

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

正員 辻 敏夫[†] 学生員 西田 正孝[†]
 非会員 高橋 利彰[†] 正員 伊藤 宏司[†]

Gravity Compensation for Manipulator Control by Neural Networks with Partially Preorganized Structure

Toshio TSUJI[†], *Member*, Masataka NISHIDA[†], *Student Member*,
 Toshiaki TAKAHASHI[†], *Nonmember and Koji ITO[†], Member*

あらまし マニピュレータの重力トルクは、運動方程式を正確に導出できる場合には補償することが可能である。しかしながら、一般の産業用マニピュレータでは、質量中心の位置などのパラメータの値が明確でない場合が多く、またハンド部の取換えや物体の把持などにより、これらの値は大きく変化する。更に多くの場合、このようなパラメータの不明確さに加えて、機構的な重力補償（ばねやカウンタバランス）によって発生する運動方程式で表現するのが困難な要素が存在する。本論文では、ニューラルネットを用いてこのようなマニピュレータの重力トルクを補償することを試みる。そのため、ニューラルネットの入出力間の写像に含まれるとわかっている構造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の隠れユニットと並列に用意したモデルを提案する。これにより、学習対象であるリンク系の特徴をあらかじめ先見的知識としてネットワークに埋め込むことができる。最後に産業用マニピュレータを用いて行った実験結果を示し、本モデルを用いることによりマニピュレータの重力トルクを補償できること、手先の負荷に対しても適応的に学習が可能なることを明らかにする。

1. ま え が き

一般に多関節型マニピュレータには、各関節間に干渉が存在し、姿勢によって慣性特性が大きく変わったり、摩擦や重力、コリオリ力、遠心力が存在する。そのため、多関節型マニピュレータは非常に非線形性の強いシステムとなり、各関節間の独立したフィードバック制御だけでは、高速な運動を精度良く行うことは難しい。

一方、生体は多関節機構である四肢をうまく動かし、速くて巧みな運動ができる。生体運動の高速性、柔軟性という優れた特性は、運動制御が単に視覚や自己受容器によるフィードバック制御だけでなく、筋骨格系の力学特性を反映した内部モデルに基づくフィードフォワード制御、プログラム制御が行われていることを示唆している⁽¹⁾。このような内部モデルを生成するために

は、作業内容、作業対象、環境、自分自身の運動機構に関する広範な知識、それらを状況に応じて組み合わせるための知識が必要となる。特定の状況ごとに内部モデルを用意するというよりも、運動制御に必要とされる情報をサブシステムとしてもち、それらを状況に合わせて適宜、組み合わせるのである。もちろん、頻繁に起こる運動に関しては、運動スキーマのような内部表現が学習的に生成されていると考えられる。

最近、生体の中枢神経系に倣ったニューラルネットを運動の制御に応用しようとする研究が活発に行われている。川人は、異シナプス可塑性に基づいた運動学習の階層モデルを提案し、目標関節角度から各関節への入力トルクを計算する逆システム内部モデルを学習的に実現している⁽²⁾。このニューラルネットは、目標軌道を非線形変換するユニット層とそれを線形和する出力ユニット層の2層からなる。リンク系の運動方程式が非線形項の線形和として表される点をうまく利用している。しかしながら、一般の産業用マニピュレータには、複雑で不明確な非線形要素がかなり含まれてお

[†] 広島大学工学部, 東広島市
 Faculty of Engineering, Hiroshima University, Higashi-Hiroshima-shi, 724 Japan

り、必ずしも一般的な運動方程式が成り立つとは限らない場合も多い。従って、どのような非線形変換を用意しておくかという点が問題となる。

また、川人らは誤差逆伝搬型ニューラルネット⁽³⁾を用いて非線形変換そのものも学習的に獲得できることを示している⁽⁴⁾。誤差逆伝搬型ニューラルネットは、その一様な構造によって、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、ノイズや故障に強い、などといった利点を備えており、運動制御内部モデルを構築するための有効な手段となり得る。しかしながら、その一様な構造のため、逆に学習に時間がかかったり、解がローカルミナマに落ち込むなどの問題点を含んでいる。

そこで本論文では、学習対象であるリンク系の特徴をあらかじめ先見的知識としてネットワークに埋め込むことを考える。そのため、写像に含まれるとわかっている構造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の隠れユニットと並列に用意したモデルを提案する。そして、このモデルを用いて運動制御内部モデルのうち、重力の影響を補償するための重力補償内部モデルを学習的に生成することを試みる。

マニピュレータの重力トルクは運動方程式を正確に導出できる場合には能動的に補償することが可能である⁽⁵⁾。しかしながら、一般にはアクチュエータの負荷を軽減するため、カウンタバランスやばねなどを用いて機構的に釣合いをとって重力トルクの影響を補償する方法が用いられる。このような方法では正確な補償ができないだけでなく、運動方程式に未知の要素を組み込む結果となり、能動的な補償法の適用が困難となる。本論文で提案するモデルは運動方程式で表現できる重力トルクを既知特性ユニットで、また未知の要素を誤差逆伝搬型ニューラルネットで学習的に獲得することができ、複雑な機構をもつマニピュレータに対応することが可能となる。以下、2.では、既知構造を有するニューラルネットについて述べ、3.では、重力補償内部モデルの構成法を示す。最後に、4.では、産業用マニピュレータを用いて行った実験結果を示し、重力補償内部モデルを用いることにより、位置制御の精度が改善できることを明らかにする。

2. 既知構造を有するニューラルネット

図1は、本論文で提案するニューラルネットである。外界から入力を受ける入力ユニットと、外界に出力を送る出力ユニットだけでなく、その間で作用する隠れ

ユニット、既知特性ユニットの層を考える。各ユニットは一つ前の層から入力を受け、次の層へ出力を送る多層フィードフォワード型ネットワークで、層内のユニット間には結合がないものとする。

各ユニットの入出力 x_i , y_i を次のように定義する。

$$x_i = \begin{cases} I_i & (\text{入力ユニット}) \\ \sum_j w_{ij} y_j & \end{cases} \quad (1)$$

$$y_i = f_i(x_i) \quad (2)$$

各ユニットは一つ前の層のユニットの活性値 y_j を重み係数 w_{ij} を通して受け取り、微分可能な出力関数 f_i に従って活性値を出力する。但し、入力ユニットに関しては外部からの入力 I_i をそのままユニットの入力 x_i とする。

$$f_i(x_i) = \begin{cases} x_i & (\text{入力ユニット, 出力ユニット}) \\ \phi_i(x_i) & (\text{既知特性ユニット}) \\ \frac{2}{1+e^{-x_i}} - 1 & (\text{隠れユニット}) \end{cases} \quad (3)$$

このモデルの特徴は、誤差伝搬型ニューラルネットに既知特性ユニットを組み込んだ点にある。すなわち、学習しようとする写像に含まれる構造を既知特性ユニットの出力関数 ϕ_i と入力ユニットから既知特性ユニットへの重みを用いてネットワークに埋め込むのである。これにより、写像に含まれる既知構造は、入力層→既知特性層→出力層のネットワークで表現でき、その他の未知の要素は、入力層→隠れ層→出力層のネットワークで表現できる。あらかじめわかっている知識を構造的に用意しておくことにより、学習速度を速めることが可能になると思われる。

モデルの学習目標は、通常の誤差逆伝搬学習⁽³⁾と同




図1 既知構造を有するニューラルネット
Fig. 1 Neural network with partially preorganized structure.

じく、入力に対して目標出力が得られるようにユニット間の重み係数 w_{ij} を調節することである。

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial y_i} \frac{dy_i}{dx_i} y_j \quad (4)$$

$$\frac{\partial E}{\partial y_i} = \begin{cases} y_i - t_i & (\text{出力ユニット}) \\ \sum_k \frac{\partial E}{\partial y_k} \frac{dy_k}{dx_k} w_{ki} & \end{cases} \quad (5)$$

ここで、 η は学習率、 t_i は出力ユニットに与えられる教師信号、 k は i の次の層のユニットを表す。但し、入力ユニットと既知特性ユニットの間の重みは固定とする。

3. 重力補償内部モデルの構成法

一般に、多関節型マニピュレータの運動方程式は、 $M(\theta)\ddot{\theta} + f(\theta, \dot{\theta}) + g(\theta) + B_f\dot{\theta} + B_c(\dot{\theta}) = \tau$ (6) で表すことができる⁽⁶⁾。ここで θ は関節角度、 $M(\theta)$ は慣性行列、 $f(\theta, \dot{\theta})$ はコリオリ力・遠心力、 $g(\theta)$ は重力トルク、 B_f は関節の粘性摩擦行列、 $B_c(\dot{\theta})$ はクーロン摩擦、静止摩擦などの非線形摩擦力、 τ は関節トルクを表している。

本論文では、重力トルク $g(\theta)$ を補償する方法を考える。重力トルクは、位置制御を行う際、定常偏差を発生する要因となるため、通常、制御系の安定性を満足する範囲内で位置フィードバックゲインを大きく設定したり、PID 制御を採用するといった方法が用いられる。しかしながら、このような方法が適用できない場合も存在する。例えば、手先の柔らかさが要求されるコンプライアンス制御を行う場合には、むやみに位置フィードバックゲインを大きくすると手先の動きが硬くなってしまい、マニピュレータの手先のコンプライアント動作を実現できない。従って、何らかの方法で重力トルクを推定し、補償しておく必要がある。

マニピュレータの重力項は、各リンクの質量や質量中心の位置などのパラメータが既知の場合、式(6)の運動方程式に従って、計算することができる。しかしながら、一般の産業用マニピュレータでは、質量中心の位置はもちろんのこと、各リンクの質量でさえ明確でない場合が多い。また、ハンド部の取換えや物体の把持等により、各パラメータは大きく変化する。更に多くの場合、重力による影響を機構的な工夫(例えば、関節に取り付けられたばねなど)によって軽減する試みがなされており、このような複雑な機構が存在する場合は、運動方程式の適用自体が不可能である。そこで、運動方程式からの重力トルクの導出ではなく、前章で示したニューラルネットを用いて学習的に重力補償を

行うことを試みる。

提案する構成法は以下のとおりである。

(1) マニピュレータを目標関節角度 θ_d ($n \times 1$ ベクトル) へ位置決めする。制御則は PD 制御とし、

$$v = K(\theta_d - \theta) + B\dot{\theta} \quad (7)$$

を用いる。ここで、 K は位置フィードバックゲイン ($n \times n$ 行列)、 B は速度フィードバックゲイン ($n \times n$ 行列) で、 v ($n \times 1$ ベクトル) はサーボモータへの制御電圧である。

(2) マニピュレータが外力として重力、摩擦の影響を受ける場合は、 θ_d とは異なった関節角度 θ_a で静止する。釣合い条件を考えると、

$$\tau_s + g(\theta_a) \geq f_0(K(\theta_d - \theta_a)) \quad (8)$$

を満たしている場合は、リンクは上向きに動かない。ここで、 τ_s ($n \times 1$ ベクトル) は下向きの静止摩擦、 $f_0(\cdot)$ ($n \times 1$ ベクトル) は関節トルクとサーボモータの入力電圧の関係を表す関数である。

(3) 上方向への駆動力と下方向へ働く静止摩擦力と重力の和を釣り合わせるため、静止した状態で位置フィードバックゲイン K を徐々に大きくし、制御電圧を上げていく。そして、その関節が動き出した瞬間の制御電圧

$$v_d = K^*(\theta_d - \theta_a) \quad (9)$$

を測定する。

(4) 以上の手続きを目標関節角度を変えて M 回繰り返す。そして、静止摩擦に相当する電圧を差し引いた制御電圧 V_{ai} ($i=1, \dots, M$) を教師信号、 θ_{ai} ($i=1, \dots, M$) を入力信号として、教師信号とネットワークの出力との誤差の 2 乗和が小さくなるまでニューラルネットの学習を行う。

既知特性ユニットには、例えば、運動方程式の $g(\theta)$ に含まれる三角関数を用意しておく。これにより、リンクの質量や質量中心の位置などのパラメータは既知特性ユニットから学習でき、重力補償のための機構などの未知要素は隠れユニットを介するネットワークで学習することができる。また、学習を電圧レベルで行うことにより、式(8)に含まれる関数 f_0 を意識する必要がない。次章では、実際にマニピュレータを用いて、この方法の評価を行う。

4. マニピュレータ制御実験

前章で述べた手続きを図 2 に示す産業用マニピュレータ (MOVE MASTER II : 三菱電機製、質量約 27 kg) に適用し、重力補償内部モデルの生成を試みた。但




図2 多関節型マニピュレータ; MOVE MASTER II.
Fig. 2 A multi-articular manipulator; MOVE MASTER II.




図4 2リンクモデル
Fig. 4 Two-link model.




図3 学習過程
Fig. 3 Learning history of gravity compensation models.

し、手首 (θ_3, θ_4) とウエスト回り (θ_0) の関節は固定して、肩 (θ_1) と肘 (θ_2) の関節について重力補償を行った。

4.1 学習過程

まず、目標関節角度 θ_d を肩、肘関節ともそれぞれ 0° から 90° まで 10° きざみで 10 パターンとし、計 100 パターンの教師信号を用いて学習を行った。図 3 に学習過程を示す。図中(a)は、本論文で提案した既知構造を有するニューラルネット、(b)は、誤差逆伝搬型ニューラルネット⁽³⁾、(c)は、適応フィルタモデル⁽⁷⁾を用いた学習過程である。但し、(a)については、隠れ層を 2 層、隠れユニットを各層 10 個、既知特性ユニットを 6 個用意した。既知特性ユニットに用いた非線形関数は、 $\sin\theta_1, \sin\theta_2, \sin(\theta_1 + \theta_2), \cos\theta_1, \cos\theta_2, \cos(\theta_1 + \theta_2)$ の 6 種類である。また(b)には、隠れ層を 2 層、隠れユニットを各層 10 個、(c)については、(a)と同じ 6 種類の非線形関数を用いた。いずれも入力層、出力層のユニット数は各 2 個、学習率は 0.01 に設定して学習を行った。

ところで、実験中、手首関節とウエスト関節は固定しているので、このマニピュレータは図 4 に示す 2 リ

ンクアームと考えることができる。もし、マニピュレータの運動が式(6)の運動方程式によって完全に記述されるならば、重力トルク $g(\theta)$ は、

$$g_1(\theta) = (m_1 l_{g1} + m_2 l_1) g \sin(\theta_1) + m_2 g l_{g2} \sin(\theta_1 + \theta_2) \quad (10)$$

$$g_2(\theta) = m_2 g l_2 \sin(\theta_1 + \theta_2) \quad (11)$$

となる⁽⁶⁾。但し、 θ_i は関節角度、 m_i は各リンクの質量、 l_i はリンク長、 l_{gi} は関節から質量中心までの距離、 g は重力加速度で、添字 i は、1 が肩関節、2 が肘関節を表す。従って、重力トルクの計算に必要な非線形変換は、式(10)、(11)に含まれる \sin 関数だけとなる。しかし、この \sin 関数を用意した適応フィルタモデル(図 3(c))では誤差の減少が遅く、学習がうまく進まないことがわかる。これは、マニピュレータの重力トルクに式(10)、(11)以外の影響が含まれているためである。一方、誤差逆伝搬型ニューラルネット(図 3(b))では、誤差は減少するが学習速度はかなり遅い。これらに対して本論文で提案したモデル(図 3(a))では、精度を保ちながら速い学習速度を実現している。これは、内部モデル生成の際にあらかじめわかっている非線形変換を既知特性ユニットとして用意しているためである。

4.2 教師信号のパターン数

前節の実験では 100 個の教師信号を用いて学習を行った。本節ではこの教師信号のパターン数が学習に与える影響を検討してみる。

目標関節角度 θ_d を 10° きざみとした前節の教師信号に加えて、 $5^\circ, 15^\circ, 20^\circ, 25^\circ, 30^\circ$ 刻み(パターン数はそれぞれ、361 個、49 個、25 個、16 個、16 個となる)とした 6 種類の教師信号を用いて学習を行った。図 5 は 10,000 回の学習後の 2 乗誤差の平均値である。いずれも、学習後のネットワークに 5° 刻みの入力(361 個)を与え、実際の計測値との 2 乗誤差を入力数で平均して

いる。従って、 5° 刻みの教師信号の場合は学習時の2乗誤差の平均値と一致し、角度の刻みが増加するに従って学習時に用いていない入力パターンが増加する。図から角度の刻みが増加するにつれて誤差が増加していることがわかる。但し、 5° から 20° 刻みの間の教師信号では大幅な誤差の増加は見られず、ニューラルネットによる補間がうまく行われている。従って、本実験条件では肩、肘関節とも 20° 刻み、計20個という少ない教師信号で重力補償内部モデルを生成できることが明らかになった。

4.3 位置決め精度

次に、学習の結果得られた内部モデル(学習回数10,000回)の有効性を確認するため、制御電圧を

$$v = K(\theta_d - \theta) + B\dot{\theta} + v_g(\theta) \quad (12)$$

として位置決め制御を行った。 $v_g(\theta)$ はモデルを用いて計算した重力補償電圧である。但し、 K, B は対角行列で、 $K = \text{diag.}[11.191 \ 11.191]$ (v/rad), $B = \text{diag.}[26.857 \ 26.857]$ (v/(rad/sec))とした。なお、

本実験の目的は重力補償内部モデルの妥当性の確認にあるので、位置決めの際に定常偏差が残るように位置ゲイン K をかなり小さく設定した。

実験結果を図6に示す。(a)は補償前、(b)は補償後の肩と肘関節について、横軸に目標角度、縦軸に目標角度と実際の角度との誤差($\theta_d - \theta_a$)をとり、その関係を示したものである。図6(a)を見ると、肩の関節角度が 90° (アームが水平の位置)に近づくにつれて、誤差が減少していることがわかる。通常重力とは逆の影響である。これは、マニピュレータの関節に組み込まれている重力補償用のばねの効果である。このばねは、重力の影響が最も大きい姿勢($\theta_1 = 90^\circ, \theta_2 = 0^\circ$)に合わせて設定されているため、式(10), (11)とは全く異なった重力の影響がマニピュレータの位置決め誤差に現れている。これに対して、内部モデルによる補償を行うと(図6(b)), 肩、肘両関節とも誤差はほぼ $\pm 5^\circ$ の範囲に収まり、位置決め精度が内部モデルの付加によって向上している。しかも、これには教師信号として用いなかっ




図5 教師信号パターンと平均2乗誤差
Fig. 5 The relationship between teacher signals and their mean square errors.

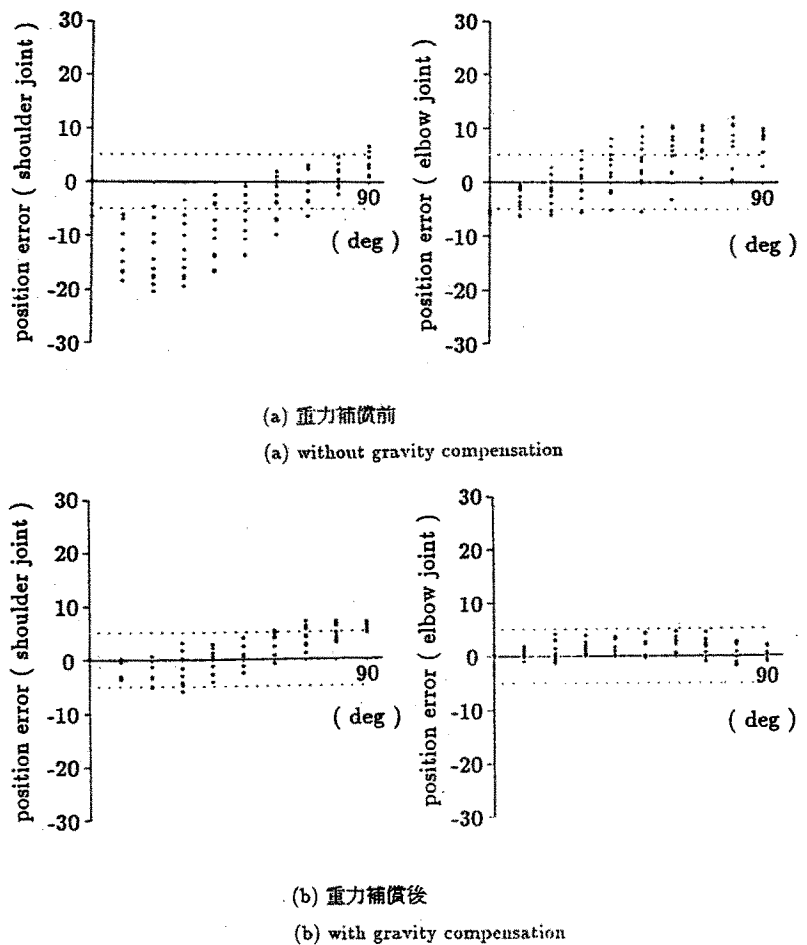


図6 位置決め制御実験
Fig. 6 Experimental results of position control.

た姿勢も含まれており、ニューラルネットが教師信号以外の姿勢に対しても重力補償をうまく行っていることがわかる。但し、学習回数を増加させてもこれ以上の改善は見られなかった。これは、教師信号に含まれるノイズの影響や、ニューラルネットの学習法によるものと考えられる。今後、よりロバストな教師信号の獲得法やニューラルネットの学習法を開発する必要がある。

次に、マニピュレータの手先に負荷を与えて、これに対する重力補償内部モデル生成実験を行った。500 gの物体を手先で把持したときの教師信号(10°刻み、計100パターン)を用いて学習した結果を図7に示す。図中、(a)は、4.3で学習した無負荷時のネットワークを初期値として再学習をした場合で、(b)は、負荷のあるときの教師信号だけで学習した場合である。また点線は、無負荷時のネットワークにおける学習後(10,000回)の出力ユニットでの誤差の2乗和を示す。図から、無負荷時のネットワークを再学習させた場合は、手先負荷

による誤差の増加が少なく、また、300回程度の少ない学習回数で誤差が減少していることがわかる。図8はこの時の位置決め制御の結果である。図6と比較して、肘関節の誤差が若干、増加している。これは、手先負荷による摩擦力の変化によるものと考えられ、今後検討する必要がある。但し、重力補償なしの場合(図8




図7 手先負荷(500 g)に対する学習過程
Fig. 7 Learning history for an end-point load (500 g).

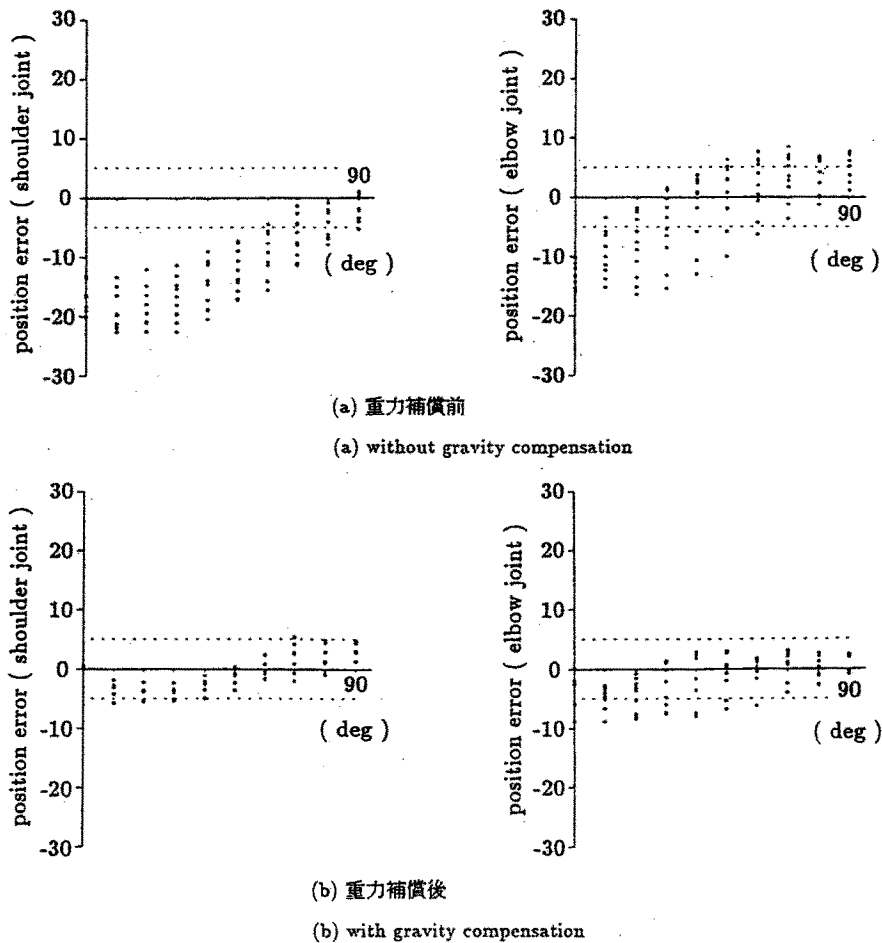


図8 手先負荷をもつマニピュレータの位置決め精度
Fig. 8 Position control accuracies of the manipulator with an end-point load.

(a)に比べると、位置決め精度は大きく改善されており、負荷変動に対して重力補償内部モデルが適応的に調節されたことがわかる。

5. むすび

本論文では、運動制御内部モデルを学習的に構築することを目的として、あらかじめリンク系の特徴をニューラルネットに埋め込むことを試みた。そのため、誤差逆伝搬型ニューラルネットに既知特性ユニットを組み込んだモデルを提案し、このモデルを用いて重力補償を行う内部モデルを学習的に生成する方法を示した。

一般の産業用ロボットには、減速機構に伴うガタや摩擦など複雑で不明確な非線形特性が存在する。これらの非線形特性には、関数の形がわかっているものも多く含まれている。本論文で示した方法は、このような先見的知識を有効に利用することができると共に、未知の特性に対してもその写像関係を学習的に獲得することができる。今後は、動力学や運動学に関する内部モデルのモデル化を行い、状況に応じてこれらの内部モデルを切り換えるという方法で、運動プログラム全体を構成していくことを考えている。

謝辞 本研究の一部は文部省科学研究費(62460142, 63750415)の研究助成によるもので、ここに改めて謝意を表します。

文 献

- (1) 伊藤宏司：“筋運動制御機構”，計測と制御，25，2，pp. 131-135 (昭61)。
- (2) 川人光男：“随意運動制御における適応と学習”，日本ロボット学会誌，4，2，pp. 184-193 (昭59)。
- (3) D. E. Rumelhart, et al: "Learning Internal Representations by Error Propagation", in PARALLEL DISTRIBUTED PROCESSING, 1, eds. D. E. Rumelhart and J. L. McClelland, pp. 318-362, MIT Press (1986)。
- (4) 川人光男, 宇野洋二, 鈴木良次：“随意運動制御における適応と学習II”，日本ロボット学会誌，6，3，pp. 222-230 (昭63)。
- (5) 新井健生, 矢野智昭, 橋本亮一, 中野栄二：“7自由度人間腕形ダイレクトドライブ・マニピュレータの開発”，日本ロボット学会誌，5，1，pp. 27-35 (昭62)。
- (6) R. P. Paul 著, 吉川恒夫訳：“ロボット・マニピュレータ”，コロナ社(昭59)。
- (7) B. Widrow and R. Winter: "Neural net for adaptive filtering and adaptive pattern recognition", IEEE Computer, 21, 3, pp. 25-39 (1988)。
- (8) 吉川恒夫：“ロボット制御基礎論”，コロナ社(昭63)。

(平成元年7月5日受付，9月7日再受付)



各会員。

辻 敏夫

昭60 広島大学院工学研究科博士課程前期システム工学専攻了。同年同大学工学部助手，現在に至る。生体工学，ロボット工学，マン・マシンシステムに関する研究に従事。計測自動制御学会，電気学会，日本ロボット学会，日本人間工学会，IEEE



西田 正孝

広島大・工・第2類(電気系)在学中。ニューラルネットを用いたロボット制御に関する研究に従事。計測自動制御学会会員。



高橋 利彰

昭63 広島大・工・第2類(電気系)卒。現在，同大学院工学研究科博士課程前期情報工学専攻在学中。ロボットのインピーダンス制御，ニューラルネットを用いた制御に関する研究に従事。計測自動制御学会，日本ロボット学会各会員。



伊藤 宏司

昭44 名古屋大学院工学研究科修士課程了。昭45 同工学部自動制御研究施設助手。昭54 広島大学工学部第2類(電気系)助教授，現在に至る。生体システム，ロボティクス，マン・マシンインタフェースの研究に従事。電気学会論文賞受賞。計測自動制御学会，電気学会，日本エム・イー学会，日本ロボット学会，IEEE 各会員。