

緊急行動を伴うドライバモデルに関する研究*

A Study on Model for Describing Drivers' Behaviors under Urgent Maneuverings *

横山 貴士**・M.ハジホセインルー***・中辻 隆****

By Takashi YOKOYAMA**, Mansour Hadji Hosseinlou***, Takashi NAKATSUJI****

1. はじめに

近年のスタッドレス化に伴ったツルツル路面の出現による交通事故を未然に防ぐために有効な予防安全技術が必要とされている。自動車の高知能化を狙いとした安全実験車の開発の推進などもその一つである。どのような安全対策を講じるにせよ、人間の運転動作のモデル化が非常に重要なものとなってくる。モデル化によって人間の運転特性をとらえることができ、事故の防止、事故の再現、道路の線形設計に役立てることができる。

ドライバモデルに関する研究には、直線モデル、曲線モデル、車線変更モデル、追従モデルなどがあり、様々な手法で研究がされてきた。本来、ドライバモデルは人間の運転動作を数式で模擬的に表現するものであるが、単純に線形的なモデルで再現することは困難であり、現在は非線形モデルの研究¹⁾²⁾³⁾が主流となっている。

本研究でも非線形モデルであるニューラルネットワークシステム（以下NNSと略記）を適用し、冬期路面状態における緊急停止、緊急回避時におけるドライバモデルを実車実験を基に構築を行った。

2. ニューラルネットワーク・バックプロパゲーション学習法

本研究ではバックプロパゲーション学習が可能なパターン連想型のNNSを使用した。

この方式の特徴は、目的とする系の入力値と出力値の組を用意し、これを教師信号として繰り返す

*キーワーズ：ドライバモデル、ニューラルネット

ワークモデル、車両制御、緊急行動

**正員、工修、日本道路公団

***学生員、工修、北海道大学大学院

****正員、工博、アジア工科大学

(北海道北区北13条西8丁目、

TEL011-706-6215、FAX011-706-6216)

し学習させると、その学習した系が徐々に目的の系に近づくという点にある。すなわち、これをドライバモデルに応用すれば、ドライバの特性が自動的にモデル化される。

以下、ここでは、繁雑になるのを防ぐために最終層を例にとって、バックプロパゲーション学習法を説明する。

形式ニューロンにおける情報処理は以下のように行われるものと考える。すなわち、ニューロンへのn個の入力を X_i ($i=1 \sim n$)、ニューロンの出力を o とすると、入出力の関係は式(1)で記述できる。

$$o = f(u) = f\left(\sum_{i=1}^n W_i \cdot X_i\right) \quad (1)$$

ここで、 u はニューロンの内部状態、 W_i は結合の重みである。また、 f は出力関数で(2)式で表されるシグモイド関数を使用する。

$$f(u) = \frac{2}{1 + \exp(-\alpha \cdot u)} - 1 \quad (2)$$

実際のNNSは多層構造となっているため、入力 X_i は前層の出力であり、出力は次層の入力となる。この形式ニューロンの処理のネットワーク化により入力値から出力値が順次計算される。

学習前には結合の重みがランダムな数値で与えられているため最終出力も教師信号の出力とはかけ離れたものになっているが、この重みを以下のバックプロパゲーション学習アルゴリズムにより修正する。出力 o に対して、教師信号 d との差により、その層の学習信号 δ が(3)によって計算される。

$$\delta = (d - o) \cdot f'(u) \quad (3)$$

ここで f' は前述の f の微分関数である。さらに(4)式により結合の重みの修正値 $\Delta W_i(n+1)$ を求める。

$$\Delta W_i(n+1) = \eta \cdot \delta \cdot X_i + \alpha \cdot \Delta W_i(n) \quad (4)$$

ここで、 $\Delta W_i(n)$ は前回の学習時の結合の重みの修正値で、 η は学習定数、 α は安定化定数である。最終出力層のユニットの学習信号を用いて、(5) 式によってその直前層の学習信号 δ_i が再帰的に計算される。

$$\delta_i = f'(u_i) \cdot \delta \cdot W_i \quad (5)$$

ここで、 u_i は、 δ_i の層のユニットの内部状態である。同様に (5) 式により、学習信号の計算が出力層から入力層へ通常の信号の流れとは逆に伝播する。

3. 実車実験

実験内容として、直線路での障害物に対する緊急停止、緊急回避実験を考えた。

そこで、実車走行実験は手稻試験場夏期冬道実験コースにて被験者は 3 人（被験者 A,B,C）で行い、2 車線の 50 (m) 直線実験路をコース上に設置し（図-1）、ドライバモデル用のデータ測定を行った。

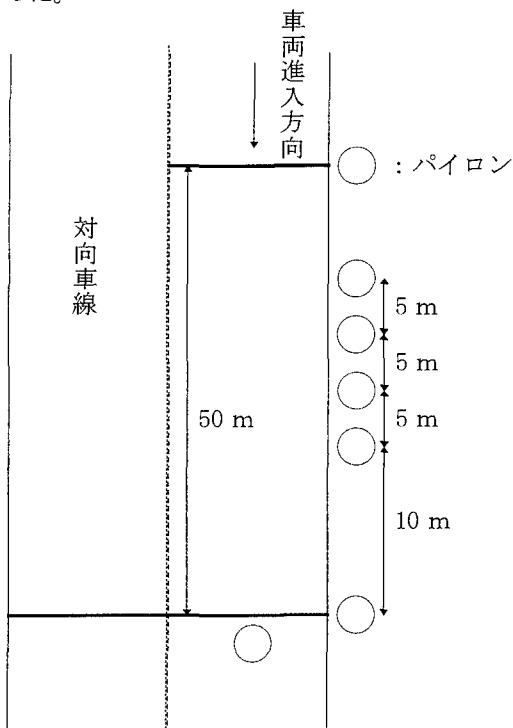


図-1 実験コース

実験は直線開始点手前までに設定した車速 (30km/h) にし、出来るだけ通常走行することを指示した。直線開始点に進入後、障害物までの距

離 10, 15, 20, 25 (m) のいずれかの位置で合図を被験者に対して送った。

合図については対向車あり（緊急停止状態）、対向車なし（緊急回避状態）の二種類を設定し、被験者に対し二種類の信号を送ることによって行った。また被験者に対して、緊急停止状態については車速制御のみ、緊急回避状態については操向制御のみで行うことを指示した。

以上の組み合わせを信号でランダムに被験者に送ることにより実験を行った。

4. モデルの構築

実験結果をふまえて、ドライバモデルの作成に当たっては、緊急停止状態車両制御と緊急回避状態車両制御に関し以下の仮定を行った。

(1) 緊急停止状態車両制御動作

運転者は、直線路を定常走行中、信号が点灯した時点で障害物を発見したとし、対向車がいるためにやむなく車速制御動作のみで車両制御を行ったとする。

(2) 緊急回避状態車両制御動作

運転者は、直線路を定常走行中、信号が点灯した時点で障害物を発見したとし、対向車がないためすばやく対向車線に回避動作を行ったとする。

以上の仮定のもとに、多層階層型のニューラルネットワーク・バックプロパゲーション法によるそれぞれの車両制御状態におけるドライバモデルの構築を行った。

入力データは、車両の進行方向速度、横速度、障害物までの距離、信号が出る距離、加減速度、横加減速度、回転角速度とした。出力データは緊急停止状態の場合は、車速制御を表現するブレーキ力、そして回避状態の場合は、操向制御を表現する操舵角とした。

そこでニューラルネットワークは、緊急停止状態、回避状態とも $7 \times 6 \times 3 \times 1$ の 4 層構造とし、学習回数は 5000 回とした。1 パターンずつ 2 回の走行のうち 1 回を学習データとして、残りの 1 回で検証のためのシミュレーションを行うものと

した。また他の被験者のデータでもシミュレーションを行った。シミュレーションは、緊急停止状態の場合は、実験開始地点である障害物手前 50m から障害物との緊急停止地点まで、回避状態の場合は、障害物真横の地点までとしてシミュレーションを行うものとした。

5. 学習精度

ニューラルネットワークドライバモデルにおける学習精度を検証するために、学習結果と実測値の比較を行った。

図-2 は緊急停止状態車両制御動作と回避状態車両制御動作の学習結果と実測値の RMS 誤差のグラフである。どの実験条件でも RMS 誤差は低く、学習精度は高いものであるといえる。また、障害物までの距離が短い方が、どちらの車両制御動作とも精度が高くなる傾向にある。

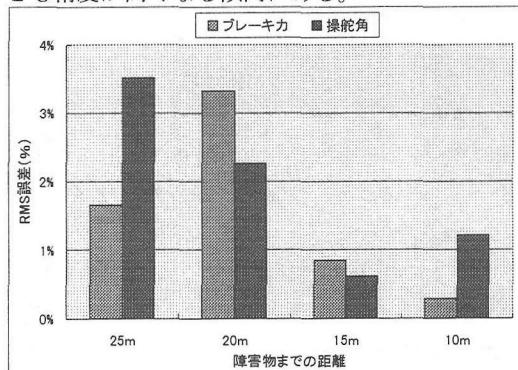
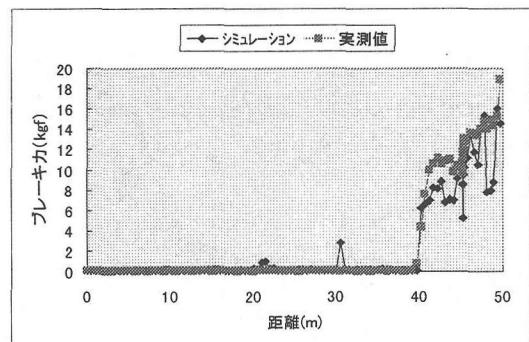


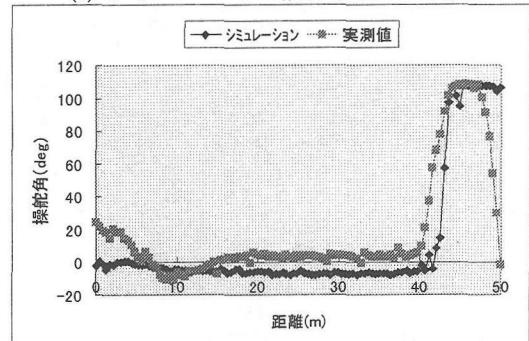
図-2 学習データの RMS 誤差

6. シミュレーション解析

図-3(1)、(2)は障害物までの距離 10 (m) における、緊急停止状態車両制御動作（ブレーキ力）、緊急回避状態車両制御動作（操舵角）のシミュレーション結果である。緊急停止状態車両制御動作に関しては、ブレーキを踏む強さに若干のずれがみられるが、踏むタイミング、追従性は再現性が高くなっている。緊急回避状態車両制御動作に関しては、直進時の操舵に若干のぶれが見られるが、ハンドルを切るタイミング、その大きさとともに再現性が高くなっている。



(1) シミュレーション結果 (ブレーキ力)



(2) シミュレーション結果 (操舵角)

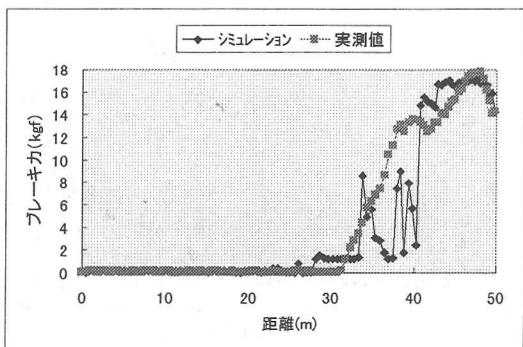
図-3 未学習データによるシミュレーション

次に他の被験者のデータを未学習のデータとして使用したシミュレーションを行った。学習された重みは被験者 B のものを用い、被験者 A のデータを未学習データとしてシミュレーションを行った。

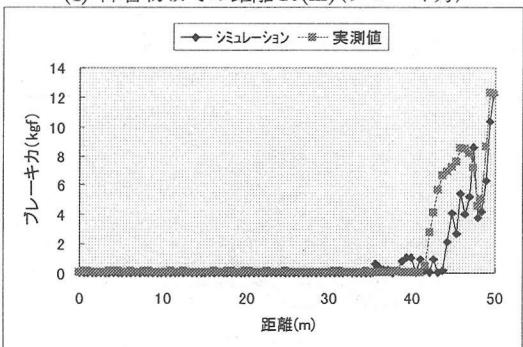
図-4(1)～(4)は障害物までの距離 25、10 (m) における、緊急停止状態車両制御動作（ブレーキ力）、緊急回避状態車両制御動作（操舵角）の被験者 A のデータを未学習データとしたシミュレーション結果である。

どちらの車両制御動作とも障害物までの距離が近い状態の時に、言い換えればより緊急行動である時にシミュレーションの再現性が高くなっている。

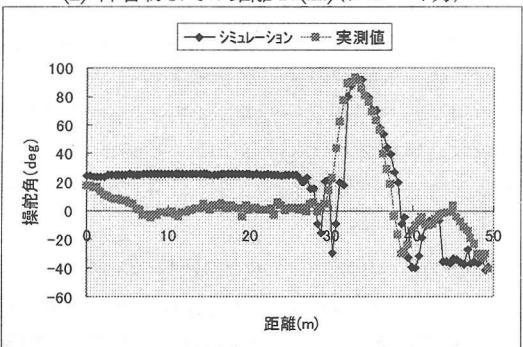
よって、障害物までの距離が近くなるほど被験者两者の運転挙動が似ているということが考えられる。



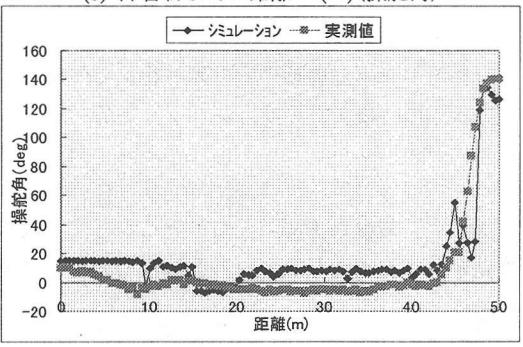
(1) 障害物までの距離 25(m)(ブレーキ力)



(2) 障害物までの距離 10(m)(ブレーキ力)



(3) 障害物までの距離 25(m)(操舵角)



(4) 障害物までの距離 10(m)(操舵角)

図-4 他の被験者データでのシミュレーション

図-5は被験者Bの重みを用いて被験者Aのデータを未学習データとしてシミュレーションさせたシミュレーション結果と実測値との RMS 誤差である。

このグラフを見ると、全体的にブレーキ力に比べると操舵角の方がシミュレーションがうまくいっているようである。

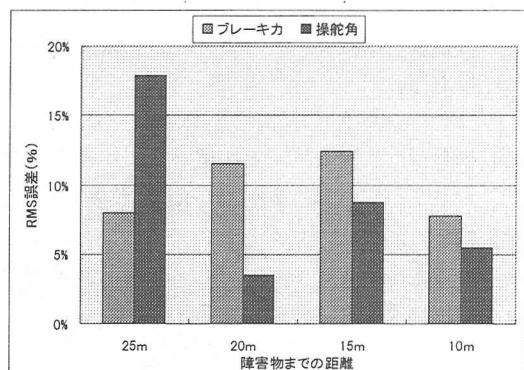


図-5 RMS 誤差

7.まとめ

ニューラルネットワークの使用により、線形モデルでは困難であった緊急行動時のドライバモデルの開発を行った。その結果、学習データに対して良好な同定の結果を得た。

シミュレーションの再現性については、より緊急行動である時に再現性が高くなった。

また、他の被験者のデータを未学習データとしたシミュレーション結果から、より緊急行動である時には、ドライバ個々の運転特性に大きな差異はないのではないかと考えられる。

8.参考文献

- 1.藤岡ら：神経回路網（ニューラルネットワーク）を利用した運転者モデルの研究、自動車技術会学術講演会前刷集 901,901062,1990
- 2.藤岡ら：神経回路網（ニューラルネットワーク）を利用した運転者モデルの研究－第2報：一般路での走行シミュレーション－、自動車技術会学術講演会前刷集 902,902262,1990
- 3.影山ら：ニューラルネットワークを用いた人間－自動車系のモデル化、自動車技術会論文集、Vol.48,No12,1994