ニューラルネットワークを利用した 未知環境でのハイブリッド制御

木 口 量 夫*¹ Dan S. Neculescu*² 福 田 敏 男*³

Hybrid Control for an Unknown Environment Using Neural Networks

Kazuo Kiguchi*¹, Dan S. Neculescu*² and Toshio Fukuda*³

In this paper, the nonlinear three-layer Neural Network using a dynamic back-propagation method which based on the output signals of the hybrid controller and past output information of the plant is proposed for the Cartesian position/force control of multi-DOF robots. The generalized delta law is used as a learning law to adjust the weights of the Neural Network at every sampling time in order to adapt to an unknown environment.

Experiments were done with a 3-DOF Direct-Drive Planar Robot Manipulator. The proposed Neural Network Controller controls the position and the angle of the end-effector as well as the applied force to an unknown environment. The experimental results show the effectiveness and flexibility of the proposed Neural Network Position/Force Controller for Multi-DOF Robots.

Key Words: Direct-Drive Robots, Neural Network, Position/Force Control

1. は じ め に

当初人間の脳とその神経システムの研究により始められたニューラルネットワークは、数多くのシナプスとニューロンから成り立っている。ちなみに、人間の脳では約 10^{11} のニューロンと 10^{15} のシナプスを持っている。ニューラルネットワークには、いろいろな種類のアーキテクチャーと学習則が提案されており、学習則ではバックプロパゲーション法がよく使われている。McCulloch と Pitts が 1943 年に最初のニューロンモデルを提案して以来[1]、ニューラルネットワークは多くの研究者により研究されてきた。ロボットの分野では、順/逆キネマティクスあるいはダイナミクスの実現、ロボットのコントロール、同定などに利用されている。

ニューラルネットワークの制御への応用は、1960 年代に Widrow により行われている[2]。後に川入らによってロボット制御へ適用された[3][4]。その後ニューラルネットワークのロボット制御への応用はいろいろと行われてきた[5]~[15]。しかし、そのほとんどが位置制御や軌道制御への応用であり[13]~[15]、ニューラルネットワークの持つ未知環境への

適応能力を力制御に応用した例は少なかった[5]~[12]。力制御への応用では、コントローラのゲイン調整など間接的にニューラルネットワークを利用することが多く[5]~[9]、直接コントローラとして用いた例[10]~[12]は、一自由度の力制御だけで、多自由度ロボットマニピュレータの位置/力制御への応用はされていなかった。また、これまでの力制御への応用の多くは、予めニューラルネットワークを学習させておく必要があったり[5]~[8]、繰返し学習する必要があった[9]。そこで筆者らは、未学習のニューラルネットワークを直接的に多自由度ロボットマニピュレータの位置と力のハイブリッド制御へ応用し、動特性の未知な環境に対しコントローラを適応させる方法を提案する。

ハイブリッド制御は Raibert と Craig により提案されたもので、位置/力制御で最も重要な方法の 1 つである[16]。しかし、ハイブリッド制御、つまり従来の制御系で未知環境に力を加える場合、動特性の未知な環境に対して力制御のゲインを大きくするとシステムが不安定になる可能性があるため、大きなゲインを使うことができないが、力制御のゲインが小さいと目標力に達することが難しい。したがって、従来の制御系では環境の動特性に応じてゲインを設定してやる必要があり、動特性の未知な環境に対しては適切なゲインの設定ができなかった。この問題を解決するため、ハイブリッドコントローラにニューラルネットワークを直接的に利用して補償を行うことにより、動特性が未知な環境に対して多自由度のロボットマニピュレータで位置/力を制御する方法を提案するのが本論文の目的であ

原稿受付 1994 年 4 月 26 日

*¹新潟工業短期大学

*²オタワ大学

*³名古屋大学工学部

*¹Niigata College of Technology

*²University of Ottawa

*³Faculty of Engineering, Nagoya University

る。この方法を用いることにより、力制御のゲインが小さくても、また、動特性の異なる未知環境に対しても、ニューラルネットワークの補償により目標力に達することができ、目標力の変動に対しても追従できることを実験により確認した。筆者らはまずハイブリッドコントローラを構築し、このコントローラからのアウトプットをニューラルネットワークコントローラのインプットの一部として使用した。

本論文では、このニューラルネットワークコントローラを平面3自由度のダイレクトドライブロボットマニピュレータを用いて実験を行った。

2. ハイブリッドコントロール

Fig. 1 の様な環境にロボットマニピュレータで力を x 方向に加えるには、エンドエフェクタの y 方向の位置と環境に対する角度も制御しなければならない。この場合ハイブリッド制御が適当であると思われる。

平面ロボットの運動方程式は次式で表すことができる。

$$M(q)\ddot{q} + h(q, \dot{q}) + F_c \operatorname{sgn}(\dot{q}) = \tau - J^T f_d \quad (1)$$

ただし、 $M(q)$ は慣性行列、 $h(q, \dot{q})$ は遠心・コリオリ力、 F_c はクーロン摩擦、 τ は駆動トルクベクトル、 J はヤコビ行列、そして f_d は環境に加える目標の力であり、 q は関節位置ベクトルである。またここではロボットの速度は低速であると仮定し、粘性摩擦抵抗は無視した。

式(1)より、必要なモータトルクは次式のように表される。

$$\tau = M(q)\ddot{q} + h(q, \dot{q}) + F_c \operatorname{sgn}(\dot{q}) + J^T f_d \quad (2)$$

基準座標系でのエンドエフェクタの加速度は、

$$\ddot{x} = J\ddot{q} + \dot{J}\dot{q} \quad (3)$$

である。ただし、 x は基準座標系での位置ベクトルである。

式(2)(3)とセレクションマトリクス S を使うと、

$$\tau = M(q)J^{-1}[(I-S)u_p - \dot{J}\dot{q}] + h(q, \dot{q}) + F_c \operatorname{sgn}(\dot{q}) + J^T f_d + J^T S u_f \quad (4)$$

となる。ただし u_p は位置制御のコマンドベクトルで、 u_f は力制御のコマンドベクトルである。ここで加速度分解制御を用い

Fig. 1 Robot manipulator

Fig. 2 Block diagram of hybrid controller

ると、これらの入力コマンドは次式の様になる。

$$u_p = \ddot{x}_d + K_{pv}(\dot{x}_d - \dot{x}) + K_{pp}(x_d - x) \quad (5)$$

$$u_f = K_{fp}(f_d - f) + K_{fi} \int (f_d - f) dt \quad (6)$$

ハイブリッド制御系のブロック線図は **Fig. 2** に示される。このコントローラを使うことにより、環境に加える力やエンドエフェクタの角度と y 方向の位置が制御される。

このハイブリッドコントローラにより目標の位置と力を得ることは次の理由により困難である。第1に、ロボットマニピュレータと環境の完璧な数学モデルを作ることは非常に難しい。第2に、未知環境での力制御に高ゲインを使うことはできない。第3に、摩擦を完全に補償することは不可能である。特にロボットにおいては、そのロボットの形態により摩擦力が変化する。第4に、外乱を完全に無くすることはできない。さらに、環境がゴム、プラスチック、または発泡スチロールなどの場合、温度や湿度などにより特性が変化するため、ゲインを固定しておくのは適切でない。これらの問題を解決するためには何らかの適応スキームがコントローラに要求される。

3. ニューラルネットワークコントローラ

目標の位置と力を得るためには、未知環境に適応し、ロボットの非線形性を補償するニューラルネットワークコントローラを用いることが解決策の1つである。ニューラルネットワークコントローラにはいくつかのタイプがあるが、**Fig. 3** に示す様な直接型のニューラルネットワークコントローラがニューラルネットワークの最も効果的なロボットコントローラへの適用だと思われる。しかし、ハイブリッドコントローラのような既存型のコントローラは比較的容易に設計可能なので、そのようなコントローラを最初に作成し、このコントローラからのアウトプットをニューラルネットワークコントローラのインプットとして利用する方法を提案する (**Fig. 4**)。ここでハイブリッドコントローラからのアウトプットは、そのままロボットへのインプットとしても利用し、ニューラルネットワークはハイブリッドコントローラを補うために利用されるものとする。このコントローラにおいては、ニューラルネットワークが摩擦、モデリ

Fig. 3 Direct neural network controller

Fig. 4 Proposed neural network controller

Fig. 5 Neural network controller

ングエラー，外乱の補償等を行うので，ハイブリッドコントロール部での摩擦の補償は不要となる．したがって，式(4)は次式のようなハイブリッドコントローラ部からの出力式に書き換えられる．

$$\tau_n = M(q)J^{-1}[(I-S)u_p - \dot{J}\dot{q}] + h(q, \dot{q}) + J^T f_d + J^T S u_f \quad (7)$$

ここでは，ニューラルネットワークの出力 τ_n と区別するためにハイブリッドコントローラ部からの出力を τ_n とした．このコントローラのコマンドベクトルは次式のようになる．

$$u_p = \ddot{x}_d + K_{pv}(\dot{x}_d - \dot{x}) + K_{pp}(x_d - x) \quad (8)$$

$$u_f = K_{fp}(f_d - f) \quad (9)$$

式(9)で見られるように，ニューラルネットワークがハイブリッドコントロール部のエラーの補償を行うため，エラーの積分はもはや必要なくなる．さらに，式(9)でのゲインは，ニューラルネットワークが未知環境に適応するため環境が変化しても変える必要がない．このニューラルネットワークコントローラの詳細は，Fig. 5 に示されている．この図より，このコントローラは Fig. 2 のハイブリッドコントローラと Fig. 3 のニューラルネットワークコントローラを合わせたものであるということがわかる．

4. ニューラルネットワークのアーキテクチャ

ニューラルネットワークのアーキテクチャは Fig. 6 に示されている．これは，入力層，中間層そして出力層各1層ずつの非線形3層の階層型ニューラルネットワークである．入力層は9個，中間層は12個，出力層は3個のニューロンから成っている．ニューラルネットワークへの入力は，1サンプリングタイム前と現時点でのロボットマニピュレータの基準座標系における位置情報とハイブリッドコントロール部からの各モータへのトルクコマンド出力である．これにより，ロボットの形態(位置)と速度，目標位置/力を得るためにハイブリッドコントローラ部で計算された目標加速度情報がインプットされる．ニューラルネットワークからの出力は，基準座標系でのロボットマニピュレータへの力コマンドである．これらの力コマンドは，ジョイントトルクと基準座標系の力との関係を表す次式によって各モータへのトルクコマンドに変換される．

$$\tau_n = J^T f_n \quad (10)$$

ここで f_n はニューラルネットワークからの出力である．これによりロボットマニピュレータは，ハイブリッドコントロール部とニューラルネットワークからのコマンドトルクの合力をニューラルネットワークコントローラからの出力として受けとることになる．このコントローラからの出力によるロボットマニ

Fig. 6 Architecture of neural network

ピュレータの動きは，各モータのエンコーダと力センサにより計測される．ニューラルネットワークの各ウエイトは，位置と力のエラーの値(目標値と測定値の差)によりサンプリングタイム毎(この実験では1[msec]毎)にバックプロパゲーション法で調整される．

各ウエイトの変化量は，学習係数を α (>0) とすると，

$$\Delta w = -\alpha(\partial E / \partial w) \quad (11)$$

ただし，評価関数 E は誤差 ϵ (目標値 y_d と測定値 y の差) を2乗したものを用いる．

$$\epsilon = y_d - y \quad (12)$$

$$E = (1/2)\epsilon^2 \quad (13)$$

式(11)(13)より，

$$\Delta w = -\alpha \cdot \epsilon \cdot (\partial y / \partial f) (\partial f / \partial u) (\partial u / \partial w) \quad (14)$$

となる．ここで， f はニューラルネットワークで用いたアクティベーションファンクション(シグモイド関数)であり，次式で表される．

$$f(u) = 2 / (1 + e^{-u}) - 1 \quad (15)$$

ただし， u は層への入力である．

式(14)で $\partial y / \partial f$ は不明であるが，調整パラメータである α により加味される[10]．したがって，ウエイトの変化量は次のように表される．

$$\Delta w = -\alpha \cdot \epsilon \cdot f'(u) (\partial u / \partial w) \quad (16)$$

ニューラルネットワーク部からの出力はハイブリッドコントロール部からの出力を補償するものであるため，ウエイト初期値は小さなランダム値($10^{-3} \sim 10^{-4}$)に設定した．

ニューラルネットワークコントローラの安定性は重要な問題であるが，本論文ではシミュレーションによるケーススタディで安定性を確認する．Fig. 7 にシミュレーション結果を示す．これは(a)を標準パターン(学習係数 $\alpha = 1.0 \times 10^{-4}$)とし，(b)(c)では学習係数を増減させたときのコントローラの収束性を，また(d)では学習係数が(a)と同じで，ウエイト初期値だけを変更したときのコントローラの収束性を目標力10[N]に対する追従性で確認したものである．このシミュレーション結果より，学習係数やウエイト初期値を多少変更しても安定した制御が可能であることがわかる．

5. 実験

5.1 実験装置

実験装置は Fig. 8 に示すように，3自由度ダイレクトドライ

Fig. 7 Simulation results

Fig. 8 Experimental set-up

プロボットマニピュレータ (Fig. 1 参照), モータドライバ, コントロールシステムそして力センサから構成される. 各マニピュレータジョイントには異なったタイプのモータが使われている. コントロールシステムとして dSPACE を用いた. dSPACE は DSP を基にして, AD/DA コンバータとインクリメンタルエンコーダを含んだリアルタイムコントロールシステムである. コントローラからのトルクコマンドは, コントロールプログラムをストアした dSPACE から各モータドライバへ送られ, モータドライバはモータにパワーを送る. 各モータのレゾルバーと力センサからフィードバックシグナルが dSPACE へ送られることにより, その時点での位置と力がわかる. Fig. 8 での表記は次の通りである.

Motor 1 - NSK Megatorque Motor System 0810
(Max. 88.2 Nm)

Motor 2 - NSK Megatorque Motor System 0408
(Max. 9.8 Nm)

Motor 3 - Parker Hannifin Co. System 7

Type 7521.250 (Max. 2 Nm)

Force Sensor - Barry Wright Co.

6-axis force sensor FS 6-120 A

5.2 実験結果

この実験においてコントローラは, 環境に加える力, エンドエフェクタの角度と y 方向の位置 (Fig. 1 参照) を制御する. この実験の目的は, 提案したニューラルネットワークコントローラを使うことにより, 未知環境に対して目標通りの力を正確に加えることができることを確かめることである. 未知環境として, バネ定数約 $6.8[\text{K} \cdot \text{N}/\text{m}]$ の発泡スチロールとバネ定数約 $50[\text{K} \cdot \text{N}/\text{m}]$ のゴムを使用した. 前項で説明したように, このコントローラではハイブリッドコントロール部の力フィードバックのゲインを環境の動特性に合わせて変える必要はないので小さな値にした.

実験に用いた式 (8) (9) のフィードバックゲイン行列は次の通りである.

$$K_{pp} = \text{diag}(200, 200, 200)$$

$$K_{pv} = \text{diag}(80, 80, 80)$$

$$K_{fp} = \text{diag}(0.25, 0.25, 0.25)$$

Fig. 9 は発泡スチロールを環境に用いたときのロボットマニピュレータの力応答の実験を開始してから数十秒後の結果である. 目標力はステップシグナルのコンビネーションであり, 2.5 秒毎に $10[\text{N}]$ と $20[\text{N}]$ の間で変化する. この実験結果より, ロボットマニピュレータが目標力に追従しているのがわかる.

Fig. 9 Measured force response 1

Fig. 11 Measured force response 2

Fig. 10 Force response without neural network

Fig. 12 Measured force response 3

この実験でニューラルネットワークの補償をしなかった場合、つまり従来のハイブリッド制御の場合は、ゲインが小さすぎて目標力に追従できない。これを確認するためにニューラルネットワークによる補償無しで同じ実験を行った結果を Fig. 10 に示す。この実験結果より、ゲインが小さすぎて目標力まで達していないことが確認できる。

Fig. 11 は発泡スチロールを環境に用いた別の実験で、開始してから数十秒後の結果である。目標力は 2.5 秒毎に 10[N] と 20[N] の間で変化するステップシグナルと $4 \sin(\pi t)$ の曲線とを合わせた複雑なものであるが、目標力変化が滑らかな場合は、オーバーシュティングもほとんど無くうまく追従しているのがわかる。

Fig. 12 はゴムを環境に用いた実験で、開始してから数十秒後の結果である。このときの環境のバネ定数は発泡スチロールとは大きく異なるがコントローラのゲインは発泡スチロールのときと同じである。この実験の目標力はステップシグナルのコンビネーションで、2.5 秒毎に 10[N] と 20[N] の間で変化する。この実験結果より、環境の動特性が異なってもロボットマニピュレータは前の実験結果と同じように目標力に追従するの

Fig. 13 Measured force response 4

がわかる。

Fig. 13 はゴムを環境に用いた別の実験で、実験開始直後 10 秒間の結果である。目標力は Fig. 11 の実験のときと同じ

で、2.5秒毎に10[N]と20[N]の間で変化するステップシグナルと $4 \sin(\pi t)$ の曲線とを合わせたものである。この実験により、制御開始後約0.5秒でニューラルネットワークコントローラが未知環境に適応していることがわかる。当然のことながら、未知環境への適応に要する時間はニューラルネットワークの学習レートに依存する。

各実験結果に見られるオーバーシュートは、ロボットマニピュレータのダイナミクスがニューラルネットワークでまだ十分に学習されていないため生ずるものであると考えられるので、十分学習することにより解決されるものと思われる。

6. お わ り に

未知環境での力制御のため提案されたニューラルネットワークコントローラにより、基準座標において未知環境の動特性に関係無く目標力が得られることを実験により確認した。この未知環境での目標力追従能力は、固定された目標力だけでなく、時間により変化する目標力についても有効であり、ステップシグナル値を基準として±20%程度の滑らかな目標力変化に対しては問題なく追従できる。したがって、このコントローラにより、動特性が未知な環境に対し、従来のハイブリッド制御とは異なり、ゲインを小さく設定しておいても望みどおりの力を加えることが可能となる。しかしながら、ロボットマニピュレータのダイナミクスが十分に学習されていないために生じるオーバーシュートにより環境にダメージを与える危険性があるため、このコントローラのアプリケーションは制限される。この問題の解決は今後の課題である。また、コントローラで使用したニューラルネットワークは、十分に調整されたものでないので今後の調整が必要とされる。さらに、ニューラルネットワークコントローラの安定性について今後理論的な検討が必要である。

参 考 文 献

- [1] W. S. McCulloch and W. Pitts: "A Logical Calculus of the Idea Immanent in Nervous Activity," Bull. Math. Biophysics, 5, pp.

115-133, 1943.

- [2] B. Widrow: "Generalization and information storage in network of adaline 'neurons'," Self-Organizing Systems-1962, Spartan Books, pp. 435-462, 1962.
- [3] M. Kawato, K. Furukawa and R. Suzuki: "A Hierarchical Neural-Network Model for Control and Learning of Voluntary Movement," Biological Cybernetics, 57, pp. 169-185, 1987.
- [4] M. Kawato, Y. Uno, M. Isobe and R. Suzuki: "Hierarchical Neural Network Model for Voluntary Movement With Application to Robotics," IEEE Contr. Syst. Mag., vol. 8, pp. 8-16, 1988.
- [5] 鶴田, 光岡, 福田, 栗原: "神経回路モデルによるロボットの力制御 (1 自由度マニピュレータの制御)", 日本ロボット学会誌 7 巻 1 号, pp. 47-51, 1989.
- [6] 福田, 栗原, 鶴田, 光岡: "神経回路網によるロボット・マニピュレータの位置・力制御の研究 (第 1 報)", 機論, 56-527, C, pp. 210-216, 1990.
- [7] 福田, 柴田, 鶴田, 光岡: "神経回路網によるロボット・マニピュレータの位置・力制御の研究 (第 2 報)", 機論, 57-535, C, pp. 866-873, 1991.
- [8] 柴田, 福田, 小菅, 新井, 鶴田, 光岡: "神経回路モデルによるロボットマニピュレータの位置・力制御の研究 (第 6 報)", 機論, 58-549, C, pp. 108-115, 1992.
- [9] 辻, 西田, 伊藤: "ニューラルネットによるインピーダンスパラメータの繰返し学習", 計測自動制御学会論文集, 27-7, pp. 1461-1468, 1991.
- [10] T. Yabuta and T. Yamada: "Possibility of Neural Networks Controller for Robot Manipulators," Proc. of IEEE Int. Conf. on Robotics and Automation, pp.1686-1691, 1990.
- [11] 山田, 藪田: "ダイレクトニューロコントローラに関する一考察", 計測自動制御学会論文集, 27-7, pp. 784-791, 1991.
- [12] T. Yamada and T. Yabuta: "Neural Network Controller Using Autotuning Method for Nonlinear Functions," IEEE Trans. on Neural Networks, 3-4, pp. 595-601, 1992.
- [13] S. Kung and J. Hwang: "Neural Network Architectures for Robotic Applications," IEEE Trans. on Robotics and Automation, 5-5, pp. 641-657, 1989.
- [14] 堤: "ニューロコンピューティングによるロボットの軌道生成", 日本ロボット学会誌 9 巻 2 号, pp. 89-95, 1991.
- [15] J. Helferty and S. Biswas: "Neuromorphic Control of Robot Manipulators," Proc. 1991 IEEE Int. Conf. on Robotics and Automation, pp. 2436-2441, 1991.
- [16] M. H. Raibert and J. J. Craig: "Hybrid Position/Force Control of Manipulators," Trans. ASME Journal of Dynamic Systems, Measurement and Control, vol. 102, pp. 126-133, 1981.

木口量夫 (Kazuo Kiguchi)

1964年2月15日生。1986年新潟大学工学部機械工学科卒業、マツダ株式会社等の勤務を経て、1993年カナダ University of Ottawa 大学院博士前期課程修了。現在新潟工業短期大学生産システム工学科助手。ロボットのニューロ・ファジィ制御、知能ロボットの研究等に従事。日本機械学会、計測自動制御学会、IEEEの会員。(日本ロボット学会正会員)

福田敏男 (Toshio Fukuda)

1948年12月12日生。1977年東京大学大学院博士課程修了、工学博士。通産省工業技術院機械技術研究所研究員、東京理科大学工学部機械工学科助教授を経て、現在名古屋大学工学部機械情報システム工学科教授。自己組織化ロボット、マイクロロボット、ニューロ・ファジィ制御の研究等に従事。IEEE Industrial Electronics Society Vice President(1991-), IEEE Robotics & Automation Society 会議担当委員長及びマイクロロボット技術委員会委員長。(日本ロボット学会正会員)

Dan S. Necsulescu

Born in Apr. 17, 1943, received the Dip. Eng. from the Polytechnic Institute of Bucharest, Romania in 1966. He received in 1973, the License of Philosophy from the University of Bucharest and in 1974 the doctorate in engineering from Polytechnic Institute of Bucharest. In 1980, he joined the Dept. of Mechanical Engineering, University of Ottawa, where he holds the position of Professor. He chaired the Dept. of Mechanical Engineering from 1990 to 1993. His research activities are in the impedance control of robots and large flexible structures, autonomous mobile robots, friction compensation and error propagation in robot arms.