

# 既知構造を含むニューラルネットの誤差逆伝搬学習と マニピュレータの逆ダイナミクス学習への応用

正員 辻 敏夫 (広島大)  
非会員 森 大一郎 (広島大)  
正員 伊藤 宏司 (豊橋技科大)

## Error Back Propagation Learning of Neural Networks Including Preorganized Structure and its Application to Inverse Dynamics Learning of Robot Manipulators

Toshio Tsuji, Member, Daiichiro Mori, Non-member (Hiroshima University), Koji Ito, Member (Toyohashi University of Technology)

Estimating some mappings by neural networks, a part of mapping properties is often known beforehand. The back propagation type neural networks, however, do not utilize this kind of knowledge about the mapping. The present paper proposes to incorporate known nonlinear functions involved in the mapping into the back propagation type neural networks in order to utilize the knowledge about the mapping. As a result, the known and unknown parts of the mapping can be learned in preorganized and unorganized layers of the neural networks respectively.

Then, the preorganized neural network is applied to inverse dynamics problems of robot manipulators. Experimental results show that the learning abilities such as convergence characteristics, generalization abilities and parameter identification can be improved compared to the conventional one by incorporating the motion equation of the manipulator into the preorganized layer.

キーワード：ニューラルネット，誤差逆伝搬学習，マニピュレータ，逆ダイナミクス学習

### 1. まえがき

誤差逆伝搬型ニューラルネット<sup>(1)</sup>は、高度に並列な処理が可能、任意の非線形写像を獲得できる強力な学習則をもつ、雑音や故障に強いなどの利点を備え、パターン認識、学習制御をはじめ多くの分野に应用されている。しかしながらその反面、学習に時間がかかったり、解がローカルミニマに落ち込むなどの問題点をもっており、これらの解消のために、様々な研究がなされている<sup>(2)</sup>。

それらの多くは、学習パラメータの調節、他の非線形最適化手法の適用などであるが、ネットワークを構成するユニットの入出力特性を一般化しようとする研

究も幾つか行われている。例えば、Rumelhartらの $\Sigma\Pi$ (積和)ユニット<sup>(1)</sup>、Durbínらの積ユニット<sup>(3)</sup>、Leeらの三角関数によるロボット運動学の学習<sup>(4)</sup>などである。また福見ら<sup>(5)</sup>は、ユニットの出力関数にシグナム関数を共存させることによって、2値出力に対する学習の高速化を実現している。

本研究では、学習対象とする写像に含まれている非線形関数の一部が既知の場合を想定し、その既知の関数をユニットとしてネットワークに組込むことを考える。このことは、学習対象の特徴をあらかじめ先見の知識としてネットワークに埋込むことを意味している。

例えば、多関節マニピュレータのフィードフォワー

ド制御を考えよう。多関節マニピュレータは、各関節間に存在する動的な干渉、姿勢による慣性特性の変化など非線形性の強いシステムである。このため、マニピュレータの運動方程式を導出し、与えられた目標軌道から運動に必要なトルクを計算する方法が一般に用いられる。この方法では、運動方程式を正確に導出することができれば、マニピュレータを精度良く制御することができる。しかしながら、一般の産業用マニピュレータでは、質量中心の位置や慣性モーメントなどのパラメータが不明確であり、また摩擦や重力補償機構など通常の運動方程式だけでは表現できない未知の要素も含まれるため、正確な運動方程式の導出は困難である。これらの問題を解決するために、最近では、ニューラルネットを用いてマニピュレータの逆ダイナミクスを学習的に獲得しようとする試みが盛んに行われており、直接逆モデリング法<sup>(6)</sup>、順逆モデリング法<sup>(7)</sup>、フィードバック誤差学習法<sup>(8)</sup>などが提案されている。しかし、これらの方法ではいずれも誤差逆伝搬型ニューラルネットをそのまま用いており、学習対象(マニピュレータの運動)に関する知識が全く利用されていない。

一般にマニピュレータの運動方程式には、三角関数などの非線形関数が含まれることがあらかじめわかっている。そこで著者らは、さきにこれらの非線形関数を既知特性ユニットとして誤差逆伝搬型ニューラルネットに組込むことを提案した<sup>(9)</sup>。しかし、このネットワークでは、既知特性ユニットより入力側の重み係数は既に与えられているものと仮定し、その修正は行っていない。

そこで本論文では、学習対象の特徴を表現した既知特性ユニットにも誤差逆伝搬学習を適用できることを示し、従来のシグモイド関数のみからなるニューラルネットと比較して、汎化能力、学習速度を改善できることを明らかにする。以下、第2章では本論文で提案するニューラルネットの構造について説明し、簡単な数値例を用いてこのネットワークの学習能力を解析する。第3章ではこのニューラルネットを2関節平面マニピュレータの逆ダイナミクス学習に適用した実験結果について述べる。

## 2. 既知構造ニューラルネット

〈2・1〉ニューラルネットの構成 学習によって問題を解決する場合、その学習対象に含まれる写像特性がある程度知られている場合が多い。ところが、従来の誤差逆伝搬型ニューラルネットでは、各ユニットの出力関係にシグモイド関数

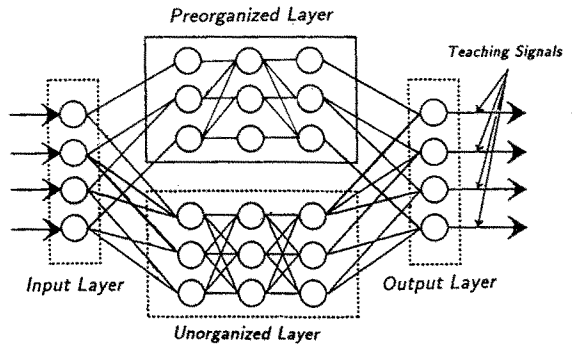


図1 既知構造ニューラルネット  
Fig. 1. Preorganized neural network.

$$f_i(x) = \frac{1}{1 + e^{-x}} \dots\dots\dots (1)$$

を用いたような構造で学習が行われており、先見的知識は全く利用されていない。シグモイド関数を用いられる理由は、実際の脳の神経細胞の入出力特性に類似していること、および有界で準線形(単調非減少で微分可能)という数学的な性質をもつためである。

これに対し本論文では、学習対象に含まれることが既知な非線形関数をニューラルネット内に既知構造層として組込むことを考える。図1に、既知特性を組込んだニューラルネット(以下、既知構造ニューラルネットと呼ぶ)の構造を示す。ネットワークは、入力層、出力層、中間層、既知構造層からなるフィードフォワード型である。このとき、教師信号  $t_i$  とネットワークの出力  $y_i$  の誤差の自乗和を最小にするという評価のもとに、各層間と中間層内の重み係数  $w_{ij}$  を、次式に従って修正する。

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial x_i} y_j \dots\dots\dots (2)$$

$$\frac{\partial E}{\partial y_i} = \begin{cases} y_i - t_i & \text{(出力層)} \\ \sum_k \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial x_k} w_{ki} & \text{(出力層以外)} \end{cases} \dots\dots\dots (3)$$

ここで、 $x_i$  は各ユニットの入力、 $\eta$  は学習率で、中間層内のユニットの出力関数にはシグモイド関数((1)式)を用いることにする。

既知構造層のユニットの出力関数には、既知関数

$$f_i(x) = \phi_i(x) \dots\dots\dots (4)$$

を用いる。以下、出力関数に  $\phi_i(x)$  を用いたユニットを既知特性ユニットと呼ぶことにする。

誤差逆伝搬学習則((2)、(3)式)には、ユニットの出力  $y_i$  をその入力  $x_i$  で偏微分する項が含まれるだけなので、出力関数  $f_i(x)$  は、シグモイド関数でなくとも、入力定義域において一階微分可能であるならば適

用が可能である。そこで、(4)式の  $\phi_i(x)$  は、一階微分可能な入出力特性をもち、かつ学習対象に含まれることが理論的、経験的にわかっている非線形関数であると仮定する。この場合、(2)、(3)式の誤差逆伝搬学習則を中間層と同様に適用することができ、適切な学習率を与えれば、重み係数  $w_{ij}$  は、教師信号  $t_i$  とネットワークの出力  $y_i$  との誤差自乗和を極小にする値に収束する。ここで、既知構造層の重み係数  $w_{ij}$  の初期値には、必ずしも乱数を用いる必要はない。既知構造層の重み係数は、学習対象によっては、その推定値(真値ではない)が与えられる場合や、理論的に類推できる場合が考えられる。このような場合には、その推定値を重み係数の初期値として用いればよい。学習対象に関する一種の事前知識を利用するのである。

このネットワークの特徴は、既知構造層にあらかじめわかっている関数を組込むことができるという点にある。これにより、学習対象のうち既知の部分は既知構造層で、未知の部分は中間層で学習でき、従来のシグモイド関数のみで構成されるネットワークに比べ、より正確で速い学習が可能となると考えられる。

〈2・2〉 既知構造ニューラルネットの学習能力

まず、既知構造ニューラルネットの学習能力を明らかにするため、以下のようなシミュレーション実験を行った。学習対象は、

$$t = 2 \sin(x_1 + x_2) - 2 \sin(x_1 - 2x_2) + \cos(2x_1 - x_2) + 2 \cos(-x_1 - 2x_2) - (-x_1 + 2x_2)^2 + (-2x_1 + 2x_2)^2 \dots (5)$$

の2入力1出力システムで、教師信号は  $x_1, x_2 = 0, \pm 1.0$  をそれぞれ組合せた9パターンとした。学習率  $\eta$  の設定にはデルタ・バー・デルタ法<sup>(10)</sup>を用い、重み係数は  $|w_{ij}| < 1.0$  の一様乱数からなる10通りの初期値に対して学習を行った。中間層は、シグモイド関数からなるユニットを10ユニット×2層、10ユニット×1層の2種類を用意し、既知構造層は、(A)  $\sin x, \cos x$  の非線形関数を既知特性ユニットに用いた

場合、(B)  $\cos x, x^2$  の非線形関数を既知特性ユニットに用いた場合、(C)  $\sin x, \cos x, x^2$  の非線形関数を既知特性ユニット用いた場合の3種類とした。また、比較のため、(D)シグモイド関数のみで構成したネットワークでも同様に学習を行った。ここで、学習対象に含まれる非線形関数で既知構造層に組込まれていない関数(例えば、(A)の場合では、学習対象の中の自乗項)は未知の特性となり、中間層で学習しなければならない。

表1に学習結果を示す。表中の Preorganized Layer は既知構造層の構成を、Unorganized Layer はシグモイド関数よりなる中間層の構成を示している。また、MIN (Mean Iteration Number) は誤差自乗和  $E$  が  $10^{-7}$  未満になるまでに要した10通りの重み係数の初期値に対する平均学習回数である。同表から、本論文で提案する既知構造ニューラルネットのほうが、シグモイド関数のみで構成したネットワークに比べ、誤差の収束が速くなっていることがわかる。また、既知特性ユニットの数が学習対象より多いネットワーク(それぞれ5ユニットずつ：表1中の5+5)のほうが、一致しているネットワーク(それぞれ2ユニットずつ：表1中の2+2)に比べ誤差の収束が速い。これは、冗長な既知特性ユニットが対象とする非線形関数を分担して学習したためであると考えられる。


一方、表1の Success Rate は、学習が十万回以内で収束した割合で、学習の成功率を表している。中間層を1層にすると、シグモイド関数のみでは学習ができないのに対し、既知構造層を組込むことによってかなり成功率が改善されていることがわかる。ネットワークがローカルミナに陥込むのを既知特性ユニットが防いでいるのである。

図2は、ニューラルネットの補間能力を示している。(a)図は、従来のシグモイド関数によりなるネットワーク(中間層は、10ユニット×2層)、(b)図は既知特性ユニットを  $\sin x, \cos x, x^2$  各5ユニットずつ用意した既知構造ニューラルネット(表1C)で学習を行った結果で、いずれも点線は学習対象を、実線は学習後(誤差自乗和が  $10^{-7}$  未満)のネットワークの出力写像である。


(a)図のシグモイド関数からなるネットワークの出力は教師信号で与えた点 ( $x_2 = -1, 0, 1$ )こそ学習対象と一致しているものの、未学習の部分では学習対象と大幅にずれている。一方、(b)図の既知構造ニューラルネットでは、学習対象とのずれが少ない。この傾向は  $x_1$  についても同様に観察された。これにより、既知構造ニューラルネットは、シグモイド関数からなる

表1 既知構造ニューラルネットの学習能力  
Table 1. Learning ability of preorganized neural networks.

Type		Preorganized Layer	Unorganized Layer	Success Rate (%)	M.I.N. ( $E < 10^{-7}$ )
A	1	$\sin x, \cos x$ (2+2)	(10×1)	60	1078
	2	$\sin x, \cos x$ (2+2)	(10×2)	100	411
	3	$\sin x, \cos x$ (5+5)	(10×1)	100	146
	4	$\sin x, \cos x$ (5+5)	(10×2)	90	162
B	1	$x^2, \cos x$ (2+2)	(10×1)	60	1001
	2	$x^2, \cos x$ (2+2)	(10×2)	100	1174
	3	$x^2, \cos x$ (5+5)	(10×1)	100	1169
	4	$x^2, \cos x$ (5+5)	(10×2)	100	1328
C	1	$\sin x, \cos x, x^2$ (2+2+2)	---	60	239
	2	$\sin x, \cos x, x^2$ (5+5+5)	---	100	164
D	1	---	(10×1)	0	---
	2	---	(10×2)	100	4087



(a) 誤差逆伝搬型ニューラルネット



(b) 既知構造ニューラルネット

図2 既知構造ニューラルネットの汎化能力  
Fig. 2. Generalization ability of preorganized neural network.

ネットワークに比べ、教師信号で与えた点以外でのネットワークの能力、すなわち汎化能力が優れていることがわかる。

以上、本章では既知構造ニューラルネットについて説明し、その学習能力をシミュレーション実験により調べた。既知構造ニューラルネットでは、学習対象に含まれる一部の非線形関数を既知構造層として用意しているため、中間層で学習しなければならない写像が単純化される。これにより、中間層での学習の負担が軽減され、シミュレーション結果に見られた学習能力の改善が実現されたと考えられる。今後は、この理論的根拠を明確にする必要がある。

### 3. マニピュレータの逆ダイナミクス学習への応用

本章では、既知構造ニューラルネットを2関節水平型ダイレクトドライブロボット<sup>(11)</sup> [(株)神戸製鋼所製:以下、DDロボットと呼ぶ]の逆ダイナミクス学習に適用し、その能力を検討する。

〈3・1〉 DDロボットの運動方程式 図3に実験に使用したDDロボットを示す。DDロボットでは、




図3 実験に使用した2関節水平型ロボット  
Fig. 3. Two-joint planar robot used in experiments.

サーボ系からギアなどの減速機構を排除し、モータで各関節を直接駆動することができるので、ガタやバックラッシュなどがなくなり、高速で正確な動作を実現できる。しかし、逆に減速機構がないために、ロボットに作用する慣性力や遠心力、コリオリ力などといった非線形力の影響が顕著に現れる。このため、制御系を構成する際には、ロボットダイナミクスの同定が重要な問題となる。

2関節平面マニピュレータの場合、運動方程式は

$$I(\theta)\ddot{\theta} + h(\theta, \dot{\theta}) = \tau \quad \dots\dots\dots (6)$$

と書くことができる<sup>(12)</sup>。ここで、 $\theta \in R^2$ は関節角度、 $\tau \in R^2$ は関節トルク、 $I(\theta) \in R^{2 \times 2}$ は慣性行列、 $h(\theta, \dot{\theta}) \in R^2$ はコリオリ力・遠心力で、以下のように与えられる。

$$I(\theta) = \begin{bmatrix} p_1 + 2p_3 \cos \theta_2 & p_2 + p_3 \cos \theta_2 \\ p_2 + p_3 \cos \theta_2 & p_2 \end{bmatrix} \quad \dots\dots\dots (7)$$

$$h(\theta, \dot{\theta}) = \begin{bmatrix} -(p_3 \dot{\theta}_2^2 + 2p_3 \dot{\theta}_1 \dot{\theta}_2) \sin \theta_2 \\ p_3 \dot{\theta}_1^2 \sin \theta_2 \end{bmatrix} \quad \dots\dots\dots (8)$$

(7)、(8)式の  $p_1$ 、 $p_2$ 、 $p_3$  はパラメータで、

$$p_1 = I_1 + I_2 + m_1 a_1^2 + m_2 (l_1^2 + a_2^2) \quad \dots\dots\dots (9)$$

$$p_2 = I_2 + m_2 a_2^2 \quad \dots\dots\dots (10)$$

$$p_3 = m_2 l_1 a_2 \quad \dots\dots\dots (11)$$

ただし、 $m_i$ : リンク  $i$  の質量、 $l_i$ : リンク  $i$  の長さ、 $a_i$ : リンク  $i$  の関節から質量中心までの長さ、 $I_i$ : リンク  $i$  の質量中心回りの慣性モーメント

である。

ニューラルネットを用いてマニピュレータの逆ダイナミクスを学習する場合の先見的知識は運動方程式[(6)式]である。この運動方程式中に含まれる三角関数と乗算を特性関数  $\phi_i$  として用いると、既知構造




図 4 逆ダイナミクス学習のための既知構造層

Fig. 4. Preorganized layer for inverse dynamics learning.

表 2 既知構造層の重み係数とリンクパラメータの関係

Table 2. Relationships between weight values in preorganized layer and link parameters.

$w_{ij}$	$w_{11}$	$w_{21}$	$w_{22}$	$w_{13}$	$w_{14}$	$w_{15}$	$w_{16}$	$w_{26}$	$w_{17}$	$w_{27}$
$P$	$2p_3$	$p_3$	$p_3$	$p_3$	$-2p_3$	$-p_3$	$p_1$	$p_2$	$p_2$	$p_2$

層を図4のように構成することができる。ここで、既知構造層の出力層の第*i*ユニット(*i*=1, 2)とその前の層の第*j*ユニット(*j*=1, 2, ..., 7)の結合の重み係数 $w_{ij}$ (図4参照)と、運動方程式のパラメータ $p_1, p_2, p_3$ には、表2のような対応関係がある。

この既知構造層に、シグモイド関数のみからなる中間層(5ユニット×2層)を加えて、既知構造ニューラルネットを構成する。このネットワークを用いることによって、運動方程式中の不明確なパラメータは既知構造層で、また(6)式の運動方程式で表現できない未知の要素は中間層でそれぞれ学習できると考えられる。

〈3・2〉 逆ダイナミクスの学習 前節で述べた既知構造ニューラルネットを用いてDDロボットの逆ダイナミクスの学習実験を行った。ここでは直接逆モデリング法を用いることにし、実際にDDロボットを動かして得た関節角度 $\theta$ 、角速度 $\dot{\theta}$ 、角速度 $\ddot{\theta}$ 、および関節トルク $\tau$ のデータ対100個(サンプリング間隔125ms)を教師信号とした。また、既知要素は既知構造層、未知要素は中間層という学習の分離を行いやすくするため、以下のような学習スケジュールを採用した。

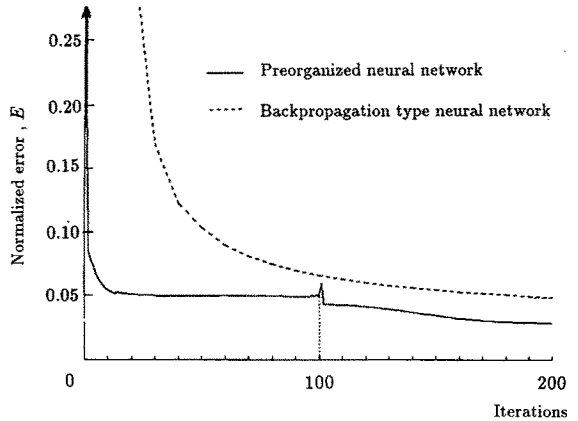


図 5 学習過程の一例

Fig. 5. An example of learning history.

まず図4の既知構造層のみを用い、重みの初期値を $|w_{ij}| < 1.0$ の乱数として、出力層とその前の層の間の重み係数のみを修正し、それ以外の重み係数は1.0に固定しておく。そして、このネットワークで誤差が減少しなくなるまで学習を行う。次に、中間層(5ユニット×2層)をネットワークに加え、中間層、既知構造層の誤差逆伝搬学習を行う。なお、中間層の重みの初期値も $|w_{ij}| < 1.0$ の乱数とする。

この学習スケジュールは、既知構造層と出力層の間の重み係数を通常最小自乗法で推定し、その推定結果を誤差逆伝搬学習の初期値に用いることを意味している。このような初期学習は必ずしも必要ではないが、最小自乗法によって修正された重み係数を、学習対象に関する一種の事前知識として利用することにより、あとに続く誤差逆伝搬学習の負担を軽減することができる。既知構造ニューラルネットでは、誤差逆伝搬学習を実行する重み係数を選択するだけで、このような初期学習を行うことが可能である。

以上の方法を用いて行った学習過程の一例を図5に示す。縦軸は誤差、横軸は学習回数で、実線は既知構造ニューラルネット、破線は比較のために行ったシグモイド関数のみからなる誤差逆伝搬型ニューラルネット(中間層:7ユニット×2層)の誤差を表している。ただし、誤差 $E$ は次式のように教師信号(トルク)の自乗和で正規化している。

$$E = \frac{\sum_{i=1}^{100} \sum_{j=1}^2 \{t_j(i) - y_j(i)\}^2}{\sum_{i=1}^{100} \sum_{j=1}^2 t_j(i)^2} \dots\dots\dots (12)$$

既知構造ニューラルネットでは100回で学習の切換えが行われている。

また、10通りの重み係数の初期値に対して、(12)式の誤差が0.05(出力と教師信号との誤差の自乗和がトルクの自乗和の5%)以下になるまでに要した学習回数は、既知構造ニューラルネットで平均190.8回(標準偏差92.3回)、誤差逆伝搬型ニューラルネットで平均599.8回(標準偏差161.7回)であった。このことから、既知構造ニューラルネットを用いたほうが通常の誤差逆伝搬型ニューラルネットの場合よりはるかに速く誤差が収束していることがわかる。ここで、修正可能な重み係数の個数は、どちらのネットワークも共に105であり、更に100回目までは既知構造ニューラルネットの修正できる重み係数は10個であることを考えれば、既知構造ニューラルネットが学習速度の点で誤差逆伝搬型ニューラルネットよりも優れていることがわかる。

〈3・3〉汎化能力 〈2・2〉節では、既知構造ニューラルネットの汎化能力が誤差逆伝搬型ニューラルネットに比べて優れていることを示した。しかしながら、本章で教師信号として用いているデータ $(\theta, \hat{\theta}, \check{\theta}, \tau)$ には計測時の偶発的な雑音が含まれている。従って、汎化能力を調べるためには学習をいつ打切るかということが問題になる。そこで、Cross Validation<sup>(13)</sup>の考え方をを用いて、汎化能力が最も高いと期待されるところで学習を打ち切り、既知構造ニューラルネットの汎化能力を通常の誤差逆伝搬型ニューラルネットと比較した。

いま、ネットワークの重み係数の組 $\omega$ のもとで $i$ 個目のデータに対するネットワークの出力 $y_i(\omega) \in R^L$ と教師信号 $t_i \in R^L$ の誤差

$$\varepsilon_i(\omega) = t_i - y_i(\omega) \quad \dots\dots\dots (13)$$

が、平均0、分散 $\sigma_j^2$  ( $j=1, 2, \dots, L$ )の互いに独立な $L$ 次元正規分布に従うと仮定する<sup>(14)(15)</sup>。


$$P(\varepsilon_i | \omega, \sigma_1^2, \sigma_2^2, \dots, \sigma_L^2) = \prod_{j=1}^L p(\varepsilon_{ij} | \omega, \sigma_j^2) \quad \dots\dots\dots (14)$$

$$p(\varepsilon_{ij} | \omega, \sigma_j^2) = \left[ \frac{1}{2\pi\sigma_j^2} \right]^{\frac{1}{2}} \exp \left[ -\frac{\varepsilon_{ij}^2(\omega)}{2\sigma_j^2} \right] \quad \dots\dots\dots (15)$$


ここで、 $N$ 個の未知の標本に対する対数尤う度

$$l(\omega, \sigma_1^2, \sigma_2^2, \dots, \sigma_L^2) = -\frac{N}{2} \sum_{j=1}^L \log 2\pi\sigma_j^2 - \sum_{i=1}^N \sum_{j=1}^L \frac{\varepsilon_{ij}^2(\omega)}{2\sigma_j^2} \quad \dots\dots\dots (16)$$

を最大にする $\omega$ 、 $\sigma_j^2$ が得られるとき、このネットワークの汎化能力が最も高くなると期待される。 $\omega$ の最ゆう推定量の代わりに $k$ 回の学習後のネットワークの重み係数の組 $\omega^k$ を考え、 $\sigma_j^2$ の推定量に(16)式を



(a) 既知構造ニューラルネット



— Normalized error for teaching patterns  
 --- Generalization index  
 ..... Normalized error for unlearned patterns  
 (b) 誤差逆伝搬型ニューラルネット

図6 汎化指数 $G^{(N)}(k)$

Fig. 6. Generalization index  $G^{(N)}(k)$ .

$\sigma_j^2$ で偏微分して0とおいた

$$\bar{\sigma}_j^2 = \frac{1}{N} \sum_{i=1}^N \varepsilon_{ij}^2(\omega^k) \quad \dots\dots\dots (17)$$

を用いると結局、汎化指数 $G^{(N)}(k)$ ,

$$G^{(N)}(k) = -l(\omega, \bar{\sigma}_1^2, \bar{\sigma}_2^2, \dots, \bar{\sigma}_L^2) = \frac{2}{N} \sum_{i=1}^N \log 2\pi \left[ \frac{1}{N} \sum_{j=1}^L \varepsilon_{ij}^2(\omega^k) \right] + \frac{2}{LN} \quad \dots\dots\dots (18)$$

が最小となるところで、学習を打ち切れば最も高い汎化能力が得られると考えられる。

そこで、汎化能力を調べるために、教師信号と同じ方法で得た100個×9パターンのデータのうち、これからランダムに100個抽出したものをテスト用データとした( $N=100$ )。このテスト用データに対して、(18)式の $G^{(N)}(k)$ が最小になったところで学習を打ち切り、その時点でのネットワークを用いて未学習の9パターンについて関節角度 $\theta, \hat{\theta}, \check{\theta}$ からトルク $\tau$ を求め、実際のトルクに対する誤差を(12)式によって計算した。

図6にこの汎化指数 $G^{(N)}(k)$ を示す。(a)図は既知構造ニューラルネット、(b)図は誤差逆伝搬型ニューラルネットで、左の縦軸は誤差、右の縦軸は $G^{(N)}(k)$ 、横軸は学習回数である。実線は教師信号に

表 3 逆ダイナミクスの学習結果  
Table 3. Results of inverse dynamics learning.

	Normalized error, $E$										
	Teaching patterns	Unlearned patterns									Mean
		1	2	3	4	5	6	7	8	9	
Preorganized N.N.	0.03	0.05	0.08	0.09	0.05	0.10	0.05	0.10	0.06	0.10	0.07
Backpropagation type N.N.	0.04	0.18	0.16	0.34	0.13	0.23	0.21	0.34	0.24	0.36	0.24

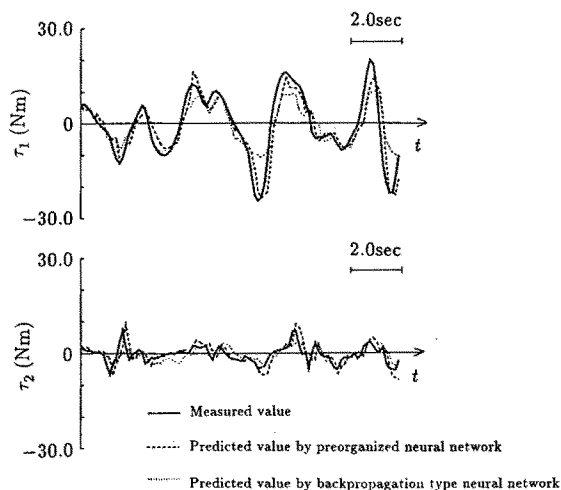



図 7 未学習パターンに対して予測した関節トルク

Fig. 7. Predicted joint torques for unlearned patterns.


対する誤差, 破線は  $G^{(N)}(k)$ , 点線は未学習データに対する誤差を表す。図から, 学習を続けていくと, 教師信号に対する誤差は減少していくが, 未学習のデータに対してはある学習回数を超えると誤差は増加し始める。これは, 教師信号が偶発的な雑音を含んでいるためである。また,  $G^{(N)}(k)$  (破線) と未学習データに対する誤差 (実線) が最小となる学習回数はほぼ一致しており,  $G^{(N)}(k)$  によってネットワークの汎化能力をうまく表現できることがわかる。

そこで,  $G^{(N)}(k)$  が最小になったところで学習を打ち切り (既知構造ニューラルネット: 202 回, 誤差逆伝搬型ニューラルネット: 378 回), 未学習の 9 パターン  $\times$  100 個のデータに対して誤差を求めた結果を表 3 に示す。既知構造ニューラルネットの未学習パターンに対する平均誤差は誤差逆伝搬型ニューラルネットと比べて 3 分の 1 程度に減少しており, その汎化能力が優れていることがわかる。

また, 既知構造ニューラルネットと誤差逆伝搬型ニ



(a) 既知構造層の重み係数



(b) マニピュレータの仕様から計算したリンクパラメータ

図 8 学習によって獲得されたリンクパラメータ

Fig. 8. Link parameters learned in neural networks.

ューラルネットを用いて, それぞれ未学習パターンの関節角度  $\theta, \dot{\theta}, \ddot{\theta}$  から関節トルク  $\tau$  を推定した結果を図 7 に示す。上は第 1 関節, 下は第 2 関節で, 縦軸はトルク, 横軸は時間を表し, 実線は実測値, 破線は既知構造ニューラルネット, 点線は誤差逆伝搬型ニューラルネットによる出力である。誤差逆伝搬型ニューラルネットは, 実測値からかなりずれており, 汎化能力に欠けることがわかる。一方, 既知構造ニューラルネットは, 未学習のパターンであっても実測値に近い値を出力できている。

〈3・4〉 力学パラメータの同定 学習後の既知構造ニューラルネットのうち, 既知構造層の出力層への重み係数 10 個を図 8(a) に示す。一方, これに対応する運動程式のパラメータ (表 2) を DD ロボットの仕様から求めた値は (b) 図のようになる。(b) 図のパラメータ値は真値ではないが, かなり真値に近い値になっているはずである。既知構造ニューラルネットでは重み係数の初期値を乱数にしたにもかかわらずロボッ

トの仕様から求めたものと近い値になっている。これは、既知構造層での学習によって、マニピュレータの力学モデルをある程度、同定できたことを表している。

#### 4. むすび

本論文では、学習対象に関する知識をニューラルネットで利用するための一方法として、学習対象に含まれることが既知な非線形関数を誤差逆伝搬型ニューラルネットに組込むことを提案した。このネットワークを用いれば、学習対象のうちあらかじめわかっている部分は既知構造層で、未知な部分は中間層で学習することができる。本論文では、マニピュレータの逆ダイナミクス学習にこの既知構造ニューラルネットを適用し、実際にDDロボットから得たデータを用いて学習実験を行った。そして、運動方程式に見合った既知構造層を用意することにより、学習速度の改善、汎化能力の向上、力学パラメータの同定などが実現でき、従来の誤差逆伝搬型ニューラルネットと比べて効率の良い学習が可能であることを示した。

今後は、既知構造ニューラルネットの有効性を理論的に明らかにすると共に、対象領域に関する知識をより有効に利用する方法について検討する必要があると考えている。終りに、本実験に積極的に取組んでくれた本学卒業生 柴田美紀さん(現、ローランド)に感謝いたします。また、本研究の一部は文部省科学研究費(03452188)の研究助成によるもので、ここに改めて謝意をします。

(平成3年10月23日受付, 平成4年2月3日再受付)

#### 文 献

- (1) D. E. Rumelhart, G. E. Hinton, & R. J. Williams: "Learning internal representation by error propagation," in *Parallel Distributed Processing Vol. 1: Foundations*, Edited by D. E. Rumelhart, J. L. McClelland and the PDP Research Group, p.318, (1986) MIT-Press
- (2) 麻生:「誤差逆伝播学習の数理的性質」, 信学技報, PRU 89-14 (平元)
- (3) R. Durbin & D. E. Rumelhart: "Product units: A computationally powerful and biologically plausible extension to backpropagation network," *Neural Computation*, 1, 133 (1989)
- (4) S. Lee & R. M. Kil: Robot kinematic control based on bidirectional mapping neural network, *Proceedings of the IJCNN*, p.III 327 (1990) IEEE
- (5) 福見・大松:「新しいニューロンモデルCONEとその学習アルゴリズム」, 電学論C, 110, 191 (平3-3)
- (6) J. S. Albus: "A new approach to manipulator control: The cerebellar model articulation controller (CMAC)", *Trans. ASME J. Dynamic System, Meas. & Control*, p. 220 (1975)
- (7) M. I. Jordan & D. E. Rumelhart: Supervised learning with

the a distal teacher (1989) *Cognitive Science*

- (8) M. Kawato, Y. Uno, M. Isobe & R. Suzuki: "Hierarchical neural network model for voluntary movement with application to robotics", *IEEE Control System Magazine*, 8, 8 (1988)
- (9) 辻・西田・高橋・伊藤:「既知構造を有するニューラルネットによるマニピュレータの重力補償」, 信学誌 D-II, J73-D-II, 243 (平2-2)
- (10) R. A. Jacobs: "Increased rates of convergence through learning rate adaptation," *Neural Networks*, 1, 295 (1988)
- (11) 永岡・辻・伊藤:「ダイレクトドライブロボットを用いたインピーダンス制御系の構成」, 平元電気関係学会中国支部連大, p.149
- (12) 吉川: ロボット制御基礎論 (昭63) コロナ社
- (13) N. Tishby, E. Levin & S. Solla: "Consistent Inference of Probabilities in Layered Networks: Predictions and Generalization," *Proc. IJCNN*, p.II 403, (1989) IEEE
- (14) 栗田:「ニューラルネットにおけるモデル選択の試み」, 信学技報, PRU 89-16, 17 (平元)
- (15) 和田・川人:「Cross Validationによる汎化能力をもった神経回路網モデルサイズの選択」, 第5回生体・生理工学シンポジウム論文集, 2 A 3-3, 185 (平2)



辻 敏夫 (正員)

昭和60年広島大学大学院工学研究科博士課程前期修了。同年同大学工学部助手。ロボット工学, 生体工学, マン・マシンシステムなどの研究に従事。工学博士。計測自動制御学会, 日本ロボット学会, 電子情報通信学会, IEEE 会員。



森 大一郎 (非会員)

平成2年広島大学工学部第二類(電気系)卒業。現在, 同大学大学院工学研究科博士課程前期情報工学専攻在学中。ニューラルネットを用いたロボットの制御, パターン識別に関する研究に従事。



伊藤 宏司 (正員)

昭和44年名古屋大学大学院工学研究科修士課程前期修了。45年, 同大学工学部自動制御研究施設助手。54年広島大学工学部第二類(電気系)助教授, 現在に至る。生体運動制御, ロボティクス, マン・マシンインタフェースの研究に従事。工学博士。計測自動制御学会, 日本ロボット学会, 電子情報通信学会, IEEE 会員。