 J S T ファイル ( J O I S )  
 C S D B ( 日本国特許庁 )