ニューラルネットワークによるロボットマニピュレータ の線形化補償器*

尾崎 友哉**・鈴木 達也***・古橋 武***・
大熊 繁***・内川 嘉樹***

A Nonlinear Compensator Using Neural Networks for Robotic Manipulators*

Tomochika OZAKI**, Tatsuya SUZUKI***, Takeshi FURUHASHI***,
Shigeru OKUMA*** and Yoshiki UCHIKAWA***

This paper presents a nonlinear compensator using neural networks for trajectory control of robotic manipulators. The nonlinear compensator has a new architecture using both the computed torque method with the model of the manipulator and the neural networks. The neural networks in the compensator are to compensate only the parameter deviations and unmodeled effects of the manipulator and do not have to compensate all the nonlinearities of the manipulator. The neural networks are efficient in learning.

1. はじめに

近年, ロボットマニピュレータの高速, 高精度な軌道制御への要求が高まっている. ロボットマニピュレータは, パラメータ同定誤差や構造的な同定誤差の影響を受ける. パラメータ同定誤差としては, マニピュレータの重さや重心位置のズレなどが挙げられ, 構造的な同定誤差としては, マニピュレータの高周波振動モード, 制御遅れ, 非線形摩擦などが挙げられる. トルク計算法¹は, ロボットマニピュレータの有効な軌道制御法であるが, 高速な軌道制御を行なう場合に, パラメータ同定誤差, 構造的な同定誤差の影響を受けて精度が落ちる. これは, ダイレクトドライブロボットのように減速機を持たない構造の場合に顕著に現れる. パラメータ同定誤差は, パラメータ適応アルゴリズムにより補償が可能である^{2,3}. しかし, 構造的な同定誤差に対しては, 適応アルゴリズムの有効性が明らかではない.

ニューラルネットワーク⁴は, 学習能力, 非線形変換

能力, 並列処理などの特徴を持つ. このニューラルネットワークの制御への適用は, 適応制御の新しいアプローチと考えられる. これまでにもニューラルネットワークはマニピュレータの軌道制御に応用されてきたが, それらは, 制御対象であるマニピュレータの逆システムを学習により獲得するというものであった^{5,6}. しかし, このシステムにおいては, ニューラルネットワークの規模が大きくなり, 学習に時間がかかる. また, ニューラルネットワークによる制御系においては, 系の安定性の保証が得られていないなどの問題があり, ニューラルネットワークを逆システムの構築に用いる方法の有効性には疑問がある.

本論文では, ニューラルネットワークを逆システムの構築に用いるのではなく, マニピュレータの未知要素の補償に用いることを提案する. 本方法では, マニピュレータの非線形補償法であるトルク計算法¹とニューラルネットワークを併用し, トルク計算法で用いる概略モデルのパラメータ同定誤差および構造的な同定誤差をニューラルネットワークにより補償する. そして, 従来の適応制御を用いた場合との比較を行ない, ニューラルネットワークを用いた制御系がパラメータ同定誤差のみならず構造的な同定誤差をも補償できる可能性を持つことを示す. また, 本論文で述べるニューラルネットワークとトルク計算法を併用する手法が, 先に筆者らの提案した非線形

* 原稿受付 1990 5. 7

** 日立製作所 Hitachi Ltd. ; 4-6 Surugadai, Kanda, Chiyoda-ku, Tokyo 101, JAPAN

*** 名古屋大学 工学部 Nagoya University ; Furo-cho, Chikusa-ku, Nagoya 464-01, JAPAN

Key Words : neural network, robotic manipulator, trajectory control, nonlinear compensation, manipulator model.

補償器全部をニューラルネットワークにより実現する手法⁷に比べてニューラルネットワークの規模を小さくできることを示す。

なお、本手法においても制御系の安定性を保証することは困難であるが、本手法はニューラルネットワークを制御対象の未知部分の補償に用いており、ニューラルネットワークの特徴である学習能力・非線形変換能力を活かす有効な使い方をしていると考ええる。

2. トルク計算法

n 個の剛体リンクからなるロボットマニピュレータのダイナミクスは次式で与えられる。

$$\tau = M(\theta)\ddot{\theta} + h(\theta, \dot{\theta}) + F \quad (1)$$

ここで τ : $n \times 1$ のトルクベクトル

M : $n \times n$ のマニピュレータ慣性行列

h : 遠心力, コリオリ力などの $n \times 1$ ベクトル

θ : $n \times 1$ のリンク回転角ベクトル

$\dot{\theta}$: $n \times 1$ のリンク回転角速度ベクトル

F : $n \times 1$ の構造的な同定誤差や外乱による未知の項

従来のトルク計算法による制御則は次式で与えられる (Fig. 1)¹。

$$\begin{aligned} \tau &= \hat{M}(\theta)u + \hat{h}(\theta, \dot{\theta}) \\ u &= \ddot{\theta}_d + K_p(\theta_d - \theta) + K_v(\dot{\theta}_d - \dot{\theta}) \end{aligned} \quad (2)$$

$\hat{M}, \hat{h}$ はそれぞれ、マニピュレータの慣性行列 M , 遠心力・コリオリ力の項 h の推定値であり、 θ_d は目標リンク回転角である。また、 K_p, K_v はそれぞれフィードバックループの比例ゲインおよび微分ゲインであり、 $n \times n$ の対角行列である。パラメータ同定誤差や構造的な同定誤差が存在しない場合、(2) 式 of 非線形補償によりシステムは線形となる。一般的な場合、誤差 $e (= \theta_d - \theta)$ のダイナミクスは以下のように与えられる。

$$\hat{M}(\ddot{\theta}_d + K_p e + K_v \dot{e}) + \hat{h} = M\ddot{\theta} + h + F \quad (3)$$

つまり次式となる。

$$\ddot{e} + K_v \dot{e} + K_p e = \hat{M}^{-1}((M - \hat{M})\ddot{\theta} + h - \hat{h} + F) \quad (4)$$

Fig. 1 Controller using computed torque method

(4) 式からわかるように、パラメータ同定誤差や構造的な同定誤差がある場合、トルク計算法では制御系は漸近安定とはならない。

3. ニューラルネットワークを用いた制御系

構造的な同定誤差 F の存在が無視できるならば、パラメータ適応アルゴリズム^{2,3}を用いることによって、パラメータ同定誤差に対して制御系を漸近安定にできる。しかし、現実には F の項は無視し難く、その場合のパラメータ適応アルゴリズムの有効性に疑問が残る。そこで本論文では、最初にモデルに構造的な同定誤差が存在する場合において、Fig. 2 に示すようなニューラルネットワーク (NN) を用いた制御系を提案する。この制御系は、ニューラルネットワークとトルク計算法とを併用し、構造的な同定誤差の補償のみをニューラルネットワークが行なうものであり、ニューラルネットワークの規模を小さくできる。マニピュレータの各定数が実際の精度で測定できる場合、精度の良い軌道制御が可能である。マニピュレータの未知要素のみの補償をニューラルネットワークにより行なう本手法は、ニューラルネットワークの特徴である学習能力・非線形変換能力をよく活かしていると考ええる。

ここでは、Fig. 3 に示す 2 自由度スカラー型ロボットを

Fig. 2 Controller using computed torque method with neural network

Fig. 3 Two-degree-of-freedom manipulator

Table 1 Parameters of manipulator

		Link 1	Link 2	Unit
Arm length	L	0.25	0.16	m
Link center of gravity	k	0.20	0.14	m
Mass	m	9.5	5.0	kg
Inertia	I	4.3×10^{-3}	6.1×10^{-3}	$\text{kg} \cdot \text{m}^2$
Gear ratio	N	40	30	
Coulomb friction coefficient	T	1.0	1.0	$\text{N} \cdot \text{m}$
Motor inertia	J_m	4.61×10^{-5}	2.65×10^{-5}	$\text{kg} \cdot \text{m}^2$
Motor damping coefficient	D_m	3.84×10^{-3}	1.39×10^{-3}	$\text{kg} \cdot \text{s} \cdot \text{m}^{-1}$

Fig. 4 Neural network

制御対象とした。Table 1 にマニピュレータの各パラメータの値を示す。また、Fig. 4 はここで用いるニューラルネットワークである。ニューラルネットワークの入力は、各関節の角度と角速度 $\theta_1, \theta_2, \dot{\theta}_1, \dot{\theta}_2$ である。目標となる出力は、構造的な同定誤差の項 F_1, F_2 である。フィードバック信号を用いて、次式で与えられるバックプロパゲーションアルゴリズム (BP 法) により、学習を行なう。

$$\Delta W_{ji} = \eta \delta_j \cdot o_i \quad (5)$$

出力層

$$\delta_j = (K_p(\theta_d - \theta) + K_v(\dot{\theta}_d - \dot{\theta})) f'(net_j) \quad (6)$$

中間層

$$\delta_i = f'(net_i) \sum_l W_{li} \delta_l \quad (7)$$

ここで、 net_j はユニット j への入力を、 o_i はユニット i からの出力であり、 W_{ji} はユニット i からユニット j への結合の強さを表す重み係数である。また、 η は小さな正の定数で、学習率である。しきい値を b_j とすると、ユニット j の入出力は次式で与えられる。

$$net_j = \sum_i W_{ji} o_i + b_j$$

$$o_j = f(net_j) \quad (8)$$

ただし、 f はユニットの入出力関数で次式で与えられる。

$$f(x) = \frac{2}{1 + \exp(-x)} - 1 \quad (9)$$

2 自由度スカルロボットを用い、シミュレーションを行なった。構造的な誤差 F は、次のようなクーロン摩擦とする。

$$F_1 = T_1 \cdot \text{sgn}(\dot{\theta}_1) \quad (10)$$

$$F_2 = T_2 \cdot \text{sgn}(\dot{\theta}_2)$$

クーロン摩擦の係数は操作中にマニピュレータに印加する最大トルクの数パーセント程度とした。

まず、パラメータ適応アルゴリズムをもつトルク計算法と、ここで提案するニューラルネットワークを用いた制御系との比較を行なった。目標軌道としては、 X - Y 平面内での円軌道を与えた。Fig. 5 (a) が従来のトルク計算法にパラメータ適応アルゴリズム²⁾を適用した場合のマニピュレータの軌道である。サンプリング周期を 2 (ms) とし、円軌道を 1 周描くのに約 0.4 (s) 要している。比例ゲイン K_p の各対角要素は 20、微分ゲイン K_v のそれは 5 とした。これらのゲインは、関節の角度 θ と角速度 $\dot{\theta}$ の測定値に含まれるノイズに対して過敏とまらない程度の値とした。トルク計算法に用いる $\hat{M}, \hat{h}$ は、パラメータ適応アルゴリズムにより毎サンプリング修正した。円軌道を 1 周描いて 1 回の試行とし、図は 100 回目の試行結果を示す。Fig. 5 (b) は誤差の推移を示す。誤差の定義は次式による。

$$E = \sum_{i=1}^N (X_{di} - X_i)^2 + (Y_{di} - Y_i)^2 \quad (11)$$

ここで、 N は 1 回の試行におけるサンプリング回数である。また、 X_{di}, Y_{di} はサンプリング時点 i における X - Y 平面上の軌道指令値であり、 X_i, Y_i は得られた軌道である。この場合、モデル $\hat{M}, \hat{h}$ ではクーロン摩擦の項が考慮されていないため、誤差が残っている。Fig. 6 がニューラルネットワークを用いた場合の軌道で、100 回試行後の結果である。Fig. 2 のニューラルネットワークにおいて中間層のユニット数を 2 とし、学習率 η は 0.002 とした。ニューラルネットワークの出力は、マッチングゲインにより 2 倍され、ネットワークの出力ユニットの動作点が適切な値となるようにした。また、重み係数 W_{ji} はランダムに初期化した。重み係数の更新は毎サンプリング行ない、やはり、円軌道を 1 周描い

Fig. 5 Computed torque method with adaptive scheme

て1回の試行とした。ニューラルネットワークが学習によりクーロン摩擦の補償を行なっているため、100回の試行の後にはパラメータ適応アルゴリズムを用いた場合に比べ誤差がおおよそ1/10程度に小さくなっている。以上の結果より、ニューラルネットワークを用いた制御系は構造的な同定誤差が存在する場合でも精度の良い軌道制御が行なえる可能性を持つということが明らかとなった。

つぎに、本論文で提案するニューラルネットワークを用いた制御系で、ニューラルネットワークの小規模化について示す。比較のため、Fig. 7に示すようにニューラルネットワークが遠心力・コリオリ力の補償も行なう場合について検討した⁷⁾。中間層のユニット数を始めに2とし、その後ユニット数を次第に増して行き、誤差がFig. 6の場合と同じ程度に小さな値に収束するユニット数を探した。学習率およびマッチングゲインは試行錯誤

Fig. 6 Computed torque method with neural network

Fig. 7 Neural network controller without manipulator model

によりそれぞれ0.002, 6とした。マッチングゲインはニューラルネットワークが遠心力・コリオリ力の補償も行なうため大きな値を必要とした。Fig. 8はシミュレーション結果を示す。図は150回試行したときの誤差の様子を示す。Fig. 6の誤差に近い結果が得られている。こ

Fig. 8 Computed torque method with neural network (without manipulator model)

のときの中間層のユニット数は5であった。したがって、同程度の精度を出す場合に本法はニューラルネットワークの規模を小さくすることが可能である。このことをニューラルネットワーク内の計算回数により比較すると、本手法ではかけ算が12回、足し算が12回、シグモイド関数の使用が4回であるのに対して、Fig. 7に示す手法では、それぞれの回数が30, 30, 7であり、計算回数の総和では約0.4倍となっている。遠心力・コリオリ力の項 $\hat{h}(\theta, \dot{\theta})$ の演算を考慮した場合は、上記の値は約0.6倍である。このような比較は、ニューラルネットワーク専用の演算素子が開発された場合にはあまり意味を持たない恐れがあるが、その場合においても本手法によりネットワークのユニット数を少なくできることは、演算素子の負担を減らすことができ有効と思われる。また、本手法の有効性を示すもう一つの利点として、Fig. 6とFig. 8の誤差の推移からわかるように、本手法においては誤差の収束が格段に早くなっていることがあげられる。提案した制御系は、シミュレーションで用いたシステムにおいて数パーセント程度のパラメータ同定誤差があっても有効であった。

4. パラメータ同定誤差が大きい場合の制御系

3. で提案した制御系は、パラメータ同定誤差が小さい場合に有効な方法である。本章では、大きなパラメータ同定誤差が存在する場合にも有効な制御系の提案を行なう。本章で提案するニューラルネットワークを用いた制御系を Fig. 9 に示す。本制御系においては、2個のニューラルネットワークを用いる。NN1でマニピュレータの慣性行列 M の同定を行ない、NN2で遠心力、コリオリ力の項 h のパラメータ同定誤差および構造的

Fig. 9 Neural network controller

Fig. 10 Neural network (NN1)

な同定誤差 F の補償を行なう。NN1の構成を Fig. 10 に示す。NN1への入力 $\cos \theta_2$ とした。これは、2自由度スカラロボットの慣性行列 $M_{ij}(i, j=1, 2)$ の各要素が、 $\alpha \cos \theta_2 + \beta$ (α, β : 定数) という形で与えられることによる。このように、慣性行列は非常に簡単な形で与えられるので、概略モデルを併用しなくとも十分な軌道精度が得られると期待できる。ニューラルネットワーク NN1 は、マニピュレータの慣性行列 M そのものを同定するが、上記のようにネットワークの構成は極めて簡単であり、Fig. 2に示すニューラルネットワークの用い方の特徴を損なうことはない。なお、このニューラルネットワーク NN1の学習には、マニピュレータの概略モデルを用いて初期学習を行なうことが有効である⁷。また、NN2の構成は3. に用いたものと同じで、Fig. 4に示すものである。中間層のユニット数は2とした。学習アルゴリズムは3. の場合と同じで、フィードバック信号を用いたバックプロパゲーションアルゴリズムを用いる。試行錯誤により NN1, NN2 の学習率はそれぞれ 0.00002, 0.002 とし、マッチングゲインはそれぞれ 0.5, 6 とした。

パラメータ同定誤差が大きい場合のシミュレーションを行なった。一般に、リンクの慣性、および重心の位置の同定が最も困難である。そこで、パラメータ同定誤差としては、次のような重心の位置とリンクの慣性の同定

Fig. 11 Using single network

Fig. 12 Using double network

誤差を仮定する.

$$\begin{aligned} k_i &= 1.2 \hat{k}_i \\ I_i &= 1.2 \hat{I}_i \end{aligned} \quad (12)$$

ただし, $i = 1, 2$

また, 構造的な同定誤差には (10) 式で与えられるクーロン摩擦を考えた. 3. で提案した制御系の学習結果を Fig. 11 に示し, 本章で提案する制御系の学習結果を Fig. 12 に示す. 誤差は, 本章で提案する制御系において Fig. 11 の誤差の約 1/30 となった. シミュレーション結果から, ここで提案する制御系が構造的な同定誤差だけでなく, 大きなパラメータ同定誤差に対しても有効であることがわかる.

5. まとめ

本論文では, ニューラルネットワークを従来のように

逆システムの構築に用いるのではなく, 非線形補償に用いた. そして, パラメータ適応制御ではできなかった構造的な同定誤差に対する補償が可能であることを示した. ニューラルネットワークを用いた制御系においては安定性の保証が困難である. ニューラルネットワークをマニピュレータの概略モデルを用いたトルク計算法と併用し, 未知要素の補償を行なう本手法が, ニューラルネットワークの有効な使い方であることを示した.

本論文で検討したマニピュレータの構造の未知な要素としては, クーロン摩擦という比較的簡単な構造を用いた. ニューラルネットワークにより補償できる非線形関数のクラスは明らかでない. また, ニューラルネットワークの教師信号は, 本論文ではフィードバックループの信号を用いたが, 学習の収束性に対する保証がない. これらの問題点が今後の課題である.

参 考 文 献

- 1) J. Y. S. Luh et. al. : On-line Computational Scheme for Mechanical Manipulators ; ASME J. Dynamic Systems Measurement and Control, Vol. 102, No. 2, pp. 69~76 (1980)
- 2) John J. Craig : Adaptive Control of Mechanical Manipulators, Addison-Wesley Publishing (1988)
- 3) J. E. Slotine & W. Li : Adaptive Manipulator Control- A Case Study ; IEEE Trans. Automatic Control, Vol. AC-33, No. 11, pp. 995~1003 (1988)
- 4) Rumelhart, et. al. : Parallel Distributed Processing, The MIT Press (1987)
- 5) M. Kawato, et. al. : Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics ; IEEE Control System Magazine, pp. 8~16 (1988)
- 6) 瀬戸山, 他 : 多層神経回路網内に学習される逆ダイナミクスモデルによるマニピュレータの制御 ; 信学技報, MBE 87-135 (1987)
- 7) 尾崎, 他 : ニューラルネットワークを用いたマニピュレータの軌道制御 ; 第 7 回日本ロボット学会学術講演会 No. 3501 pp. 719~720 (1989)