

# ニューラルネットワークを用いたアクティブサスペンションの制御

小机 わかえ<sup>1</sup>・宮地 秀征<sup>1</sup>

<sup>1</sup> 機械工学科

## Control of Vehicle Suspension Using Neural Network

Wakae KOZUKUE<sup>1</sup> and Hideyuki MIYAJI<sup>1</sup>

### Abstract

Holographic neural network, which is new algorithm of neural network, is applied to the control of a vehicle suspension. For the simplified suspension model, using the feedback gain obtained from the optimal control theory, the equation of motion is solved by Runge-Kutta method. The displacement, velocity and control force obtained is adopted as training data for neural network. For simulation the road displacement is assumed to be sinusoidal and its frequency is changed from 1.0Hz to 4.0Hz by 0.1Hz intervals. As the trained network is tested, the results for the road frequency not contained in the training data agree well with the results obtained from the optimal control theory.

Key Words : Optimal Control, Neural Network, Vehicle Suspension.

### 1.はじめに

近年、高速道路の発達とともに、運転者の長時間、長距離運転が盛んに行われるようになってきた。そのために、運転者の疲労を軽減する乗り心地の良い自動車のサスペンションの開発が強く望まれている。自動車のサスペンション制御システムに関しては、電子技術やセンシング技術の発達に伴い、ばねとダンパの値を路面形状に合わせて切り替え制御するパッシブ制御システムの開発が広く行われるようになり、さらに飛躍的な性能向上が見込めるアクティブサスペンションの研究へと進んでいる<sup>①</sup>。

アクティブサスペンションとは次の2つの特徴を有するサスペンションである<sup>②</sup>。

- (1) エネルギーを常時供給し、これを連続的に制御する。
- (2) 各種センサとこれらの信号の演算装置とを有し、いくつかの変数の関数として力を発生する。

現状では、上記システムを実現するには油圧制御方式が有利であり、最近ではサスペンション内に油圧アクチュエータを設け、積極的に車体の制御を行うアクティブサスペンションが市販車に搭載されるようになった。このような制御を行う際には、古典、あるいは現代制御理論に基づいた制御ロジックの適用が必要である。現代制御理論に関しては $H_{\infty}$ 制御理論に基づくトラックのシートサスペンションのアクティブ制御の設計例が見られる。しかし、たとえ各種

の制御理論を用いた制御が可能でも、アクティブサスペンションにおいては、高価なセンサを多数用いる必要があったり、複雑な油圧システムの装着が必要で、その適用は高級車に限られたものになっている。

本研究では車体の上下方向の振動を抑制するためには状態を平衡状態にもどす働きを持つ最適レギュレータが有効と考え、基本となる制御理論として最適レギュレータ理論を用いる。最適レギュレータ理論では状態変数の値がすべて直接測定できるという前提が存在する。しかし、仮に状態変数が測定できなくても、未知の状態変数の値をニューラルネットワーク(NN)により推定することにより、制御を実行する際に必要なセンサの数を節約できる可能性がある。センサの数を節約するために、直接測定できない状態変数を推定する機構の一つがオブザーバであるが、本研究ではオブザーバは使用せず、NNによって未知状態変数の値や制御力を求める。

センサを節約するという上記の目的を達成するための第一歩として、本報ではNNによって最適制御理論の結果を内挿できるかどうかを検討する。またここでは、NNのうちでも特にホログラフィックニューラルネットワーク(HNN)と呼ばれる新しいNNのアルゴリズムを利用するが、従来幅広く用いられてきたバックプロパゲーションニューラルネットワーク(BNN)も比較のために対象とする。

## 2. サスペンションを含む車両のモデル化

最適制御理論による解析に用いたサスペンションを含む車両のモデルを図1に示す。対象とするモデルは大型バスのサスペンションの1/2モデル、すなわち1軸分とする。

以下に図1内の各パラメータの内容を示す。

- $m_1$  : 車軸質量
- $m_2$  : 車体質量
- $k_1$  : タイヤのばね定数
- $k_2$  : サスペンションのばね定数
- $c_1$  : タイヤの減衰係数
- $c_2$  : サスペンションの減衰係数
- $x_1$  : ばね下変位
- $x_2$  : ばね上変位
- $x_0$  : 路面変位
- $u$  : サスペンション制御力




Fig.1 Suspension Model

2.1 運動方程式 図1に示す2自由度系の方程式は以下のように表わせる。

$$m_1 \ddot{x}_1 = c_2(\dot{x}_2 - \dot{x}_1) + k_2(x_2 - x_1) - c_1(\dot{x}_1 - \dot{x}_0) - k_1(x_1 - x_0) - u \quad (1)$$

$$m_2 \ddot{x}_2 = -c_2(\dot{x}_2 - \dot{x}_1) - k_2(x_2 - x_1) + u \quad (2)$$

2.2 路面変位の設定 路面変位としては、ステップ状の段差や不規則な凹凸が考えられるが、本研究では簡単のために正弦波を仮定する。

すなわち、以下のように表わす。

$$x_0 = A \sin \omega t \quad (3)$$

ここで、振幅  $A = 0.1$  (m),  $\omega = 2.0\pi - 8.0\pi$  とする。

2.3 状態方程式 式(1)、(2)で表わされる運動方程式から、以下のような状態方程式を得る。

$$\dot{x}(t) = A x(t) + B u(t) + D w(t) \quad (4)$$

$$\dot{x}_2(t) = C x(t) \quad (5)$$

$$x(t) = [x_1 \ x_2 \ \dot{x}_1 \ \dot{x}_2]^T \quad (6)$$

$$w(t) = [x_0 \ \dot{x}_0]^T \quad (7)$$

ここで、行列  $A$ ,  $B$ ,  $C$ ,  $D$  は以下の通りである。

$$A = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -\frac{k_1+k_2}{m_1} & \frac{k_2}{m_1} & -\frac{c_1+c_2}{m_1} & \frac{c_2}{m_1} \\ \frac{k_2}{m_1} & -\frac{k_2}{m_2} & \frac{c_2}{m_2} & -\frac{c_2}{m_2} \end{bmatrix} \quad (8)$$

$$B = [0 \ 0 \ -\frac{1}{m_1} \ \frac{1}{m_2}]^T \quad (9)$$

$$C = [0 \ 0 \ 0 \ 1] \quad (10)$$

$$D = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ \frac{k_1}{m_1} & \frac{c_1}{m_1} \\ 0 & 0 \end{bmatrix} \quad (11)$$

## 3. 最適制御理論の適用

3.1 評価関数の設定 ここでは、状態変数である車軸の絶対変位  $x_1$ 、車軸の絶対速度  $\dot{x}_1$ 、車体の絶対変位  $x_2$ 、車体の絶対速度  $\dot{x}_2$  の合計4個の変数をそれぞれ自乗した値に適切な重み係数を乗じて加え合わせたものを目的関数とする。また、制御エネルギーが過大にならないように、制御入力  $u$  の自乗値に適切な重み係数を乗じたものを制約条件と

する。これより、評価関数を以下のように設定した。

$$J = \int_0^{\infty} (q_1 x_1^2 + q_2 x_2^2 + q_3 \dot{x}_1^2 + q_4 \dot{x}_2^2 + r u^2) dt \quad (12)$$

これを状態ベクトル $Y$ を用いて二次形式の評価関数に書き直すと以下ようになる。

$$J = \int_0^{\infty} (Y^T Q Y + r u^2) dt \quad (13)$$

ここで $Q$ は各変数に対応した重み係数を要素として持つ対称行列であり、 $r$ は制御入力にかかる重み係数を表す。

3.2 最適制御理論 式(13)の評価関数を最小にする最適制御則 $u^0$ は以下のように表わされる。

$$u^0 = -F Y \quad (14)$$

$$F = r^{-1} B^T P \quad (15)$$

ただし、 $P$ は次のリカッチ型代数方程式の一意正定解である。

$$P A + A^T P - r_0^{-1} P B B^T P + Q = 0 \quad (16)$$

3.3 離散時間系での最適制御理論 本制御系を離散時間系で定式化するために、連続系の評価関数を離散化し、離散時間系の最適制御理論に基づいて最適制御則を求める。

式(13)で表わされる連続系の評価関数と等価な離散時間系の評価関数は次のように表わされる。

$$J = \sum_{i=0}^{\infty} [Y(i)^T Q_d Y(i) + 2 Y(i)^T S_d u(i) + r_d u(i)^2] \quad (17)$$

ここで、 $Q_d$ 、 $S_d$ 、 $r_d$ はサンプリング時間 $T$ と連続系の重み係数 $Q$ 、 $r$ 、状態方程式における $A$ 、 $B$ を用いて次のように表わされる。

$$Q_d = \int_0^T [\Phi^T Q \Phi] d\tau \quad (18)$$

$$S_d = \int_0^T [\Gamma^T Q \Phi] d\tau \quad (19)$$

$$r_d = \int_0^T [\Gamma^T Q \Gamma + r_0] d\tau \quad (20)$$

$$\Phi(\tau) = \exp(A \tau) \quad (21)$$

$$\Gamma(\tau) = \int_0^T [\exp(A t)] dt \cdot B \quad (22)$$

離散時間系の評価関数である式(16)を最小にする最適制御則は次のように求められる。

$$u^0(i) = -F_d Y(i) \quad (23)$$

$$F_d = r_d^{-1} S_d + (r_d + b_d^T M b_d)^{-1} b_d^T M (A_d - r_d^{-1} B_d S_d) \quad (24)$$

ここで行列 $M$ は次の離散型リカッチ方程式の正定対称解である。

$$M = Q_d - r_d^{-1} S_d^T S_d + [A_d - r_d^{-1} B_d S_d]^T M [A_d - r_d^{-1} B_d S_d] - [A_d - r_d^{-1} B_d S_d]^T M B_d [r_d + B_d^T M B_d]^{-1} B_d M [A_d - r_d^{-1} B_d S_d] \quad (25)$$

本研究において、離散時間系のフィードバックゲイン $F_d$ を求めるにあたっては、MATLAB CONTROL SYSTEM TOOLBOX lqrdを使用した。

#### 4. ホログラフィックニューラルネットワーク(HNN)の概要<sup>(9)</sup>

HNNはSutherland<sup>(9)</sup>によって開発されたNNで、その最大の特徴は、入力データと出力データを複素平面上に均一に写像することによって、両者の間に線形関係を持たせていることである。HNNではニューロンの数は1個であり、NNの構築は、入力と出力の間の伝達関数を求めることに等しい。そのため、計算が収束するまでの時間を大幅に短縮することが可能となる。

学習に $l$ 組の $m$ 次元入力ベクトル $s$ と $n$ 次元出力ベクトル $r$ を用いるとする。入出力ベクトルの各要素は、非線形変換関数により、複素平面上に変換される。

$$f(s_{hk}) = \lambda_{hk} e^{i\theta_{hk}} \quad (26)$$

$$g(r_{jk}) = \gamma_{jk} e^{i\phi_{jk}} \quad (27)$$

ここで、 $i$ は虚数単位、 $\theta_{hk}$ 、 $\phi_{jk}$ はシグモイド関数のような写像関数により、変換される位相角度で区間 $[0, 2\pi)$ の値を持つ。 $\lambda_{hk}$ 、 $\gamma_{jk}$ は入出力データが、対応する位相角領域に出現する確率を示し、区間 $[0, 1]$ の値を持つ。以上の式(26)、(27)の操作により次のような入力行列 $[S]$ 、教師行列 $[T]$ が得られる。

$$[S] = \begin{bmatrix} \lambda_{11} e^{i\theta_{11}} & \lambda_{12} e^{i\theta_{12}} & \dots & \lambda_{1m} e^{i\theta_{1m}} \\ \lambda_{21} e^{i\theta_{21}} & \lambda_{22} e^{i\theta_{22}} & \dots & \lambda_{2m} e^{i\theta_{2m}} \\ \vdots & \vdots & & \vdots \\ \lambda_{l1} e^{i\theta_{l1}} & \lambda_{l2} e^{i\theta_{l2}} & \dots & \lambda_{lm} e^{i\theta_{lm}} \end{bmatrix} \quad (28)$$

$$[T] = \begin{bmatrix} \gamma_{11} e^{i\phi_{11}} & \gamma_{12} e^{i\phi_{12}} & \dots & \gamma_{1n} e^{i\phi_{1n}} \\ \gamma_{21} e^{i\phi_{21}} & \gamma_{22} e^{i\phi_{22}} & \dots & \gamma_{2n} e^{i\phi_{2n}} \\ \vdots & \vdots & & \vdots \\ \gamma_{l1} e^{i\phi_{l1}} & \gamma_{l2} e^{i\phi_{l2}} & \dots & \gamma_{ln} e^{i\phi_{ln}} \end{bmatrix} \quad (29)$$

出力行列 $[A]$ は、伝達関数 $[X]$ を用いて、次式のように表わされる。

$$[A] = [S] \cdot [X] \quad (30)$$

$[X]$ は、次式に表わされる $[A]$ と $[T]$ との差が最小となるように決定される。

$$E_{rr} = ([A] - [T])^H \cdot ([A] - [T]) \quad (31)$$

ここで、 $H$ は共役転置を表わす。この条件より、次式が得られる。

$$[X] = ([S]^H \cdot [S])^{-1} \cdot [S]^H \cdot [T] \quad (32)$$

$[S]$ 、 $[T]$ は既知であるので、 $[X]$ は式(7)により直接求まる。しかし、Gauss-Jordan消去法で $n$ 次の行列の逆行列を求める場合、その演算回数は $n^3$ 回となるので、 $[S]$ が高次元になると演算に膨大な時間が必要となる。そこで、これを避けるため、次式の反復学習により $[X]$ を求める。

$$[X]_i = \frac{1}{E} [S]^H \cdot [T] \quad (33.a)$$

$$[X]_{i+1} = [X]_i + [S]^H \cdot \left( [T] - \frac{1}{E} [S] \cdot [X]_i \right) \quad (33.b)$$

ここで $E$ は $[X]$ のノルムを正規化するパラメータである。伝達関数 $[X]$ の収束を速くするためには、入力ベクトルを複素平面上に均一に変換することが望ましい。このため、変換関数には、次のような形を持つシグモイド関数などが用いられる。

$$\theta_k = \frac{2\pi}{1 + e^{(\mu - s_k)/\sigma}} \quad (34)$$

ここで、 $s_k$ は入力、 $\mu$ 、 $\sigma$ は、パラメータである。

#### 5.NNの学習データの作成

3.で述べた最適制御則から得られるフィードバックゲインを求める。それを用いて、4次精度のルンゲクッタ法を使用して運動方程式を解く。使用したパラメータの値を以下に示す。これらの値は大型バスのサスペンションの1/2モデルにたいする値である。

$$k_1 = 1.8 \times 10^5 [N/m]$$

$$c_1 = 0.56 \times 10^4 [N s/m]$$

$$k_2 = 2.2 \times 10^5 [N/m]$$

$$c_2 = 2.044 \times 10^4 [N s/m]$$

$$m_1 = 770 [kg]$$

$$m_2 = 5950 [kg]$$

また、路面変位の振動数は以下の範囲に設定した。

$$f = 1.0 (Hz) - 4.0 (Hz)$$

まず5秒間、正弦波状の路面変位を与え、サンプリング時間0.01秒毎に、路面、車軸、車体の上下方向の絶対速度と絶対変位、及び制御力の値を求める。路面の周波数が2.5 Hzの時の車体の速度が、制御をかけた時に20%減少するように最適制御の重み係数を決定する。決定した重み係数の値は以下の通りである。 $u$ にかかる重み係数は $r = 10^{-5.4}$ 、変位 $x_1$ にかかる重み係数は $q_1 = 10^{-5}$ 、変位 $x_2$ にかかる重

み係数は $q_2 = 10^5$ 、速度 $\dot{x}_1$ にかかる重み係数は $q_3 = 10^{-5}$ 、速度 $\dot{x}_2$ にかかる重み係数は $q_4 = 10^5$ である。

N.N.を用いて、上記で得られたデータを次のように学習させる。すなわち、ある時刻 $k$ での、次の6つの状態変数と制御力

$$x_0(k), x_1(k), x_2(k), \dot{x}_0(k), \dot{x}_1(k), \dot{x}_2(k), u(k)$$

を入力とし、次の時刻 $k+1$ での、次の3つの状態変数

$$x_2(k+1), \dot{x}_2(k+1), u(k+1)$$

を出力とする。これは、状態 $k$ から、次の状態 $k+1$ の状態変数を予測することに対応している。

実際には、上記の数値シミュレーションで得た、路面周波数1.0-4.0 Hz間を0.1 Hz間隔で刻んだ計31個の路面状況におけるデータを1つの学習データとして編集する。編集に際しては、各路面周波数において、出力変数の1つである車体速度 $\dot{x}_2$ を基準に約2周期分のデータを抜きだし、それらを路面周波数が小さい順に合成した。

また、HNNで用いる各パラメータの値を以下のような手順で設定した。入出力データにたいしては、各々3種類の変換方法がある。すなわち入力データについてはDDF、Sigmoid、Linearがあり、出力データについてはReal、Sigmoid、Linearがある。これらの組み合わせで、9通りの変換方法がある。各変換方法で学習データを5回学習させ、最も誤差が少なく学習状態の良い変換方法を選択する。ここでは、入力変換としてはDDF、出力変換としてはRealを採用した。これらの変換方法の詳細を述べることは、ここでは省略する。

#### 6.H.N.Nによる解析結果

まず、制御をかけない場合のバッシブサスペンションの解析を行い、次に制御をかけた場合の解析を行った。両者で得られた車体の速度の時刻歴の比較を図2に示す。これらの解析で得られたデータをH.N.Nに学習させ、出力である車体の絶対速度 $\dot{x}_2$ 、絶対変位 $x_2$ 、制御力 $u$ の時刻歴を求め、対応する最適制御の解析結果と比較した。N.N.に与えるテストデータとしては、路面周波数1.0-4.0 Hzの中から、学習データとして使用されていない適当な周波数の路面変位を選んだ。

図3に路面変位の周波数1.45Hzに対するバッシブ状態の車体の速度、変位の比較結果を示す。また、図4に同一周波数に対するアクティブ制御状態の車体の変位、速度、制御力の比較結果を示す。いずれも、最適制御理論から得られた値とN.N.より得られた値は良く一致している。これにより、学習されていない周波数の路面に対しても、状態変数の値を得ることができることがわかる。

H.N.N.によって、最適制御理論により得られた状態変数や制御力の値に近い値を得るためには、学習データを作成する際に、路面周波数を0.1Hzごとに細かく設定する必要が

あった。また、H.N.Nにおける学習誤差が小さい値になれば、テスト結果の精度も向上する。そのために、5.で述べたように、H.N.Nにおける各種のパラメータの設定方法を最適にする必要もあった。

7.階層型ニューラルネットワークによる解析結果

従来から、最もよく採用されてきたバックプロパゲーションアルゴリズムを用いた3層の階層型ニューラルネットワークに、6.と同様に、5.で得られたデータを学習させた。入力ノードの数は、制御ありのとき7、制御なしのとき6、出力ノードの数は、制御ありのとき3、制御なしのとき2、中間層のノードの数は、制御あり、制御なしのとき、いずれも10と設定した。誤差評価関数のしきい値としては、0.1%を用いた。

図5に本方法により求めた、制御ありのときのテスト結果である車体の速度の時刻歴を示す。最適制御理論の結果と、N.N.のテスト結果はかなり異なっており、本方法による内挿は精度が良くないことを示している。




Fig.3(b) Analysis results for passive control for road frequency 1.45 Hz (absolute displacement of the body)




Fig.2 Absolute velocity of the body for passive and active control




Fig.4(a) Analysis results for active control for road frequency 1.45 Hz (absolute velocity of the body)




Fig.3(a) Analysis results for passive control for road frequency 1.45 Hz (absolute velocity of the body)




Fig.4(b) Analysis results for active control for road frequency 1.45 Hz (absolute displacement of the body)

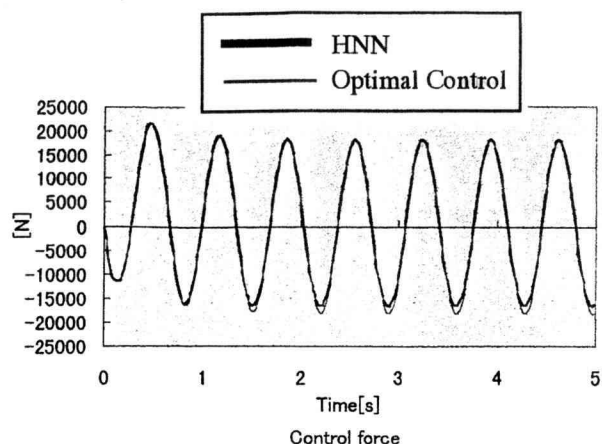


Fig.4(c) Analysis results for active control for road frequency 1.45 Hz (control force)

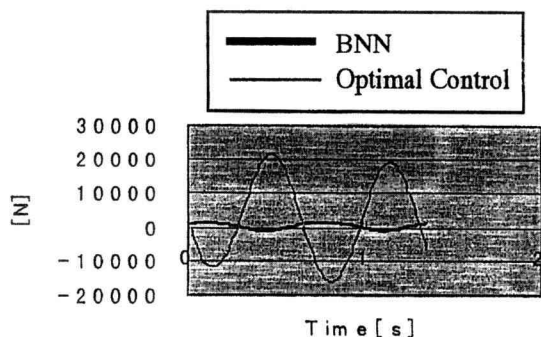


Fig.5(a) Analysis results for active control for road frequency 1.5 Hz (absolute velocity of the body)

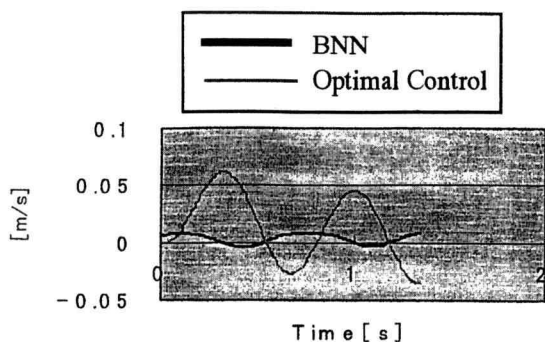


Fig.5(b) Analysis results for active control for road frequency 1.5 Hz (absolute displacement of the body)




Fig.5(c) Analysis results for active control for road frequency 1.5 Hz (control force)

#### 8.まとめと今後の課題

新しいニューラルネットワークのアルゴリズムであるホログラフィックニューラルネットワーク(H.N.N)、及び従来から広く用いられているバックプロパゲーション(B.P)アルゴリズムに基づく階層型ニューラルネットワークを、車両のサスペンションのアクティブ制御に適用した。H.N.Nについては学習データを注意深く作成することにより、最適制御理論で得られる状態変数と制御力の値を高精度で補間できる可能性を得た。階層型ニューラルネットワークについては、満足できる精度で内挿することはできなかった。

今後は、正弦波では表わすことができない不規則な路面や、より詳細なサスペンションモデルを対象に、H.N.Nが精度良く最適制御理論を近似できるかどうかを検討する必要がある。さらに、学習データを適切に作成することにより、車両に搭載するセンサの数の節約がどの程度可能かを検討する必要がある。また、実際の車両のサスペンションに実装できるかどうか調査することも今後の課題として挙げられる。

#### 参考文献

- (1)芳村、田坂、ニューラルネットワークを用いたピークルのアクティブサスペンションの設計、日本機械学会論文集(C編)、59巻567号(1993-11)、pp. 3424 - 3430.
- (2)永井、アクティブサスペンションの制御と制御理論、計測と制御 第32巻 第4号(1993-4)、pp. 290 - 295.
- (3)福島 他4名、油圧アクティブサスペンションによる車両の振動制御、日本機械学会論文集(C編)、57巻535号(1991-3)、pp. 722 - 736.
- (4)J.G.Sutherland, "The Holographic Model of Memory, Learning and Expression", International Journal of Neural Systems, 1990, Vol.1 No.3, pp. 259 - 267.
- (5)MATLAB Control System Toolbox User's Guide (The Math Works Inc.)
- (6)カヤバ工業(株)編、自動車のサスペンション、山海堂(1992)
- (7)下郷他3名、トラックシートのアクティブサスペンション、日本機械学会論文集(C編)、62巻600号(1996-8)、pp. 3132 - 3138.