ニューラルネットワークによる四輪操舵車の同定と制御*

塩 塚 稔 也^{*1}, 太 田 和 重^{*2}
吉 田 和 夫^{*3}, 長 松 昭 男^{*4}

Identification and Control of Four-Wheel-Steering Car by Neural Network

Toshinari SHIOTSUKA, Kazusige OHTA,
Kazuo YOSHIDA and Akio NAGAMATSU

Recently many kinds of four-wheel-steering (4WS) systems have been studied and proposed. Design of these control systems is based mainly on the two-degrees-of-freedom model. However, vehicle motion is influenced by various nonlinear factors, for example, tire characteristics and road condition. Hence, it is difficult to express the vehicle motion accurately by the two-degrees-of-freedom model. In this paper, a method of 4WS control system is presented by applying a neural network. First we identify the vehicle motion as a system neural network. Next we construct a neural network controller by using this system neural network. The effectiveness of the proposed method is demonstrated by a computer simulation.

Key Words: Neural Network, Automobile, Identification, Four - Wheel - Steering, Vehicle Dynamics, Feedback Control

1. 緒 論

操舵にともなう車両の運動は、タイヤやサスペンション等の部品の特性や路面状態などの環境に起因する非線形性を有している。ところが、筆者らの知るところによれば、現在発表されている四輪操舵(以下4WSと言う)システムの設計の大半が比較的簡単な2輪線形モデルを基に行われている^{(1)~(3)}。この2輪モデルを用いれば、比較的簡単に制御系が構成できるものの、4WS車のメリットを十分に発揮できないと考えられる。よって、車両運動の非線形性を考慮したモデル化と制御を4WS車に適用すれば、さらに優れた制御系の構成が可能になると考えられる。そこで本報告では、非線形特性を有するニューラルネットワークの特性に着目⁽⁴⁾し、これを車両システムの同定と制御に応用することを提案する。同定には実車両の走行実験の結果を用い、コントローラには様々な運動特性を持たせるように設計する。このことにより、多様な制御目標に

対応できる4WSシステムの設計が可能になると期待される。また、その有効性について計算機シミュレーションにより検討する。

2. 同 定 モード

2・1 車両実験 システム同定に用いるデータを得るため、実車両による実験を行った。実験には、前輪のみ操舵する2WSと前輪と後輪を操舵する4WSが切り替えられる車両を用いた。測定したデータは、車両重心点における横すべり角 β [rad]、ヨーレート r [rad/sec]、車速 V [m/sec]、前輪舵角 δ_f [rad]、後輪舵角 δ_r [rad]で、サンプリング時間は0.02[sec]とした。測定は、2WS・4WSそれぞれについて速度40, 60, 80, 100[km/h]の4通りについて行った。ドライバーにはできるだけ速度を一定に保ってもらい、ハンドル操作はステップ状、方形波形、サインカーブ状の入力としてもらうようにした。

2・2 ニューロンモデル 本研究で用いたニューロンモデル⁽⁵⁾を図1に示す。 u_i^n , o_i^n をそれぞれ第 n 層の第 i ユニットの内部状態および出力とする。 $w_{j,i}^{n-1,n}$ を第 $n-1$ 層の第 j ユニットから第 n 層の第 i ユニットへの結合の強さ(結合係数)、 θ_i^n を第 n 層の第 i ユニットのしきい値、出力関数を f とするとニューロン

* 平成4年7月10日 Dynamics & Design Conferenceにおいて講演、原稿受付 平成4年6月19日。

^{*1} 正員、東京工業大学大学院 (〒152 目黒区大岡山 2-12-1)。

^{*2} 東京工業大学大学院。

^{*3} 正員、慶応義塾大学理工学部 (〒223 横浜市港北区日吉3-14-1)。

^{*4} 正員、東京工業大学工学部。

の内部状態および出力は式(1), (2)のように表される。

$$u_i^n = \sum_j w_{ji}^{n-1,n} o_j^{n-1} - \theta_i^n \dots \dots \dots (1)$$

$$o_i^n = f(u_i^n) \dots \dots \dots (2)$$

2・3 ニューラルネットワークによるシステム同定

通常用いられる車両の平面運動の線形2輪モデルの運動方程式は、式(3), (4)のように表される。

$$\begin{aligned} \frac{d\beta}{dt} = & -\frac{2(K_f + K_r)}{mV} \beta - \left\{ \frac{2(l_f K_f - l_r K_r)}{mV^2} + 1 \right\} r \\ & + \frac{2K_f}{mV} \delta_f + \frac{2K_r}{mV} \delta_r \dots \dots \dots (3) \end{aligned}$$

$$\begin{aligned} \frac{dr}{dt} = & -\frac{2(l_f K_f - l_r K_r)}{I} \beta - \frac{2(l_f^2 K_f + l_r^2 K_r)}{IV} r \\ & + \frac{2l_f K_f}{I} \delta_f - \frac{2l_r K_r}{I} \delta_r \dots \dots \dots (4) \end{aligned}$$

ここで、 m は車体質量、 I はヨー慣性モーメント、 $K_{f,r}$ は前後コーナリングパワー、 $l_{f,r}$ は車両重心と前後車軸との距離である。このとき必要な諸元のうち、車体質量、重心点まわりのヨー慣性モーメント、重心点と前後輪軸までの距離については、実験を行わずに設計資料から求めることができる。また、タイヤのコーナリングパワーについても、タイヤ特性から知ることができる。ここで、実験車の車両諸元を以下に示す。

$$m=1300[\text{kg}] \quad I=1700[\text{kgm}^2]$$

$$l_f=1.0[\text{m}] \quad l_r=1.4[\text{m}]$$

$$K_f=45000[\text{N/rad}] \quad K_r=40000[\text{N/rad}]$$

これらの値は、実験車のシミュレーション・制御系設計に用いられる値であるが、システムのより良い一致を期するため、 $K_f=40000[\text{N/rad}]$ 、 $l_r=1.6[\text{m}]$ とし以下のシミュレーションにはこれらの値を用いる。

ところが、この単純なモデルでは実際のシステムを十分に表現できない場合があると考えられる。そこで本報告では、車両システムをニューラルネットワーク内に獲得するシステム・ニューラルネットワークを用いる。これを図2に示す。学習法は誤差逆伝ば法を用いた。ニューラルネットワークの構成は、入力層6個、出力層2個、中間層8個とした。入力には横すべり角

図1 ニューロンモデル

β , ヨーレート r , 速度に関する項として $1/V$, $1/V^2$, 前輪舵角 δ_f , 後輪舵角 δ_r を与える。出力層には、横すべり角 β , ヨーレート r が出力するように学習させる。ここで、速度に関する項として V ではなく $1/V$, $1/V^2$ の項をいれたのは、式(3), (4)から速度に関する項がこのような形で現われていることによる。学習には車両の走行実験のデータを用いる。学習に用いたデータは2WS, 4WSそれぞれ12パターン、計24パターンである。

図3に同定結果の一例を示す。実線が測定したデータ、破線がニューラルネットワークにより同定された結果、一点鎖線が2輪線形モデルで計算された結果である。同定結果を見ると、時速40[km/h]で測定データと2輪モデルとの横すべり角の振幅および位相のずれが目立つ。時速100[km/h]の結果においても、2輪モデルの横すべり角の位相のずれが目立つ。また、ヨーレートについては、測定データと比べ2輪モデルでも位相のずれは小さいものの、振幅が少し大きくなっている。これらに対し、ニューラルネットワークによる同定結果は実車の測定データと比べ良い一致を見ている。これらの原因は、車両の運動が複雑であるため、その運動を2輪モデルで正確に記述することが困難であること。また、2輪モデルでは、車両の運動を2次元平面内に規定することでモデル化を単純化しているため、速い操舵を行った時のローリング、荷重移動などの三次元の動きに対応できない。さらに、コーナリングフォースがタイヤの横すべり角（スリップ角）に比例すると仮定しているため、タイヤの非線形性が無視できない速度、操舵時の運動を表現させるには無理が生じる。など、2輪モデルのモデル化の際に用いた仮定が成り立たなくなるからであると考えられる。一方、

図2 システム同定用ニューラルネットワーク

(a) 同定結果 [40 km/h]

(b) 同定結果 [100 km/h]

図3 同定結果の一例

ニューラルネットワークを使った場合、容易に非線形性を表現できることから、より正確なシステムの表現ができると考えられる。また、特に低速で2輪モデルが実験と一致しにくい原因としては、車両速度が大きな範囲で成り立つという2輪モデル作成上の仮定が成立しないためと考えられる。このことは、同定結果によっても十分に確認できる。

3. シンセシスモード

3.1 コントローラの学習 コントローラは、一般にモデルの運動方程式を基に設計されるが、この場合モデルが制御対象を十分に表現できていなければならない。本報告では、システム・ニューラルネットワークを用いてコントローラの設計を行う。今回用いるニューラルネットワーク・コントローラを図4に、コントローラ学習の過程を図5に示す。

コントローラの入力として四つの値、ヨーレート r 、速度に関する項 $1/V$, $1/V^2$, 前輪舵角 δ_f を与える。これは、実験車両で比較的安定して測定できるという理由による。より良い制御を実現するため、横すべり角 β もフィードバックして制御すべきであるが、横すべり角の測定は、車両と路面の相対ベクトルを光学的に計測しているため、路面が荒れていたり、水たまりがある場合など正確に測定できない可能性がある。このため、今回は横すべり角を入力としなかった。

図5に示すシンセシスモードでは、同定モードで学習したシステム・ニューラルネットワークとニューラルネットワーク・コントローラをカスケード状に配列し、ある時刻 $(k-1)$ の β , r , $1/V$, $1/V^2$, δ_f をシステム・ニューラルネットワークに、またその一部の r , $1/V$, $1/V^2$, δ_f をニューラルネットワーク・コントローラに入力する。ニューラルネットワーク・コントローラの出力は、次の時刻 k のシステム・ニューラルネッ

図4 ニューラルネットワーク・コントローラ

トワークの入力となる。コントローラ学習のための誤差に関する情報は、システム・ニューラルネットワークの出力を評価しその誤差をシステム・ニューラルネットワーク内を逆伝ぱし、ニューラルネットワーク・コントローラに誤差情報が与えられる。ニューラルネットワーク・コントローラは、その誤差情報を基に学習する。ニューラルネットワーク・コントローラの学習に用いた前輪の舵角は、図6に示す8パターンをそれぞれ速度40, 100 [km/h] について、合計16パターンを与えた。

3・2 評価関数 車両の理想的な運動を実現するためには、適切な評価関数を設定する必要がある。4WS車の制御目的としては一般に、次のような項目があげられる。

- (1) 走行コースに沿った車体の姿勢制御。(このためには、車体の横すべり角が常に零)
- (2) ヨーレートあるいは横加速度を望ましい操舵応答性に近づける。

そこで、今回は以下の三つのタイプのコントローラを設計した。

Type A：常に横すべり角を零に保つ

Type B：常にニュートラルステアに保つ

Type C：AとBの条件をバランスさせたもの

3・2・1 Type A (常に横すべり角を零に保つ)

すべての時間において、横すべり角 $\beta(k)=0$ となるように評価関数を式(5)のように与える。この場合、車

両は走行コースに沿った制御を行う。ここで、 p はパターン、 k は離散時系列の数、 E はコントローラの制御結果を評価するための誤差である。

$$E = \frac{1}{2} \sum_{p=1}^{16} \sum_{k=1}^{200} \beta^2(k) \quad \dots\dots\dots (5)$$

3・2・2 Type B (常にニュートラルステアに保つ)

中速域では、ハンドル入力に対するヨーレートのゲインを2WS車両と同程度に保ちながら、高速域においてもニュートラルステアを実現させるように学習を進める。実験車両の走行データから、中速域での運動特性は、ホイールベースが約4mの車両に匹敵することがわかったので、すべての時間においてヨーレートが式(6)を満たすように、評価関数を式(7)のように与える。この場合、ハンドル入力に対して車両を速く反応させる制御になる。

$$r(k) = \frac{V}{4} \delta_f(k) \quad \dots\dots\dots (6)$$

$$E = \frac{1}{2} \sum_{p=1}^{16} \sum_{k=1}^{200} \left\{ \frac{V}{4} \delta_f(k) - r(k) \right\}^2 \quad \dots\dots\dots (7)$$

3・2・3 Type C (AとBの条件をバランスさせる)

Type A ではヨーレートのゲインが小さく、Type B では横すべり角が大きくなってしまう可能性がある。そこで、二つの評価関数に重みをかけることにより、遅い操舵の時にはAの条件、速い操舵の時にはBの条件を満たすような評価関数を設定する。前輪舵角の変化量を、

$$\Delta \delta_f(k) = \delta_f(k) - \delta_f(k-1) \quad \dots\dots\dots (8)$$

とすると、評価関数は式(9)のようになる。

図5 シンセシスモード

図6 前輪舵角のパターン

$$E = \frac{1}{2} \sum_p \sum_k^{200} \left[K_1 \beta^2(k) + K_2 \left\{ \frac{V}{4} \delta_f(k) - r(k) \right\}^2 \right] \quad \dots\dots\dots (9)$$

ここで,

$$K_1 = 500(0.002 - \Delta\delta_f)^2, K_2 = \Delta\delta_f^2$$

とした。この場合には、車線変更時や緩やかなカーブでは安定したコーナリング、ワインディングロードを走行する時や危険回避するときは、すばやく姿勢変化ができるような制御をすることになる。

4. シミュレーション

ここでは、ニューラルネットワーク・コントローラの学習結果を時刻歴応答と周波数応答について検討する。比較として、2WS車両、ヨーレートフィードバック形4WS車両も同時にシミュレーションした。ヨーレートフィードバック形4WS車の制御則は、車体横すべり角が常に零になるように後輪舵角を式(10)のように与える。ただし、この制御則は2輪線形モデルを基礎として導かれたものである。

$$\delta_r = -\frac{K_f}{K_r} \delta_f + \frac{2(l_f K_f - l_r K_r) m V^2}{2K_r V} r \quad \dots\dots (10)$$

4・1 時刻歴応答 図7, 8に2WS, ヨーレートフィードバック制御, ニューラルネットワーク制御(Type A)による結果を示す。シミュレーションは、コントローラの応答遅れを0.02 [sec]として計算する。また、ここでシミュレーションに用いた車両システムは、同定モードで学習したシステム・ニューラルネットワークを用いた。ヨーレートフィードバック形4WSのコントローラは式(10)に示した通りであるが、このコントローラは、応答遅れに対して、安定性に問題があるとの報告⁽⁶⁾がある。実際、今回のシミュレーションにおいても急激な前輪舵角の入力に対しては、横すべり角・ヨーレートともに発散する結果となった。そこで、ヨーレートフィードバックのゲインは、基本設計の0.4倍にしてある。実用化されて車両においても、アクチュエータ等の応答遅れに対処するために、同様の変更をしてあるようである。

図7, 8を見ると、車速40, 100 [km/h]の場合とも、ニューラルネットワーク(Type A)のほうがヨーレートフィードバック形よりも横すべり角をかなり小さくすることができることがわかる。また、ヨーレートフィードバック制御の後輪舵角の時刻歴を見ると、時速40 [km/h]と100 [km/h]の場合逆相に出ている。時速40 [km/h]では、2WSよりも横すべり角が大きくなり、時速100 [km/h]では、横すべり角は2WSよりは小さくなるものの、十分とは言えない。これは、2輪

図7 時刻歴応答 [40 km/h]

図8 時刻歴応答 [100 km/h]

図 9 周波数応答 [40 km/h]

図 10 周波数応答 [100 km/h]

モデルが、低速では車両システムを十分に表現できないこと、ヨーレートフィードバック制御におけるコントローラの設計が線形モデルを基に行われているためによると考えられる。

4・2 周波数応答 図 9, 10 に 2WS, ヨーレートフィードバック制御, ニューラルネットワーク制御 (Type A, B, C) の周波数応答を示す。破線の 2WS と一点鎖線のヨーレートフィードバック制御 [式(10)による制御] の結果は、2輪モデルを用いた結果である。

本報告でのコントローラの設計は、時刻歴を基準としており、周波数応答については特に考慮していないが、制御系設計における評価基準として重要となる。位相については、高周波まで位相遅れを生じないほうが、良い操舵系と考えられる。図 9, 10 を見ると、位相については Type A が中・高速とも良い結果がでている。また一般に、ニューラルネットワーク (Type A, B, C) による制御では、速度の変化に対する特性変化が少ないことがわかる。また、Type A は中・高速とも、ヨーレートフィードバック形では高速において、高周波でゲインが増加してしまい、高い周波数の入力があった場合、発散してしまう危険性がある。

5. 結 言

四輪操舵車のシステム同定と制御に、ニューラルネットワークを用い、従来の手法と比較した結果次のような結論を得た。

- (1) ニューラルネットワークを用いたシステム同

定では、線形 2 輪モデルに比べかなり良い同定ができた。2 輪モデルが実験と一致しにくい理由としては、2 輪モデルではタイヤの非線形性を考慮していないことが考えられる。また、特に低速で 2 輪モデルが実験と一致しにくい原因としては、車両速度が大きな範囲で成り立つという 2 輪モデル作成上の仮定が成立しないためと考えられる。

(2) 制御系の設計にニューラルネットワークを用いることにより、より良い性能が得られることがわかった。また、評価関数を変えて学習することにより、さまざまな制御特性をもつコントローラが設計できる。

最後に、本研究を実施するにあたりご指導賜ったマツダ(株)角田鎮男氏、渡辺憲一氏およびデータ測定に御協力いただいた長岡満氏にこの場をかりて感謝の意を表します。

文 献

- (1) 永井・大木, 仮想モデル追従制御による四輪操舵システムの研究, 自動車技術, **39** (1988), 70.
- (2) 金井・ほか 4 名, 四輪操舵車の適応形ヨーレート, 横加速度および D^* 制御系の設計, 計測自動制御学会論文集, **24-4** (1987), 426.
- (3) 藤代・ほか 3 名, モデル追従制御と四輪操舵車, 自動車技術, **42-3** (1988), 304.
- (4) 長門・吉田, ニューラルネットワークを用いた非線形システムの最適制御, 機論, **58-545, C** (1992), 171.
- (5) 麻生, ニューラルネットワーク情報処理, (1989), 40, 産業図書.
- (6) 田中・ほか 3 名, ヨーレートフィードバック式アクティブ 4WS の開発, 第 2 回運動と振動の制御シンポジウム, **910-52**, (1991), 85.