

ニューラルネットを利用した
マニピュレータのインピーダンス制御法

正員 辻 敏 夫
正員 徐 炳 鴻
非会員 金 子 真

電 気 学 会 論 文 誌 C

(電子・情報・システム部門誌)

平成 11 年 11 月号 抜 刷

Trans. IEE of Japan, Vol. 119-C, No. 11, Nov., 1999

ニューラルネットを利用した マニピュレータのインピーダンス制御法

正員 辻 敏夫 (広島大)
正員 徐 炳鴻 (山本電気)
非会員 金子 真 (広島大)

Impedance Control Method for Manipulators Utilizing Neural Network

Toshio TSUJI, Member (Hiroshima University), Bing Hong XU, Member (Yamamoto Electric Corporation), Makoto KANEKO, Non-member (Hiroshima University)

Impedance control is one of the most effective control method for a manipulator in contact with its environment. The method, however, cannot regulate the end-effector impedance accurately without the exact model of the manipulator. The present paper proposes a new impedance control method in which an identification model based on a neural network (NN) is connected in parallel with a model of the manipulator. The NN in this method can identify the uncertainties of the manipulator model and modify a control signal to the manipulator according to the identified results. Computer simulations are performed to illustrate the effectiveness of the proposed method.

キーワード：マニピュレータ，インピーダンス制御，ニューラルネット，学習

1. はじめに

インピーダンス制御⁽¹⁾⁽²⁾とは、目的とする作業に応じてマニピュレータの手先に機械インピーダンスを設定し、位置と力の制御を統一的に取り扱う方法である。このインピーダンス制御では、手先の目標インピーダンスを実現するためにマニピュレータの正確なモデルを必要とする。しかしながら、マニピュレータの動特性を正確に同定することは難しく、この同定誤差のために手先インピーダンスを正確に実現できないことが多い。この問題に対して、従来からいくつかの制御法が提案されている。

例えば、Carelli and Kelly⁽³⁾は適応インピーダンス制御法を、Colbaugh and Engelmann⁽⁴⁾はロバスト制御に基づいたインピーダンス制御法を構成した。また Lu and Meng⁽⁵⁾、Liu and Goldenberg⁽⁶⁾、畑木、辻、金子⁽⁷⁾は、マニピュレータの手先の目標インピーダンスを作用する外力に応じた目標軌道に変換し、適応制御法を用いて間接的にインピーダンス制御を実現している。しかしながら、適応制御やロバスト制御ではマニピュレータ制御の特徴である非線形誤差に対応することが難しく、正確な制御は困難であると言わざるを得ない。

これに対して非線形特性に対して優れた学習能力を有するニューラルネットをインピーダンス制御に適用した研究も

数多く報告されている。例えば、Ishiguro, Furuhashi and Okuma⁽⁸⁾は関節空間でのコンプライアンス制御においてモデル化誤差による影響を NN を用いて補正する方法を、Dusko and Miomir⁽⁹⁾は二つの NN を用いてマニピュレータの慣性と非線形力をそれぞれ補償する方法を、Lin and Lee⁽¹⁰⁾は理想とする接触力との力の制御誤差を用いて NN を学習し、制御対象への入力を適応的に補正する方法を提案した。これらの方法は制御対象の入出力を逆にして構成した NN を用いて制御対象の逆モデルを学習的に表現しようというものである。また、Gomi and Kawato⁽¹¹⁾はインピーダンス制御系の非線形力の補償器として、NN を用いた学習型非線形フィードバック制御法を、Jung and Hsia⁽¹²⁾は NN を制御器と並列に組み込むことにより制御器の出力を適応的に補正する方法を提案した。これらの方法では NN を従来のフィードバック制御器と並列に配置して逆モデルを獲得している。しかしながら、従来法ではいずれも制御対象の逆システムを NN を用いて学習しているため、制御対象に含まれるモデル化誤差を陽に表現できない。したがって制御対象の順モデルが必要な場合には、学習済みの運動パターンに対してさえなんらかの方法でモデル化誤差の同定をやり直す必要が生じる。

一方、我々は先に 1 入力 1 出力の制御系において、ただ一つの NN で制御対象のモデル化誤差の同定と操作量の補

正を実現する方法を提案した⁽¹³⁾。そこで本論文ではこの制御法を多変数系に拡張しマニピュレータのインピーダンス制御系を構成する。本手法では、あらかじめわかっているマニピュレータのモデルとそれに並列に配置した NN を用いて同定モデルを構成し、この NN によってマニピュレータのモデル化誤差を同定する。同時に、マニピュレータのモデルに対してあらかじめ設計したインピーダンスコントローラからの操作量を、NN の出力に基づいて補正する。これにより学習済みの運動パターンに対して正確なインピーダンス制御が実現できるだけでなく、マニピュレータの順モデルも同時に獲得することが可能となる。本論文では、提案した制御系によりマニピュレータのインピーダンス制御が実現可能なことを示すとともに、モデル化誤差を含むマニピュレータに対してシミュレーションを行い、提案法の有効性を検証する。

2. インピーダンス制御

マニピュレータの運動方程式は、作業空間の自由度を l 、関節自由度を m とすると、

$$M(\theta)\ddot{\theta} + h(\theta, \dot{\theta}) + g(\theta) = \tau + J^T(\theta)F_{ext} \quad \dots (1)$$

となる。ここで、 $\theta \in \mathbb{R}^m$ は関節角度ベクトル、 $M(\theta) \in \mathbb{R}^{m \times m}$ は慣性行列、 $h(\theta, \dot{\theta}) \in \mathbb{R}^m$ はコリオリ力、遠心力、関節摩擦等を表す項、 $g(\theta) \in \mathbb{R}^m$ は重力項、 $\tau \in \mathbb{R}^m$ は関節駆動トルク、 $F_{ext} \in \mathbb{R}^l$ は外力、 $J \in \mathbb{R}^{l \times m}$ はヤコビ行列を表す。ただし $l \leq m$ で、 θ は特異姿勢にはないと仮定する ($\text{Rank } J = l$)。

いま、手先の目標インピーダンスを

$$M_e d\ddot{X} + B_e d\dot{X} + K_e dX = F_{ext} \quad \dots (2)$$

により記述する。ただし、 $M_e, B_e, K_e \in \mathbb{R}^{l \times l}$ はそれぞれ、手先の目標慣性行列、目標粘性行列、目標剛性行列で、 $dX = X - X_d$ は手先の平衡位置と現在位置との偏差を表す。

このとき、ヤコビ行列の逆行列を用いないインピーダンス制御則⁽²⁾は次のようになる。

$$\tau = \tau_{effector} + \tau_{comp} \quad \dots (3)$$

$$\tau_{effector} = J^T \{ \hat{M}_x(\theta) [M_e^{-1}(-K_e dX - B_e d\dot{X}) + \ddot{X}_d - \dot{J}\dot{\theta}] - [I - \hat{M}_x(\theta)M_e^{-1}]F_{ext} \} \quad (4)$$

$$\tau_{comp} = J^T (\hat{M}^{-1}(\theta) J^T \hat{M}_x)^T \hat{h}(\theta, \dot{\theta}) + \hat{g}(\theta) \quad (5)$$

ただし、 I は l 次の単位行列、 $\hat{h}(\theta, \dot{\theta}), \hat{g}(\theta)$ はそれぞれ $h(\theta, \dot{\theta}), g(\theta)$ の推定値、 $\hat{M}_x(\theta) = (J\hat{M}^{-1}(\theta)J^T)^{-1} \in \mathbb{R}^{l \times l}$ は正則な手先の等価慣性行列の推定値で、 $\hat{M}(\theta)$ は慣性行列の推定値を表す。(4) 式の $\tau_{effector}$ はマニピュレータの手先のインピーダンスを調節するための関節トルク、(5) 式の τ_{comp} は運動方程式に含まれる $h(\theta, \dot{\theta}), g(\theta)$ を補償するための関節トルクである。

以上より、マニピュレータの正確なモデルが与えられれば ($\hat{h}(\theta, \dot{\theta}) = h(\theta, \dot{\theta}), \hat{g}(\theta) = g(\theta), \hat{M}(\theta) = M(\theta)$)、

マニピュレータの手先のインピーダンスを自由に調節することができる。しかしながら、各式に必要なパラメータを正確に知ることは一般に非常に困難であり、また現実のマニピュレータには (1) 式では表現できないような未知の要素が存在している場合もある。

3. ニューラルネットを利用したインピーダンス制御

インピーダンス制御は非線形制御法であり、この非線形性をどのように扱うかが NN を利用した制御系の構成を考える際の重要なポイントになる。本論文では、非線形特性の線形化を基本的な考え方とし、通常の運動方程式に基づいた非線形補償による線形化手法だけでは対応しきれないモデル化誤差を NN で同定し、同時にこの同定結果を使ってシステムを線形化する方法を導く。

〈3・1〉作業空間における定式化 (1) 式のマニピュレータの運動方程式を作業空間に変換すると、

$$M_x(\theta)\ddot{X} + \mu_x(\theta, \dot{\theta}) + g_x(\theta) = F + F_{ext} \quad \dots (6)$$

を得る。ただし、 $\mu_x(\theta, \dot{\theta}) = (M^{-1}(\theta)J^T M_x)^T h(\theta, \dot{\theta}) - M_x J \dot{\theta} \in \mathbb{R}^l$ 、 $g_x(\theta) = (M^{-1}(\theta)J^T M_x)^T g(\theta) \in \mathbb{R}^l$ 、 $F \in \mathbb{R}^l$ は関節駆動力 τ と等価な手先駆動力である。ここで (3)~(5) 式より、 F を

$$F = \hat{M}_x(\theta)u + \hat{\mu}_x(\theta, \dot{\theta}) + \hat{g}_x(\theta) - F_{ext} \quad \dots (7)$$

$$u = u_n + \Delta_u \quad \dots (8)$$

$$u_n = M_e^{-1} \{ F_{ext} - B_e d\dot{X} - K_e dX \} + \ddot{X}_d \quad \dots (9)$$

のように構成する。 u_n は手先インピーダンスを実現するために必要な手先駆動力で、 Δ_u はマニピュレータのモデル化誤差が存在する場合にその誤差を補償するための入力である。このとき、関節制御トルク τ は

$$\tau = J^T F \quad \dots (10)$$

として求めることができる。

ここで、マニピュレータのモデルが正確な場合は $\hat{M}_x(\theta) = M_x(\theta)$ 、 $\hat{\mu}_x(\theta, \dot{\theta}) = \mu_x(\theta, \dot{\theta})$ 、 $\hat{g}_x(\theta) = g_x(\theta)$ で、 $\Delta_u = 0$ となる。このとき、(7) 式を (6) 式に代入すると、

$$\ddot{X} = u_n \quad \dots (11)$$

を得る。

しかしながら実際のシステムでは、運動方程式に基づいた線形化手法 ((7), (9) 式) だけでは対応しきれないモデル化誤差が存在する。そこでこのモデル化誤差を NN で同定し、この同定結果を使ってシステムを線形化することを考える。まず、(11) 式に対して以下のような乗法的なモデル化誤差 $\Delta_H(p) \in \mathbb{R}^{l \times l}$ を含む制御対象 $H(p) \in \mathbb{R}^{l \times l}$ を定義する⁽¹⁴⁾。

$$X(t) = H(p)u(t) \quad \dots (12)$$

$$H(p) = H_n(p)[I + \Delta_H(p)] \quad \dots (13)$$

$$H_n(p) = \frac{1}{p^2} I \quad \dots (14)$$




図1 インピーダンス制御系

Fig. 1. Block diagram of an impedance control system

ここで、 I は l 次の単位行列、 p は微分オペレータ $p = d/dt$ (15)、 $H_n(p) \in \mathbb{R}^{l \times l}$ はマニピュレータモデル、 $u(t) \in \mathbb{R}^l$ と $X(t) \in \mathbb{R}^l$ はそれぞれ制御対象の入力と出力である。

図1にモデル化誤差がない場合のインピーダンス制御系の構成を示す。マニピュレータモデル $H_n(p)$ とコントローラ $G_n(p)$ を用いた閉ループ連続時間伝達関数 $F_n(p) \in \mathbb{R}^{l \times l}$ は

$$F_n(p) = [I + H_n(p)G_n(p)]^{-1}H_n(p)G_n(p) \quad (15)$$

となる。ただし、(9)式よりインピーダンスコントローラ $G_n(p)$ は、

$$G_n(p) = M_e^{-1}B_e p + M_e^{-1}K_e \quad (16)$$

である。

ここで、モデル化誤差を含む制御対象 $H(p)$ に対するコントローラ $G(p)$ を次のように定義する。

$$G(p) = [I + \Delta_G(p)]G_n(p) \quad (17)$$

ただし、 $\Delta_G(p)$ はコントローラ $G_n(p)$ の修正量である。(13)式のモデル化誤差 $\Delta_H(p)$ とは構成が異なることに注意されたい。このとき、 $H(p)$ とコントローラ $G(p)$ を用いた閉ループ連続時間伝達関数 $F(p) \in \mathbb{R}^{l \times l}$ は

$$F(p) = [I + H(p)G(p)]^{-1}H(p)G(p) \quad (18)$$

に変化する。したがって、(15)式と(18)式を等価にすることができれば、コントローラ $G(p)$ による $H(p)$ の応答を望ましい制御系の応答に一致させることができる。(18)、(15)式を等しく置くと、次の関係式を導出することができる。

$$\Delta_G(p) = [I + \Delta_H(p)]^{-1} - I \quad (19)$$

ただし、 $\det(I + \Delta_G(p))$ 、 $\det(I + \Delta_H(p))$ 、 $\det(\Delta_G(p))$ 、 $\det(\Delta_H(p)) \neq 0$ と仮定した。

しかしながら、モデル化誤差 $\Delta_H(p)$ は未知なので、(19)式を直接計算することはできない。そこでこの問題を解決するために、NNをマニピュレータのモデル化誤差に対する同定器として利用した制御系を提案する。

〈3・2〉ニューラルネットの利用 図2に本論文で提案するインピーダンス制御系を示す。この制御系では、NNがマニピュレータモデル $H_n(p)$ と並列に配置され、NNの出力 $X_{NN}(t) \in \mathbb{R}^l$ を $H_n(p)$ に通した推定出力 $X_{ID}(t) \in \mathbb{R}^l$ とモ

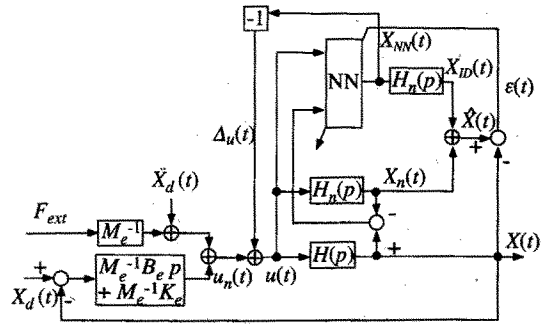


図2 提案するインピーダンス制御系

Fig. 2. Block diagram of the proposed impedance control

デル出力 $X_n(t) \in \mathbb{R}^l$ との和が同定モデルの出力 $\hat{X}(t) \in \mathbb{R}^l$ となる。NNの学習は同定モデルの出力 $\hat{X}(t)$ と出力 $X(t)$ との同定誤差 $\varepsilon(t) \in \mathbb{R}^l$ を用いて行う。すなわち、 $\varepsilon(t)$ は手先の位置誤差を表すことになる。

次に、この制御系の動作について説明する。図1と(17)式より入力 $u(t)$ は

$$u(t) = u_n(t) + \Delta_u(t) \quad (20)$$

となる。ただし、

$$u_n(t) = -G_n(p)dX(t) \quad (21)$$

$$\Delta_u(t) = \Delta_G(p)u_n(t) \quad (22)$$

である。また、(12)、(13)式からマニピュレータの出力 $X(t)$ は

$$X(t) = X_n(t) + H_n(p)\Delta_X(t) \quad (23)$$

で与えられる。ただし、

$$X_n(t) = H_n(p)u(t) \quad (24)$$

$$\Delta_X(t) = \Delta_H(p)u(t) \quad (25)$$

である。ここで、 $\Delta_X(t) \in \mathbb{R}^l$ はモデル化誤差 $\Delta_H(p)$ に起因するマニピュレータの出力である。また、(20)、(22)、(25)式から $\Delta_X(t)$ は

$$\Delta_X(t) = \Delta_H(p)[I + \Delta_G(p)]u_n(t) \quad (26)$$

と書くことができる。(22)、(26)式から $\Delta_u(t)$ は

$$\Delta_u(t) = \Delta_G(p)[I + \Delta_G(p)]^{-1}\Delta_H^{-1}(p)\Delta_X(t) \quad (27)$$

となり、上式に(19)式を代入すると、

$$\begin{aligned} \Delta_u(t) &= \Delta_G(p)[I + \Delta_G(p)]^{-1}\Delta_H^{-1}(p)\Delta_X(t) \\ &= \{[I + \Delta_H(p)]^{-1} - I\}[I + \Delta_H(p)]\Delta_H^{-1}(p)\Delta_X(t) \\ &= -\Delta_H(p)\Delta_H^{-1}(p)\Delta_X(t) \\ &= -\Delta_X(t) \end{aligned} \quad (28)$$

を得る。

一方、図2と(23)式から、同定誤差 $\varepsilon(t)$ は、




図3 本手法で用いるニューラルネット

Fig.3. Neural network used in the proposed control system

$$\varepsilon(t) = H_n(p)[X_{NN}(t) - \Delta_X(t)] \dots\dots\dots (29)$$

となる。したがって、この $\varepsilon(t)$ に基づいて $X_{NN}(t)$ と $\Delta_X(t)$ との誤差を0にするようにNNの学習則を構成することができれば、

$$X_{NN}(t) = \Delta_X(t) \dots\dots\dots (30)$$

となり、NNを利用した制御対象の順システムの構成が可能となる。この学習則については(3・3)で導出する。このとき、NNの出力 $X_{NN}(t)$ は操作量 $u_n(t) \in \mathcal{R}^l$ に対する補正量 $\Delta_u(t) \in \mathcal{R}^l$ として用いられる(図2)。

$$\Delta_u(t) = -X_{NN}(t) \dots\dots\dots (31)$$

以上より、本論文で提案する制御系を用いれば、(13)式で表現できる線形のモデル化誤差を含むマニピュレータに対してはインピーダンス制御を学習的に実現できることが明らかになった。本手法の制御系は結局、(23)式の右辺第二項をキャンセルするように構成しているため、もしマニピュレータの出力 $X(t)$ を(23)式の形で表現することができ、かつNNが $\Delta_X(t)$ を正確に同定できるなら、 $\Delta_X(t)$ が非線形特性を含んでいても正確なインピーダンス制御が実現できる。

〈3・3〉学習則 次に図2に含まれるNNの構成および学習アルゴリズムについて説明する。図3に、例として三層の階層型NNの構成を示す。入力層と中間層のユニット数はそれぞれ N 個と M 個、出力層のユニット数は L 個とする($L=l$)。同図において、 w_{jk} は入力層の k 番目のユニットと中間層の j 番目のユニットを結ぶ重み、 v_{ij} は中間層の j 番目のユニットと出力層の i 番目のユニットを結ぶ重みである。また、NNの入力ベクトル $U_{IN}(t) \in \mathcal{R}^N$ は(25)式を考慮して、

$$\begin{aligned} U_{IN}(t) &= [u^T(t), \Delta_X(t)^T]^T \\ &= [u_1(t), u_2(t), \dots, u_N(t)]^T \dots\dots\dots (32) \end{aligned}$$

とする。このとき $N = 2l$ である。

また入力層の k 番目のユニットの出力 I_k は $I_k = u_k(t)$ ($k = 1, \dots, N$)とする。一方、中間層の j 番目の

ユニットの出力 H_j は $H_j = \sigma(s_j)$, $s_j = \sum_{k=1}^N w_{jk} I_k$ で与えられる。ただし、 $\sigma(\cdot)$ はシグモイド関数である。本論文では、シグモイド関数 $\sigma(\cdot)$ として

$$\sigma(x) \equiv \tanh(x) \dots\dots\dots (33)$$

を用いることにする⁽¹⁶⁾。同様に、出力層のユニットの出力 $X_{NN}(t)$ は $X_{NN}(t) = \sigma(\kappa_i)$, $\kappa_i = \sum_{j=1}^M v_{ij} H_j$ となる。

ここで、(29)式の同定誤差を用いて、NNの学習のための評価関数 $E(t)$ を定義する。ここではマニピュレータの手先位置の同定誤差 $\varepsilon(t)$ が0の場合でも(29)式の $H_n(p)$ による被積分項(手先の速度、加速度誤差)が0にならないケースを考慮して次のような $E(t)$ を用いた。

$$\begin{aligned} E(t) &= \frac{1}{2} \dot{\varepsilon}^T(t) \dot{\varepsilon}(t) + \frac{1}{2} \varepsilon^T(t) \dot{\varepsilon}(t) + \frac{1}{2} \varepsilon^T(t) \varepsilon(t) \\ &= E^{(1)}(t) + E^{(2)}(t) + E^{(3)}(t) \dots\dots\dots (34) \end{aligned}$$

学習は、この評価関数 $E(t)$ を重み v_{ij} および w_{jk} に関して最小化(極小化)するように行う。誤差逆伝播学習法⁽¹⁷⁾により重み v_{ij} および w_{jk} の更新則は

$$v_{ij}(t + \Delta t) = v_{ij}(t) + \Delta v_{ij}(t) \dots\dots\dots (35)$$

$$\Delta v_{ij}(t) = -\eta \left[\frac{\partial E^{(1)}(t)}{\partial v_{ij}(t)} + \frac{\partial E^{(2)}(t)}{\partial v_{ij}(t)} + \frac{\partial E^{(3)}(t)}{\partial v_{ij}(t)} \right] \dots\dots\dots (36)$$

$$w_{jk}(t + \Delta t) = w_{jk}(t) + \Delta w_{jk}(t) \dots\dots\dots (37)$$

$$\Delta w_{jk}(t) = -\eta \left[\frac{\partial E^{(1)}(t)}{\partial w_{jk}(t)} + \frac{\partial E^{(2)}(t)}{\partial w_{jk}(t)} + \frac{\partial E^{(3)}(t)}{\partial w_{jk}(t)} \right] \dots\dots\dots (38)$$

となる。 $\eta > 0$ は学習係数、 Δt は学習を行う時間間隔である。

4. シミュレーション

本手法の有効性を示すために図4に示す4関節の平面マニピュレータモデルを用いてコンピュータ上でシミュレーションを行った($l=2$)。各パラメータは、各リンクがそれぞれ長さ $l_i = 0.4$ [m]、質量 $m_i = 3.75$ [kg]、関節からリンクの重心位置までの距離 $l_{gi} = 0.2$ [m]、関節の粘性摩擦係数 $d_i = 10$ [Nm s/rad]、慣性モーメントは $I_i = 0.8$ [kgm²]とした($i = 1, \dots, 4$)。このマニピュレータの手先に振幅が10 [N]、周期 T_c が3 [s]の矩形波を x 方向には正、 y 方向には負の方向へ外力として加えたときの手先の変化量をアッペル法⁽¹⁸⁾を用いて計算した。

NNの入力には、マニピュレータが有する非線形な誤差を考慮し式(32)の $U_{IN}(t)$ に加えて各関節の角度 θ_i 、および角速度 $\dot{\theta}_i$ を追加した($i = 1, \dots, 4$)。したがって、NNのパラメータは入力層のユニット数 $N = 12$ となる。また中間層は2層としそれぞれユニット数 $M_1 = 20, M_2 = 16$ 、出力層のユニット数は $L = 2$ とし、NNの重みの初期値には $[-0.1, 0.1]$ の一様乱数を用いた。学習係数 $\eta = 0.0001$ で、学習時間 $T_l = 300$ [s]とした。




図4 4関節平面マニピュレータ

Fig. 4. A four-joint planar manipulator




図5 関節摩擦に誤差がある場合のシミュレーション結果

Fig. 5. Time histories of the end-effector motion with parameter error of joint viscous friction: $\hat{d}_i = 12.5$ [Nms/rad], $d_i = 10.0$ [Nms/rad]

図5はマニピュレータの各関節の粘性摩擦係数 \hat{d}_i 、図6は各リンクの質量 \hat{m}_i にモデル化誤差がある場合 ($\hat{d}_i = 12.5$ [Nms/rad], $\hat{m}_i = 1.875$ [kg]), 図7は d_i が非線形に変化する場合 ($\hat{d}_i = 12.5$ [Nms/rad], $d_i = 10.0 + \sin \theta_i$ [Nms/rad]) のシミュレーション結果である。NNが学習する前(破線)では手先の軌道は理想軌道(実線)から大きく外れている。しかしながら、NNが学習後(学習時間 T_l 経過後: 図中、点線)はマニピュレータのモデル化誤差があるにもかかわらず手先の軌道は理想的な軌道とほぼ一致している。これは、NNがマニピュレータの非線形なモデル化誤差による影響を学習していることを示している。なお、手先のインピーダンスは $M_e = \text{diag}[1, 1]$ [kg], $B_e = \text{diag}[6, 6]$ [Ns/m], $K_e = \text{diag}[100, 100]$ [N/m] に設定し、サンプリングタイム Δt は 1 [ms] とした。

ここで取り上げた関節の粘性摩擦係数やリンク質量のパラメータ誤差は、(6)式の作業空間の運動方程式においては極めて複雑な非線形のモデル化誤差を生じることには注意されたい。すなわち、(23)式の $\Delta_x(t)$ が関節角度や角速度に依存して非線形的に変化することになる。シミュレーション結果から、このような複雑なモデル化誤差に対しても本手法がかなり有効に動作することが示された。

5. 結 言

本論文では、マニピュレータのモデルに誤差が含まれる




図6 リンク質量に誤差がある場合のシミュレーション結果

Fig. 6. Time histories of the end-effector displacements with parameter error of mass $\hat{m}_i = 18.75$ [kg], $m_i = 3.75$ [kg]




図7 関節摩擦に非線形誤差がある場合のシミュレーション結果

Fig. 7. Time histories of the end-effector motion with nonlinear parameter error of joint viscous friction: $\hat{d}_i = 12.5$ [Nms/rad], $d_i = 10.0 + \sin \theta_i$ [Nms/rad]

場合でも、ニューラルネットを用いて正確なインピーダンス制御を実現する方法を提案した。この方法はただ一つのNNでモデル化誤差の同定及びマニピュレータへの入力補正を同時に行うことができるという特徴を持つ。さらにシミュレーション結果から、非線形のモデル化誤差を含むマニピュレータに対しても本手法がある程度有効であることを示した。

ただし本論文ではNNを利用したインピーダンス制御系の構成法に注目したため、NN自身の構造については特に工夫しなかった。しかしながら、NNが学習しなければならない非線形特性がさらに複雑になったり、より速い学習が要求されるような場合には、効率よく学習を進めるためにやはりNNの工夫(例えば、運動方程式やヤコビ行列の構造をNNに埋め込んでおく方法⁽¹⁹⁾やダイナミクスの導入、問題に応じて適切な入力を選択する方法、学習率の設定法など)が必要になる。今後は、より効果的な学習を可能にするNNの構造を明らかにするとともに、学習の安定性とNNのパラメータの関係、実機での実現可能性などについて考察する必要があると考えている。なお本研究の一部は文部省科学研究費(11555113, 11650450)の助成によ

るもので、ここに改めて謝意を表します。

(平成11年1月11日受付, 同11年5月10日再受付)

文 献

- (1) N.Hogan, "Impedance Control: An Approach to Manipulation, Parts I, II, III," ASME Journal of Dynamic Systems, Measurement and Control, 107, 1, pp. 1-24 (1985).
- (2) N.Hogan, "Stable Execution of contact tasks using impedance control," Proc.IEEE International Conference on Robotics and Automation, pp. 1047-1054 (1987).
- (3) R. Carelli and R. Kelly, "An Adaptive Impedance/Force Controller for Robot Manipulators," IEEE Transactions on Automatic Control, 36, pp. 967-971 (1991).
- (4) R. Colbaugh and A. Engelman, "Adaptive Compliant Motion Control of Manipulator," IEEE International Conference on Robotics and Automatin, 4, pp. 2719-2726 (1994).
- (5) W.-S. Lu and Q.-H.Meng, "Impedance Control with Adaptation for Robotic Manipulations," IEEE Transactions on Robotics and Automation, 7, 3, pp. 408-415 (1991).
- (6) G. Liu and A. A. Goldenberg, "Robust hybrid impedance control of robot manipulators via a tracking control method," Proc. of the 1994 International Conference on Intelligent Robot and Systems, pp. 1594 - 1601 (1994).
- (7) 畑木, 辻, 金子, "モデル化誤差を含むダイレクト・ドライブ・ロボットのインピーダンス制御", 電気学会論文誌C, 116-c, 12, pp. 1390-1395 (1996).
- (8) A. Ishiguro, T. Furuhashi and S. Okuma "A Neural Network Compensator for Uncertainties of Robotics Manipulators," IEEE Transactions on Industrial Electronics, 39, 6, pp. 565-570 (1992).
- (9) Dusko Katic and Mimir Vukobratovic, "Learning Impedance Control of Manipulation Robots by Feedforward Connectionist Structures," Proc. IEEE International Conference on Robotics and Automation, pp. 45-50 (1994).
- (10) Shin-Tin Lin and Jien-Shuin Lee, "Impedance Control with On-Line Neural-Network Compensator for Robot Contact Tasks," Journal of Intelligent and Robotic Systems, 15, pp. 389-399 (1996).
- (11) H. Gomi, M. Kawato, "Neural network control for a closed loop system using feedback-error-learning," Neural Networks, 6, 7, pp. 993 - 946 (1993).
- (12) S. Jung and T. C. Hsia, "On Neural Network Application to Robust Impedance Control of Robot Manipulators," Proc. IEEE International Conference on Robotics and Automation, pp. 869-974 (1995).
- (13) 徐, 辻, 金子, "ニューラルネットを利用したモデル化誤差を含むプラントの同定と制御", 計測自動制御学会論文集, 32, 4, pp. 510-516 (1996).
- (14) 木村, 藤井, 森: ロバスタ制御, コロナ社 (1994).
- (15) K. J. Åström and B. Wittenmark: Adaptive Control, Addison-Wesley publishing Company (1989).
- (16) 徐, 辻, 金子, "ニューラルネットに基づく適応制御を用いたフレキシブルビームのトルク制御", 計測自動制御学会論文集, 33, 2, pp. 109-117 (1997).
- (17) D.E.Rumelhart, G.E.Hinton and R.J.Williams: Learning Representations by Error Propagation, Parallel Distributed Processing, 1, MIT Press (1986).
- (18) V.Potkonjak and M.Vukobtatovic, "Two new methods for computer forming of dynamic equation of active mechanisms," Mechanism and Machine Theory, 14, 3, pp. 189-200 (1987).
- (19) T. Tsuji, K. Ito and P. G. Morasso, "Neural Network Learning of Robot Arm Impedance in Operational Space," IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics, 26, 2, pp. 290-298 (1996).

辻 敏夫 (正員) 1959年12月25日生。1985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, 1994年同助教授, 現在に至る。工学博士。人間とロボットの運動制御, ニューラルネット, マン・マシンシステムなどの研究に従事。計測自動制御学会, 日本機械学会, 電気学会, 電子情報通信学会などの会員。



徐 炳鴻 (正員) 1949年11月30日生, 1988年中国上海科学技術大学大学院修士課程修了。上海建築材料工業学院講師を経て, 1997年3月広島大学大学院工学研究科博士課程後期修了。同年4月, 山本電気(株)に入社。ニューラルネット, パワーエレクトロニクス, モーションコントロールなどの研究に従事。現在同社管理本部研究室参事, 工学博士。電気学会, IEEE, 計測自動制御学会などの会員。



金子 真 (非会員) 1981年3月東京大学工学系研究科博士課程卒業。工学博士。同年4月, 通産省工業技術院機械技術研究所入所。1990年4月, 九州工業大学情報工学部助教授。1993年10月, 広島大学教授, 現在に至る。ロボットハンド, 力覚センサ, 触覚ベースアクティブセンシングなどの研究に興味を持つ。IEEE, 計測自動制御学会, 日本機械学会などの会員。

