路面の特性変化に対応可能なアクティブステアリングのための
非線形ニューロ制御*志村明彦^{*1}, 吉田和夫^{*2}

Non-Linear Neuro Control for Active Steering for Various Road Condition

Akihiko SHIMURA and Kazuo YOSHIDA^{*3}^{*3} Keio University, Graduate School of Science and Technology,
Hiyoshi 3-14-1, Kohoku-ku, Yokohama-shi, Kanagawa, 223-8522 Japan

To develop a front steering control system, a nonlinear steering control law is necessary, since the dynamical characteristics of cars are nonlinear at the situation of large side slip angle and high yaw rate. The robustness to change of friction coefficient μ is required on the controller. In this study, an intelligent control of front steering wheel is presented. The controller consists of two neural network controllers for specific μ and an integrator under the Cubic Neural Network (CNN) architecture. The neural networks are designed with error backpropagation learning. By using the CNN architecture, the controller can adapt to various values of μ . The effectiveness and the feasibility of the present active steering method are demonstrated by numerical simulation of simple 7 DOF model and DADS full vehicle model.

Key Words: Automobile, Nonlinear Control, Neural Network, Steering Control, Cubic Neural Network

1. 緒言

車両の運動制御技術は当初は俊敏な機動の実現を目的としていたが、近年では予防安全に主眼が移ってきている。当初はアクティブ制御に対する信頼感がさほど高くなかったため、微小角の後輪操舵による4輪操舵(4WS)⁽¹⁾に始まった車両運動のアクティブ制御であるが、アクティブ制御に対する信頼感の醸成や期待の増大により、次第により積極的に活用されるようになってきた。特に、DYC(Direct Yaw Moment Control)技術^(2,3)は高い評価を得ている。現行のDYCは駆動力制御を用いるものであるが、一般に車両は縦長であるため単にヨーモーメントを発生させるだけなら舵角を制御したほうが大きいヨーモーメントが得られる。車体の横滑り角は後輪の横力に支配される⁽⁴⁾ため、前輪操舵制御のみでできることには限りがあるが、電動パワーステアリングの普及が進めばその機構を利用できること、アクティブブレーキのようにエネルギー損失やブレーキパッドの消耗が発生しないこと等のメリットもあるため、前輪操舵制御が一部において検討されつつある。

車両の操舵制御に限らず制御系を組む場合には制御則

を決定する必要がある。既に実用化された後輪操舵制御⁽⁵⁾では、ヨー角速度遅れ補償や車体横すべりゼロ化制御が用いられたが、前輪の操舵制御は未開拓の分野であり、新しい制御則の開拓が必要である。一方、非線形写像獲得能力を持つニューラルネットワーク(Neural Network:以下、NN)は制御器としての利用価値が高く、また制御則の探索法としても有力な手段である。また、NN制御器を複数組み合わせ、知的情報処理の枠組みを導入した制御系⁽⁶⁾も提案されており、制御対象の変動に対応した制御系が構成できる。

そこで本研究では、前輪操舵制御により、線形に近くスピンやコースアウト等の破綻をしにくい特性を実現するNN制御器に知的制御の一手法であるCubic Neural Network(以下、CNN)を導入することにより、様々な状況に対応可能な統合前輪操舵制御器の構築を行う。また、同制御器の有効性について機構解析言語により全車両モデルを構成し検討を行う。

2. 設計手法

車両の動特性は特に高ヨー角速度、大横すべり角領域において非線形であるため、線形制御理論では高ヨー角速度、大横すべり角領域にまで有効な制御器の設計を行うことができない。しかし、一般のドライバでは対処不能である同領域こそが、制御による破滅回避が期待される領域である。また、同領域における車両の特性は路面-タイヤ間の摩擦係数の値(以下、 μ)によって大きく左右されるため、様々な μ に対応できる制御器が求めら

* 原稿受付 2000年3月31日。

*¹ 正員、慶應義塾大学大学院(〒223-8522 横浜市港北区日吉3-14-1)。*² 正員、慶應義塾大学理工学部。

E-mail: yoshida@sd.keio.ac.jp

れる。そこで本研究では、高い μ 、低い μ それぞれにおいて設計した制御器⁽⁷⁾で知的制御の枠組みとして提案されているCNNを構成することにより、様々な μ に対応可能なNN前輪操舵制御器を導出する。

2・1 設計用車両モデル 制御器の設計および数値シミュレーションに用いる車両モデルは、単純な4輪、2WS、車体3自由度、各車輪1自由度の計7自由度のモデルであり、車体のロール、ピッチ、荷重移動は考えない。車両モデルの諸元を表1に、構成を図1に示す。諸元は小型SUVのものであり、カタログ等を参考に設定した。路面-タイヤ間力モデルはマジックフォーミュラ⁽⁸⁾である。マジックフォーミュラはタイヤの前後力、横力およびセルフアライニングトルクを横すべり角とスリップ比の調和関数で表現した関数近似型のタイヤモデルであり、駆動力と横力の連成を考慮できる非線形モデルであるが、本研究では、各車輪には駆動力および制動力はかからず、

Table 1 Specifications of Car Model

Body Mass	1470 kg
Body Yaw moment of Inertia	1850 kg m ²
Distance from Front Axle to G.C.	1.01 m
Distance from Rear Axle to G.C.	1.19 m
Tread	1.46 m
Time Constant of Steering Angle	0.02 sec
Cornering Power -Front-	54,500 N/rad
-Rear-	49,100 N/rad

Fig. 1 7DOF Vehicle Model

Fig. 2 Scheme of Forward Inverse Learning

Fig. 3 Characteristics of Side Slip Angle and Side Force

Fig. 4 Symmetric Double Sigmoidal Output Function

空転状態であるものとしている。また、セルフアライニングトルクは無視できるものとしている。マジックフォーミュラの各パラメータは195/65R15-6Jのもの⁽⁹⁾である。

2・2 単一 μ 対応制御器の設計 前輪操舵制御により、滑りやすい条件である μ が0.4の場合、通常の条件である μ が0.8の場合条件、それぞれにおいて線形に近い特性を持つ領域を拡大し操縦を容易化する制御器を順逆モデル法^(9,10)を用いて設計する。図2に順逆モデル法の学習スキームを示す。制御対象の動特性をシステムNNに獲得しておき、システムNNを通して誤差逆伝播することにより、所要の特性を実現するNN制御器を学習する手法であり、NN制御器の設計法としては基本的なものであるが、制御後の特性を与えて学習できるということと、誤差逆伝播法で安定した学習が行えるという利点がある。

2・2・1 システムNNの学習 NN制御器を学習させる誤差信号はシステムNNを経由してNN制御器に伝播されるため、システムNNの精度はNN制御器の性能に大きく影響する。そこで、制御対象である車両の動特性を考慮したシステムNNの入出力、構造および学習方法を用いシステムNNの精度の向上を図ることを考える。

そのため、最も単純な車両の動解析モデルである等価2車輪車両モデル⁽¹¹⁾を参考にシステムNNの入出力を検討することとする。同モデルの運動方程式を式(1)に示す。ここで、 β , r , m , I , v , l_f , l_r および δ_f はそれぞれ横すべり角、ヨー角速度、車両質量、車両ヨー慣性モーメント、車速、前車軸-重心点間距離、後車軸-重心点間距離および操舵角である。また $f(x)$ は横すべり角に対する路面-タイヤ間横力の特性である。

$$mv \left(\frac{d\beta}{dt} + r \right) = 2 \left(f \left(\beta + \frac{l_f}{v} - \delta_f \right) \right) + 2 \left(f \left(\beta - \frac{l_r}{v} \right) \right) \quad \dots\dots(1)$$

$$I \frac{dr}{dt} = 2l_f \left(f \left(\beta + \frac{l_f}{v} - \delta_f \right) \right) - 2l_r \left(f \left(\beta - \frac{l_r}{v} \right) \right)$$

横すべり角に対する路面-タイヤ間力は一般に図3に示すような特性であり、横すべり角が小さい領域ではほぼ線形であるが、横すべり角が大きくなるにつれて非線形性を増す。そのため、車両の運動特性は直進状態近傍では線形である。したがって、システムNNの出力に同モデルの状態量である横すべり角およびヨー角速度の時間変化率の2個を、入力に同モデルの運動方程式中の項の7個を用いれば、直進状態近傍の運動特性は線形の隠れ層ノード2個のみで獲得することが可能である。また、横すべり角の増大につれて増大する非線形性は、車両の運動が左右方向に対して対称であることも考え合わせると、一般によく用いられるシグモイド出力関数を図4に示すように2個対称に組み合わせた対称複シグモイド(以下、

SDS) 出力関数を隠れ層に用いることで獲得可能である。

そこで、システムNNの隠れ層を線形領域の特性を獲得する線形出力関数ノードと、非線形性を獲得するSDS出力関数ノードとで構成し、まず線形領域の学習を行った後に非線形性の学習を行うこととする。図5(a)にシステムNNの構造を示す。入力層、隠れ層、出力層のノード数はそれぞれ7個(他に、オフセットのための定数入力ノード1個)、線形ノード2個およびSDSノード7個、2個である。システムNNの入力ベクトル、出力ベクトルを(2)式に示す。

$$I_{SNN} = [\beta \quad r \quad \delta_f \quad \beta/v \quad r/v \quad \delta_f/v \quad r/v^2]^T \quad \dots\dots\dots(2)$$

$$O_{SNN} = [\dot{\beta} \quad \dot{r}]^T$$

表2にシステムNNの学習条件の範囲を示す。隠れ層の線形ノードに関する重みの学習は車両が線形に近い挙動を示す直進近傍の領域において行う。教師信号は学習条件のすべての組み合わせに対し、(1)式の車両モデルの微分方程式により作成する。隠れ層のSDSノードに関する重みの学習も同様であるが、非線形領域の特性を学習するため、より広い範囲の学習条件において行う。

2・2・2 NN制御器の学習 NN制御器にはシステ

ムNNと同様の理由から隠れ層にSDS出力関数を、出力層に線形出力関数を用いる。図5(b)にNN制御器の構造を示す。入力層、隠れ層、出力層のノード数はそれぞれ7個(他に、オフセットのための定数入力ノード1個)、14個、1個である。入力ベクトルはシステムNNと同じであり、出力はドライバからの操舵入力を加減する前輪操舵角補正值である。

学習は、NN制御器の出力がシステムNNに入力される状態、すなわちNN制御器が車両を制御している状態で行い、教師信号は表2の学習条件のすべての組み合わせについて等価2車輪モデルで路面-タイヤ間横力が横すべり角に比例するものとした線形モデルにより作成し、制御された車両が線形に近い応答を示すように学習を行う。このとき、極端に横すべり角やヨー角速度が大きい領域では、どのような操舵を行っても制御できないと考えられるので、そのような領域は学習条件から外すこととし、システムNNよりは若干狭い範囲で学習を行う。このように、学習条件すべての組み合わせで制御器を学習する方法は、すべての状態を網羅でき、想定範囲内では破綻することのない制御則が得られるが、学習条件が増えると教師信号のサンプル数が非常に多くなる。

Fig. 5 Structure of NNs

Table 2 Learning Condition of System NN and NN Controller

	Velocity [m/s]	Side Slip Angle [rad]	Yaw Rate [rad/sec]	Steering Angle [rad]
System NN Linear Section	12 24	± 0.018 ± 0.009 0	± 0.09 ± 0.03	± 0.0075 ± 0.003 0
System NN SDS Section (a=1)	$\mu=0.4: 12$ 18 $\mu=0.6: 14$ 21	$\pm 0.2 \times \mu \times a$ $\pm 0.1 \times \mu \times a$ $\pm 0.05 \times \mu \times a$	$\pm 1.0 \times \mu \times a$ $\pm 0.6 \times \mu \times a$ $\pm 0.2 \times \mu \times a$	$\pm 0.2 \times \mu \times a$ $\pm 0.1 \times \mu \times a$ $\pm 0.05 \times \mu \times a$ 0
NN controller for specific μ (a=0.6)	$\mu=0.8: 16$ 24	0	$\pm 0.2 \times \mu \times a$	0

Fig. 6 Structure of CNN

Table 3 Learning Condition of Integrator

μ	Velocity [m/s]	Side Slip Angle [rad]	Yaw Rate [rad/sec]	Steering Angle [rad]
0.4	$\mu=0.4: 12, 18$	$\pm 0.12 \times \mu$	$\pm 0.6 \times \mu$	$\pm 0.2 \times \mu$
0.6	$\mu=0.6: 14, 21$	$\pm 0.06 \times \mu$	$\pm 0.36 \times \mu$	$\pm 0.1 \times \mu$
0.8	$\mu=0.8: 16, 24$	0	$\pm 0.12 \times \mu$	0

2.3 CNNの設計 上記のように、単一の μ においてそれぞれNN制御器を設計するが、これらはフィードフォワード制御器であり、制御対象すなわち路面状況を含む車両の変動には対応できない。そこで、この2つの制御NNをCNNにより統合することにより、様々な μ に対応できるCNN統合制御器を構成する。

2.3.1 CNNの構成 図6にCNNの構成を示す。CNNは大きく分けて特定の状況に対応する複数のNN制御器と、それらを統合するNNであるインテグレータから構成される。各制御器はそれぞれの設計時に想定したシステムNNを並列に持ち、その出力と制御対象の応答との差をとることにより、制御対象と設計時の想定モデルとの差を自己評価し出力する。インテグレータは、各NN制御器の評価結果、現在の制御対象の状態から、CNN統合制御器全体としての出力を行う。各NN制御器は特定状況で設計されるが、複数のNN制御器を並列に用意し、その制御結果を評価しながら統合するため、インテグレータの学習条件に含めれば、各NN制御器の想定外の状況にもある程度の対応が可能である。

本制御器では、 μ が0.4および0.8の場合に対応するNN制御器をインテグレータを用いて統合することにより、様々な μ に対応できるCNN統合制御器を構成する。各NN制御器を順逆モデル法で設計しているため、システムNNは学習用に用いたものが使用できる。本制御器では、インテグレータは直接制御信号を出力するのではなく、各NN制御器の出力の混合比を出力するものとする。インテグレータの出力が1の場合には μ が0.8の場合に対応するNN制御器の出力が選択され、-1の場合には μ が0.4の場合に対応するNN制御器の出力が選択されるものとする。また、インテグレータの出力は-1.2から1.2の範囲とする。(3)式にインテグレータの入力ベクトルを示す。ここで $\dot{\beta}_{SNN04}$ 、 $\dot{\beta}_{SNN08}$ 、 $\dot{r}_{SNN04}$ および $\dot{r}_{SNN08}$ はそれぞれシステムNNの出力である。

$$I_I = \begin{bmatrix} I_{SNN}^T & \frac{2(\dot{\beta} - \dot{\beta}_{SNN04})}{(\dot{\beta}_{SNN08} - \dot{\beta}_{SNN04})} - 1 & \frac{2(\dot{r} - \dot{r}_{SNN04})}{(\dot{r}_{SNN08} - \dot{r}_{SNN04})} - 1 & \dot{\beta} & \dot{r} \end{bmatrix}^T \quad \dots\dots(3)$$

2.3.2 インテグレータの学習 システムNN、NN制御器は共に車両特性の左右方向の対称性を特に考慮して若干特殊な構造のNNとしたが、インテグレータの出力は各NN制御器の出力の混合比であるため、隠れ層、出力層ともにシグモイド出力関数を持つ通常のNN構造を用いる。図5(c)にインテグレータの構造を示す。入力層、隠れ層、出力層のノード数は11個（他に、オフセットのための定数入力ノード1個）、11個、1個である。学習を行う範囲はNN制御器と同様であるが、様々な μ における制御則を学習するため、 μ が0.4、0.6および0.8の場合にお

いて学習を行う。学習条件を表3に示す。学習条件に μ が0.6の場合が含まれているためそれに対応するシステムNNも用意する必要がある、これについても事前に他のシステムNNと同様に学習を行う。

インテグレータの学習は各NN制御器と同様に順逆モデル法のスキームにより行い、CNNによる制御時の応答が線形車両モデルにより近い応答になるように学習条件のすべての組み合わせで線形2車輪モデルの応答を教師信号として学習するものとする。

これまでに提案されたCNNではインテグレータの学習は、各種条件における時刻歴シミュレーションの結果を適応度として評価する遺伝的アルゴリズム (Genetic Algorithm: 以下, GA) によっていたが、評価に用いる時刻歴シミュレーションを全ての走行条件を網羅するように選択することは困難である。またGA学習では、個体数や使用する遺伝オペレータの数や種類等、非常に多くの学習パラメータを設定する必要があるが、誤差逆伝播法による学習は、比較的少ない学習パラメータにより安定した学習が可能である。

3. 学習およびシミュレーション結果

3.1 システムNN μ が0.4、0.6および0.8それぞれの場合において、システムNNの線形部分は20,000回、非線形部分は200,000回の学習の結果、車両モデルの動特性を精度良く獲得した。

3.2 単一 μ 対応NN制御器 μ が0.4および0.8それぞれの場合において、各NN制御器は20,000回の学習

Fig. 7 Difference of Response from Linear Model

Fig. 8 Time History of Double Lane Change

Fig. 9 Vehicle Running Trajectory of Double Lane Change

Fig. 10 Time History of Double Lane Change by CNN

Fig. 11 Vehicle Running Trajectory of Double Lane Change

Fig. 12 Time History of Double Lane Change by CNN

Fig. 13 Vehicle Running Trajectory of Double Lane Change

Fig. 14 Time History of Double Lane Change by CNN

Fig. 15 Vehicle Running Trajectory of Double Lane Change

の結果、制御則を獲得した。図7(a, b)に非制御時および制御時の $\mu=0.4$, $v=15\text{m/s}$, 直進操舵状態での状態量の变化率の線形モデルとの差を等値線図で状態平面上に示す。等値線化するパラメータは等価2車輪車両モデルの状態量である横すべり角とヨー角速度の変化率の線形結合であり、この値が小さいほど線形モデルに近い応答を示していることを示す。状態平面中央の値が小さく線形モデルに近い応答を示す領域が拡大できており、目的通りのNN制御器が得られていることがわかる。また、制御例として $\mu=0.4$, $v=15\text{m/s}$, 操舵振幅 0.07rad でのダブルレーンチェンジの数値シミュレーションでの横すべり角, ヨー角速度, 操舵角の時刻歴を図8に, 走行軌跡を図9に示す。非制御では横すべり角が発散してしまい正常走行できないが, 前輪操舵制御により危険状態に陥ることを防止できている。しかし制御の結果, 操舵角は多少制限されてしまっており, 各NN制御が, あくまで μ の制限の中でより線形モデルに近い応答を求めるものであることを示している。また, 操舵終了後に車両の状態を安定させる制御が行われていることがわかる。

3.3 インテグレータ インテグレータは1,000回の学習の結果, 制御則を獲得した。図10に $\mu=0.4$, $v=18\text{m/s}$ で操舵振幅 0.065rad のダブルレーンチェンジの横すべり角およびヨー角速度の時間変化率およびインテグレータの出力の時刻歴シミュレーション結果を, 図12に $\mu=0.6$, $v=17.5\text{m/s}$, 操舵振幅 0.07rad の場合, 図14に $\mu=0.8$, $v=24\text{m/s}$, 操舵振幅 0.055rad の場合の結果を示す。また, 図11, 13, 15にそれぞれの場合の走行軌跡を示す。

どの μ においても非制御ではスピン状態に陥ってしまったり, コースを大きく逸脱してしまったりするところ, スピンを回避したり, 逸脱量を小さく抑えたりすることができている。

μ が0.4の場合, 0.8の場合ともに, その μ に対応するシステムNNに近い車両の応答が得られており, 2つのシステムNNの出力と車両の応答とを比較することによりその時点での μ に関する情報が得られることがわかる。またそれに応じて, インテグレータの出力も変化しており, μ が0.8の場合は1に近い値, 0.4の場合は-1に近い値, また0.6の場合はその中間程度の値となっており, インテグレータが適正なNN制御器を選択していることがわかる。乗り移り区間以外で操舵が全く行われておらず, 直進状態になっている時点では, μ に関する情報が得られず, またどちらのNN制御器を選択しても差異はないため, インテグレータは1に近い値を出力し μ が0.8の場合に対応するNN制御器を選択している。また, 操舵開始時や, ヨー角加速度が0になる場合にインテグレータの出力がスパイク状に変化しているが, これは制御器後段の

Fig. 16 DADS Full Vehicle Model (icon view)

ローパスフィルタにより除去される。

このように, インテグレータの導入により, 各NN制御器では学習しなかった μ についても学習した μ と同様な制御結果が得られており, 目的とした様々な μ に対応するCNN統合制御器が得られていることがわかる。

4. 機構解析言語モデルによる検証

制御器の設計に用いた車両モデルは, プログラミングおよび学習のための数値計算の制約から非常に単純化されたモデルとなっているが, 実際の車両ははるかに複雑な多自由度系である。これを完全に考慮したモデルにより設計を行うことが望ましいが, マルチボディダイナミクスのモデル化は, 多体間相互の力の作用や運動の非線形性のために容易ではない。サスペンションのリンクを含む車両のモデル化は構成各部材について運動方程式を書き下していくような方法では膨大で困難な作業であり, 間違いの発生も予想される。そのため本研究では, 設計は単純化された設計用モデルで行い, 得られた制御器を機構解析言語⁽¹²⁾DADSにより作成した全車両モデルと制御系設計言語Matlab/Simulinkとの組み合わせを用いて検証するというアプローチをとることとする。

4.1 モデルの構成 構成した車両モデルは, サスペンションは前:マクファーソンストラット, 後:ダブルウィッシュボーン, 物体数は18である。物体間を結合するジョイント要素の配置を図16に示す。車両諸元は, 前述の7自由度モデルと同じ小型SUVのものであり, リンク長等は実測結果に基づき設定した。

路面-タイヤ間力のモデルは設計用モデルと厳密に対応をとるため, マジックフォーミュラの定式化に従ってSimulinkのサブブロックとして前後力, 左右力をモデル化した。セルフアライニングトルクに関しては車両全体の運動におよぼす影響は小さいものとしてモデル化しないものとした。また, 垂直力に関しては単純なばねダンパでモデル化した。

CNN統合操舵制御器はSimulinkブロックで構成すると

Fig. 17 Evalutaion with DADS Full Vehicle Model

非常に複雑な構成となってしまうので、Matlab Functionブロックを用いてMatlabプログラムで作成した。また、DADSモデルへの制御器からの入力、操舵角に対する変位入力となるが、DADSでSimulinkからの入力を受けるPlant Input要素では、数値積分上の制約から変位入力の型は許されていない。本モデルでは、操舵変位入力をシミュレーションに関係ないダミー物体への力入力として一旦受け、その際、コントロールノードに残った変数値をDriver要素により、ステアリングラックの変位として導入するという手法を用いている。この際、Driver要素により駆動される物体は質量を持たず、また他の質量を持つ物体とは力要素で結合されている必要がある。同様のことは、力入力を用いて所望の変位入力になるようにサーボ系を組むことによっても実現できるが、連続系としてみた場合、これら2つの手法はほぼ等価である。

4・2 検証結果 設計用モデルとDADSモデルとは、パラメータ類を厳密に合わせているため、DADSモデルのサスペンションおよびタイヤのたわみを拘束することにより双方の自由度を一致させれば解析結果は一致する。しかし、実走行状態での解析では多少の差が出る。図17に $\mu = 0.8$, $v = 23\text{m/s}$ で操舵振幅 0.07rad のレーンチェンジを行った場合の実走行状態のDADSモデルによるシミュレーション結果を示す。単純化された設計用モデルでのシミュレーションと同様に非制御では横

すべり角が発散してしまい正常走行できないが、CNNを用いた前輪操舵制御により若干の進路の偏差はあるものの、危険状態に陥ることを防止できていることがわかる。このことより、単純化された設計用モデルを用いて設計した本CNN統合制御器が、より実車に近いDADSモデルに対しても有効であることがわかる。

5. 結言

より線形に近い特性を実現するNN前輪操舵制御器の設計を試みた。高い μ 、低い μ それぞれに対し制御器の設計を行い、またこれらを知的制御の一手法であるCNNを用いて統合することにより、非線形性のため従来の線形設計理論では設計不可能な、様々な μ における、高ヨー角速度、大横すべり角領域での操舵制御の有効なCNN統合制御器を構築した。また、本制御器の有効性について、機構解析言語DADSによる全車両モデルを用いてより实际的に示した。

これにより、非線形操舵制御へのNN制御器の適用および車両運動制御への知的制御の適用の有効性が示された。

今後の発展としては、 μ の変化のみではなく様々な条件の変化を想定したNN制御器をさらに統合することによる対応可能な走行条件の拡大、DADSモデルの高度化によるシミュレーション精度の向上等が考えられる。

最後に、本研究は日本学術振興会未来開拓プロジェクトJSPS-RFTF97200103の一環で行ったことを記し、謝意を表する。

文献

- (1) 菅沢ほか、日産技報(1987/1988), 42-50.
- (2) 杉山ほか、TOYOTA Technical Review, **46-2** (1996), 60-67.
- (3) 田中ほか、三菱自動車テクニカルレビュー, **9** (1997), 40-51.
- (4) 安部、自技会シンポジウム資料、タイヤと車両におけるアクティブセーフティの新制御技術, **01-00** (2000), 8-15.
- (5) 自動車技術会編、自動車の運動性能向上技術(1998), 朝倉書店.
- (6) 木通・神谷・吉田、計自論, **33-1** (1997), 42-50.
- (7) 志村・吉田、機講論, **99-59** (1999), 173-176.
- (8) Bakker, E., et al., SAE Paper 890087 (1989).
- (9) Jordan, M. I., IEEE Proc. of Int. Joint Conference on Neural Networks Vol. 1 (1989), 217-225.
- (10) 長門・吉田、機論, **58-550C** (1992), 1755-1761.
- (11) 安部、自動車の運動と制御(1992), 山海堂.
- (12) 日本機械学会編、講習会資料、コンピュータシミュレーションダイナミクス, **97-78** (1997).