可動作業台をもつ DD ロボットのニューラルネットワーク による位置と力の学習制御*

内 海 典 之^{*1}, 藤 堂 勇 雄^{*2}

Learning Control of Position and Force of a Direct-Drive Robot with a Variable Table Using Neural Networks

Noriyuki UTSUMI and Isao TODO

In this paper, a learning control algorithm using neural networks (NN's) for controlling the motion and force of a direct-drive (DD) robot with a variable table, which has six degrees of freedom, is proposed. The motion of an end effector attached on the robot arm and the internal force between the end effector and the table through an object can be obtained by the DD robot arm in cooperation with the variable table. The control of the motion and the internal force is achieved by hybrid controllers and a feedforward controller using NN's. After the completion of learning, the NN acquires a model of inverse dynamics for the DD robot arm and the DD table. Thus the outputs of the hybrid controllers are nearly equal to zero. The effectiveness of the proposed control algorithm is demonstrated by an experiment on the control of both the position of an end effector and the contact force on the constraint surface of the object.

Key Words: Mechatronics and Robotics, Measurement and Control, Robot, Control Device, Digital Control, Direct-Drive Robot, Hybrid Control, Cooperative Control, Motion Control, Neural Network, Learning

1. ま え が き

可動作業台をもつダイレクトドライブ(以下, DD)ロボットは, 並進運動を行うロボットアームと回転運動を行う可動作業台とに機構的に分離することによって一組の3自由度系を構成し, これを協調制御することにより, ばり取り・研磨作業といった6自由度を必要とする作業をDDロボットで実現させたものである⁽¹⁾. すなわち, 6自由度DDロボットを3自由度の垂直多関節DDロボットアームと3自由度DD可動作業台とにより構成し, 可動作業台上の作業対象物に対してアーム先端のロボット手先効果器(以下, 効果器)の位置と力を協調制御する。

本ロボットシステムでは, 効果器の6自由度運動は可動作業台上に設けられた作業座標系で記述され, ロボットアームと可動作業台との相対的な運動で実現される。また, 効果器が作業対象物に加える力とモーメントは作業対象物を介してすべて可動作業台に伝わり, 環境へは直接には伝わらない。すなわち, 本ロボッ

トシステムで実現される力は, 内力である。以下, 本論文では, 内力を単に力と記す。

2台のDDロボットによる協調制御は, 可搬質量および発生可能な力を増すことに対し有効な方法であり, 2台の水平3自由度DDロボットを仮想内部モデルに基づき協調制御する方法⁽²⁾や, DDロボットアームとDD可動作業台との協調により6自由度の組立作業を実現させる方法⁽³⁾が報告されている。

一方, DDロボットは関節部におけるバックラッシュやコンプライアンスが少なく, アームを剛体とみなして誘導した運動方程式を実ロボットの動力学モデルとみなすことができる。この動力学モデルを用い, 目標軌道を実現させるために必要な関節トルクを求め, フィードフォワード補償する方法が高精度化に有効であるということが知られている。しかしながら, (1)モデルのパラメータに含まれる誤差と(2)モデル化における誤差を少なくすることは難しい。

このため, ニューラルネットワーク(以下, NN)を用いた学習によってモデルを獲得させ, NNの出力をフィードフォワード補償する方法が提案されている。この方法では, 必要となる制御対象に関する知識は非常に少なくてもよく, 場合によってはまったく不要である。2台の2自由度DDロボットの協調制御に関して

* 平成6年3月29日 第71期通常総会講演会において講演, 原稿受付 平成6年3月22日。

^{*1} 正員, 横浜国立大学大学院 (〒240 横浜市保土ヶ谷区常盤台156)。

^{*2} 正員, 横浜国立大学工学部。

ついで、3個のトランスピュータからなる制御装置に本制御アルゴリズムを組み込み、(1)作業座標系で記述された効果器の6自由度運動と、(2)作業対象物に加える力とを実現する実験を行い、提案した制御アルゴリズムの有効性を示す。

ベース座標系 Σ_0 における効果器先端の位置を ${}^0\mathbf{p}_1$ 、姿勢を ${}^0\mathbf{R}_1$ で表す。また、可動作業台の位置(作業座標系 Σ_2 の原点)を ${}^0\mathbf{p}_2$ 、姿勢を ${}^0\mathbf{R}_2$ で表す、ただし、位置ベクトル $\mathbf{p}$ 、姿勢を表す回転行列 $\mathbf{R}$ の左上の添字 0, 1, 2 は、それぞれ定義されている座標系 $\Sigma_0, \Sigma_1, \Sigma_2$ を表す。また右下の添字は、1 のときロボットアーム

$$+ {}^0\mathbf{J}_{22}^T(\boldsymbol{\theta}_2)[({}^0\mathbf{p}_1 - {}^0\mathbf{p}_2) \times] {}^0\mathbf{f} = \boldsymbol{\tau}_2 \quad \dots\dots\dots (11)$$

のように簡略化される。ただし

$${}^0\hat{h}_i(\theta_i, \dot{\theta}_i) = {}^0h_i(\theta_i, \dot{\theta}_i) + {}^0D_i\dot{\theta}_i + {}^0g_i(\theta_i) \quad (i=1, 2) \dots (12)$$

ロボットアームは、平行リンク機構からなる垂直多関節ロボットであり、 ${}^0M_1(\theta_1)$, ${}^0\hat{h}_1(\theta_1, \dot{\theta}_1)$ はすでに誘導されている。また、可動作業台は、直列機構からなり、各関節軸は互いに直交し1点で交わっているため、 ${}^0M_2(\theta_2)$, ${}^0\hat{h}_2(\theta_2, \dot{\theta}_2)$ の誘導は容易である。このように、本ロボットシステムは6自由度でありながら、比較的簡単な運動方程式で動力学モデルが表現できる。

3. 制御系の構成

本論文では、(1)可動作業台上に固定された作業対象物に対する効果器の6自由度運動と、(2)作業対象物に加える力を制御する。

制御系への目標値は、作業座標系で記述された効果器の先端の位置 ${}^2p_{1d}(k)$ 、姿勢 ${}^2R_{1d}(k)$ と作業対象物に加える内力 ${}^2f_d(k)$ であり、サンプリング周期 T の離散時間信号である。ここでは、効果器と作業対象物との間に作用させるモーメントは制御しない。また、目標値は3サンプリングだけ未来まで既知であるとする。

3.1 逆動力学モデルを用いた制御 式(10), (11)の一組の運動方程式で表される動力学モデルを用い、目標軌道を実現させるために必要な関節トルクを

逆動力学モデルより求め、フィードフォワード補償する。その制御系を図2に示す。

ロボットアームおよび可動作業台の関節角の目標値

$\theta_{1d}(k)$, $\theta_{2d}(k)$ は逆運動学関数 A_1^{-1} , A_2^{-1} より

$$\theta_{id} = A_i^{-1}({}^2p_{1d}, {}^2R_{1d}) \quad (i=1, 2) \dots (13)$$

である。速度、加速度に関する目標値は与えられていないので、次式で定義する関節角速度 $\theta_{id}^c(k)$ および関節角加速度 $\theta_{id}^{cc}(k)$ を用いる。

$$\theta_{id}^c(k) = \frac{\theta_{id}(k+1) - \theta_{id}(k)}{T} \quad (i=1, 2) \dots (14)$$

$$\theta_{id}^{cc}(k) = \frac{\theta_{id}^c(k+1) - \theta_{id}^c(k)}{T} \quad (i=1, 2) \dots (15)$$

これより、フィードフォワード補償の関節トルク $\tau_1^{FF}(k)$, $\tau_2^{FF}(k)$ は

$$\tau_i^{FF}(k) = f_i^{-1}[\theta_i(k), \theta_i^c(k), \theta_i^{cc}(k)] \quad (i=1, 2) \dots (16)$$

となる。ただし

$$\begin{aligned} f_1^{-1}[\theta_1(k), \theta_1^c(k), \theta_1^{cc}(k)] \\ = {}^0M_1[\theta_1(k)]\theta_1^{cc}(k) + {}^0\hat{h}_1[\theta_1(k), \theta_1^c(k)] \\ + {}^0J_{11}^T[\theta_1(k)]{}^0f_d(k) \dots (17) \end{aligned}$$

$$\begin{aligned} f_2^{-1}[\theta_2(k), \theta_2^c(k), \theta_2^{cc}(k)] \\ = {}^0M_2[\theta_2(k)]\theta_2^{cc}(k) + {}^0\hat{h}_2[\theta_2(k), \theta_2^c(k)] \\ + {}^0J_{22}^T[\theta_2(k)][({}^0p_1 - {}^0p_2) \times] \cdot {}^0f_d(k) \dots (18) \end{aligned}$$

逆動力学モデルの計算では、演算遅れを考慮して1サンプリングだけ未来の値 $\tau_1^{FF}(k+1)$, $\tau_2^{FF}(k+1)$ を

図2 逆動力学モデルを用いたフィードフォワード補償をもつ制御系

用いる。

位置と力のハイブリッド制御系から得られる操作力 ${}^2\mathbf{f}_u$ 、モーメント ${}^2\mathbf{n}_u$ は、図2から

$${}^2\mathbf{f}_u = \mathbf{G}_{p1}(z)\mathbf{S}_{p1}({}^2\mathbf{p}_{1d} - {}^2\mathbf{p}_1) + \mathbf{G}_{f1}(z)\mathbf{S}_{f1}({}^2\mathbf{f}_d - {}^2\mathbf{f}) \quad \dots\dots\dots (19)$$

$${}^2\mathbf{n}_u = \mathbf{G}_{p2}(z)\beta \cdot {}^2\mathbf{r} \quad \dots\dots\dots (20)$$

で表される。ただし、 $\mathbf{G}_{pi}(z)$ ($i=1, 2$) は位置の制御装置を、 $\mathbf{G}_{f1}(z)$ は力の制御装置を表すパルス伝達関数行列である。 $\mathbf{S}_{p1}$ は位置、 $\mathbf{S}_{f1}$ は力の選択行列である。また、 $\beta \cdot {}^2\mathbf{r}$ は姿勢 ${}^2\mathbf{R}_1$ を ${}^2\mathbf{R}_{1d}$ に一致させる回転を与える回転ベクトルであり、 $\beta \cdot {}^2\mathbf{r}$ を求める関数を $\mathbf{h}({}^2\mathbf{R}_{1d}, {}^2\mathbf{R}_1)$ とする。

操作力 ${}^2\mathbf{f}_u$ 、モーメント ${}^2\mathbf{n}_u$ は

$$\begin{bmatrix} \tau_1^{HB}(k) \\ \tau_2^{HB}(k) \end{bmatrix} = {}^2\mathbf{J}^T[\theta(k)] \begin{bmatrix} {}^2\mathbf{f}_u(k) \\ {}^2\mathbf{n}_u(k) \end{bmatrix} \quad \dots\dots\dots (21)$$

により関節トルク $\tau_1^{HB}(k)$ 、 $\tau_2^{HB}(k)$ に変換される。ただし、 ${}^2\mathbf{J}(\theta)$ は作業座標系におけるヤコビ行列であり

$$\begin{aligned} {}^2\mathbf{J}(\theta) &= \begin{bmatrix} {}^2\mathbf{J}_{11}(\theta) & {}^2\mathbf{J}_{12}(\theta) \\ {}^2\mathbf{J}_{21}(\theta) & {}^2\mathbf{J}_{22}(\theta) \end{bmatrix} \\ &= \begin{bmatrix} {}^0\mathbf{R}_2^{-1} & \mathbf{O} \\ \mathbf{O} & {}^0\mathbf{R}_2^{-1} \end{bmatrix} \begin{bmatrix} {}^0\mathbf{J}_{11}(\theta_1) & -{}^0\mathbf{J}_{12}(\theta) \\ {}^0\mathbf{J}_{21}(\theta_1) & -{}^0\mathbf{J}_{22}(\theta_2) \end{bmatrix} \quad \dots\dots\dots (22) \end{aligned}$$

で表される。 $\mathbf{O}$ は 3×3 の零行列である。

本制御を実現するためには ${}^0\mathbf{M}_i(\theta_i)$ 、 ${}^0\hat{\mathbf{h}}_i(\theta_i, \dot{\theta}_i)$ ($i=1, 2$)に関するすべてのパラメータが既知である必要がある。また、作業対象物や効果器を変更させたときは対応するパラメータも変化させる必要があり、この制御の実現は容易ではない。

3・2 NNを用いた学習制御 逆運動学関数

$\Lambda_i^{-1}({}^2\mathbf{p}_1, {}^2\mathbf{R}_1)$ ($i=1, 2$)や逆動力学関数 $\mathbf{f}_i^{-1}[\theta_i(k), \theta_i^c(k), \theta_i^{cc}(k)]$ ($i=1, 2$)をNNの学習によって獲得させ、NNの出力をフィードフォワード補償に用いる。NNを用いた学習制御系を図3に示す。この制御系を実現するには、NNへの入力を選定するとき動力学的な知識を必要とするが、これ以外には制御対象に関する動力学的な知識は不要である。

NNには、入力層、中間層、出力層の3層からなるフィードフォワード階層形を用いる。入力層の入出力関係は線形であり、中間層、出力層の出力は

$$f(x) = \frac{2}{1 + e^{-(2/\mu_0)x}} - 1 \quad (\mu_0 > 0) \quad \dots\dots\dots (23)$$

で表されるシグモイド関数 $f(x)$ を通したものである。ただし、 μ_0 はシグモイド関数の特性を決める定数である。

入力層をA層、中間層をB層、出力層をC層とし、ニューロンの数をそれぞれ L, M, H とおくと、各層の入出力関係は、次式で与えられる。

$$\begin{aligned} x_j^B &= \sum_{i=1}^L w_{ij}^{AB} y_i^A + z_j^B, \\ x_n^C &= \sum_{j=1}^M w_{jn}^{BC} y_j^B + z_n^C \quad \dots\dots\dots (24) \end{aligned}$$

$$y_i^A = x_i^A, \quad y_j^B = f(x_j^B) \quad \dots\dots\dots (25)$$

$$y_n^C = f(x_n^C) \quad \dots\dots\dots (26)$$

ただし

x_i^A, y_i^A : A層の i 番めの入力、出力

x_j^B, y_j^B : B層の j 番めの入力、出力

x_n^C, y_n^C : C層の n 番めの入力、出力

図3 ニューラルネットワークによる位置と力の学習制御

w_{ij}^{AB} : y_i^A と x_j^B との間の結合荷重

w_{jn}^{BC} : y_j^B と x_n^C との間の結合荷重

z_j^B : B 層の j 番めのバイアス値

z_n^C : C 層の n 番めのバイアス値

結合荷重, バイアス値を変更する手続きには, 誤差逆伝ば法を用いる. 学習の駆動信号を d_n , 学習率を η_w, η_z とおけば, 結合荷重, バイアス値は次のように更新される.

$$\delta_n^C = (1/\mu_0) d_n [1 - (y_n^C)^2] \quad \dots\dots\dots (27)$$

$$\delta_j^B = (1/\mu_0) \left(\sum_{n=1}^H w_{jn}^{BC} \delta_n^C \right) [1 - (y_j^B)^2] \quad \dots\dots\dots (28)$$

$$\Delta w_{jn}^{BC} = \eta_w \delta_n^C y_j^B, \quad \Delta z_n^C = \eta_z \delta_n^C \quad \dots\dots\dots (29)$$

$$\Delta w_{ij}^{AB} = \eta_w \delta_j^B y_i^A, \quad \Delta z_j^B = \eta_z \delta_j^B \quad \dots\dots\dots (30)$$

本論文では, おもに効果器の位置と力を制御することを目的としているので, ロボットと可動作業台の逆力学モデルのうち, ロボットについてのみ完全なモデルを NN に獲得させる. 可動作業台に関しては運動方程式(11)のうち重力と内力による静的なトルクの項だけを獲得させる. また, モデルの獲得に NN の演算遅れが影響しないように, 1 サンプリグだけ未来の目標値を入力する. これより, NN への入力は

$$\mathbf{x}^A(k) = \begin{bmatrix} \mathbf{s}_{f1}^{*2} \cdot \mathbf{f}_d(k+1) \\ \mathbf{S}_{p1}^{*2} \cdot \mathbf{p}_{1d}(k+1) \\ \mathbf{S}_{p1}^{*2} \cdot \mathbf{v}_{1d}(k+1) \\ \mathbf{S}_{p1}^{*2} \cdot \mathbf{a}_{1d}(k+1) \\ \mathbf{c}^2 \mathbf{R}_{1d}(k+1) \end{bmatrix} \quad \dots\dots\dots (31)$$

となる. ただし, $\mathbf{x}^A(k)$ は NN への入力ベクトルであり, $\mathbf{v}_{1d}(k), \mathbf{a}_{1d}(k)$ は

$$\mathbf{v}_{1d}(k) = \frac{\mathbf{p}_{1d}(k+1) - \mathbf{p}_{1d}(k)}{T} \quad \dots\dots\dots (32)$$

$$\mathbf{a}_{1d}(k) = \frac{\mathbf{v}_{1d}(k+1) - \mathbf{v}_{1d}(k)}{T} \quad \dots\dots\dots (33)$$

で与えられる. $\mathbf{c}^2 \mathbf{R}_{1d}$ は姿勢の目標値 $\mathbf{R}_{1d}$ のうち独立な 3 要素を求める関数である. $\mathbf{S}_{p1}^*, \mathbf{s}_{f1}^*$ はそれぞれ, 選択行列 $\mathbf{S}_{p1}, \mathbf{S}_{f1}$ において, 要素がすべて零である行を削除した行列, 横ベクトルである.

NN の出力の大きさは -1 から 1 の範囲にあるので, NN の出力にゲイン $\mathbf{K}_1, \mathbf{K}_2$ を乗じて必要な大きさの関節トルクに換算する. すなわち, NN の出力をベクトル $\mathbf{y}^{NN}(k)$ とすれば, 得られる関節トルクのフィードフォワード補償量 $\boldsymbol{\tau}_1^{NN}(k), \boldsymbol{\tau}_2^{NN}(k)$ は

$$\boldsymbol{\tau}_1^{NN}(k) = \mathbf{K}_1 [\mathbf{I} \quad \mathbf{O}] \mathbf{y}^{NN}(k) \quad \dots\dots\dots (34)$$

$$\boldsymbol{\tau}_2^{NN}(k) = \mathbf{K}_2 [\mathbf{O} \quad \mathbf{I}] \mathbf{y}^{NN}(k) \quad \dots\dots\dots (35)$$

である. ただし,

$$\mathbf{y}^{NN}(k) = [y_1^C \quad y_2^C \quad \dots \quad y_H^C]^T$$

であり, $\mathbf{I}$ は 3×3 の単位行列である.

図 3 のハイブリッド制御系から得られる操作力 ${}^2\mathbf{f}_u$,

モーメント ${}^2\mathbf{n}_u$ は

$$\begin{bmatrix} \boldsymbol{\tau}_1^{HB}(k) \\ \boldsymbol{\tau}_2^{HB}(k) \end{bmatrix} = \begin{bmatrix} {}^2\mathbf{J}_{11}^T(\boldsymbol{\theta}(k)) & \mathbf{O} \\ \mathbf{O} & {}^2\mathbf{J}_{22}^T(\boldsymbol{\theta}(k)) \end{bmatrix} \begin{bmatrix} {}^2\mathbf{f}_u(k) \\ {}^2\mathbf{n}_u(k) \end{bmatrix} \quad \dots\dots\dots (36)$$

により関節トルクに変換される. すなわち, 図 3 のハイブリッド制御系では, (1) 操作力 ${}^2\mathbf{f}_u$ が可動作業台に及ぼす影響, ならびに (2) モーメント ${}^2\mathbf{n}_u$ がロボットアームに及ぼす影響を無視し, NN の出力 $\boldsymbol{\tau}_1^{NN}, \boldsymbol{\tau}_2^{NN}$ によって補償する.

これより操作量として加えられる関節トルクは

$$\boldsymbol{\tau}_i(k) = \boldsymbol{\tau}_i^{HB}(k) + \boldsymbol{\tau}_i^{NN}(k) \quad (i=1, 2) \quad \dots\dots\dots (37)$$

である.

NN を学習する駆動信号 $\mathbf{d}(k)$ は

$$\mathbf{d}(k) = \mathbf{K}_b \{ [\mathbf{I} \quad \mathbf{O}]^T \cdot \boldsymbol{\tau}_1^{HB}(k) + [\mathbf{O} \quad \mathbf{I}]^T \cdot \boldsymbol{\tau}_2^{HB}(k) \} \quad \dots\dots\dots (38)$$

である. NN は $\boldsymbol{\tau}_1^{HB}(k), \boldsymbol{\tau}_2^{HB}(k)$ が 0 となるように学習する. 学習の速度はゲイン $\mathbf{K}_b$ と学習率 η_w, η_z によって調整される.

4. 実 験

本論文で取上げたロボットアームと可動作業台とからなる 6 自由度ロボットシステムに対して, (1) 動力学に関するすべてのパラメータを高精度に同定すること, (2) 逆運動学関数と逆動力学関数を含むアルゴリズムを高速で演算させることは難しい. このため, 図 2 に示した逆動力学モデルを用いた制御系をそのまま実ロボットシステムで実現させることは困難である. そこで, 図 3 に示した NN による学習制御を実ロボットシステムに適用し, 図 3 の制御系が逆動力学モデルを用いた図 2 の制御系と同等の効果が得られることを実験により確認する.

実験装置を図 4 に示す. ロボットリンク ($l_1=0.40$ m, $l_2=0.51$ m, $l_3=0.14$ m, $\alpha=\pi/3$ rad) は 3 個の DD モータ [横河プレジジョン(株)製] で駆動される. 可動作業台は, ロボットベースに対し ${}^0\mathbf{p}_2=[0.55$ m, 0.0 m, 0.0 m] T の位置に設置され, ロボットアームと同様に 3 個の DD モータで駆動される. ロボット手先には 6 軸力覚センサ [ビー・エル・オートテック(株)製 F/T 5/50] が取付けられている. DD モータの仕様を表 1 に示す.

制御装置はパーソナルコンピュータを中心に構成される. パーソナルコンピュータ(PC-9801 RA)には, 制御アルゴリズムを高速で演算させるためトランスピュータ(インモス, T 805, 30 MHz)が 3 個搭載されている. 3 個のトランスピュータにはそれぞれ, (1) NN

図 4 実験装置

の出力の演算と NN の学習, (2)位置と力のハイブリッド制御演算, (3)DD モータやセンサおよびパーソナルコンピュータとの入出力制御を割振る。サンプリング周期 T は 5 ms である。

位置制御装置(PD 制御)のパルス伝達関数行列 $G_{pi}(z)$ は

$$G_{pi}(z) = K_{pi} + K_{di}(1 - z^{-1}) \quad (i=1, 2) \quad \dots (39)$$

で表される。力制御装置(PI 制御)のパルス伝達関数行列 $G_{f1}(z)$ は

$$G_{f1}(z) = K_{f1} + K_{i1} \frac{z}{z-1} \quad \dots (40)$$

で表される。

NN は入力層 10, 中間層 20, 出力層 6 から構成されている。 w_{ij}^{AB} , w_{jn}^{BC} , z_j^B , z_n^C については, 初期値に -1 から 1 までの乱数を与える。

この実験装置を用いて, 可動作業台上に固定された黄銅製の円盤に対し, ロボット手先に取付けられた鋼製の丸棒からなる効果器を拘束面の法線方向から一定の力 ${}^2f_{d3}$ で押付けながら, 効果器の姿勢を変え拘束面上に半径 r の円を角速度 ω_0 で描かせる作業を行わせた。

位置の目標値 ${}^2p_{1d}(k)$ は半径 r の円

$${}^2p_{1d}(k) = [r \sin k\omega_0 T \quad r \cos k\omega_0 T \quad z_0]^T \quad \dots (41)$$

である。姿勢の目標値 ${}^2R_{1d}(k)$ は, 姿勢変化が大きくなるよう

表 1 DD モータの仕様

	Joint	Maximum torque N·m	Mass kg
DD robot arm	θ_{11}	60	12
	θ_{12}	70	14
	θ_{13}	45	9.5
DD variable table	θ_{21}	45	9.5
	θ_{22}	45	9.5
	θ_{23}	15	5.5

表 2 制御パラメータ

K_{p1}	= diag[1500 1500 0]	N/m
K_{p2}	= diag[40 40 0]	N·m/rad
K_{d1}	= diag[90 90 0]	N/m
K_{d2}	= diag[4 3.5 0]	N·m/rad
K_{f1}	= diag[0 0 0.2]	
K_{f1}	= diag[0 0 16]	
K_1	= diag[15 15 15]	
K_2	= diag[10 10 10]	
K_b	= diag[0.8 0.8 0.8 0.8 0.8 0.8]	
η_w	= 0.2,	
η_z	= 0.1,	
μ_0	= 6	

$${}^2R_{1d}(k) = R[b(k), \varphi] \cdot {}^2R_{10} \quad \dots (42)$$

のように初期姿勢 ${}^2R_{10}$ を変化させた。

$R[b(k), \varphi]$ は回転軸 $b(k)$ の回りに角度 φ の回転を与える回転行列である。ただし

$$b(k) = [\cos k\omega_0 T \quad -\sin k\omega_0 T \quad 0]^T \quad \dots (43)$$

力の目標値 ${}^2f_d(k)$ は

$${}^2f_d = [0 \quad 0 \quad {}^2f_{d3}]^T$$

である。これより選択行列は次のようになる。

$$S_{p1} = \text{diag}[1 \quad 1 \quad 0]$$

$$S_{f1} = \text{diag}[0 \quad 0 \quad 1]$$

制御パラメータは制御系が過減衰となるように選んだ。また, 駆動信号のゲイン K_b と学習率 η_w , η_z は, 学習が一様に収束するように選んだ。実験に用いた制御パラメータの値を表 2 に示す。

実験では

$${}^2R_{10} = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ -1 & 0 & 0 \end{bmatrix}$$

$r=0.08$ m, $z_0=0.04$ m, $\omega_0=1.7$ rad/s, $\varphi=\pi/18$, ${}^2f_{d3}=-15$ N とした。

図 3 の制御系による実験結果を図 5, 6 に示す。図 5 は NN の学習過程であり, 横軸は試行回数, 縦軸は次式で定義される位置の二乗平均誤差 $(e_{pj})^2$ ($j=1, 2$)

および力の二乗平均誤差 $(e_{fj})^2$ である。

$$\overline{(e_{pj})^2} = \frac{\sum_{k=1}^N \{ {}^2p_{1d}(k) - {}^2p_{1j}(k) \}^2}{N} \quad (j=1, 2) \quad \dots\dots\dots (44)$$

$$\overline{(e_{f3})^2} = \frac{\sum_{k=1}^N \{ {}^2f_{d3}(k) - {}^2f_3(k) \}^2}{N} \quad \dots\dots\dots (45)$$

ただし、

$${}^2p_{1d} = [{}^2p_{1d1} \quad {}^2p_{1d2} \quad {}^2p_{1d3}]^T$$

$${}^2p_1 = [{}^2p_{11} \quad {}^2p_{12} \quad {}^2p_{13}]^T$$

$${}^2f = [{}^2f_1 \quad {}^2f_2 \quad {}^2f_3]^T$$

であり、 N は総サンプル数である。 x 軸、 y 軸、 z 軸は作業座標系 Σ_2 における軸である。10 回の試行で誤差は 1/10 程度に減少している。

図 6 は学習後(試行 20 回め)の応答である。図 6 (a) は作業対象物平面上における効果器先端の軌跡であ

り、(b) は効果器の姿勢誤差、(c) は z 軸方向の力応答である。姿勢誤差は関数 $h({}^2R_{1d}, {}^2R_1)$ の出力 $\beta \cdot {}^2r$ の絶対値である。位置、姿勢、力とも目標値に対する誤差が少ないことが図 6 からわかる。図 6 (d), (e), (f) はロボットの、図 6 (g), (h), (i) は可動作業台の関節トルクであり、ハイブリッド制御系からの出力 τ_1^{HB} , τ_2^{HB} と NN からの出力 τ_1^{NN} , τ_2^{NN} を示している。

τ_1^{HB} , τ_2^{HB} はほぼ 0 になっており、操作量 τ_1 , τ_2 はほぼ τ_1^{NN} , τ_2^{NN} に等しい。このとき位置と力の誤差が少ないことから NN はこの動作領域の近傍においてロボットアームと可動作業台の近似逆動力モデルを獲得しているといえる。このことから、この制御アルゴリズムは、図 2 の制御系の代わりをする簡便な方法であるといえることができる。ただし、可動作業台の 3 関

図 5 学習過程

図 6 実験結果(試行 20 回め)

節の中で慣性が最も大きい θ_{21} 軸に関してはハイブリッド制御系からの出力 τ_{21}^{HP} が大きい。これは NN へ姿勢変化の角加速度を入力せず、運動方程式の慣性項を獲得させなかったため、可動作業台の近似逆力学モデルの精度がよくなかったためである。さらにより応答を得るには、NN の入力層のニューロンの数を増やすか、目標軌道に応じて NN への入力信号を変化させる必要がある。このように、付加した NN による学習制御は、並進運動と回転運動のどちらを重視するかによって、何を NN への入力に選ぶかを決定することが可能であり、必要な精度に応じて NN の入力を選定することにより NN の演算量を調整できる。

また、この実験結果によれば、NN を用いた学習制御を付加することにより、(1)ハイブリッド制御系における操作力 2f_u が可動作業台に及ぼす影響、ならびに(2)モーメント 2n_u がロボットアームに及ぼす影響が少なくなり、ハイブリッド制御系を簡略化できることを示している。

5. ま と め

本研究で得られた結果は次のとおりである。

(1) 3自由度垂直多関節 DD ロボットアームと3自由度 DD 可動作業台とからなる6自由度 DD ロボットにおいて、(a)作業座標系で記述されたロボット手

先効果器の6自由度運動を実現させ、(b)可動作業台上の作業対象物に加える力を制御するため、NN を用いた学習制御方式を提案した。

(2) 手先効果器を作業対象物の拘束面上に一定の力で押付けながら位置と姿勢を目標値に追従させる作業に本学習制御方式を適用し、実験を行った。その結果、(a)NN は動作領域の近傍においてロボットアームと可動作業台の近似逆力学モデルを獲得することにより、NN の出力は逆力学モデルに基づくフィードフォワード補償と等価になること、(b)位置と力の協調ハイブリッド制御においてロボットアームと可動作業台の操作力・モーメントの干渉は NN によって補償されハイブリッド制御系が簡略化されること、(c)大きな姿勢変化を伴う目標値に対しても位置と力の精度が高いことが判明し、提案した学習制御方式の有効性が示された。

文 献

- (1) 内海・藤堂, 機論, 60-573, C(1994), 1705.
- (2) 小菅・古賀・古田・野崎, 計測自動制御学会論文集, 27-1(1991), 93.
- (3) 宇野・谷口・杉本・三田・坂上・大成, 精密工学会誌, 59-5(1993), 737.
- (4) 黄・藤堂, 機論, 58-547, C(1992), 851.