

ファジィモデル自動車の再構成データを与える実測データ 規範シミュレーションの提案と検討†

千葉 信二*・板倉 直明**・本多 中二**・猪飼 國夫***

ABSTRACT We have proposed a microscopic road traffic simulator (MITRAM) for analyzing chronic traffic congestion on road in a city area. The fuzzy model vehicle (FMV) is used for the MITRAM. We have tried to simulate the actual accelerator and brake operations to follow a leading vehicle by using the FMV constructed by neural networks. This FMV was trained with actual measurement data to reproduce the actual operations. The actual operations were reproduced in most of the simulation results. However, the simulation results greatly different from the actual operations also existed in some cases. It is thought that one certain operation was gained by experiencing many driving situations. Therefore, it was thought that some actual operation that we wanted to reproduce might not be reproduced by the FMV trained with only measurement data obtained during the same actual operation that we wanted to reproduce. In this paper, measurement data reference simulation was proposed as the technique of giving the training data which are not only the measurement data to the FMV. Since the FMV runs referring to the measurement data even when the FMV separates greatly with those in this simulation, ideal data which brings the FMV close to the measurement data can be made. We investigated whether some actual operation would be reproduced by the FMV which was trained with both data from the measurement data reference simulation and measurement data. It was found that the measurement data reference simulation was effective method as the technique of making the training data for the FMV.

1. はじめに

近年、都市部における自動車交通量の増加により、市街地での慢性的な自動車の渋滞が大きな社会問題となっている。この問題の対策として、自動車の総量規制および新規道路の建設など挙げられるが、これらの対策の実現は非常に困難であると言える。そのような状況の中、渋滞問題を解消していくためには現状の道路施設を有効に使用することが現実的な対策であり、そのためにはシミュレータを用いて渋滞解析をする必要がある。そこで現在に至るまでに道路交通シミュレータにおいて、車両移動の表現を全体的に流体として捉えるマクロモデルや個々の車両を表現するミクロ

モデルなど様々なシミュレータが開発されている^{1)~15)}。しかし市街地を対象とした場合、車線変更・追い越しなどの様なより細かな車両挙動を直接的に表現できるミクロレベルで渋滞解析を行えるようなシミュレーションシステムが必要であり、またその際の人間の運転操作は道路上の様々な情報からファジィ的に決定しており、その車両挙動のモデル化が非常に重要になってくる。

そこで我々はファジィ推論処理専用のプロセッサを開発し、それを用いた微視的道路交通シミュレータ(MITRAM)を提案した^{16)~19)}。このシミュレータでは運転者の運転操作論理をファジィモデルで表現し、個々の車両挙動を決定するファジィモデル自動車(Fuzzy Model Vehicle, 以下 FMV と略す)を用いている。また、このようなミクロモデルでのシミュレータ構築において追従運転論理を基本として考え、そのシミュレータに FMV を適用し先行車に追従する車両の挙動を決定している。

FMV とは個々の運転者の意思決定機構を、2 入力 1 出力の二項ファジィ論理を表現するファジィニューラルネットワーク (Fuzzy Neural Network 以下 FNN

Proposal and investigation of measurement data reference simulation to provide reconstruction data for fuzzy model vehicle. By Shinji Chiba (Fuji Photo Film Co., Ltd.), Naoki Itakura, Nakaji Honda (The University of Electro Communications) and Kunio Yikai (MI Venture's Corp.).

*富士写真フイルム㈱

**電気通信大学電気通信学部システム工学科

***㈱エム・アイ・ベンチャー

†2000 年 11 月 15 日受付 2001 年 3 月 8 日再受付

と略す)に場合分け要素を取り入れ、運転操作論理を人間に分かり易いようにモデリングしたものであり^{20~27)}、これは一般に人間が自動車を運転する際に周囲の状況によって運転の仕方が異なるという点に着目することにより、あらかじめこの異なる状況に対応したファジィ論理を複数用意し、これらのファジィ論理を使い分けるものである。また、この FMV は個々の運転特性をモデル化することが出来、測定された実走行時系列データさえあれば、それを FMV の学習用データとして FMV に学習させることにより個々の特性をモデル化することが出来る。また、その FMV を用いてシミュレーションを行った際に時系列で、しかも距離レベル(車間距離)で評価する必要があることがわかっている²⁷⁾。我々の FMV はこのような評価を用いてシミュレーションを行った場合でも、ほとんどのデータにおいて実走行を再現することが出来ていたのだが、データによっては上手く再現できないものがあった。

本来、実走行データはあくまで結果論であり、それをシミュレーション上で再現するには、その結果に至るまでの過程も重要な要素である。しかし、従来の方法では FMV に学習用データとして実走行データしか学習させておらず、上記の原因がその辺にあるのではないかと考えた。

以上の点を踏まえて本研究では、この FMV に与える学習用データに対して実走行データだけでなく、それ以外のデータを外挿することによって再構築し、その再構築された学習用データを FMV に学習させることによって FMV を再構成していく方法を提案する。また、FMV により有効な学習をさせるために、どの様なデータを供給すればよいのかということに焦点を絞り、学習と従来のシミュレーションのほかに、シミュレーション中に実走行データと比較して修正を掛けながら走らせる実測データ規範シミュレーションを行い、その結果と実測データを用いて学習用データを再構築し、FMV を再構成していくことを試みた。

2. 従来の FMV の学習法

2.1 階層構造からなる FMV

図 1 に本研究で用いる FMV のモデル構造を示す。詳細は文献²⁷⁾にあるので、ここではその概要を簡単に説明する。このモデルは階層構造になっており下位論理である後件部(二項演算部)と上位論理である前件部(場合分け部)から成り立っており、図中の FNN の部分が二項演算部を示す。




図 1 FMV のモデル構造

この FMV は入力を任意に設定することが出来、それら入力には先行車加速度、先行車速度、追従車加速度、追従車速度、相対速度、車間距離の 6 種類のパラメータを設定することが出来る。今後はどの様なパラメータの組合せを入力として与えれば良いのか検討する必要があるが、今回は入力として二項演算部に相対速度と追従車速度、場合分け部に車間距離と先行車加速度の 4 つのパラメータを用いた。

二項演算部 FNN は 1 つのファジィ論理として解釈することが出来、二項演算部では、入力として相対速度、追従車速度を与えることによって出力として Y_1 , Y_2 , Y_3 , Y_4 が得られる。次に場合分け部では車間距離、先行車加速度を入力とし、それぞれ、車間距離に対するメンバーシップ関数 (MSF) は、 W_{11} , W_{12} であり、先行車加速度に対する MSF は、 W_{21} , W_{22} である。また 2 つのファジィ変数 (車間距離→遠い, 近い: 先行車加速度→加速, 減速) についてそのファジィルールは、

R1→If 車間距離が近い and 先行車加速度が減速
then FNN1 出力 (追従車加速度 Y_1)

R2→If 車間距離が遠い and 先行車加速度が減速
then FNN2 出力 (追従車加速度 Y_2)

R3→If 車間距離が近い and 先行車加速度が加速
then FNN3 出力 (追従車加速度 Y_3)

R4→If 車間距離が遠い and 先行車加速度が加速
then FNN4 出力 (追従車加速度 Y_4)

と表される。また、FNN1~4 のファジィルールはそ

れぞれ R1~4 の入れ子構造と見なせる。

上記のファジィルールを用いて、最終出力 Y は各 FNN の出力 Y_1, Y_2, Y_3, Y_4 と、場合分け部入力の車間距離から得られるメンバーシップ値 W_{11}, W_{12} と先行車加速度から得られるメンバーシップ値 W_{21}, W_{22} より、次のように求められる。

$$Y = W_{21}(Y_1 \times W_{11} + Y_2 \times W_{12}) + W_{22}(Y_3 \times W_{11} + Y_4 \times W_{12})$$

学習時の誤差の分配も $W_{11}, W_{12}, W_{21}, W_{22}$ を用いる事により、それぞれの FNN が車間距離、先行車加速度の大小に応じた学習がなされる。学習はモデル化したい実走行データを学習に用い、この時の学習回数は 150 回とする。また、従来はこの様に FMV に実走行データのみを学習させる事によってそれぞれの実走行データをモデル化してきた。本論文ではこの従来の方法をノーマルモデルとする。

2.2 ノーマルシミュレーション

図 2 に我々が行っている追従運転のノーマルシミュレーションの様子を示す。FMV は次時点の追従車加速度を出力するように学習させているので、 t 時点のデータを入力した時、FMV から $t+1$ 時点の追従車加速度 $A_{FMV}[t+1]$ が出力され、それから $t+1$ 時点の各パラメータを差分の一般的な関係式

$$\begin{aligned} A[t+1] &= V[t+1] - V[t], \\ V[t+1] &= X[t+1] - X[t] \end{aligned} \quad (1)$$

$X[t], V[t], A[t]$: シミュレーション中 t 時点での位置、速度、加速度

によって計算し、その各パラメータを再び FMV に入力することによってさらに $t+2$ 時点のパラメータが求められる。この様にして FMV は、初期値 (0 秒目) のみ実走行データを与えることによってそれ以降は実走行先行車を追従しながら自律的に走行することができる。また、我々はモデルの評価をすべてこのノーマルシミュレーションの結果によって行っている。

2.3 ノーマルモデルでの問題点

次に図 3 にノーマルモデルでのノーマルシミュレーション結果を示す。従来の方法ではほとんどの場合において実走行データを再現することが出来ていたのだが、中には図 3 の結果の様に実走行とかけ離れた走行をしてしまい、場合によっては衝突してしまうことがあった。この原因としてノーマルモデルでは学習用データとして実走行データしか与えていないため、実走行データ以外の場面、つまり学習されていない場面に陥ってしまうことが考えられる。そこで本研究では、この問題点を改善するためにノーマルシミュレ




図 2 追従運転のノーマルシミュレーション




図 3 ノーマルモデルでのノーマルシミュレーション結果

ーションのほかに、本研究で提案する実測データ規範シミュレーションを行い、その結果を用いて学習用データを再構築し、FMV を再構成していく方法を提案する。

2.4 評価

上述のノーマルシミュレーションの結果を以下に示すような評価値によって評価を行う。

1) 平均車間距離誤差

追従運転のシミュレーションでは、文献²⁷⁾でも示している様に追従車加速度や追従車速度で実走行との誤差が少ない場合でも距離 (車間距離) レベルでは離れてしまう場合があることから、評価値の一つとして平均車間距離誤差を用いる。

2) 衝突係数

実際の車間距離が近い時と遠い時では車間距離誤差の重要度が変わってくる。つまり車間距離が近い時誤差の持つ意味合いが大きくなるはずなので、これに対応するような評価を (2) 式に示す。

$$Av(\Delta d/D) = (1/N) \cdot \sum_{t=0}^T (\Delta d[t]/D[t]) \quad (2)$$

$\Delta d[t]$: t 時点における実走行データとシミュレーションの車間距離誤差

$D[t]$: t 時点における実走行データでの車間距離

離

T: データの最後の時点

この $Av(\Delta d/D)$ は車間距離が近い時の誤差が大きいはど先行車に衝突する可能性が高くなる. また, $Av(\Delta d/D)$ を衝突係数とする.

3. 本研究で用いる FMV の学習法

本研究では 2.3 で述べたような問題点を解決するために実測データ以外の部分も学習させる方法を提案した. これは実測データのほかに実測データという規範をもうけて得られたデータを用いて FMV への学習用データを再構築することによって実現する. 実測データを規範として, 学習用データを構築するために, 我々は実測データ規範シミュレーションを提案した. つまりこの実測データ規範シミュレーションの結果が実測データ以外の部分をうまく補うような学習用データになっていれば, それを FMV に学習させることによってシミュレーション中に FMV が実測データ以外の部分に陥っても対応できるのではないかと考えた.

3.1 アルゴリズム

図 4 に本研究で提案した学習法のアルゴリズムを示す. ノーマルモデルでは図 4 に示しているように, 学習用データとして実測データのための 1 種類しか用いないため 1 種類の FMV しか構成できなかった. それに対し本研究で提案した学習法では, FMV の再構成回数 N を設定し反復して図 4 の試行を繰り返し行い, 学習前にその都度 FMV を初期化することによって学習データの異なる N 種類の FMV が得られることになる. また, 評価はノーマルモデルでも本研究で提案した学習法でもどちらの場合もノーマルシミュレーションによって行っている. 次に学習用データの再構築は, 実測データに規範シミュレーションの結果を $N-1$ 回分だけ付け加えている.

では, 実際に図 4 にそってアルゴリズムを説明する. まず始め再構成回数 N を設定し, FMV への 1 回目学習用データとして実測データのみを用意し, FMV の各 FNN 内の重みを初期化する. 次に 1 回目の学習用データによって FMV が学習され, 1 番目の FMV が構成される. また, その構成された FMV を用いてノーマルシミュレーションを行い, 平均車間距離誤差によって評価を行う. ノーマルモデルではここまでであったのだが, 本研究ではさらに衝突係数という評価値を提案し, それによっても評価を行った. この時点で, 再構成回数が設定された回数 N に達していればそのまま終了し, 達していなければ 1 回目の実




図 4 本研究で提案した学習法のアルゴリズム

測データ規範シミュレーションを行う. 次に実測データと 1 回目の実測データ規範シミュレーションの結果を足しあわせることで 2 回目の学習用データを再構築する. 次に先程と同様にして FMV を初期化し, 2 回目の学習用データによって学習を行い, 2 番目の FMV が再構成される. つまり n 回目の再構築された学習用データによって n 回目の学習を行い, n 番目の FMV が再構成されていく. また, 学習用データの再構築は実測データに $n-1$ 回目までの実測データ規範シミュレーション結果を足し合わせていったものである. これを設定された再構成回数 N を満たすまで反復して行う. また, 再構成のたびに FMV を初期化しているの, 最終的に N 種類の FMV が作り出されることになる.

今回提案する実測データ規範シミュレーションは, あくまでも学習用データを構築するために使われるだけである. 従って, 評価はノーマルシミュレーションによって行っていることを強調しておく.

3.2 実測データ規範シミュレーション

実測データ規範シミュレーションとは実測データ以外の部分も学習出来るように, FMV の出力に対して修正をかけながら実測データからわずかに離れたところを走行するようなシミュレーションである.

次に実際の修正のかけ方を説明する. 追従運転において自動車の挙動を決めるのはアクセルの加減操作量であり, それに直接関係するのは加速度であるので, 本研究の実測データ規範シミュレーションは, この加速度に対して修正係数 K を用いて修正をかけ, 式 (4) の追従車加速度 $A_n[t+1]$ により走行させる. ま

た、この時、規範となる加速度は車間距離を評価の対象としているので、 $t+1$ 時点での実測の車間距離 $D[t+1]$ に合うような規範追従車加速度 $A_c[t+1]$ を用いる。実際には各パラメータの計算は、ノーマルシミュレーションの時と同様にして

$$\begin{aligned} A[t+1] &= V[t+1] - V[t], \\ V[t+1] &= X[t+1] - X[t] \end{aligned} \quad (1)$$

のような差分の関係式によって求めているので、これから $A_c[t+1]$ は

$$A_c[t+1] = X_r[t+1] - X_n[t] - V_n[t] \quad (3)$$

として求めている。そしてこれを規範として、修正係数 K を導入し、

$$\begin{aligned} A_n[t+1] &= K \cdot \Delta A_c[t+1] + A_{FMV}[t+1], \\ \Delta A_c[t+1] &= A_c[t+1] - A_{FMV}[t+1] \end{aligned} \quad (4)$$

のように修正をかけることにする。例えば、 $K=1$ ならば $A_n[t+1] = A_c[t+1]$ となり、規範シミュレーションでは、実測データとまったく同じデータを作り出すことになる。次に $K=0$ ならば $A_n[t+1] = A_{FMV}[t+1]$ となり、規範シミュレーションでは、FMV からの出力そのままの値となる。

$X_r[t]$: t 時点における追従車位置の実測値

$A_c[t]$: t 時点における実測値の車間距離となるような追従車加速度

$A_{FMV}[t+1]$: t 時点のパラメータを入力して FMV から出力される $t+1$ 時点の加速度

$A_n[t]$: t 時点における修正後の追従車加速度

$X_n[t]$, $V_n[t]$: 規範シミュレーション中 t 時点における追従車位置、追従車速度

また、この実測データ規範シミュレーションの様子を図 5 に示す。

本研究では実測データ規範シミュレーションにおいて、どのような修正をかければ、より有効な学習用データとなる規範シミュレーション結果を得られるのか検討を行い、2.4 で示した 2 つの評価に対応したそれぞれ 2 つの *pattern* の規範シミュレーションを行った。以下に 2 つの評価に対してそれぞれ 2 つずつの *pattern* を示す。

3.2.1 平均車間距離誤差で評価する時

図 6 に平均車間距離誤差の評価値に対応した *pattern 1* と *pattern 2* の修正係数 K の設定法とその K の時系列での変化の様子を示す。

1) K を固定 (*pattern 1*)

pattern 1 では K を図 6 に示すように時系列で固定して走らせ、どのような K の値をとれば良いか検討する。 K の値のとりうる条件としては図 5 に示すように




図 5 実測データ規範シミュレーションの様子




図 6 *pattern 1* と *pattern 2* の修正係数 K の設定法とその様子

$K=0$ の時まったく修正がかからないので FMV からそのままの出力になり、 $K=1$ の時規範追従車加速度 $A_c[t+1]$ によって実測の車間距離となる。つまり K の値が 1 に近いほど実測データに近い走行をすることになる。また、 $K>1$ を設定すると規範シミュレーションは振動してしまうことより本研究では K の範囲をと $0 \leq K \leq 1$ する。

2) K を可変 (*pattern 2*)

図 6 に示すような規範シミュレーション中の車間距離誤差に応じて修正係数 K を可変にする方法を提案した。 $t+1$ 時点における $K[t+1]$ と規範シミュレーション中の車間距離誤差 $\Delta d_r[t]$ の関係を式 (5) に示す。

閾値 θ は式 (6) に示すように、規範シミュレーションの前に行ったノーマルシミュレーションの平均車間距離誤差に係数 β をかけたものを用いる。従って θ に関しては時点ごとではなく再構成回数ごとに値が変

わっていく．ここで θ の値の決定にノーマルシミュレーションの平均車間距離誤差を基準とした根拠は， θ を固定として設定した場合，学習用データを再構成するごとにノーマルシミュレーションの平均車間距離誤差が小さくなっていき，当然規範シミュレーションにおいてほとんどの時間帯で $\Delta d_n[t] < \theta$ となり，修正がかけられなくなってしまうからである．そこで，再構成回数ごとに θ の値を変えていく必要があった．

*pattern 2*では係数 α 、 β の組み合わせについて検討する．また， $K[t+1]$ が1を超えてしまった場合は，値を1とするようにした．

$$K[t+1] = \alpha \times (\Delta d_n[t] - \theta) \quad (\alpha: \text{係数}) \quad (5)$$

$$\theta = \beta \times Av(\Delta d_n[t]) \quad (\beta: \text{係数}) \quad (6)$$

θ : 閾値

$\Delta d_n[t]$: t 時点における規範シミュレーションの車間距離誤差

$\Delta d_n[t]$: t 時点におけるノーマルシミュレーションの車間距離誤差

$Av(\Delta d_n[t])$: ノーマルシミュレーションの平均車間距離誤差

3.2.2 衝突係数で評価する時

1) *pattern 2*の α を可変とする(*pattern 3*)

図7に*pattern 3*の修正係数 K の設定法とその様子を示す．式(5)の α を下に示す式(7)に変える． γ は実測の平均車間距離に対する係数である．ここで $\alpha[t+1]$ の値の決定に実測データの平均車間距離 $Av(D[t])$ を基準とした根拠は，この $Av(D[t])$ を係数として与えないとFMVに学習させるデータによって γ のもつ意味合いが変わってきってしまうためである．また，この式(7)によって修正係数 K は，各時点で実測車間距離に近い時($D[t]$:小)では修正係数が大きくなり，逆に遠い時($D[t]$:大)では小さくなる．

$$K[t+1] = \alpha[t+1] \times (\Delta d_n[t] - \theta) \quad (5)'$$

$$\theta = \beta \times Av(\Delta d_n[t]) \quad (\beta: \text{係数}) \quad (6)$$

$$\alpha[t+1] = \gamma \times \{Av(D[t])/D[t]\} \quad (\gamma: \text{係数}) \quad (7)$$

$Av(D[t])$: 実測データの平均車間距離

2) *pattern 2*の α と θ を可変とする(*pattern 4*)

図8に*pattern 4*の修正係数 K の設定法とその様子を示す．式(5)の α を(7)式に，また(6)式の β を下に示す式(8)に変える．この式(8)によって閾値 θ は，各時点での実測車間距離に近い時に閾値 θ が小さくなり，逆に遠い時には閾値 θ が大きくなることによって，修正をかけない範囲を変える．ここで $\beta[t+1]$ の値の決定に実測データの平均車間距離 $Av(D[t])$ を基準とした根拠も上記1)で説明した $\alpha[t+1]$ の時




図7 *pattern 3*の修正係数 K の設定法とその変化の様子




図8 *pattern 4*の修正係数 K の設定法とその変化の様子

と同様である．

$$K[t+1] = \alpha[t+1] \times (\Delta d_n[t] - \theta[t+1]) \quad (5)''$$

$$\theta[t+1] = \beta[t+1] \times Av(\Delta d_n[t]) \quad (6)'$$

$$\alpha[t+1] = \gamma \times \{Av(D[t])/D[t]\} \quad (\gamma: \text{係数}) \quad (7)$$

$$\beta[t+1] = \eta \times \{D[t]/Av(D[t])\} \quad (\eta: \text{係数}) \quad (8)$$

4. 結果と考察

4.1 平均車間距離誤差で評価する時

ノーマルモデルでの平均車間距離誤差が大きかったデータ1に対して学習用データの再構築を行い，FMVの再構成を行った．また，図9，10の横軸の0は再構成なしの結果で，ノーマルモデルと同じものである．

1) *pattern 1*

$K=1$ の結果については1回目の再構成では良くなったが，その後の再構成では再構成なしの誤差よりも悪くなっているものもあり，あまり良い結果は得られなかった．その理由として $K=1$ とすると同じデータが再構成回数分だけそのまま増えているだけで，未学習部分があまり減らなかったためだと考えられる． $K=0$ に関してはノーマルモデル（再構成回数0回）の結果があまりにも実走行データとかけ離れているため




図9 data 1 の pattern 1 での再構成回数による平均車間距離誤差の変化の様子




図10 data 1 の pattern 2 での再構成回数による平均車間距離誤差の変化の様子

に、実走行とかけ離れた学習用データを再構築していくことになり、あまり良い学習用データを得られず良い結果が得られなかったのだと思われる。また、 $K=0.05, 0.2$ に関してはかなり良い結果が得られた。これは、規範シミュレーションによって出来たデータが上手く実走行データ付近を走るものであるため、再構成するたびに未学習部分を上手く補う学習用データを再構築できたためであると考えられる。また、再構成した後のノーマルシミュレーションでの衝突している時間はすべて 0 秒だった。

2) pattern 2

この pattern 2 での再構成した後のノーマルシミュレーションは全体的に良い結果が得られ、特に $\alpha=0.02, \beta=0$ とした時は 4 回目で実走行との誤差がほとんどない所までいった。また、この時の衝突時間についてもすべて 0 秒だった。ただし、全体的に良くなっているので α, β の組み合わせとしてどのような値が最適かは判らなかった。

表1 最小となる平均車間距離誤差

		data 1	data 5	data 36	data 43
pattern 1	usual result	10.7	2.51	3.47	3.18
	$K=0$	6.29	2.04	2.89	2.92
	$K=0.05$	0.51	1.76	2.12	2.86
	$K=0.1$	0.83	1.48	2.61	2.92
	$K=0.2$	0.66	1.65	2.29	3.12
	$K=0.5$	1.49	1.34	2.22	2.80
pattern 2	$K=1$	1.62	2.47	2.92	2.60
	$\alpha=0.02, \beta=0$	0.38	1.76	2.27	2.60
	$\alpha=0.02, \beta=0.2$	1.25	1.32	2.32	2.69
	$\alpha=0.02, \beta=0.5$	0.79	1.29	2.28	2.55
	$\alpha=0.03, \beta=0$	0.78	1.75	2.01	2.84
	$\alpha=0.03, \beta=0.2$	0.70	1.43	1.89	2.51
	$\alpha=0.03, \beta=0.5$	1.31	1.41	2.02	2.21

3) pattern 1 と pattern 2 の比較

上の表 1 のようなデータと係数の組み合わせで、それぞれ 5 回再構成を行ったうち最も良かった値のものを表に示す。さらにデータごとの各係数の中で最も良かった値のものを網掛けしている。

表 1 より網掛けした pattern 1 と 2 の値を比較するとすべてのデータについて良くなっていた。また、1), 2) の結果からも全体的に K を可変とした時の方に良い傾向が見られた。これは K が固定だと、実測データ規範シミュレーションにおいてすべての時点で同じ割合の修正をかけるので学習用データとして再構築する際に結局似たようなデータが増えるだけになってしまい再構成をしても最初の学習と同じような部分を学習してしまうため再構成の効果が低くなっていると考えられる。これに対し K を可変とすると、入力として実走行データとは似ていない質の違ったデータが増え、いろいろな学習を行うようになるため再構成の効果が高くなっていると考えられる。また、pattern 2 で各係数の組み合わせを比較すると、特にどの組み合わせの時のほうがよいのかはわからなかった。

一方、図 11 は表 1 のデータ 1 に対して網かけしてある時のノーマルシミュレーション結果と再構成をしていないノーマルモデルでのノーマルシミュレーションとの比較であるが、この図 11 から見てもわかるように時系列レベルで車間距離の誤差がほぼなくなっていることがわかりこの方法が有効であることが示された。

4.2 衝突係数で評価する時

ノーマルモデルでの衝突係数の値が大きかったデータ 1 に対して学習用データの再構築を行い、FMV の再構成を行った。また、図 12, 13 の横軸の 0 は再構成なしの結果で、ノーマルモデルと同じものである。

1) pattern 3

図 12 のグラフを見ると全体的に衝突係数が小さくなっているのがわかる。特に 3 回目の再構成でほとん




図11 平均車間距離誤差が最小となった時の時系列結果




図12 data 1 の pattern 3 での再構成回数による衝突係数の平均の変化の様子




図13 data 1 の pattern 4 での再構成回数による衝突係数の平均の変化の様子

どの係数の組み合わせについて良くなっていた。しかし、3回目以降の結果に関しては大きな変化は見られなかった。

また、白丸の $\alpha=0.02$, $\beta=0.5$ の組み合わせで4回目の再構成で著しく悪くなっているのだが何故そうなっ

表2 最小となる衝突係数の平均

		data1	data5	data36	data43
	usual result	0.32	0.212	0.223	0.127
pattern3	$\gamma=0.02, \beta=0$	0.032	0.108	0.128	0.105
	$\gamma=0.02, \beta=0.2$	0.051	0.152	0.108	0.101
	$\gamma=0.02, \beta=0.5$	0.04	0.117	0.115	0.098
	$\gamma=0.03, \beta=0$	0.029	0.12	0.123	0.097
	$\gamma=0.03, \beta=0.2$	0.031	0.138	0.133	0.102
	$\gamma=0.03, \beta=0.5$	0.099	0.12	0.115	0.116
pattern4	$\gamma=0.02, \eta=0.2$	0.034	0.091	0.135	0.095
	$\gamma=0.02, \eta=0.5$	0.022	0.116	0.135	0.102
	$\gamma=0.03, \eta=0.2$	0.029	0.127	0.14	0.096
	$\gamma=0.03, \eta=0.5$	0.029	0.146	0.132	0.093




図14 衝突係数の平均が最小となった時の時系列結果

たのかはわからなかった。そして、どのような係数の組み合わせが最適であるかについてもわからなかった。

2) pattern 4

全体的に1回目の再構成で良い結果が得られその後は振動するような感じになった。しかし、図12の時と同様に全体的に見て著しい改善が見られた。

また、 $\beta=0$ に関しては pattern 3, 4 どちらも同じ意味を持つので図13のグラフには載せていない。

3) pattern 3 と pattern 4 の比較

表1と同様にそれぞれ5回再構成を行ったうち最も良かった値のものを表2に示す。さらにデータごとの各係数の中で最も良かった値のものを網掛けしている。

まず pattern 3 と 4 の網掛け部分を比較すると pattern 4の方が良い結果が得られていた。また、全体的に見ても pattern 4の方が良くなっていた。次に各 pattern で係数による違いを調べるとここでもどのような組み合わせが良いのかはわからなかった。

また、4.1の図11の時と同様に図14は表2の網掛

けしてある時の実際の走行の様子を時系列レベルであらわしたものである。これからわかるように時系列レベルで衝突係数の値に関しても改善が見られていることがわかった。

5. ま と め

今回提案した方法でFMVに学習させ、シミュレーションを行ったところ、時系列の車間距離レベルにおいて実走行を上手く再現できていなかったデータに対しても改善が見られた。この結果からノーマルモデルにおける問題点がほぼ改善されている事がわかる。この事から本論文において、当初の推測通り実走行データは結果論で、それを再現するにはそれに至るまでの様々な場面を学習させなければならないだろうという理論を今回の結果から立証できたのではないかと考えられる。しかしながら各 *pattern* においてどのような係数の組み合わせが最適であるのかはわからなかった。また、再構成回数に関してもやればやるほど良いというわけではないので、今後はこの各 *pattern* における係数の組み合わせと再構成回数についてより研究していく必要があると考えられる。

参 考 文 献

- 1) 池之上慶一郎, 斎藤 威, 花堂紘之: 街路交通のシミュレーションモデル (MCSTRAN-1), 科学警察研究所報告, 交通編, **16**-1, 1/16 (1975)
- 2) 高橋理一, 辻 紘良: 自動車交通シミュレーションの現状と将来, 自動車技術, **35**-7, 759/766 (1981)
- 3) 栗本 譲: 交通道路交通流解析のデジタル・シミュレーション・モデル, 土木学会論文報告集, 320 号, 137/148 (1982)
- 4) 尾崎晴男: 街路網信号の評価シミュレーションモデル (DESC), 交通工学, **24**-6, 31/37 (1989)
- 5) 浜嶋鉦一郎: 交通流シミュレーションシステム, オペレーションズ・リサーチ, 1990-2, 102/106 (1990)
- 6) Rathi, A. K.: Urban Network Traffic Simulation TRAF-NETSIM Program, J. of Transportation Engineering, **116**-6 (1990)
- 7) 高橋道哉, 中西俊男他: 道路交通シミュレーションシステムの開発と応用, シミュレーション, **11**-4, 61/72 (1992)
- 8) 堀口良太, 片倉正彦, 桑原雅夫: 都市街路網の交通流シミュレータ「AVENUE」の開発, 第 13 回交通工学研究発表論文報告集, 33/36 (1993)
- 9) 横井 昭, 宮田 晋, 田村恒治: 交通管制マクロシミュレータ, 第 13 回交通工学研究発表会, 37/40 (1993)
- 10) 羽藤英二, 矢尾谷雄司他: シミュレーションによる交通制御の最適化とそれに伴う交通流の変化, 第 14 回交通工学研究発表会, 49/52 (1994)
- 11) 後藤幸夫, 駒谷喜代俊, 福田豊生: 自律型走行モデルによる道路交通シミュレータの開発, 電学論 D, **116**-5, 577/669 (1996)
- 12) 平子, 馬場, 寺本英二: 交通情報システム評価用広域交通流シミュレータ, 第 16 回交通工学研究発表論文報告集, 97/100 (1996)
- 13) 斎藤 威: 交通渋滞予測のための道路交通現象の再現, 電気学会誌, **117**-9, 600/603 (1997)
- 14) 永井 徹, 横田孝義, 堀田 都, 滑川正明: 対話型 3 次元交通流ミクロシミュレータの開発, 第 17 回交通工学研究発表論文報告集, 57/60 (1997)
- 15) 桑原雅夫: 広域ネットワーク交通流シミュレーション, 自動車技術, **52**-1, 28/34 (1998)
- 16) 本多中二 他: ファジィ制御による自動車運転論理を取り入れた道路交通シミュレーションモデル, 第 7 回ファジィシステムシンポジウム講演論文集, 593/598 (1991)
- 17) 佐藤章 他: 渋滞解析を目的とした微視的道路システムの機能と構成, 第 11 回シミュレーション・テクノロジー・コンファレンス発表論文集, 171/174 (1992)
- 18) 猪飼國夫 他: ファジィ化微視的モデルによる渋滞解析を目的とした道路交通シミュレータ, シミュレーション, **16**-3, 45/54 (1997)
- 19) Yikai K., et al: A Fuzzy Processor Consisting of Memory and Controlling I.S.I, 5th IFSA World Congress in SEOUL, 789/792 (1993)
- 20) 板倉直明, 猪飼國夫, 本多中二: MITRAM におけるファジィモデル自動車の多段二項ファジィ論理による構築, 第 11 回シミュレーション・テクノロジー・コンファレンス発表論文集, 189/192 (1992)
- 21) 板倉直明, 本多中二, 猪飼國夫: MITRAM におけるファジィモデル自動車のニューラルネットによる具体化, 第 12 回シミュレーション・テクノロジー・コンファレンス発表論文集, 153/156 (1993)
- 22) 板倉直明, 本多中二, 猪飼國夫: MITRAM における運転者の意思決定機構をエキスパートの経験と神経回路網によりモデリングする方法とそのシミュレーション, 第 13 回シミュレーション・テクノロジー・コンファレンス発表論文集, 87/90 (1994)
- 23) 板倉直明, 本多中二, 猪飼國夫: MITRAM におけるファジィモデル自動車 (FMV) の評価のための実走行データ解析, 第 14 回シミュレーションテクノロジーコンファレンス発表論文集, 205/208 (1995)
- 24) 板倉直明, 本多中二, 猪飼國夫: 場合分けを含むニューラルネットワークによるファジィモデル自動車の実現, 第 5 回インテリジェントシンポジウム講演論文集, 5/10 (1995)
- 25) N. Itakura, N. Honda and Kyikai: Simulation of Actual Driving Operations by Using Fuzzy and Neural Network Models, 29th Symposium on Automotive Technology & Automation, 197/202 (1996)
- 26) 岩間 望, 板倉直明, 本多中二, 猪飼國夫: ファジィモデル自動車のモデリングの違いによる学習結果の評価, 第 17 回シミュレーション・テクノロジー・コンファレンス発表論文集, 239/242 (1998)
- 27) 板倉直明, 本多中二, 猪飼國夫: ファジィニューラルネットワークモデルによる追従自動車運転論理の実現, シミュレーション, **18**-15, 273/281 (1999)