

ニューラルネットワークを利用したセミアクティブサスペンション*

横山 誠^{*1}, 外山 茂浩^{*2}
伊藤 浩永^{*3}, 愛田 一雄^{*1}

Semi-Active Suspensions Using Neural Networks

Makoto YOKOYAMA^{*4}, Shigehiro TOYAMA,
Hironaga ITO and Kazuo AIDA^{*4} Department of Mechanical and Production Engineering, Faculty of Engineering, Niigata University,
8050 Ikarashi 2 nocho, Niigata shi, Niigata 950-2181 Japan

This paper presents a design method of neural controllers for semi-active suspensions with nonlinear devices such as electrotheological or magnetotheological dampers. It is shown that the use of two neural networks corresponding to each signs of the relative velocity is effective to realize the desired controllers, i.e., semi-active controllers inherently include discontinuous mappings due to the passivity constraint and it is generally very difficult to realize them with single neural network. A model-following type controller with these neural networks is proposed, and two learning methods, the feedforward learning and the recurrent learning, for the controller are investigated from a viewpoint of system identification theories: the equation error method and the output error method.

Key Words: Vibration Control, Neural Network, Automobile, Semi Active Suspension, System Identification

1. 緒言

アクティブおよびセミアクティブサスペンションに関する研究が多くの研究者によって行われてきたが、電気粘性流体あるいは磁性流体の開発と相まって、近年ではセミアクティブサスペンションに関する研究が特に盛んに行われている^{(1)~(3)}。これらの流体を用いたダンパは、従来のオリフィス可変形のものと比較して一般に構造が簡単でかつ速応性に優れているが、発生する減衰力はサスペンションストローク速度と電場あるいは磁場の強度に関して強い非線形性を有している。さらに、流体特性の温度依存性などを考慮すると、時不变線形制御では、必ずしも良好な制振性能が得られない。

そこで本論文では、モデル化が困難な非線形システムなどに対して、一種の非線形適応制御器として応用されているニューラルネットワーク(以後、NNと記す)を用いたセミアクティブサスペンションの制御器

設計について検討する。NNのアクティブサスペンションへの応用に関してはすでに報告されている^{(4)~(6)}が、著者らの知る限りでは、セミアクティブサスペンションへの応用に関する研究は見受けられない。この理由の一つとして、セミアクティブサスペンションにおいては、その受動性の制約によって制御則は基本的に不連続性を有することとなり、不連続写像をNNによって精度良く近似することが極めて困難であることが考えられる。本論文では、まずこの問題を克服するために、不連続面を境に入力データ空間を二つに分離し、それぞれの領域に対応した二つのNNを用いた制御器を提案する。次に、モデル参照形適応制御の基礎として、受動性の制約条件を考慮した参照モデルを用いた二つの学習方法を提案し、それぞれの学習方法に関してシステム同定の観点から詳細に考察する。最後に、数値シミュレーションによって、理論の妥当性と提案する制御器の有効性を示す。

2. 問題の記述

ここでは、電気粘性ダンパ(以後、ERダンパと記す)を例に、非線形特性を有する可変ダンパおよびばねを装着したセミアクティブサスペンションの制御器設計における問題点を考察する。

* 原稿受付 1999年9月20日。

^{*1} 正員、新潟大学工学部(950-2181 新潟市五十嵐2の町8050)。^{*2} 正員、新潟大学大学院自然科学研究科。^{*3} 富士重工業(株)(160-8316 東京都新宿区西新宿172)。
E-mail: m.yoko@eng.niigata-u.ac.jp

制御対象は、図1に示す単輪1自由度モデルとし、次式のように表されるものとする。

$$m\ddot{y} = -F_d - h(\Delta y) \quad \dots\dots\dots(1)$$

$$F_d = \begin{cases} f(\Delta y, u) & \text{if } F_d \Delta y > 0 \\ 0 & \text{if } F_d \Delta y \leq 0 \end{cases} \quad \dots\dots\dots(2)$$

ここで、 $h(\cdot)$ は非線形ばねの弾性力、 F_d は制御入力 u (電流、電圧など)およびサスペンション、ストローク速度 Δy の非線形関数である減衰力を表す。NNを用いた制御器の学習のため、上式における微分を後退差分で離散時間化し、さらに次の状態変数を用いて得られる離散時間状態空間モデルを式(4), (5)のように表す。

$$\begin{aligned} x(k) &= [x_1(k) \quad x_2(k)]^T = [\Delta y(k) \quad \dot{y}(k)]^T \\ &\dots\dots\dots(3) \end{aligned}$$

$$x(k+1) = \Psi(x(k), \dot{x}(k), F_d(k)) \quad \dots\dots\dots(4)$$

$$F_d(k) = f(\dot{x}_1(k), u(k)) \quad \dots\dots\dots(5)$$

ここで Ψ は非線形関数である。また、従来ERダンパや磁性流体を用いたダンパ(MRダンパ)のモデルとして、次式を用いることが多い。

$$f(\dot{x}_1, u) = C_0 \dot{x}_1 + \operatorname{sgn}(\dot{x}_1) g(|\dot{x}_1|, u) \quad \dots\dots\dots(6)$$

$$u \geq 0, \quad C_0 \geq 0, \quad g(|\dot{x}_1|, u) \geq 0, \quad g(|\dot{x}_1|, 0) = 0 \\ \dots\dots\dots(7)$$

ここで、 $g(|\dot{x}_1|, u)$ は式(7)の条件を満たす非線形関数である。さて、なんらかの制御則によって望ましい減衰力 F_{Dd} が決定されたとすると、式(6)で表される f の u に関する逆関数

$$u = f^{-1}(\dot{x}_1, F_{Dd}) \quad \dots\dots\dots(8)$$

を用いて、制御入力 u を決定することができる。例えば、固定減衰係数を持つ粘性ダンパと、入力電圧によって摩擦力を変化させることができるクーロン摩擦ダンパの並列結合モデルを考えると、その特性は次式で表される。

$$f(\dot{x}_1, u) = C_0 \dot{x}_1 + \gamma \operatorname{sgn}(\dot{x}_1) u \quad \dots\dots\dots(9)$$

ここで、 γ はクーロン摩擦力の入力電圧に関する比例定数である。したがって、 $u \geq 0$ であることに注意してこの関数の u に関する逆関数を用いると、次式を

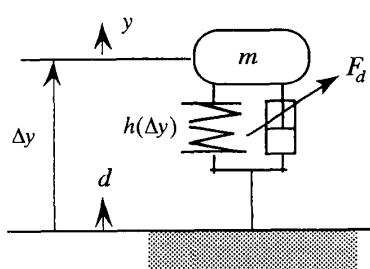


Fig. 1 1 degree-of-freedom quarter car model with semiactive suspension

得る。

$$u = \begin{cases} \frac{1}{\gamma} |F_{Dd} - C_0 \dot{x}_1| & \text{for } \dot{x}_1(F_{Dd} - C_0 \dot{x}_1) > 0 \\ 0 & \text{for } \dot{x}_1(F_{Dd} - C_0 \dot{x}_1) \leq 0 \end{cases} \quad \dots\dots\dots(10)$$

さらに、スカイフックダンパ制御の近似実現を考えるならば、望ましい減衰力は、 C_s, k_s を理想的なスカイフックシステムを与える減衰係数とばね定数とする

$$F_{Dd} = C_s x_1 + k_s x_1 - h(x_1) \quad \dots\dots\dots(11)$$

となる。このように、ダンパの逆モデルを用いる制御方法は直接的で非常に有効と考えられるが、精度の高い逆モデルを必要とする。しかし実際には、現在開発が進められているERあるいはMRダンパは一般的に複雑な非線形性を有し、精度の良い順モデルから解析的に逆モデルを得ることは容易ではない。また、解析解を得るために順モデルを簡単化すると、逆モデルの精度が劣化するという問題が生じる。

さらに、式(10)からわかるように、受動性によって制御則には必然的に不連続関数が存在することになる。説明の簡単のために、スカイフック制御の近似実現を考え、ばね特性は線形で理想的な剛性を有し、さらに $C_0=0$ と仮定すると、制御入力は図2に示すようにサスペンションストローク速度と質量絶対速度に関する不連続関数として表される。このとき、不連続面はサスペンションストローク速度が零の領域に存在することになる。

3. NN 制御器と学習方法

3・1 NN 制御器の構造

制御則は、2章の例で示したようにダンパの非線形特性を補償することを考慮し、状態変数およびサスペンションストローク速度を用いた、次の非線形フィードバックとする。

$$u(k) = N_c(x(k), \dot{x}_1(k) | \theta) \quad \dots\dots\dots(12)$$

ここで、非線形関数 N_c はNNで実現するものとし、

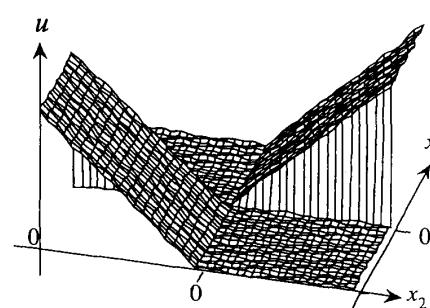


Fig. 2 Analytical controller based on simplified model

θ は NN 内の可変パラメータを表す。すなわち、ダンパーの逆モデルおよびばね特性の非線形特性をすべて包含した一つの非線形関数を考え、なんらかの評価規範のもとでこれを最適化するよう NN の学習を行うことを狙いとしている。したがって、最適化されたこの NN 制御器を用いた制御系は図 3 のようになる。ただし、NN 制御器への入力 \dot{x}_1 を実際は x_1 の差分などで推定するが、 $\dot{x}_1 = x_2 - d$ の関係を用いて形式的に図 3 のように示している。

さて、ここでまず考えなければならない問題は、2 章で述べたように NN 制御器は不連続写像を実現しなければならないことである。そこで、図 4 に示すように、不連続面(サスペンションのストローク速度が零)を境に二つの NN を用いることを提案する。すなわち、ストローク速度が正のときは N_{c1} を用い、ストローク速度が負のときは N_{c2} を用いる。しかし実際には、もし望ましい制御則(最適な N_c)がこの不連続面に対して対称性を有する場合は、一つの NN を共用することができることは明らかである。これは、制御対象の動特性が不連続面に関して対称で、かつシステム全体の制御性能も対称性を望む場合に起こる。逆に、サスペンションの伸び側と縮み側で特性が異なるダンパーを用いている従来のパッシブサスペンションのように、全体の制御性能を非対称にすることにも容易に対応できる構造となっている。

3・2 学習方法 NN 制御器の学習方法は種々考えられるが、本論文では図 5 に示すように、参照モデルの状態変数に追従させる、いわゆるモデル参照形学習について検討する。このとき、参照モデルは、受動性の制約条件を含んだシステム、言い換えると可変ダンパーで実現できるシステムを選択することが重要であ

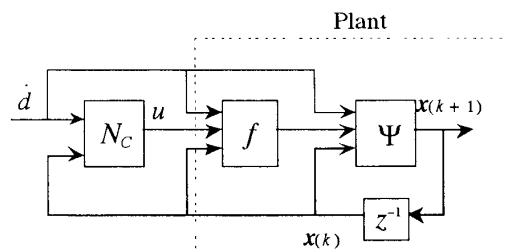


Fig. 3 Control scheme with NN controller

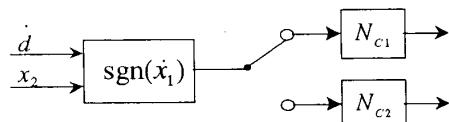


Fig. 4 Structure of NN controller for semiactive suspensions

る。例えば、油圧シリンダのような能動的アクチュエータによって実現可能な完全スカイフックサスペンションではなく、2 章で述べた近似スカイフックサスペンションとする。

さて、NN 制御器と追従誤差の間に制御対象が存在するため、NN の学習にはまず制御対象のモデルが必要となる。そこで、非線形性を有する制御対象の同定にも NN を用いることを考えるが、3・2 節ではモデルが得られているとし、制御対象の同定に関しては 3・3 節で考察する。図 5 において、破線で囲まれた部分を一つのモデルと考えると、NN の学習は参照モデルの学習同定と考えることができる。したがって、図 6 に示すように(a) フィードフォワード形学習と(b) リカレント形学習(以下それぞれ F 形学習、R 形学習と記す)を考えることができる。本論文では NN の学習方法として、それぞれ静的誤差逆伝ば法、

$$\theta(k+1) = \theta(k) - \eta c_F(k+1) \frac{\partial x(k+1)}{\partial \theta} \quad \dots \dots \dots (13)$$

$$\frac{\partial x(k+1)}{\partial \theta} = \frac{\partial \bar{\Psi}}{\partial F_d(k)} \frac{\partial \hat{f}}{\partial u(k)} \frac{\partial N_c}{\partial \theta} \quad \dots \dots \dots (14)$$

および動的逆伝ば法⁽⁷⁾

$$\theta(k+1) = \theta(k) - \eta c_R(k+1) \frac{\partial x(k+1)}{\partial \theta} \quad \dots \dots \dots (15)$$

$$\begin{aligned} \frac{\partial x(k+1)}{\partial \theta} &= \frac{\partial \bar{\Psi}}{\partial x(k)} \frac{\partial x(k)}{\partial \theta} + \frac{\partial \bar{\Psi}}{\partial F_d(k)} \\ &\times \left[\frac{\partial \hat{f}}{\partial \dot{x}_1(k)} \frac{\partial \dot{x}_1(k)}{\partial \theta} + \frac{\partial \hat{f}}{\partial u(k)} \right] \end{aligned}$$

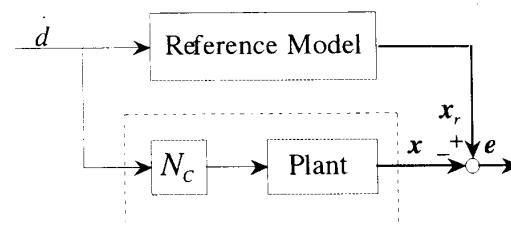
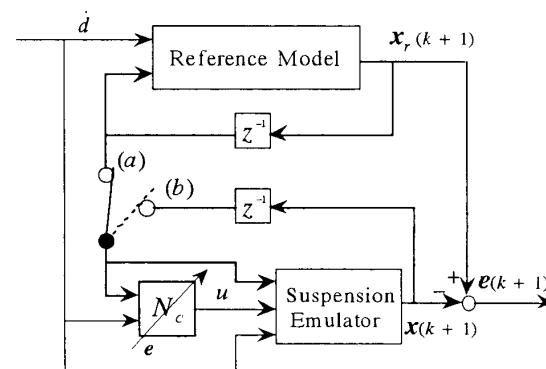


Fig. 5 Model following learning method



(a) Feedforward type (b) Recurrent type

Fig. 6 Two learning methods for NN controller

$$\times \left(\frac{\partial N_c}{\partial x(k)} \frac{\partial x(k)}{\partial \theta} + \frac{\partial N_c}{\partial \dot{x}_1(k)} \frac{\partial \dot{x}_1(k)}{\partial \theta} + \frac{\partial N_c}{\partial \theta} \right) \dots \dots \dots (16)$$

を用いることとする。ただし、ここで $\hat{\Psi}$ および \hat{f} は式(4), (5)で示される制御対象を同定したモデルを表し、 η は学習率を表す。すなわち、NN 制御の学習には、同定モデルのヤコビアンが必要となることに留意する。以下では、これらの学習方法をシステム同定の観点から比較検討する。

まず、図 6 に示す学習アルゴリズム(a), (b)が、それぞれ式誤差モデルおよび出力誤差モデルによる学習同定に対応することに注意する。すなわち、参照モデルの状態方程式モデルを

$$x_r(k+1) = A_r x_r(k) + b_r \dot{d}(k) \dots \dots \dots (17)$$

で表すと、それぞれの学習形態における誤差 e_F, e_R は以下のように表すことができる。

$$\begin{aligned} e_F(k+1) &= x_r(k+1) - \hat{\Psi}(x_r(k), \dot{d}(k), \hat{f}(x_{r2}(k) \\ &\quad - \dot{d}, N_c(x_r(k), u(k)))) = x_r(k+1) \\ &\quad - \hat{A}_r x_r(k) - \hat{b}_r \dot{d}(k) \dots \dots \dots (18) \end{aligned}$$

$$\begin{aligned} e_R(k+1) &= x_r(k+1) - \hat{\Psi}(x(k), \dot{d}(k), \hat{f}(x_{r2}(k) \\ &\quad - \dot{d}, N_c(x(k), u(k)))) = x_r(k+1) \\ &\quad - \hat{A}_{rx}(k) - b_r \dot{d}(k) \dots \dots \dots (19) \end{aligned}$$

同定理論の分野において周知のように、式誤差法の同定アルゴリズムは極めて簡素であるが、一方、出力誤差法では、パラメータに関して線形なモデルを用いた場合でも非線形推定問題となり、複雑なアルゴリズムに加えて局所最適解の存在(評価関数の多峰性)などの問題がある⁽⁸⁾。したがって、パラメータに関して非線形な NN を用いた同定では、これらの問題はさらに複雑になることは容易に予想できる。

しかし、出力誤差法に対応する R 形学習形態は、本論文における NN 制御器の実装形態(図 3)と一致しており、式誤差法に対応する F 形学習形態はそれと一致していない。すなわち、F 形学習で学習誤差が低減されても、実装時には必ずしも良好な制御性能は保証されず、一方、R 形学習での学習誤差の低減は良好な制御性能を保証すると考えられる。そこで、さらに周波数領域で両学習法を比較する。まず、式(18)を z 変換すると

$$E_F(z) = (I - z^{-1} \hat{A}_r) X_r(z) - z^{-1} \hat{b}_r \dot{D}(z) \dots \dots \dots (20)$$

を得る。出力誤差に関しては、

$$X(z) = (zI - \hat{A}_r)^{-1} \hat{b}_r \dot{D}(z) \dots \dots \dots (21)$$

の関係を用いると、

$$\begin{aligned} E_R(z) &= X_r(z) - X(z) \\ &= X_r(z) - (zI - \hat{A}_r)^{-1} \hat{b}_r \dot{D}(z) \dots \dots \dots (22) \end{aligned}$$

となる。したがって、式(20), (22)から、次の関係式

を得る。

$$E_F(z) = (I - z^{-1} \hat{A}_r) E_R(z) \dots \dots \dots (23)$$

そこで、参照モデルを近似スカイフックサスペンションとし、さらに $\hat{A}_r \cong A_r$ とすると次式を得る。

$$I - z^{-1} \hat{A}_r \cong \begin{bmatrix} \frac{z-1}{z} & -\frac{T}{z} \\ \frac{k_s T}{mz} & \frac{z + c_s T/m - 1}{z} \end{bmatrix} \dots \dots \dots (24)$$

ここで、 T はサンプリング時間を表す。上式右辺第(1, 1)要素は微分要素であり、第(2, 2)要素は C_s が零でないときは近似微分、受動性によって C_s が零になるときは微分要素となる。このことは、出力誤差に対して式誤差は高周波帯域で評価の重みが大きいことを意味する。したがって、式誤差法を用いた場合、低周波帯域での学習誤差が大きくなる可能性がある。

文献(8)では、ARMAX などの線形入出力モデルを用いた同定法に関して、上述のような誤差モデルと評価関数中の重みの関係を周波数領域で解析している。一般に $(I - z^{-1} \hat{A})$ は周波数特性としてハイパス特性を有することに注意すると、一般の F 形学習同定を行った場合、R 形と比較すると、観測雑音やモデルの低次元化による誤差が大きくなる可能性があることがわかる。なぜなら、しばしば高周波帯域で SN 比が劣化し、またモデルの低次元化の際に高周波モードがしばしば無視されるからである。

3・3 サスペンションの同定

3・2 節で述べた NN 制御器の学習を行うために必要なヤコビアンを計算するための、サスペンションの同定方法について述べる。

制御器に存在する不連続関数を精度良く実現する方法として二つの NN を用いることを提案したが、これは制御対象の同定に関しても適用できる。すなわち、まず図 3 に示すようにダンパ特性と質量・非線形ばね特性を NN で個別に同定することを考え、さらに不連続性を有するダンパモデルに対しては二つの NN を用いる。ただし、ダンパ特性が伸び側と縮み側で対称性を有する場合は、ダンパモデルの NN を一つ削除することができる。NN の学習方法は、制御器の学習と同様に F 形と R 形が考えられ、それぞれの特徴は 3・2 節で考察したとおりである。

ただし、制御器の場合と異なり、F 形学習で得られた NN はヤコビアンの計算の際に F 形と R 形両方の形態が可能である。

4. 数値シミュレーション

4 章では、3 章で提案した NN 制御器の有効性と、

NN の学習に関する考察の妥当性を検証した数値シミュレーション結果を示す。まず、4・1節で非線形サスペンションの同定に関する結果を示し、次に、4・2節で NN 制御器の有効性に関する結果を示す。本シミュレーションでは、車体質量 m を 350 kg とし、制御器の演算時間を 2 ms とした。

4・1 サスペンションの同定 中間層に 10 個、出力層に 2 個のニューロンを持つ 3 層の階層形 NN を用いて、非線形ばね質量系の同定を行った。ただし、ニューロンでの非線形処理は正接シグモイド関数とし、ばねの非線形特性は次式の硬化ばね特性とした。

$$h(x_1) = 23773 \cdot |x_1|^{1.6} \cdot \text{sgn}(x_1) + 10000 \cdot x_1 \quad \dots \dots \dots (25)$$

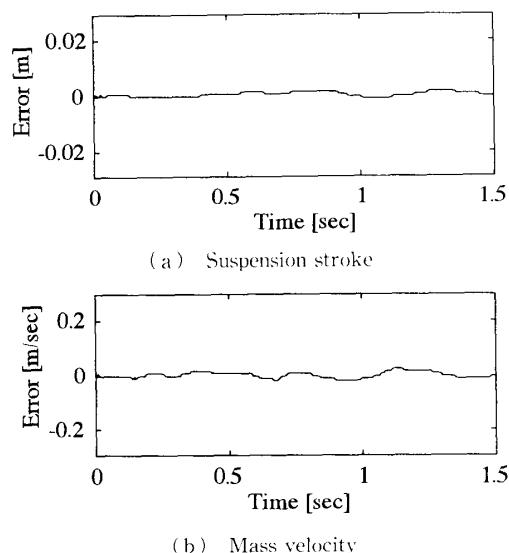


Fig. 7 Estimation error of state variables
(R-type learning)

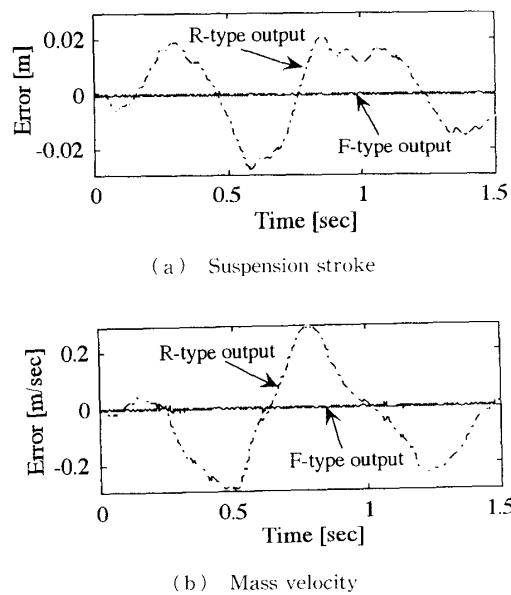


Fig. 8 Estimation error of state variables
(F-type learning)

NN 内の可変パラメータの初期値をランダムに決定すると、特に R 形学習で局所最適解に陥りやすく学習が進まなかった。そこで、局所最適解をできるだけ避けるために、まず線形近似ばね質量系を F 形で学習し、そこで得られたパラメータを初期値とした。このとき、ばね定数 $k = 23300$ [N/m] の線形ばねとして、式(25)を近似した。また、学習では、減衰力、路面変動速度を白色正規性信号とし、観測雑音は SN 比 0.001 の白色正規性信号とした。以下では、状態変数の推定精度とともに、サスペンション同定の本来の目的である式(14)、(16)中のヤコビアンの推定精度も検討した。

まず、R 形、F 形学習での状態変数の推定精度について検討する。図 7 は、R 形学習で得られた NN を R 形形態としたときの状態変数の推定誤差を示している。また、図 8 は F 形学習で得られた NN を R 形および F 形形態で用いたときの状態変数の推定誤差をそれぞれ R-type output, F-type output として示している。図 8 より、F 形学習で得られた NN は、学習形態と同じ F 形形態で用いたときのほうが R 形形態としたときに比べて推定誤差は小さくなっているが、図 7 に示す R 形学習で得られた NN と比べると高周波成分を含んでいることがわかる。図 9 は R 形と F 形学習で得られたそれぞれの NN を R 形形態とした

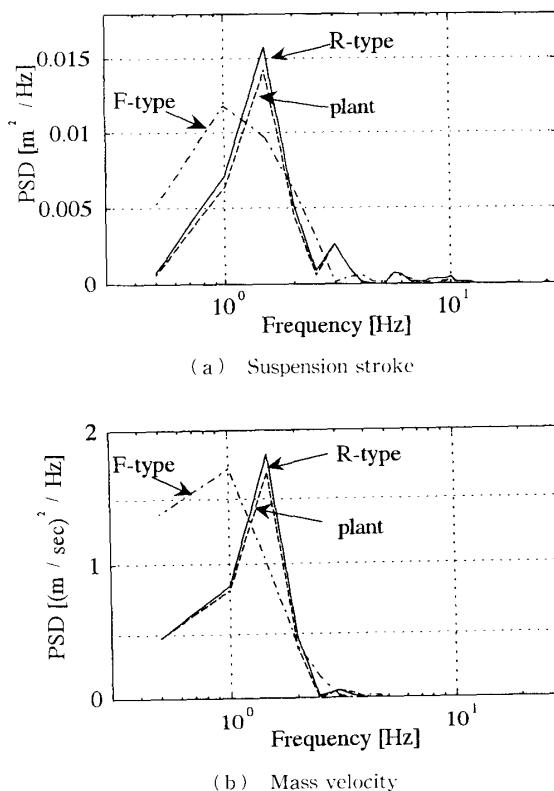


Fig. 9 Power spectral densities for NN emulators
and plant

ときの状態変数と同定対象の状態変数を、パワースペクトル密度で比較したものである。ここで、plantは同定対象から観測されたデータによるスペクトル密度である。図9から、まずR形学習で得られたモデルは、全周波数帯域で良好な推定精度が得られていることがわかる。しかし、F形学習で得られたモデルをR形で用いた場合は、高周波数帯域である程度の推定精度が得られているが、低周波数帯域では推定精度が悪い。このことは、3章での考察と一致している。

次に、R形、F形学習で得られたNNによるヤコビアンの推定精度について検討する。すでに図8で示した状態変数の推定誤差から明らかのように、F形学習で得られたNNをR形で用いた場合、モデルとしての精度は非常に低くヤコビアンの推定精度は著しく低かった。したがって、ここではF形学習で得られたNNをF形形態のまま用いてヤコビアンを推定した結果と、R形学習で得られたNNを用いてヤコビアンを推定した結果を図10に示す。図10から、F形学習ではF形のまま用いているにもかかわらず、学習時の観測雑音の影響によって、極めて振動的であることがわかる。特に、NN制御器の学習で重要なヤコビアンの符号が逆に推定されることが多く、このことがNN制御器の学習に多大な悪影響を与えることは容易に予想できる。

4・2 NN制御器の学習 ERダンパーの特性として、図11に示すようにノミナルな減衰特性をモデル1で、慣性後の減衰特性をモデル2で想定し、サスペンションストローク速度が負の部分の減衰特性は、原点に関して対称性を有するとした。また、ばねは4・1節と同様の特性を有するとし、参照モデルは $c_s = 4039$ [Ns/m] の近似スカイフックダンパー系とした。このとき、図4に示される制御器内の二つのNNは対称性を有することになるので、NNには中間層に8個、出力層に1個のニューロンを持つ3層の階層形NNを共用した。

まず、4・1節と同様に局所最適解を避けるために、ERダンパーのノミナルモデル1と線形近似ばねによって式(10)の制御器を解析的に求め、それをNN制御器に予備学習させた。その後、白色正規性の路面外乱速度に対する参照モデルの状態変数とプラントの状態変数が一致するようにNN制御器を学習させた。

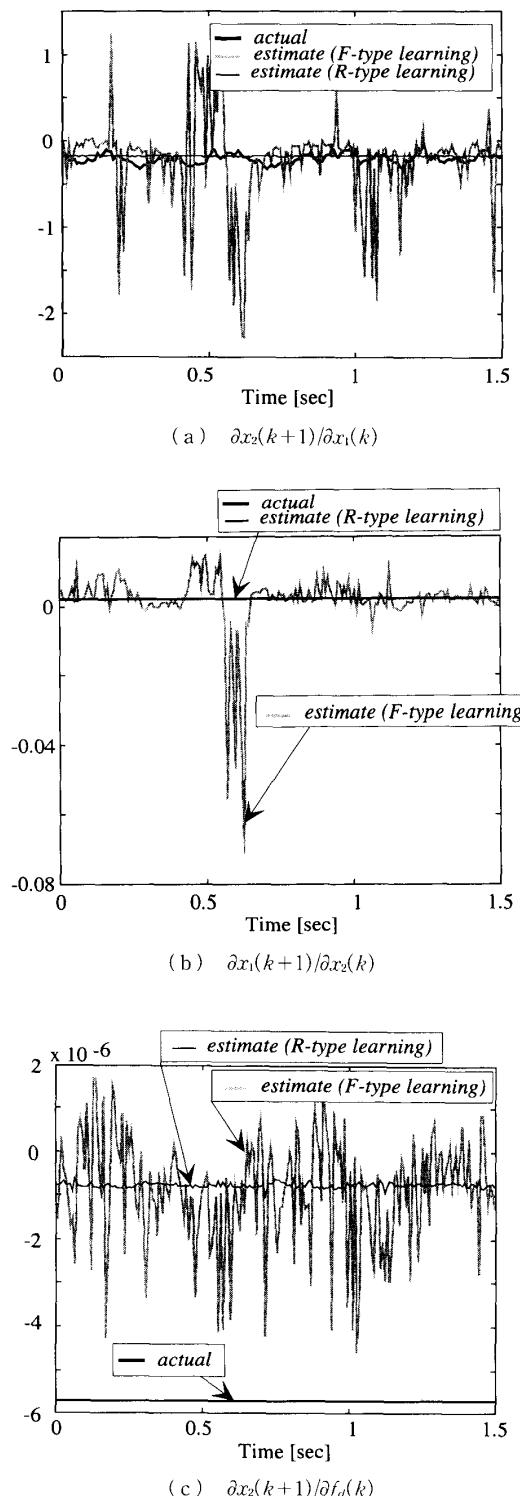


Fig. 10 Jacobians and their estimates

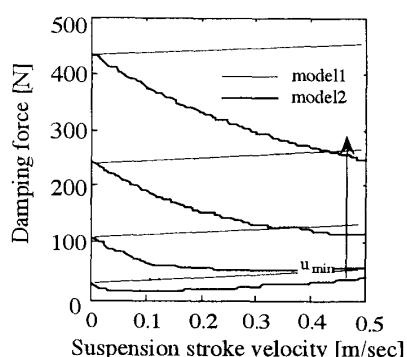


Fig. 11 Characteristics of ER damper

図12は、5種の異なる初期パラメータ値から始めたR形とF形学習の経過を示している。図12からわかるように、F形学習では初期パラメータ値によらずほぼ一定値に誤差が収束しているが、R形学習では予備学習にもかかわらず、局所最適解に陥りやすく学習が進まなかった。このように、R形のNN制御器学習では、非線形な制御対象が介在しているため、学習パラメータに関する非線形性がより強まり、4・1節で言

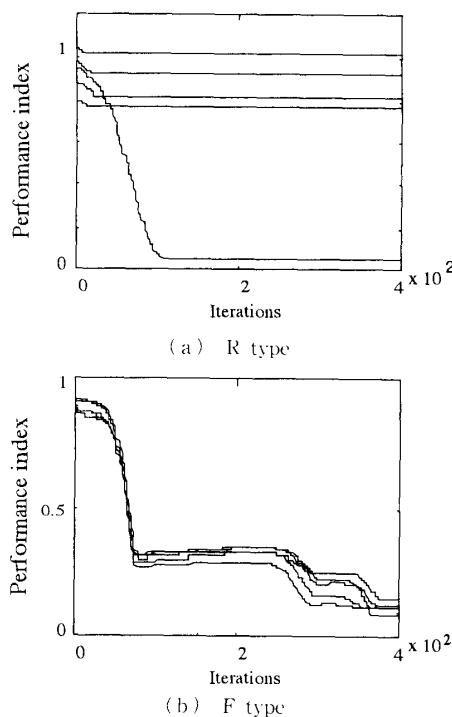


Fig. 12 Performance indexes versus learning iterations

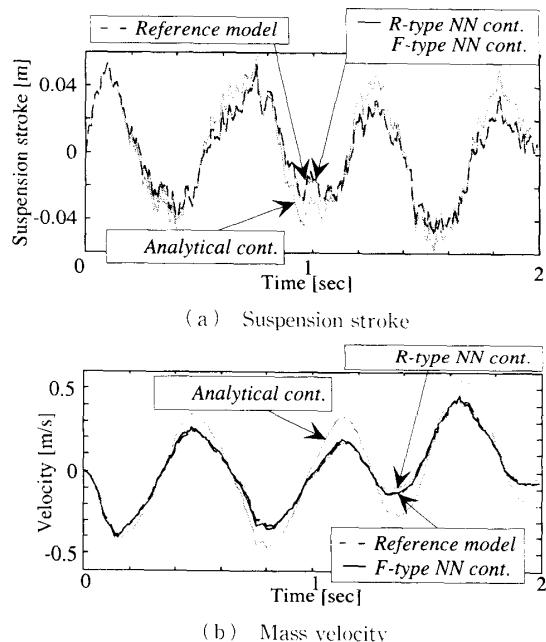


Fig. 13 State variables using NN controllers and analytical controller

及した制御対象の学習同定の場合以上に評価関数の多峰性が深刻な問題となる。

図13は、解析的に得られた式(10)の制御器と、R形およびF形学習で得られたNN制御器をそれぞれ実装したときのプラントと参照モデルの状態変数を示している。図13から、式(10)の制御器ではモデル化誤差によって制振性能が著しく悪いことがわかる。一方、NNを用いた場合には、どちらの学習法で得られた制御器でもモデル化誤差を補償し、参照モデルの状態変数に精度よく追従していることがわかる。ただし、F形学習では、式誤差を十分に低減したにもかかわらず、図14に示すように参照モデルの状態変数に追従していない場合もあった。これは、4・1節のばね質量系の同定の場合とまったく同様に説明することができ、3章の考察と一致する。

まとめると、F形学習では、学習は速やかに履行されるが、車体固有振動数を含む低周波数帯域での制振性能が必ずしも保証されなかった。一方、R形学習では、多峰性による初期値依存性が強く局所最適解となる可能性は高かったが、それを避けることができれば非常に良好な制振性能が得られた。

5. 結 言

非線形特性を有する可変ダンパとばねを用いたセミアクティブサスペンションに対して、NNを応用した制御器設計法を提案した。受動性の制約によって生じる制御器の不連続性の問題を、複数個のNNを用いることで解決した。

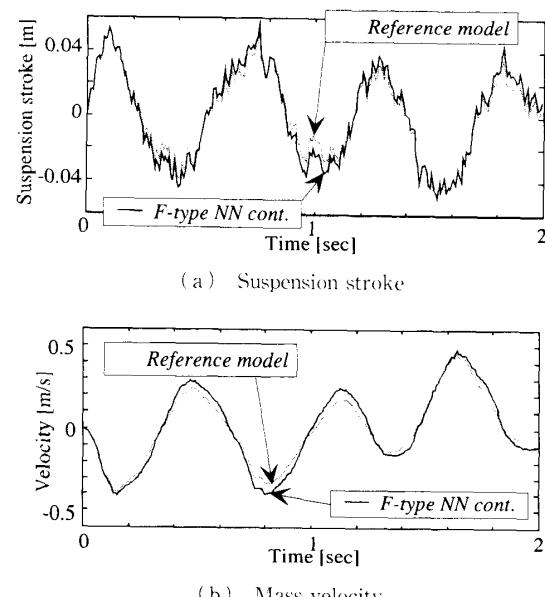


Fig. 14 State variables using a NN controller obtained by F-type learning

また、フィードフォワード形学習とリカレント形学習が、同定論における式誤差法と出力誤差法に対応することを示し、雑音特性などの基本的な特徴を明らかにした。非線形システム同定論においては、それらの誤差法に関する解析は難解でいまだに不十分であるが、線形論を拡張して考えると、フィードフォワード形学習においてその精度を向上させるためには、出入力観測データのプレフィルタリング操作などが有効であることが予想され、現在検討中である。

本論文で提案した制御器において、オフライン学習をオンライン学習に変更し、適応制御器に発展させると、制御対象の変動に対してロバストなシステムが実現できる。ただし、この場合のシステムの安定性に関しては別途議論する必要があり、現在検討中である。

文 献

- (1) 久保康丸, シンポジウム第5回「運動と振動の制御」講演論文集, (1997-11), 345-348.
- (2) 伊藤正剛・前森健一, 機論, **64**-619, C(1998), 767-771.
- (3) 吉田秀久・永井正夫, 機論, **64**-625, C(1998), 3420-3426.
- (4) 芳村敏夫・田坂茂二, 機論, **59**-567, C(1993), 3424-3430.
- (5) 塩塚稔也・江上真弘・ほか2名, 機論, **60**-625, C(1994), 1296-1302.
- (6) Moran, A. and Nagai, M., *JSME Int. J.*, **37**-4, 12(1994), 707-718.
- (7) Narendra, K. S. and Parthasarathy, K., *IEEE Trans. on Neural Networks*, **1**-1(1990), 4-27.
- (8) Ljung, L., *SYSTEM IDENTIFICATION : Theory for User*, (1987), 224-229, Prentice-Hall.