結合構造可変ニューラルネットワークによる振動制御*

小松崎 俊彦^{*1}, 佐藤 秀紀^{*1}
岩田 佳雄^{*1}, 森下 信^{*2}

Vibration Control using Neural Network with Adaptively Rearranging Structure

Toshihiko KOMATSUZAKI^{*3}, Hidenori SATO,
Yoshio IWATA and Shin MORISHITA^{*3} Department of Human and Mechanical Systems Engineering, Kanazawa University,
2-40-20 Kodatsuno, Kanazawa-shi, Ishikawa, 920-8667 Japan

The neural network has been applied to many engineering problems such as pattern recognition, optimization, system identification and control because of its nonlinear mapping capability. Although the network has a great ability to acquire solution for given problems through learning, several problems are known such as the convergence to a local minimum solution and the empirical tuning of network parameter to obtain desired accuracy. Such an instability may be overcome by finding suitable network structure. The optimized network structure with minimum connection can be obtained by employing optimization techniques such as Genetic Algorithms. However, it is hardly applicable to time-varying systems in view of computation efficiency. In the present paper, we deal with the adaptive neural network controller which rearranges its connection structure suitably according to the given problems. The network is applied to vibration control problem of single degree of freedom nonlinear system, and the performance of the controller is discussed by numerical investigation.

Key Words: Neural Network, Rearrangement, Vibration Control, Identification, Nonlinear System

1. 結 論

ニューラルネットワークは、その学習能力や、比較的容易に非線形の写像を実現できること等の特徴から、パターン認識や未知システムの同定・制御問題などへの適用が多数報告されている^{(1)~(15)}。しかし、ネットワークに含まれるパラメータの選択によっては解が極小値に収束し十分な精度の写像が得られないなど、信頼性や安定性の面で問題点も多い。

この問題を解決する一つの方法としては、学習アルゴリズムの改良が考えられ、学習精度の向上および学習過程の高速化を実現する各種アルゴリズムの提案がなされている^{(7)~(9)}。また、非線形系の問題解決のために高い非線形写像能力を有する関数をニューラルネットワークの出力関数として採用した研究⁽¹⁰⁾や、学習過程に遺伝的アルゴリズムを導入して学習の効率化・高精度化を図った研究⁽¹¹⁾⁽¹²⁾、および複数の異なるニューラルネットワークを立体的に結合し、対象に応じて自律的にレベルの切替えや各ネットワークを統合す

ることにより適用範囲の広いロバストなコントローラを実現した例などがある⁽¹³⁾。

一方、別の方法としてネットワークの結合構造を適宜変化させることで上述の問題を回避できる可能性がある。ネットワーク構造の最適化を図る手法としては、初期に大きな構造を設定し、不要な結合を順次削除することで構造の最適化を行う手法がすでにいくつか提案されており⁽¹⁵⁾⁽¹⁶⁾、これらは非常に少ない結合数で比較的精度のよい構造を発見することが可能である。しかし、例えば振動・音響系を対象とした制御のように動的問題を取扱う場合、ネットワークを制御系として導入した後、対象の特性変化に応じて逐次最適化を図ることは、計算時間の観点から適さないものと考えられる。

著者らはこれまでに、生体内のネットワーク形成過程を模擬し、上記のアプローチとは逆に結合のない状態からネットワークを成長させ、問題に適した構造を自動的に形成する自己組織化ニューラルネットワークを提案し、構造・音場連成モデルに対して、できるだけ少ない結合で迅速に制御可能なネットワークを自動的に構築できることを示した⁽¹⁴⁾。ただし、常に良好なネットワーク構造が得られるとは限らないこと、あるいは生成される結合構造に再現性がないことなど、問

* 原稿受付 2003年7月31日。

^{*1} 正員、金沢大学工学部(〒920-8667 金沢市小立野2-40-20)。^{*2} 正員、横浜国立大学大学院環境情報研究院(〒240-8501 横浜市中区谷区常盤台79-7)。

E-mail: toshi@t.kanazawa-u.ac.jp

Fig. 2 Structure of system discriminating network

Fig. 3 Structure of rearranging network

ークは図3に示すように3層の階層型ネットワークとして与え、対象識別ネットワークで得られた結合荷重を入力として用い、対象システムと最適化された同定・制御ネットワーク構造との対応関係を学習させる。ここで、構造記憶ネットワークは、同定・制御ネットワークの結合構造そのものを記憶するのではなく、あらかじめ番号付けられメモリ上に記憶された構造を読み出すスイッチとして機能する。いくつかの既知システムに対する最適なネットワーク構造は、遺伝的アルゴリズムを用いて結合数および同定・制御性能の点において最適化を図ったものを用意する。

構造記憶ネットワークの学習手順は、まず対象識別ネットワークに対して系の入出力関係を一定回数学習させ、この結果得られた結合荷重のセットを構造記憶ネットワークの入力として、結合荷重と最適化された既知構造との対応を記憶させる。この過程をいくつかの組合せについて繰返し、収束した時点で構造記憶ネットワークの学習を終了する。学習済みの構造記憶ネットワークを実装する場合も同様に、まず対象識別ネットワークに系の入出力関係を学習させ、一定回数の学習の後に得られた結合荷重群を構造記憶ネットワークに入力し、系に対応する記憶済みのネットワーク構造を同定・制御ネットワークに反映することで構造の組換えを実現する。これら3種類のネットワークを組

Fig. 4 Schematic of self-rearranging network system

Fig. 5 Process of structure alteration

合せたシステムの概念図、およびこれらの処理の流れをそれぞれ図4および5に示す。

3. 制御対象モデル

提案する制御システムを評価するモデルとして、復元力あるいは減衰特性の異なるいくつかの一自由度系モデルを採用する。系ごとに最適なネットワーク構造をあらかじめ用意して、変化に応じてネットワーク構造の切替えを自動的に行う。数値積分にはルンゲ・クッタ法を使用し、シミュレーションの時間刻みは1msで行った。同定用のフォワードモデルにより系の加速度を同定し、一方のコントローラにより質量に加える制御力を出力することで制御を行う。

図6に、本研究で用いた一自由度系モデルを示す。外力および制御力は質量に作用するものとする。図6(a)の粘性減衰系モデルについては、比例減衰および速度二乗型減衰の2種類について考える。速度二乗型減衰系は以下の運動方程式で表される。

$$m\ddot{x} + c|\dot{x}| + kx = F + F_{cont} \quad \cdots \cdots (1)$$

ここで、質量 $m=1$ kg, ばね定数 $k=10\,000$ N/m, および減衰係数 $c=1$ Ns/m とする。 F および F_{cont} はそれぞれ外力および制御力を表す。

図 6(b) の摩擦系モデルについては以下の運動方程式で記述される。

$$m\ddot{x} + kx + F_c \text{sign}(\dot{x}) = F + F_{cont} \quad \cdots \cdots (2)$$

このとき、粘性減衰項に代わり、 $F_c=1$ N の乾性摩擦力を与える。

また、図 6(c), (d) については図 7(a), (b) に示す復元力特性を有する Duffing 系およびがた系のモデルとする。Duffing 系の運動方程式は以下の式(3)のように記述される。

$$m\ddot{x} + c\dot{x} + k(x + \beta x^3) = F + F_{cont} \quad \cdots \cdots (3)$$

ここで、Duffing 系の復元力に関するパラメータ $k=30\,000$ N/m, $\beta=1\,000$ m⁻² を与えた。さらに、がた系は次の運動方程式で表すものとする。

$$\begin{aligned} m\ddot{x} + c\dot{x} + k_2(x \pm z) \mp k_1 z &= F + F_{cont} & |x| \geq z \\ m\ddot{x} + c\dot{x} + k_1 x &= F + F_{cont} & |x| < z \end{aligned} \quad \cdots \cdots (4)$$

式(4)において、 z はがた幅を表し、 k_1 および k_2 は

Fig. 6 Schematic of numerical models

Fig. 7 Spring properties of nonlinear system

折線ばね特性を表現するパラメータである。ここでは $z=4$ mm, $k_1=30\,000$ N/m, $k_2=120\,000$ N/m とした。以上、5 種類の系に作用する外乱としては、カットオフ 200 Hz のランダムノイズを採用した。

4. GA による同定・制御ネットワーク構造の最適化

遺伝的アルゴリズム (Genetic Algorithm, GA) は、生物進化の過程を人工的に模倣したアルゴリズムであり、確率的探索・最適化の一手法として知られる。ビット列で表現された遺伝子と称される解候補の初期集団を発生させ、再生産・交差・突然変異の過程を繰り返しながらその適応度を評価し、最適解へと収束させる手法である⁽¹⁷⁾。本研究では、構造記憶ネットワークを学習させるために、まず既知システムに対して最適化された同定・制御用ネットワーク構造を GA により作り出す。ここで言う最適化とは、ユニット間の結合数ができる限り少なく、かつ同定・制御性能に関してある程度以上の精度を実現できる構造を得ることを指す。2 章で述べたフォワードモデルネットワークの基本構造を基準に、その結合数が可能な限り少なくなる方向で探索する。以下にその概要を述べる。

4.1 結合の遺伝子へのコーディング 本報告では簡単のために中間層は考えず、フォワードモデルを 2 層の階層型ネットワークとし、入力・出力ユニット間の結合について考える。図 8 に示すように、結合可能なユニット間に番号を付し、番号の順に結合あり・なしを表現する遺伝子を一列に並べ、染色体とする。このビット列が乱数で初期化された染色体の集団を発生させ、集団の中で再生産・交差・突然変異等の操作を行う。

4.2 解探索の過程 個体数を 100 とし、集団中で適応度の高い上位 10% までの遺伝子を各世代において残し (エリート選択), 交差率 60%, 突然変異率 5% として解の探索を行った。計算は 100 世代まで行っている。個々の染色体に対する適応度は、振動系の

Fig. 8 Gene encoding of connections

Fig. 9 Optimized connection for each vibration system

20 秒間における制御シミュレーションの結果得られる同定誤差・制御誤差の平均値、および全結合数に対する結合割合によって評価している。

図 6 に示すおのおの一自由度振動系に対して、カットオフ周波数 200 Hz のランダムノイズを外力として与え、ニューラルネットワークの入力ユニット 15 個および出力ユニット 1 個との間の結合について最適化を行った結果を図 9 に示す。ユニットを円環状に配し、白丸は入力ユニット、黒丸は出力ユニットに対応させて表現している。これら 5 種類の振動系に対して制御可能な構造は Duffing 系の場合が最大で、6 個の結合構造が得られた。また、その構造を用いて制御の確認計算を行った結果を図 10 に示す。それぞれ良好に加速度が抑制されていることがわかる。なお、これら構造のうちいくつかは複数の系に対応可能なものもあるが、次章では制御対象の特性を切替えた場合、順序や組合せによって制御が不安定にやり、ニューラルネットワーク構造の切り替えが必要となる例について示す。

5. 制御シミュレーション

5・1 構造記憶ネットワークの学習 2 章で述べた同定用ネットワークのユニット間結合構造を記憶する構造記憶ネットワークについて、5 種類の一自由度

Fig. 10 Vibration control result with respective optimized structure

振動系に対して GA により得られた構造との対応関係を記憶学習させた。構造記憶ネットワークのユニット数は、入力にフォワードモデルの最大結合数(結合荷重数)と同じ 15 個、中間層ユニットは 5 個に設定し、出力層は学習させるフォワードモデル構造に対応した 5 個とした。入力値は対象識別ネットワークより得られる結合荷重値を用い、一方の出力値は、提示した振動系に対応するネットワーク構造に割り当てられた出力ユニットの出力値が 1、それ以外が 0 となるよう学習させた。それぞれのフォワードモデルネットワーク構造を交互に 1000 回ずつ学習させた後に学習を打ち切り、再び五つのネットワークに対応する結合荷重の組を入力させた場合の構造記憶ネットワーク出力結果の例を表 1 に示す。表の列ラベル (Q_n) は構造学習ネッ

Table 1 Test result of learned structure rearranging network

	O_1	O_2	O_3	O_4	O_5
System 1	0.996	0.003	0.000	0.002	0.001
System 2	0.003	0.996	0.002	0.000	0.000
System 3	0.000	0.003	0.996	0.004	0.000
System 4	0.003	0.000	0.004	0.995	0.004
System 5	0.002	0.000	0.000	0.002	0.997

(a) Without control

(b) Controlled by fixed structure

(c) Controlled by rearranging structure

Fig. 11 Control result for the case system varies from linear to Duffing (System changed at 25)

トワークの五つの出力ユニットを示し、行ラベルは学習後に再び入力された五つの振動系に対応する対象識別ネットワークの結合荷重パターンを表している。それぞれ良好に識別されており、構造学習が成功していることがわかる。

5・2 結合構造の動的切替え制御 学習済みの構造記憶ネットワークを用いて、対象システムに変化が生じた場合に、動的に同定・制御用ニューラルネットワークを切替え可能であることを示すためにシミュレーションを行った。ここでは切替えがないと制御が不安定になる2例について示す。

まず、線形振動系から Duffing 型振動系に移行する例について考える。これは、熱応力等の発生によって構造系に軸力が生じ、復元力特性が変位の三乗型に比例するケースを想定している。図 11 に示すように、シミュレーション開始 25 秒後に線形系から Duffing 系に変化させた場合、線形系に特化したネットワーク

(a) Without control

(b) Controlled by fixed structure

(c) Controlled by rearranging structure

Fig. 12 Control result for the case system varies from linear to piecewise linear (System changed at 25 s)

のまま切替えを行わない図 11(b)に示すように制御が発散してしまうが、一方の図 11(c)のように系の変化に伴いネットワークの切替えを行うと良好に加速度が抑制されていることがわかる。

同様に、構造物連結部分の緩みなどによって線形振動系からがた系へ移行する場合を想定したシミュレーションにおいても、切替えなしでは図 12(b)のように計算開始 25 秒後以降に制御が不安定になるのに対して、がた系に対応したネットワーク構造へ切り替えを行うと図 12(c)に見られるように安定して制御を行うことが可能である。

6. おわりに

本研究では、数種類の既知構造ネットワークを記憶学習するニューラルネットワークを用いて、過去に学習済みのネットワーク構造を想起し、制御系への実装を行うシステムを構築した。本手法により、既知システムに対して効率的に制御可能なネットワーク構造を適用することが可能となり、システムの特性変化により再構築の必要性が生じた場合でも、最適化手法を改めて用いることなく構造の組換えが可能のため、迅速に対応できることが示された。

文 献

- (1) Narendra, K. S. and Mukhopadhyay, S., *Neural Network*, 7-5 (1994), 737-752.
- (2) 長門英明・吉田和夫, 機論, 58-545, C (1992), 171-177.
- (3) 猫本善統・藤田勝久・田中守, 機論, 58-550, C (1992), 1762-1765.
- (4) 朝倉俊行・中出勇・福田繁伸, 機論, 62-596, C (1996), 1270-1276.
- (5) 小林正人・山口高司・平井洋武・藤澤二三夫・西脇宏, 機論, 60-576, C (1994), 2634-2640.
- (6) Koshigoe, S.・森下信・小松崎俊彦・宇根総一郎, 機論, 64-620, C (1998), 1333-1338.
- (7) Chinmoy, P.・榎場直樹・森下信・萩原一郎, 機論, 59-561, C (1993), 1436-1442.
- (8) 森下信・宇根総一郎・Chinmoy, P.・萩原一郎, 機論, 60-575, C (1994), 2377-2382.
- (9) Chinmoy, P.・榎場直樹・森下信・萩原一郎, 機論, 60-573, C (1994), 1699-1704.
- (10) 菅野直紀・河合素直, 機論, 60-569, C (1994), 102-106.
- (11) 福田敏男・河野忠士・柴田崇徳, 機論, 59-564, C (1993), 2298-2304.
- (12) 高橋和夫・山田孝行, 機論, 62-604, C (1996), 4587-4595.
- (13) 木通秀樹・吉田和夫, 機論, 63-613, C (1997), 3160-3167.
- (14) 小松崎俊彦・佐藤秀紀・岩田佳雄・森下信, 機論, 68-671, C (2002), 2023-2029.
- (15) Morishita, S., Takamori, T. and Nomura, D., *Proc. Third Motion and Vibration Control*, (1996), 128-132.
- (16) 津崎久宣・星野力, 情報処理学会第48回全国大会講演論文集, 12 (1994), 239-240.
- (17) 日本機械学会編, 適応化・知能化・最適化法, (1996), 124-142, 技報堂.