

操作量を用いたニューラルネットワーク による運転行動のモデリング

平成 18 年 度

三重大学大学院工学研究科
博士前期課程 情報工学専攻

織 田 勇 也

修士論文

操作量を用いたニューラルネットワーク
による運転行動のモデリング



三重大学大学院 工学研究科 情報工学専攻
博士前期課程 2006 年度 修了

織田 勇也

目次

第1章	序論	1
1.1	本研究の背景	1
1.2	本研究の目標とする運転支援システム	2
1.3	本研究の目的	4
1.4	本論文の構成	4
第2章	計測	5
2.1	計測システム	5
2.2	計測信号	6
2.3	G センサ信号の変換	10
2.4	平滑化	12
2.5	運転行動の切り出し	14
第3章	ニューラルネットワーク	15
3.1	ネットワーク構造	15
3.2	誤差逆伝播法による学習	18
3.3	運転行動の認識方法	22
第4章	最適なモデルの検討	23
4.1	入力層の検討	23
4.2	中間層及びモデルの学習の検討	25
4.3	学習パターンの選別	27
4.3.1	発進	27
4.3.2	加速	29
4.3.3	継続	30
4.3.4	減速	31
第5章	運転行動予測のシミュレーション	32
5.1	シミュレーション方法	32
5.2	シミュレーション結果	33

第6章 結論	41
6.1 まとめ	41
6.2 今後の課題	41
参考文献	42
謝辞	43
発表論文リスト	44

図一覧

図 1.1	運転支援システム	3
図 2.1	計測システム	8
図 2.2	計測ボックス	8
図 2.3	ヨーレートセンサ特性	9
図 2.4	G センサ特性	9
図 2.5	変換前の G センサ信号	11
図 2.6	変換後の G センサ信号	11
図 2.7	計測された车速の例	13
図 2.8	平滑化を行った後	13
図 3.1	階層型ネットワーク	17
図 3.2	相互結合型ネットワーク	17
図 3.3	3層パーセプトロン	17
図 3.4	誤差逆伝播法のアルゴリズム	21
図 4.1	発進パターンの選別前と選別後	28
図 4.2	加速パターンの選別前と選別後	29
図 4.3	継続パターンの選別前と選別後	30
図 4.4	減速パターンの選別前と選別後	31
図 5.1	シミュレーション 1 の結果	34
図 5.2	シミュレーション 2 の結果	36

図 5.3 シミュレーション 3 の結果.....	38
図 5.4 シミュレーション 4 の結果.....	39
図 5.5 シミュレーション 5 の結果.....	40

表一覧

表 2.1	運転行動のカテゴリ	14
表 4.1	信号の組み合わせによる認識率	24
表 4.2	入力時間に対する認識率	24
表 4.3	学習による誤差と認識率	25
表 4.4	10-fold Cross Validation 結果	26
表 4.5	発進パターンの選別条件	27
表 4.6	加速パターンの選別条件	29
表 4.7	継続パターンの選別条件	30
表 4.8	減速パターンの選別条件	31
表 5.1	モデルの各パラメータとその値	33
表 5.2	認識結果の詳細	34
表 5.3	シミュレーション 2 の設定	36
表 5.4	シミュレーション 3 の設定	38
表 5.5	シミュレーション 4 の設定	39
表 5.6	シミュレーション 5 の設定	40

第1章 序論

1.1 本研究の背景

近年の車社会では、交通事故による死亡者数が減少しているのに対し、交通事故件数は増加するという傾向が見られる[1]。死亡者数の減少に関しては車体の強度やエアバッグ、シートベルトなどの性能向上のためである。そして交通事故数の増大は自動車保有台数の増加や高齢者ドライバーの増加などが原因として考えられる。この増え続ける交通事故を減らすために国土交通省と自動車メーカーは、最先端のエレクトロニクス技術を搭載することでさらに車を高性能化、高知能化しようとするASV(先進安全自動車)の開発、実用化を行っている。また、AHS(走行支援道路システム)という、道路と車との通信や車同士の通信による情報のやり取りにより、自車両および周辺車両の位置や挙動をリアルタイムに把握し、安全な運転を支援するというシステムも開発されている。

交通事故の中で多く発生しているのは「追突」、「出会い頭」、「歩行者との衝突」である[2]。これらを回避するために重要なことは、他の車や歩行者などの障害物に衝突する前に安全に停止することである。現在実用化されているものはプリクラッシュセーフティシステムという、車に搭載したレーダが前方の障害物との距離を計測し、衝突が避けられない状況になると0.6秒前に自動ブレーキを作動させるというシステムである。この「0.6秒」という時間は国土交通省の技術指針に基づくものである。しかし、このシステムは衝突時の衝撃を軽減することはできても衝突を避けることはできない。もし絶対に衝突をさせないということを考えるのならば、この0.6秒の間に車が停止できるような強力なブレーキを作動させればよいのだが、レーダ等のセンサの認識精度の問題でそこまでは踏み切れていないというのが現状である。今後の課題としてはセンサの認識精度の向上が挙げられるが、これはコスト面での問題もある。そこで、別のアプローチ方法として、ドライバーの運転行動を監視し、その行動を予測することで、より早い段階で自動ブレーキをかけるなどして、交通事故を回避することができるような安全運転支援システムが必要とされている。

1.2 本研究の目標とする運転支援システム

本研究では 1.1 節の背景より、ドライバーの運転行動を監視することでその行動を予測することが重要であると考え、そのために有効な方法としてドライバーの運転行動のモデリングがある。

一般的にはドライバーの行動を無視して予測を行う場合、操作量が同じか、同じと見なせるような短い時間であれば、車の運動方程式を解くことで、約 0.1 秒後まで車がどのように走行するかを計算することができるが、危険を安全に回避するためには、1 ないし 2 秒の時間が必要であるとされている。つまり、それだけの時間の運転行動を予測することができれば、特別な場合を除けば衝突事故は安全に回避することが可能となる。

そこで、本研究では図 1.1 に示すような安全運転支援システムの実現を目標としている。システムの概要は、まず、車両に搭載された各種センサによって計測されるアクセル、ブレーキといったドライバーの操作量と、車速や加速度などの車両の情報を組み合わせてドライバーの運転行動を予測し、その予測に基づいて車両がどのように行動するかを計算する。また、その計算とは別に前方画像センサ等の情報から歩行者、他の車両といった周囲の状況を計算する。そして、その 2 つの計算結果を比較し、もし衝突の危険があるとシステムが判断すれば警告を発する、自動制御に切り替えるなどして安全に衝突を回避するというものである。

これまでの研究として Pentland と Liu らは Markov Dynamic Model を用いてドライバーの操作量などを入力としてモデリングを行い、予備動作から車線変更の予測を行うことを提案し、ドライビングシュミレータによって得られたデータを用いて上記の実験を行い、高い精度で 2 秒後の予測ができることを示した[3]。また、Engstrom と Victor らはニューラルネットワークを用いて実際の走行によって得られたデータから、ドライバーの操作量と方向指示器、ギア、ステアリングアングルなどを入力としてモデリングを行い、その車両が現在走行している道路の種類の認識を行い、高精度な認識結果を出した[4]。

本研究ではより実用的なシステムを考え、仮想環境であるシミュレータではなく、実際の走行によって得られたデータからモデリングを行い、運転行動予測のシミュレーションを行った。

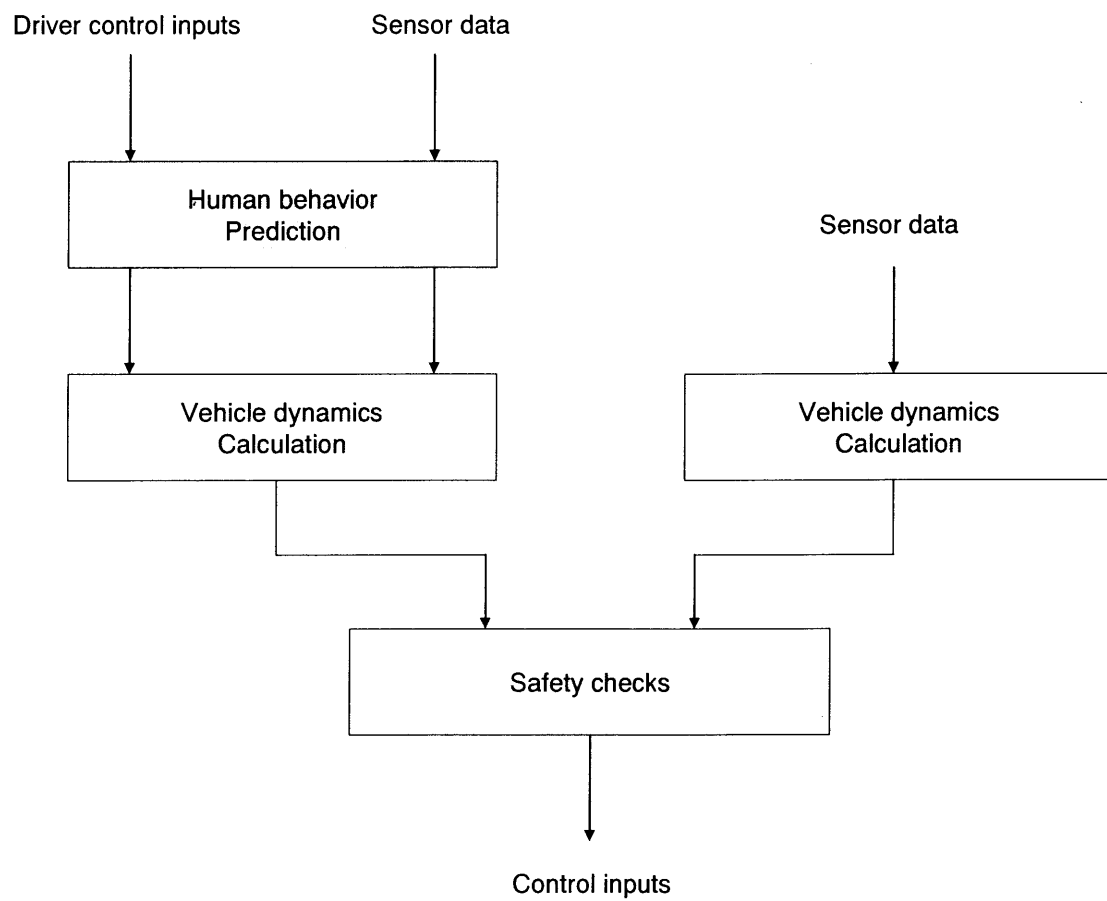


図 1.1 運転支援システム

1.3 本研究の目的

これまで私たちは、目標とする運転支援システムの実現のため、隠れマルコフモデルやニューラルネットワーク、ファジィなどを用いて運転行動のモデリングを行い、その認識や予測を行うことができるか検討を行ってきた[5]。扱う運転行動はブレーキ操作を行う運転行動である。その理由として、交通事故の多くは脇見運転や漫然運転などのドライバーのブレーキ操作ミスによって起こるからである。そして、非線形システムであり、様々な分野において予測に使われているニューラルネットワークを用いた運転行動予測のシミュレーションにおいて、実際の走行により得られた時系列データを入力として用いた場合、ある程度運転行動の予測をすることができた。

しかし、これまでの実験では数時間分の走行データしかなく、実験に用いるパターン数は約 100 パターンしかなかった。これではモデルの学習には不十分であるため、モデルの汎用性がないという問題点があった。また、ドライバーが現在行っている運転行動においては、高い精度で認識可能であるのに対し、数秒後の運転行動の予測では著しく精度が落ちるという結果であった。この原因として、モデルのパラメータ設定が運転行動の予測に対して適切でなかったことが挙げられる。

そこで本研究では、より多くの走行データを得るために開発した計測システムで、高速道路や一般道路を約 200 時間走行し、約 5000 パターンのデータを収集した。これにより、より汎用的なモデルを構築することが可能となった。そして、本研究ではドライバーの運転行動の認識や予測を行うための最適なニューラルネットワークモデルを構築することが目的である。

1.4 本論文の構成

以下に本論文の構成を記す。ここまで、本研究の背景及び目的を述べた。第2章で実験走行に用いた計測システムと得られる計測信号、その前処理についての詳細及び本研究で扱う運転行動について述べる。また、第3章でニューラルネットワークの概要と誤差逆伝播法、第4章で最適なモデルを構築するためのパラメータの検討について述べ、第5章でシミュレーション方法と結果について述べる。そして、第6章で結論を述べる。

第2章 計測

前章で述べたとおり，安全運転支援システムの実現のためにはドライバーの行動を予測する必要がある．そのために，カメラ等のデバイスを用いてドライバーの行動を監視する方法がある．武田らの行っている研究は，ドライバーの汗，脈拍，視線，手や腕の位置，ブレーキ，アクセルなどの動きを様々なシステムを用いて監視することで，ドライバーの微妙な反応や変化を検知するというものである[6]．

しかし，それらのデバイスを用いる場合にはコスト面やドライバーの不快感などの問題が生じる．そこで，本研究ではそういった特別なデバイスは使用せず，アクセルやブレーキ，車速といった既存の装置から得られる信号のみを用いて実験を行った．

第2章では，計測システム及び得られる計測信号，そしてその信号のデータをニューラルネットワークの学習及び認識や予測に用いる前に施した処理について説明する．

2.1 計測システム

本研究で使用した計測システム及び信号計測のための実験走行について説明する．まず，計測システムの概要，計測ボックスを図 2.1 と図 2.2 に示す．計測ボックスではアクセルやブレーキといったドライバーの操作量と，車速パルスといった信号を計測することができる．そして計測ボックスより得られた信号の中から車速等の信号を，リアルタイムにレーザーレーダセンサに送信することで同センサを連動させ，最大4つまでの対象物体との距離，相対速度，そして相対加速度といった信号を計測することができる．

また，計測ボックスから得られた信号を用いて予測した運転行動と，レーザーレーダセンサにより計測された外部環境の情報とを照らし合わせ，もし危険であるとシステムが判断したなら，ノート PC 上に危険を知らせるメッセージを表示するなどといった方法をとることで，システムの試験運用までも行うことができる．これまでの研究で，株式会社デンソーの援助により，このようなシ

システムの開発を行った。

計測システムの中で、ドライバーの操作量を検知するデバイスとして、ヨーレート G センサとブレーキ踏力センサという2つのセンサを新たに搭載してある。ヨーレート G センサは、車体の回転角速度を計測するジャイロセンサと2軸加速度センサが一体となったものである。ブレーキ踏力センサは、ブレーキペダルに取り付けられた感圧シートである。これらのセンサは比較的安価に搭載することができる。エンジン ECU(Engine Control Unit)は最初から自動車に搭載されているものであり、計測ボックスではこのエンジン ECU 上の信号を得ている。つまり、車速パルス、アクセル開度、ブレーキランプの計測を行うために、新たにセンサと取り付けることはしていない。また、エンジン ECU からブレーキやステアリングの操作量の計測も可能であるが、公道上で実験走行を行うことを考慮する場合、車両保全上の問題からそういった改造は不可能となっている。そこで、本研究では、ステアリングとブレーキの操作量を計測する代わりに、ブレーキ踏力とヨーレート G センサを用いている。

これらのシステムを搭載した個人所有車両で公道を走行し、計測した信号を、AD コンバータ等を通してノート PC にリアルタイムに記録した。個人所有車両にこのような計測装置を搭載し、さらに公道を走ることによって、自然な運転時の操作量を計測することができ、その特性の検討も行うことができる。また、実験走行中の交通事故などにおいても、計測者側の責任問題が発生しにくいという利点もある。

2.2 計測信号

前節で説明した計測システムを用いて行った実験走行により計測される信号についての詳細を述べる。計測ボックスから得られる信号は、車速パルス、アクセル開度、ブレーキランプ、ブレーキ踏力、ヨーレート G センサである。車速パルスは、車速に応じてパルス間隔が変化する信号であり、車速が速いほどパルス間隔は短くなる。アクセル開度は、アクセルが全閉の時に 0V、全開の時に 1V となる信号である。ブレーキランプは、ランプが ON の時に 1V、OFF の時に 0V となる。ブレーキ踏力はブレーキペダルを踏んでいないときに 0V となり、ペダルにかかる力に応じて電圧値が減少する。ヨーレート G センサについては、その仕様を図 2.3 と図 2.4 に示す。これらは、左右 100deg/s までの車体の回転角速度、および直行する2軸から $\pm 14.7\text{m/s}^2$ までの加速度に応じた電圧値が計測される。本研究では、これらのアナログ信号を、AD コンバータを用いて 0.1 秒ごとにサンプリングを行う。しかし、デバイスの使用により、サンプリング定理を満たすためのフィルタを通すことが不可能となっているため、まず

1000Hz でサンプリングし, 100 点ごとの平均をとったものを記録するという形でサンプリングを行った. また, 車速については 0.1 秒ごとに最初のパルス幅のみを記録し, そのパルス幅を用いて車速を算出しているので, 車速についても 0.1 秒ごとに記録されるということになる.

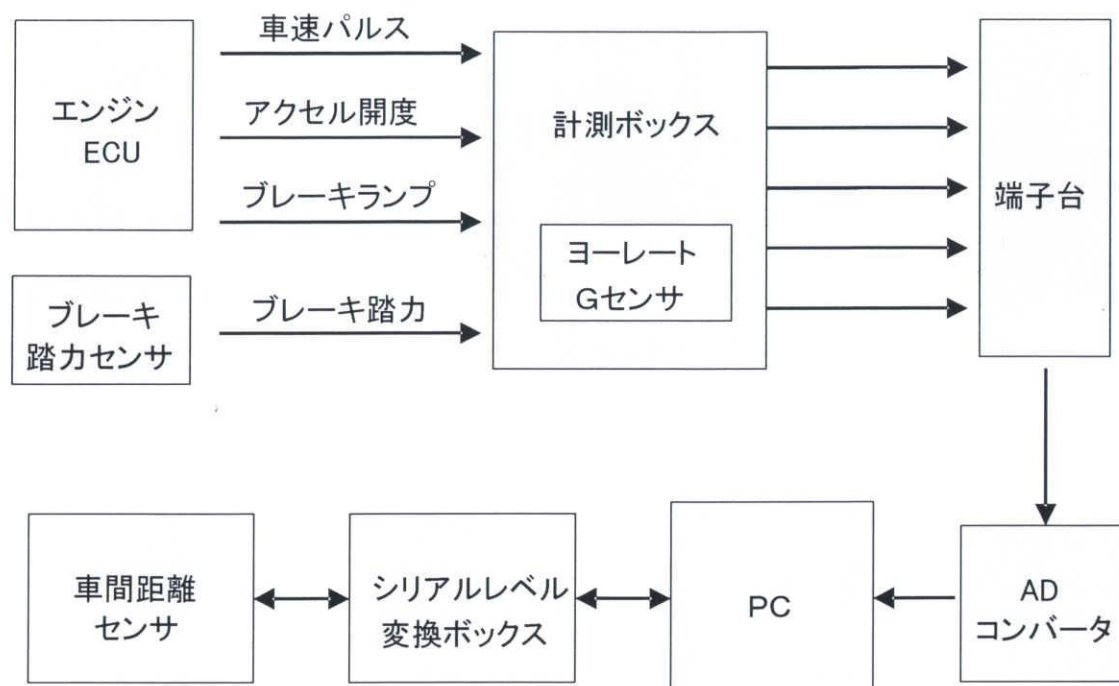


図 2.1 計測システム




図 2.2 計測ボックス




図 2.3 ヨーレートセンサ特性





図 2.4 G センサ特性

2.3 G センサ信号の変換

前説で説明したように、2つのGセンサは車両に対して斜め方向を軸として計測を行うため、同じ運転行動を行っている場合でも異なった計測値が出力されることがある。例えば同じ車速、アクセル開度であっても道が左に曲がっているか、右に曲がっているかでGセンサの値は大きく異なってしまう。これはニューラルネットワークモデルの精度を低下させる原因となる。そこで、前節で説明したGセンサの特性から信号を前後方向、左右方向の特性を持つように変換した。まず、変換前のGセンサ信号を図2.5に示す。この信号を、前後方向を $GL1-GL2$ 、左右方向を $GL1+GL2$ と変換した。変換後のGセンサ信号を図2.6に示す。これを見ると前後方向、左右方向の特徴が抽出されていることが分かる。本研究ではGセンサ信号はこの変換後の値を用いる。




図 2.5 変換前の G センサ信号




図 2.6 変換後の G センサ信号

2.4 平滑化

まず、例として計測された信号である車速の一部を図 2.7 に示す。この信号を見てみると、ノイズの影響でかなり大きく振動した形になっていることが分かる。これは計測システムの精度問題もあり、出力値が大きくなるほど影響を受け、信号の特徴を抽出するのが困難となる。そして、これらの値をそのままニューラルネットワークの学習パラメータに用いると、モデルの精度が低下するという問題が生じる。

そこで、これらの信号の特徴抽出が正確にできるように平滑化を行った。平滑化フィルタとしては移動平均法を用いた。これは式(2.1)で表される因果性のフィルタである。また、このフィルタには時系列データの持つ特徴を抽出するのに有効という性質がある。 W は *Window size* という何点の平均をとるか決める値である。この値を大きくすることで、信号がより滑らかなものとなる。しかし、そうすることで逆に信号の特徴も失われてしまうことになる。そこで本研究では *Window size* と 4 という小さな数値に設定した。

図 2.7 を平滑化した結果を図 2.8 に示す。これを見てみると、ノイズが減り、スムーズな曲線に近づいていることが確認できる。ニューラルネットワークの学習や認識、予測実験には計測された信号を、このように平滑化したものを用いた。

$$\begin{aligned}\mu_{n+1} &= \frac{n}{n+1}\mu_n + \frac{1}{n+1}x_{n+1} & (2 < n < W) \\ \mu_{n+1} &= \mu_n + \frac{1}{W}(x_{n+1} - x_{n+1-W}) & (W-1 < n)\end{aligned}\tag{2.1}$$




図 2.7 計測された車速の例




図 2.8 平滑化を行った後

2.5 運転行動の切り出し

本研究はブレーキ操作を行う運転行動に対し認識及び予測を行っている。ブレーキ操作の予測ができれば、車間距離センサや前方画像センサなどの結果と比較することで事故を回避するシステムの構築も可能となる。もし、リアルタイムにブレーキを踏んでいるかどうかを判断するだけなら、ON/OFF で判断できるブレーキランプの信号に注目するだけでよい。しかし、運転行動を予測するためにはブレーキを踏む前に判断しなければならないので、ブレーキランプによる判断では不可能である。

そこで本研究では、ブレーキを離れた直後やブレーキを踏む直前のドライバーの操作量や車速などを切り出して、その特徴をとらえるための検討を行っている。切り出したパターンを用いて認識及び予測を行うのは、ドライバーがブレーキを踏む意思があるかないかの2択問題である。しかし、本研究室で行ってきたこれまでの実験の結果から、さらに詳細なサブカテゴリを設定することで、認識及び予測精度が向上することが明らかとなった。これはニューラルネットワークの学習がより良い解に収束するからである。

こういった理由から本研究では、運転行動を発進、加速、継続、減速の4つのサブカテゴリに設定し、それぞれの定義に従う部分を走行データから切り出した。運転行動の各カテゴリの詳細を表 2.1 に示す。この中で、ブレーキをかける意思のない運転行動を発進、加速、継続とし、ブレーキをかける意思のある運転行動を減速とした。そしてこれらのカテゴリごとに切り出したパターンを用いてモデリングを行った。モデリングの詳細は第4章で説明する。

表 2.1 運転行動のカテゴリ

運転行動	定義
発進	速度が0の状態においてブレーキを放した直後の運転操作
加速	速度が0でない状態においてブレーキを放した直後の運転操作
継続	一定時間以上ブレーキを踏まず、アクセルの操作量に変化のない運転操作
減速	ブレーキをかける直前の運転操作

第3章 ニューラルネットワーク

ニューラルネットワークとは、人間の脳の情報処理システムを模倣して計算機上で高度な並列分散処理をしようとする数理モデルである。人間の脳は約 140 億の神経細胞（ニューロン）が結合して構成されており、目で見た映像は神経細胞によって細かく符号化され、電気信号として伝播される。そして、その信号を明暗や気分などの様々な環境による変化を補正や処理して、意識に蓄積する。また、「あいまいさ」に対して脳は非常に器用に判断する。ニューラルネットワークはこういった脳の構造を数学的に表現するモデルである。また、ニューラルネットワークは、多次元のデータのように解析が困難である非線形な問題に対しても有効なモデルを構築することができ、特徴を捉えにくい問題に対しては、学習を繰り返すことで柔軟に対応することができる。こういった特徴から、現在ニューラルネットワークは様々な分野でパターン認識や予測に用いられている[7]。

第3章では、ニューラルネットワークの概要、学習の仕方について詳しく説明し、それを用いた運転行動の認識及び予測の方法を説明する。

3.1 ネットワーク構造

ニューラルネットワークは複数のニューロンの結合によって構成されている。結合の種類はおおまかな分類として、階層型のネットワークと相互結合型のネットワークがある。階層型のネットワークとは、図 3.1 のようにニューロンが複数の階層となるように並び、下位層から上位層に向かう方向に結合があるものである。一方、相互結合型のネットワークとは、図 3.2 のように任意の2つのニューロン間で両方向の結合があるようなものである。この場合、ニューロンの学習過程にも必ずフィードバックループが含まれる。本研究で用いるネットワークモデルは、階層型のネットワークである3層パーセプトロンである。これはパターン認識に最も一般的に用いられるものである[8]。パーセプトロンとはS(入力)層、A(中間)層、R(出力)層からなるネットワークで、各層は問題に応じた数のニューロンで構成される。また、同じ層での結合はなく、層間の結合は、

$S \rightarrow A \rightarrow R$ という一方向の結合である。このネットワークは、まず S 層に認識したいパターンが入力されると、 $S-A$ 間の結合で変換された値が A 層に入力される。そしてその値が $A-R$ 間の結合により変換され、 R 層から結果として出力される。この時、ネットワーク結合を学習によって修正していくことでモデルを構築していく。パーセプトロンの学習については次節で説明する。




図 3.1 階層型ネットワーク




図 3.2 相互結合型ネットワーク




図 3.3 3層パーセプトロン

3.2 誤差逆伝播法による学習

ニューラルネットワークの学習は、特定の入力パターンを与えたとき、ネットワークの出力が教師信号と同じになるように、すなわち出力と教師信号との誤差が小さくなるように結合荷重を修正するというものである。ここで教師信号とは、ある入力データに対して期待する出力データのことであり、入力データと教師信号を合わせて学習データという。誤差逆伝播法とは、1986年にRumelhartらによって入力層、中間層、出力層から構成される階層型構造のニューラルネットワークに対して提案された教師信号付きの学習法である。以下で学習の内容を説明する。

まず、入力信号が入力層、中間層、出力層を経て出力されるまでの前向き計算を行う。誤差逆伝播法では各層のニューロンの値（ネット値）を規格化して出力する必要がある、本研究ではそのための関数 f として式(3.1)に示すシグモイド関数を用いた。なお、入力層のニューロン（入力素子）からは入力された信号の値がそのまま出力される。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.1)$$

入力信号を X_i 、入力素子から中間層のニューロン(中間素子)への結合荷重を W_{ij} 、 n を入力素子数とすると、中間素子 Y_j のネット値は式(3.2)で表され、 Y_j を規格化した出力を H_j とすると H_j は式(3.3)となる。

$$Y_j = \sum_{i=1}^n (X_i W_{ij}) \quad (3.2)$$

$$H_j = f(Y_j) = \frac{1}{\{1 + \exp\{-\sum_{i=1}^n X_i W_{ij}\}\}} \quad (3.3)$$

同様に、 V_{jk} を中間素子から出力層のニューロン（出力素子）への結合荷重、 m を中間素子数とすると、出力素子 Z_k のネット値は式(3.4)で表され、 Z_k を規格化した出力を O_k とすると O_k は式(3.5)となる。

$$Z_k = \sum_{j=1}^m (H_j V_{jk}) \quad (3.4)$$

$$O_k = f(Z_k) = \frac{1}{\{1 + \exp\{-\sum_{j=1}^m H_j * V_{jk}\}\}} \quad (3.5)$$

次に、出力素子からの出力値 O_k と教師信号 T_k との誤差の評価を行う。本研究では、 O_k と T_k の誤差を平均二乗誤差関数で計算した。ある学習パターン p の誤差 E_p は式(3.6)で表され、学習パターン数が P の時、全ての誤差 E_l は式(3.7)で表される。ここで l は出力素子数である。

$$E_p = \frac{1}{2} \sum_{k=1}^l (O_k - T_k)^2 \quad (3.6)$$

$$E_l = \frac{1}{P} \sum_{p=1}^P E_p = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^l (O_{pk} - T_{pk})^2 \quad (3.7)$$

そしてこの誤差 E_l が小さくなる方向に、結合荷重を修正する後向き計算を行う。本研究では最急降下法を用いて修正を行った。修正は出力層から入力層へと逆方向に進んで行われる。

まず、出力層と中間層の間の結合荷重の修正を行う。 V_{jk} に対する誤差 E_p の微小変化は、 E_p を V_{jk} により偏微分することで求められる。よって V_{jk} の修正量 ΔV_{jk} は式(3.8)で表される。

$$\Delta V_{jk} = -\eta \frac{\partial E_p}{\partial V_{jk}} = -\eta \frac{\partial E_p}{\partial O_k} \frac{\partial O_k}{\partial Z_k} \frac{\partial Z_k}{\partial V_{jk}} \quad (3.8)$$

ここで、 η は学習率という更新幅を決める定数である。学習率は、あまり小さくすると学習回数が膨大になってしまい、逆に大きくすると誤差の極小値を飛び越えてしまうため、経験で設定される定数である。(3.8)式の右辺をそれぞれ計算すると

$$\Delta V_{jk} = -\eta \{-(T_k - O_k) O_k (1 - O_k) H_j\} \quad (3.9)$$

となり，結合荷重の更新値 V_{jk}^{new} は式(3.10)となる．

$$V_{jk}^{new} = V_{jk}^{old} + \Delta V_{jk} \quad (3.10)$$

同様に中間層と入力層の間の結合荷重の修正を行う． W_{ij} の修正量 ΔW_{ij} は連鎖律により式(3.11)で表される．

$$\Delta W_{ij} = -\eta \frac{\partial E_p}{\partial W_{ij}} = -\eta \left\{ \sum_{k=1}^l \frac{\partial E_k}{\partial O_k} \frac{\partial O_k}{\partial Z_k} \frac{\partial Z_k}{\partial H_j} \right\} \frac{\partial H_j}{\partial Y_j} \frac{\partial Y_j}{\partial W_{ij}} \quad (3.11)$$

これを計算すると式(3.12)となり，結合荷重の更新値 W_{ij}^{new} は(3.13)となる．この結合荷重の修正を，学習回数による制限や誤差が極小値になるなどの終了条件まで繰り返し行う．

$$\Delta W_{ij} = -\eta H_j (1 - H_j) X_i \sum_{k=1}^l W_{kl} (T_k - O_k) O_k (1 - O_k) \quad (3.12)$$

$$W_{ij}^{new} = W_{ij}^{old} + \Delta W_{ij} \quad (3.13)$$

このように結合荷重の修正を行う時に，誤差情報が出力層から入力層，つまりパーセプトロンの流れる向きとは逆方向へ伝播していくことから，こういった学習の仕方は誤差逆伝播法と呼ばれる．

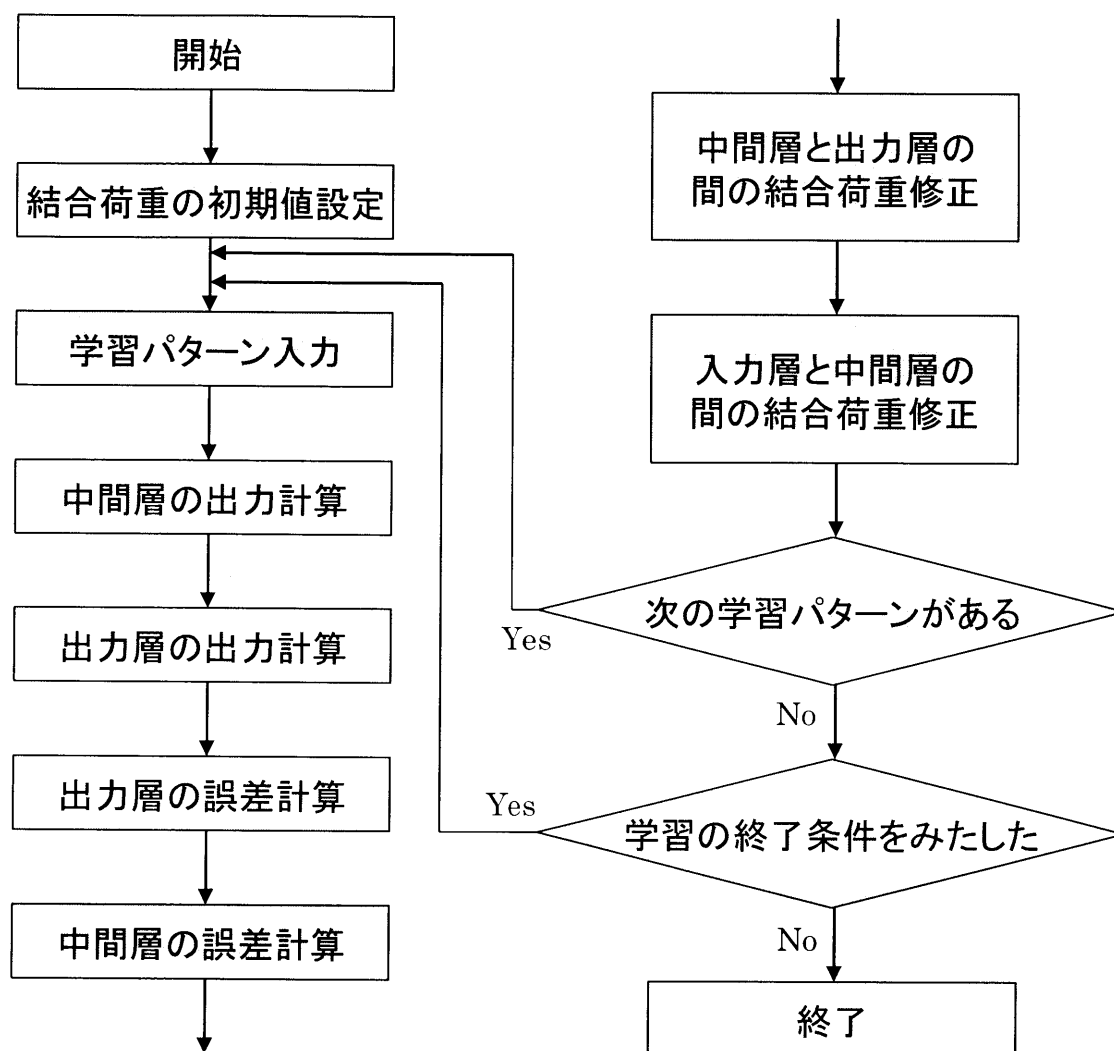


図 3.4 誤差逆伝播法のアルゴリズム

3.3 運転行動の認識方法

前節まで、ニューラルネットワークとその学習法について説明した。本節では、ニューラルネットワークを用いた運転行動の認識方法について説明する。

まず、計測した走行データを学習用とテスト用に分ける。次に、学習用のデータから各運転行動カテゴリの定義により学習パターンを切り出し、そのパターンを入力として誤差逆伝播法で学習を行い、モデルを構築する。運転行動のカテゴリは発進、加速、継続、減速の4つであるので、モデルの出力素子数は4となる。構築したモデルに未知パターンを入力すると、モデルは計算を行い、分類結果を出力する。分類結果とは、出力素子の値で最も大きいものである。そして未知パターンとしてテストデータを入力した場合に、テストデータ中で運転行動のとられた、つまりブレーキ操作のあったパターンに対して、正しく運転行動を分類することができれば、運転行動を認識しているということとなる。認識率は以下の式で表す。

また、本研究で認識及び予測する運転操作は、ブレーキをかける意思がある行動か、ない行動かということであるので、ブレーキをかける意思のない運転行動である発進、加速、継続は、その3つの中のどの運転行動に分類されても認識は成功とする。つまり発進を加速や継続と分類してしまっても、運転行動を認識できているということにする。

$$\text{認識率} = \frac{\text{正しく分類できた運転行動数}}{\text{テストデータ中の全運転行動数}}$$

次に予測の方法について説明する。本研究では、予測とはテストデータ中で運転行動のとられたパターンの、さらに数秒前のパターンを入力した時に、その運転行動を認識できるかということである。例えば、ある運転行動のとられた時間が t 秒だとすると、 $t-1$ 秒時のパターンでその運転行動を認識できれば、それは1秒後を予測できたということになる。

第4章 最適なモデルの検討

ニューラルネットワークには、ドライバーの操作パターンを時系列の形で入力する。同じ運転行動であっても、その時のドライバーの操作量は全く同じということとはほとんどなく、ドライバーによっても異なる。しかも、操作パターンは時間的に一様に伸縮するわけではない。そのため、モデリングは似たようなパターンが入力された時にも、正しく分類できるような汎用的なモデルが必要となる。学習パターンからどれだけ学習するかによってモデルの汎用性が決まるため、過学習や未学習にならない最適な学習をさせることが重要となる。そのためには、入力素子数、中間素子数、学習の終了条件などを適切に設定する必要がある。

本研究で扱う計測データは、高速道路と一般道路のデータを分けて記録してあるが、高速道路では一般道路に比べてブレーキを踏む機会が少なく、操作パターンも単調であるため、各カテゴリーの特徴がとらえにくく、モデリングが困難である。また、ブレーキ操作ミスなどによって起こる交通事故は一般道路の方が多いため、モデリングには一般道路のデータのみを用いた。

第4章では、パラメータの設定などニューラルネットワークのモデリングの詳細について説明する。

4.1 入力層の検討

ニューラルネットワークの学習は、入力される情報の特徴をとらえ、出力層の各カテゴリーに正しく分類できるように行っていく。そのため操作パターンには、計測される信号の中でも、各運転行動の特徴を多く含んでいる信号を用いるのが有効である。さらに、信号を複数組み合わせることで、より高精度なモデリングも可能となる。そこで、本研究では予備実験の結果より、入力に用いる信号を車速、アクセル開度、G センサ(前後)の3種類とした。参考までに認識精度の高かった信号の組み合わせを表4.1に示す。

次に、入力に何秒分のパターンを用いるか検討を行った。学習に用いる時間を長くすると、同じ運転行動であっても、少しでも違うパターンの入力の場合

にはうまく認識できず、逆に短くすると、入力信号が各運転行動の特徴を含まなくなりモデルの精度が低下する。そこで、入力時間を2秒から9秒まで変化させて、それぞれの認識率を求めた。結果から入力時間は7秒とした。結果を表4.2に示す。

また、入力に用いる信号は、計測値をそのまま用いるのではなく、正規化をしてから用いる。ニューラルネットワークの学習は、学習データのそれぞれの入力変数の平均がほとんど0であり、それぞれの入力変数が同じ共分散を持つときに収束が早いことから[9]、平均0、分散1となるように正規化して入力に用いた。

表 4.1 信号の組み合わせによる認識率

入力信号の組み合わせ	認識率
アクセル開度・車速・Gセンサ(前後)	89.6%
アクセル開度・車速	86.3%
アクセル開度	86.2%
車速・Gセンサ(前後)	81.8%
Gセンサ(前後)	81.4%

表 4.2 入力時間に対する認識率

入力時間	認識率
2 秒	88.2%
3 秒	87.6%
4 秒	87.0%
5 秒	88.6%
6 秒	89.7%
7 秒	90.2%
8 秒	88.3%
9 秒	86.1%

4.2 中間層及びモデルの学習の検討

前節で入力素子を決定したので、次に中間素子数の決定を行う。中間素子数も入力素子数と同様に、数が多すぎると過学習となり、少なすぎると未学習となる。また、最適なモデルを構築するために重要な要素として、学習の終了条件がある。一般的なニューラルネットワークの学習は、出力と教師信号の誤差が極小となるまで行うが、汎用的なモデルを構築するためにはこの終了条件も適切に設定する必要がある。何故なら、表 4.3 で示すように、学習を繰り返し行い、出力と教師信号の誤差が小さくなっていても、テストデータの認識率は向上するとは限らないからである。そして、中間素子数と学習の終了条件はそれぞれ独立なものではなく、依存関係がある。つまり、同じ学習の終了条件で求めた最適な中間素子数と、同じ中間素子数で求めた最適な学習の終了条件を組み合わせモデリングを行っても、それは最適なモデルとはならない。

表 4.3 学習による誤差と認識率

学習回数	出力と教師信号の誤差	認識率
800	224.207	88.8%
1000	184.499	89.3%
1200	158.415	89.1%
1500	123.268	87.9%
2000	112.354	88.1%
3000	90.432	85.8%

そこで、中間素子数と学習の終了条件の最適な組み合わせを見つけるために Weight Decay 法という、ニューラルネットワークで推定される関数を滑らかにすることにより、分散を抑えようとする正規化手法を用いる。この手法では、誤差関数 E を以下の(4.1)式のように変形する。

$$E_t = \frac{1}{P} \sum_{p=1}^P E_p + \lambda \frac{1}{S} \sum_{i=1}^S (W_i)^2 = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^I (O_{pk} - T_{pk})^2 + \lambda \frac{1}{S} \sum_{i=1}^S (W_i)^2 \quad (4.1)$$

ここで w_i は結合荷重, S は結合荷重の総数, そして λ は Weight Decay パラメータである. この右辺に付加された項によって, 過学習を防ぐため, 学習による誤差が極小となったモデルが最適なものとなる. つまり, λ の値と中間素子数を組み合わせ, 最も誤差の小さくなった組み合わせが最適なモデルとなる.

そこで, 中間素子数と λ の値を組み合わせ, 実験を行った. 評価には 10-fold Cross Validation を用いた. 結果は以下の表 4.4 となった. この結果から, モデルの中間素子数を 10, λ の値は 10 とした.

表 4.4 10-fold Cross Validation 結果

		中間素子数					
		1	2	5	10	20	50
Lambda	10^{-4}	6.37940	4.44101	2.16058	2.03136	2.21997	2.51480
	10^{-3}	6.37940	4.44101	2.16058	2.03136	2.21997	2.51480
	10^{-2}	6.37940	4.44101	2.16058	2.03136	2.21997	2.51480
	10^{-1}	6.20686	4.44101	2.17428	2.03185	2.21998	2.51480
	10^0	5.88183	4.44101	2.17993	2.03145	2.21522	2.51542
	10^1	9.92524	4.43241	2.23720	2.01791	2.20978	2.52264
	10^2	13.16904	15.22297	17.74179	14.82715	2.19875	2.61007

4.3 学習パターンの選別

本研究では、ブレーキ操作を行う運転行動の認識及び予測を行っているため、走行データからパターンを切り出すのに、ブレーキランプの ON/OFF を用いる。そのため、切り出しを行う時にパターンの入力信号の検討は行っておらず、これらの計測値はノイズの影響を受けている可能性がある。実際に各カテゴリで切り出されたパターンを調べてみたところ、アクセル操作中にブレーキランプが ON になっているなどのパターンが見つかった。アクセルとブレーキを同時に踏むことはないので、これは計測システムの問題であると考えられる。つまり、ブレーキを踏む意思がないパターンを、ブレーキを踏む意思のあるカテゴリへ切り出してしまっているということになる。このように誤って切り出されたパターンを用いてニューラルネットワークの学習を行うと、当然、モデルの精度は低下する。そこで、ノイズの影響を受けていると思われるパターンの選別を、切り出した全てのパターンに対して行った。以下に選別の詳細を示す。

4.3.1 発進

発進カテゴリの定義に従ってパターンの切り出しを行った。切り出した発進パターンは 886 個であった。発進パターンは停止状態からブレーキを離した直後であるので、パターンの開始から各操作量が高い値をとることはありえない。そこで、以下の条件でパターンを選別した。選別後、発進パターンは 719 個となった。

表 4.5 発進パターンの選別条件

信号	選別条件
車速	パターン開始時に 0(km/h)でない。
アクセル開度	パターン開始時に 0.11(v)以上である。
Gセンサ	パターン開始時に 0.15(v)以上である。

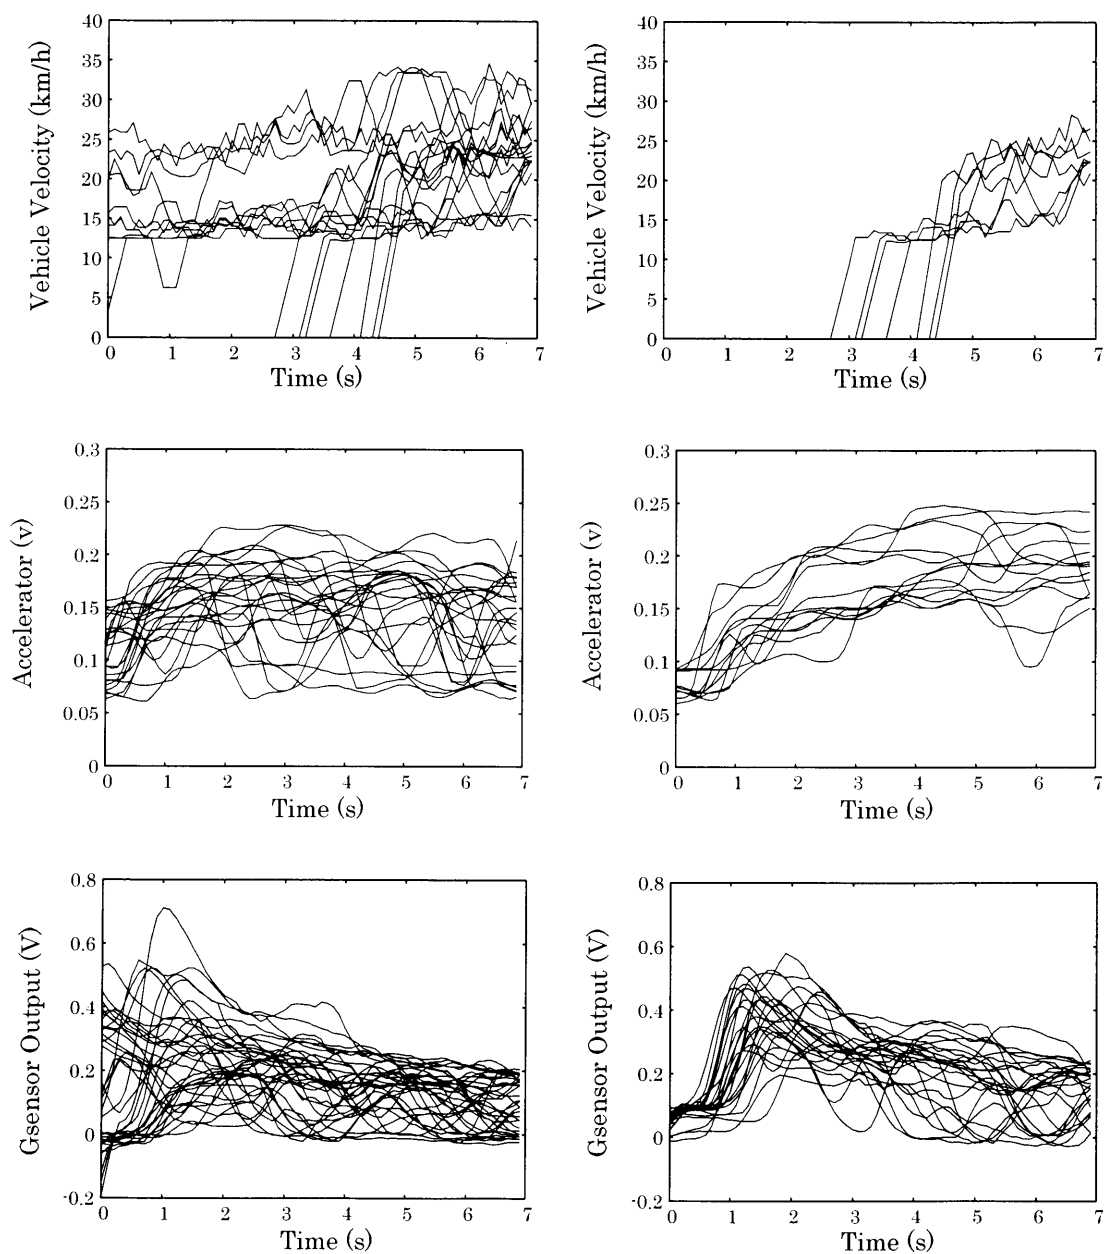


図 4.1 発進パターンの選別前と選別後

4.3.2 加速

加速カテゴリの定義に従ってパターンの切り出しを行った。切り出した加速パターンは709個であった。加速パターンも発進パターンと同様にブレーキを離した直後であるが、この中で、ノイズの影響によりアクセル開度が急激に上昇するものが見つかった。また、加速中に車速が0となることもありえない。そこで、以下の条件でパターンを選別した。選別後、加速パターンは580個となった。

表 4.6 加速パターンの選別条件

信号	選別条件
車速	パターン中に 0(km/h)となる。
アクセル開度	パターン中に 0.25(v)以上となる。

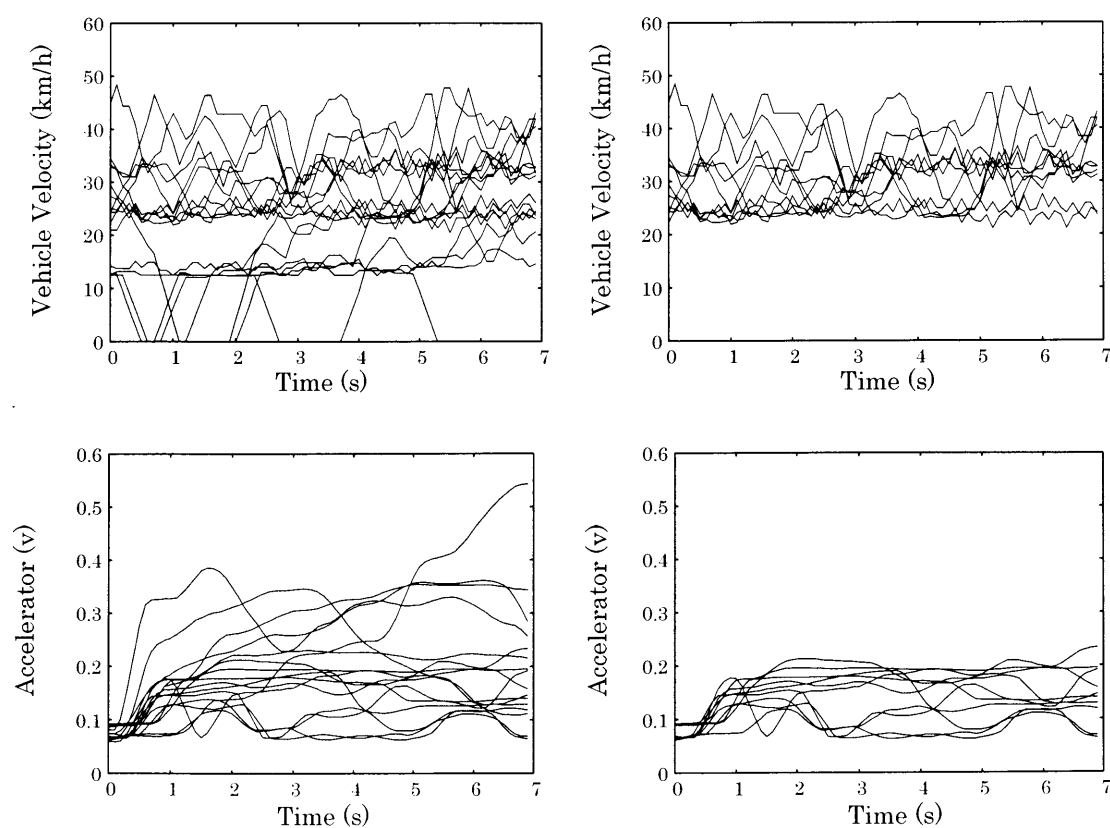


図 4.2 加速パターンの選別前と選別後

4.3.3 継続

継続カテゴリの定義に従ってパターンの切り出しを行った。切り出した継続パターンは1604個であった。継続パターンは、一定時間以上アクセルの操作量が変化しない行動と定義してあるが、切り出したパターンからはノイズの影響でアクセル開度や車速の値に変化が見られた。また、アクセルの操作量がなく、車速が低い場合は事故の危険性は少ないと考えられるので、以下の条件でパターンを選別した。選別後、継続パターンは817個となった。

表 4.7 継続パターンの選別条件

信号	選別条件
車速	<ul style="list-style-type: none"> ・パターン中に 20(km/h)以下となる。 ・パターン中の最高値と最低値の差が 20(km/h)以上となる。
アクセル開度	パターン中の最高値と最低値の差が 0.1(v)以上となる。

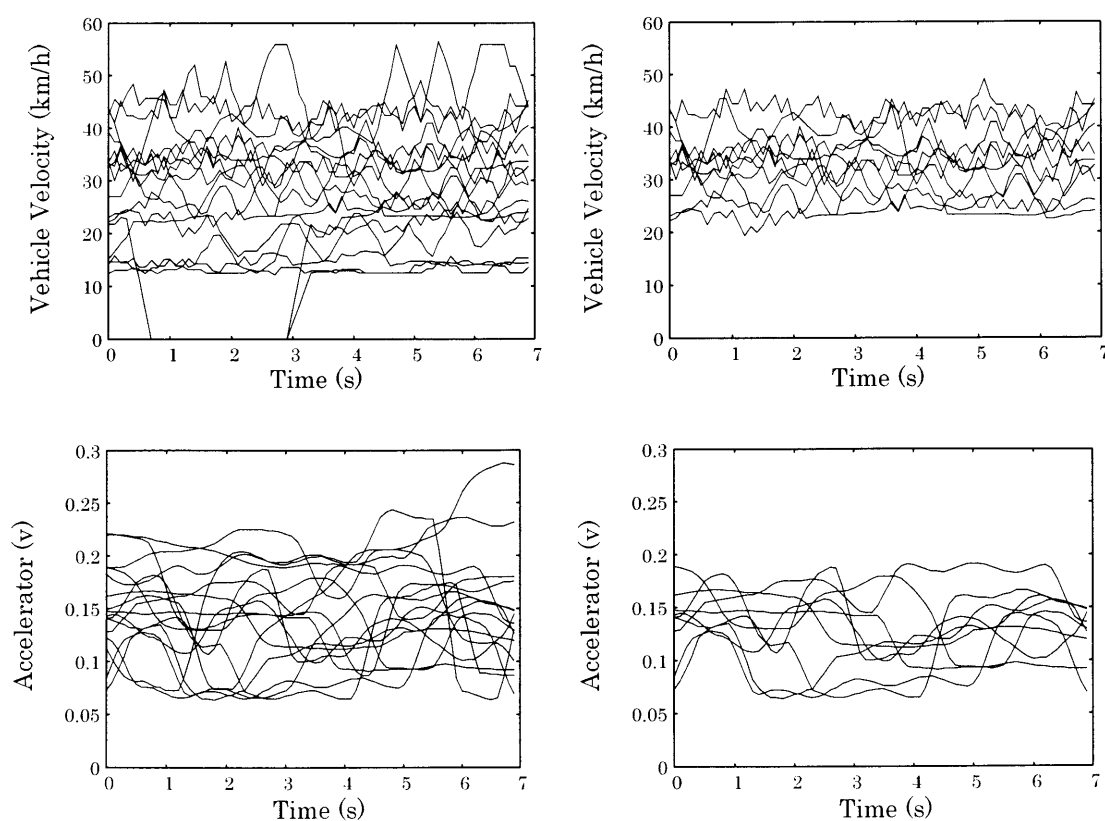


図 4.3 継続パターンの選別前と選別後

4.3.4 減速

減速カテゴリの定義に従ってパターンの切り出しを行った。切り出した減速パターンは1750個であった。減速パターンは、ブレーキを踏む直前であるので、パターン開始時に速度が0(km/h)となっていることや、ブレーキを踏む直前にアクセルを踏むということは考えられない。よって、これらはノイズの影響と考えられるので、以下の条件でパターンを選別した。選別後、減速パターンは1280個となった。

表 4.8 減速パターンの選別条件

信号	選別条件
車速	パターン開始時に 0(km/h)でない。
アクセル開度	パターン中に 0.25(v)以上となる。

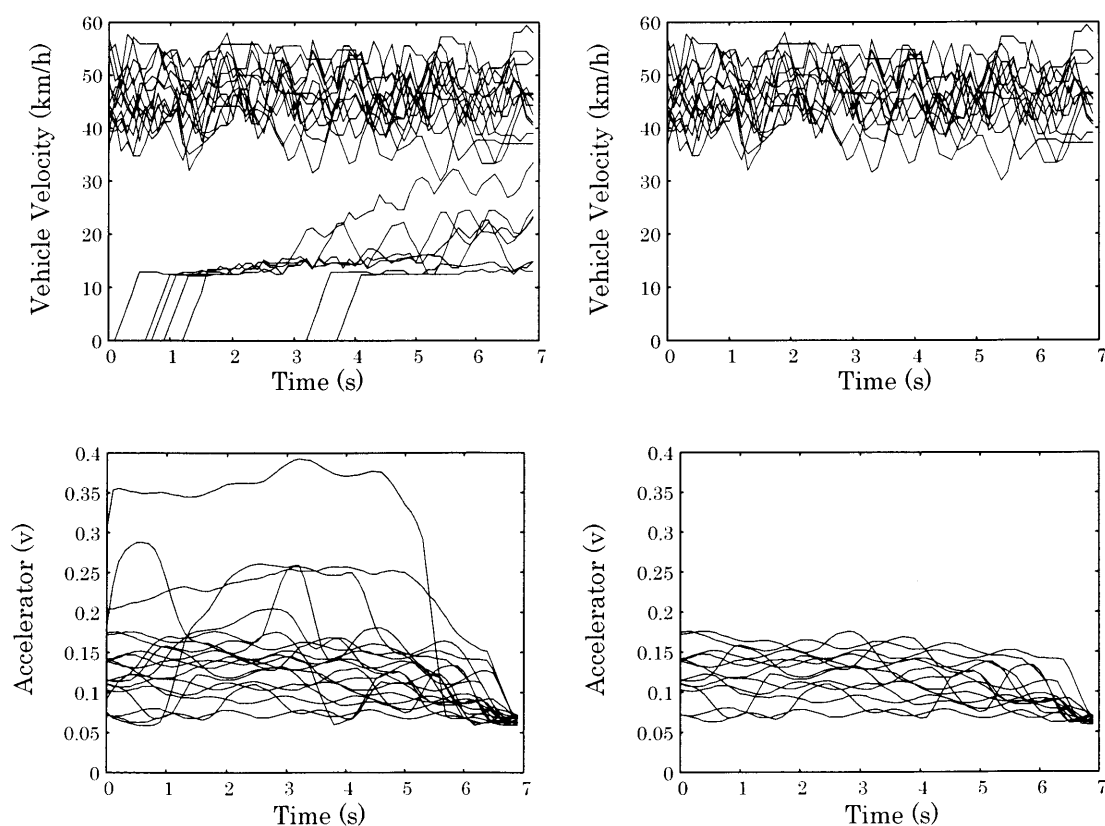


図 4.4 減速パターンの選別前と選別後

第5章 運転行動予測のシミュレーション

前章までに、最適なモデルを構築するためにそれぞれのパラメータの検討と、データの選別を行った。これまでのニューラルネットワークモデルを用いたシミュレーションでは、認識率は高い精度であったが、予測確率は隠れマルコフモデルによるシミュレーション[10]などに比べて低い精度であった。これはニューラルネットワークが学習パターンの伸縮や、アクセルを踏むタイミングが少し違うといった、パターンのずれに対応しにくいからである。この場合、ブレーキ操作の行われる直前、直後の学習パターンのみで構築したモデルで認識と予測を行うのは困難である。そこで、予測にはブレーキ操作の行われる数秒前のパターンをモデルの学習に用いることで予測精度が向上すると考えられる。

第5章では、運転行動予測のために行ったシミュレーションの方法と、その結果について説明する。

5.1 シミュレーション方法

シミュレーションに用いたパターン数は、学習用が 1525、テスト用が 1871 である。モデリングには、前章で決定した表 5.1 のパラメータを用い、結合荷重の初期値を乱数によって 100 通り設定した[11]。これらの条件で、学習にブレーキ操作のとられる t 秒前のパターンを用いた場合のシミュレーション、ブレーキ操作のとられる t 秒前から $t - \alpha$ 秒前までの数パターンを用いた場合のシミュレーションを行い、それぞれ予測確率を求めた。

また、第1章で述べたように、危険を安全に回避するためには約2秒後の予測が必要であるということから、本研究では2秒後の予測確率まで求めた。

表 5.1 モデルの各パラメータとその値

パラメータ	値
入力信号	車速・アクセル開度・Gセンサ(前後)
入力時間	7 秒
入力素子数	2 1 0 個
中間素子数	1 0 個
出力素子数	4 個
Weight Decay パラメータ	1 0

5.2 シミュレーション結果

まず、シミュレーション1として、運転行動のとられる直前や直後のパターン（0秒のパターン）を入力としてモデリングし、シミュレーションを行った。結果は、認識率は約94%、1秒後の予測確率は約70%、2秒後の予測確率は約66%となった。結果を図5.1に示す。また、参考までに認識結果の詳細を表5.2に示す。前述したように、各運転行動のとられる直前や直後の操作パターンのみでモデルを構築した場合には、予測確率が大幅に低下することが確認できる。

表 5.2 認識結果の詳細

	分類された運転行動			
	発進	加速	継続	減速
発進	402	4	0	0
加速	11	270	11	14
継続	0	21	363	66
減速	2	26	3	678




図 5.1 シミュレーション 1 の結果

次に、シミュレーション2として、各運転行動のとられる t 秒前のパターンを入力としてモデリングし、シミュレーションを行った。結果を図5.2に示す。結果から最も予測確率の高かったパターンでは、1秒後の予測確率が約77%、2秒後の予測確率が約77%となった。この結果から、学習に t 秒前のパターンを用いて構築したモデルでは、テストデータの t 秒後の予測に対してこれまでのパターンより高い精度となった。

表 5.3 シミュレーション 2 の設定

モデリングに用いるパターン	パターン名称
0.0 秒のパターン	A
0.5 秒前のパターン	B
1.0 秒前のパターン	C
1.5 秒前のパターン	D
2.0 秒前のパターン	E

	認識率	1 秒後の予測確率	2 秒後の予測確率
最高値	A : 94.1%	C : 77.0%	E : 76.6%
最低値	E : 54.6%	E : 62.1%	A : 66.4%




図 5.2 シミュレーション 2 の結果

また、シミュレーション 3, 4, 5, 6 では、1つの運転行動に対して、その運転行動のとられる t 秒前のパターンから $t-\alpha$ 秒前までの数パターンを、それぞれ入力に用いてモデリングし、シミュレーションを行った。入力として、0.5 秒分(5 パターン)、1.0 秒分(10 パターン)、1.5 秒分(15 パターン)、2.0 秒分(20 パターン)の場合で検討した。それぞれのシミュレーションの設定を表 5.4, 5.5, 5.6, 5.7 に示す。

このシミュレーションは、前述したようにパターンのずれに対応しにくいというニューラルネットワークの特徴に対して、あらかじめ1つの運転行動に対して、そのパターンをずらして学習させることで、より柔軟に予測を行うためのものである。パターンをずらすとは、例えば基準の入力パターンを1.0 秒前の操作パターンだとすると、それに対し 1.1 秒前、1.2 秒前の操作パターンも学習に用いることである。これらのシミュレーションを行った結果を図 5.3, 5.4, 5.5 に示す。

結果から 2 秒後の予測確率では、2 秒前のパターンから学習したモデルより、2 秒前のパターンから 1.6 秒前のパターンまでの 5 パターンを入力に用いた場合の方が、予測確率が高くなった。これにより、運転行動の予測を行う時にあらかじめパターンをずらして入力してモデルを構築することが有効であることが分かった。

表 5.4 シミュレーション 3 の設定

入力に用いるパターン	パターン名称
0.1 秒前のパターンから 0.5 秒前までの 5 パターン	F
0.6 秒前のパターンから 1.0 秒前までの 5 パターン	G
1.1 秒前のパターンから 1.5 秒前までの 5 パターン	H
1.6 秒前のパターンから 2.0 秒前までの 5 パターン	I

	認識率	1 秒後の予測確率	2 秒後の予測確率
最高値	F : 90.5%	G : 79.6%	I : 78.0%
最低値	I : 57.9%	I : 68.3%	F : 70.7%




図 5.3 シミュレーション 3 の結果

表 5.5 シミュレーション 4 の設定

入力に用いるパターン	パターン名称
0.1 秒前のパターンから 1.0 秒前までの 10 パターン	J
0.6 秒前のパターンから 1.5 秒前までの 10 パターン	K
1.1 秒前のパターンから 2.0 秒前までの 10 パターン	L

	認識率	1 秒後の予測確率	2 秒後の予測確率
最高値	J : 88.0%	K : 78.6%	L : 74.9%
最低値	L : 61.2%	L : 72.0%	J : 68.3%




図 5.4 シミュレーション 4 の結果

表 5.6 シミュレーション5の設定

入力に用いるパターン	パターン名称
0.1秒前のパターンから1.5秒前までの15パターン	M
0.6秒前のパターンから2.0秒前までの15パターン	N
0.1秒前のパターンから2.0秒前までの20パターン	O

	認識率	1秒後の予測確率	2秒後の予測確率
最高値	M : 86.2%	M : 78.5%	N : 76.0%
最低値	N : 76.2%	N : 78.0%	O : 73.3%

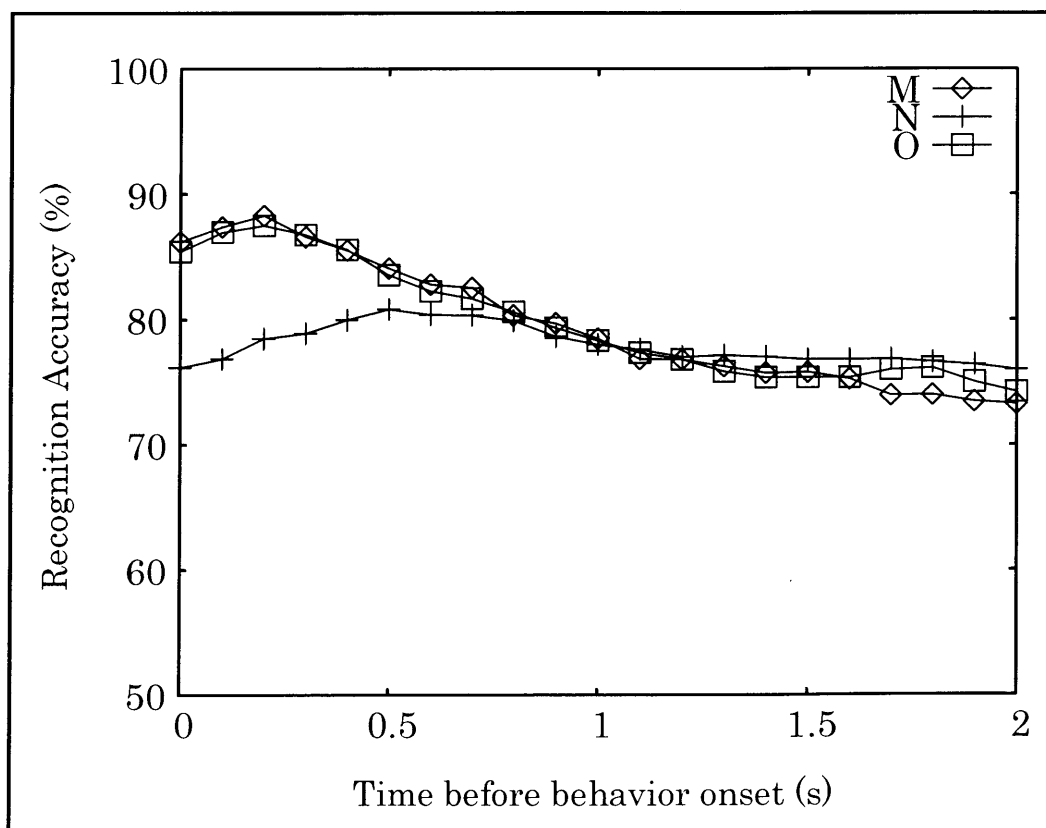


図 5.5 シミュレーション5の結果

第6章 結論

6.1 まとめ

本研究では、危険を安全に回避するための安全運転支援システムの構築を目標とし、そのために必要なドライバーの行動の予測を行うために、実際に公道を走行して計測したデータから運転行動をモデリングし、その認識及び予測のシミュレーションを行った。

ニューラルネットワークのモデリングにおいて、これまで少ないデータ数で行っていたため、未知のデータに対して汎用的でなかったモデルから、計測データのノイズ、入力素子数、中間素子数、そして学習の終了条件について検討し、運転行動の予測に対して最適なモデルを構築した。

また、運転行動の予測を行うために、ドライバーがブレーキ操作を行う数秒前のパターンや、ブレーキ操作を行う t 秒前のパターンから $t-\alpha$ 秒前のパターンを組み合わせ学習し、モデルを構築することで運転行動の予測精度の向上につながることが分かった。本研究で構築したモデルを用いて、ドライバーのブレーキ操作を認識及び予測する場合、認識率は約94%、1秒後の運転行動の予測確率は約80%、2秒後の運転行動の予測確率は約78%となり、ブレーキ操作の行われる直前や直後のパターンで学習したモデルに比べて予測確率は約10%の向上が見られた。

6.2 今後の課題

運転行動認識の詳細な検討を行うために、隠れマルコフモデルやファジィモデルといった、ニューラルネットワーク以外のモデルの検討を行うこと。また、本研究では計測信号からノイズの除去などの前処理を行っていたが、センサ特性などを把握し、計測システムの改良を行うこと。そして、ウインカーやギア、回転数など、新しい信号を用いてモデリングを行うことなどが今後の課題である。

参考文献

- [1] 交通事故総合分析センター，交通事故件数・死者数，
<http://www.itarda.or.jp>
- [2] 日経 Automotive Technology 2005 winter, 2005
- [3] A.Pentland and A.Liu, Neural Computation, Vol.11, 1999
- [4] Johan Engstrom, Trent Victor, 2001 IEEE ITSC Proceedings, 2001
- [5] T.Miyazaki, T.Kodama, T.Furuhashi, and H.Ohno, 2001 IEEE ITSC Proceedings, 2001
- [6] 武田一哉，“運転操作信号のケプストラム分析に基づく運転者識別”，情報処理学会，2006
- [7] 中野馨，飯沼一元，“ニューロコンピュータ”，技術評論社，1994
- [8] 上坂吉則，尾関和彦，“パターン認識と学習のアルゴリズム”，文一総合出版，1990
- [9] William H.Press, Brian P.Flannery, “Numerical Recipes in C”，技術評論社，2004
- [10] Genevieve B.Orr and Klaus-Robert Muller, Neural Networks : Tricks of the Trade, 1998
- [11] 坂口倍彦，“隠れマルコフモデルを用いた運転行動認識のモデル構築に関する研究”，三重大学大学院修士論文，2006

謝辞

本研究を進めるにあたり，日頃から適切なご指導を賜りました，三重大学工学部教授 成瀬央先生に深く感謝致します．本研究に対し，貴重なご助言を頂きました，三重大学工学部助手 竹内一郎先生に厚く御礼申し上げます．そして，研究の実施及び分析，本論文の作成に終始熱心なご指導を賜りました，三重大学総合情報処理センター 児玉哲司先生に心から感謝致します．

また，親身なご指導を賜りました先輩方，学生生活を共にした研究室の皆様に感謝致します．

最後に，日頃の研究活動を暖かく見守ってくれた友人，そして何より両親に感謝します．

発表論文リスト

- [1] 織田勇也, 児玉哲司, “操作量を用いたニューラルネットワークによる運転行動のモデリング”, 平成 18 年度電気関係学会東海支部連合大会, O-261, 2006