

ニューロ同定モデルによる交通流シミュレーションのパラメータ調整*

Tuning of Parameters in Traffic Simulation Model Using Neuro-Identifier*

加納誠**・桑原雅夫***

By Makoto KANO**・Masao KUWAHARA***

1. はじめに

交通流シミュレータは、道路網上の交通状態を模擬するツールであり、道路整備計画や道路交通施策の定量的な事前評価、ITSサービスの導入効果の予測などに利用されている。

交通流シミュレータが高精度に交通状態を予測するには、シミュレータが利用する道路網モデルのパラメータが正しく調整されている必要がある。このパラメータは数多くあり、相互に関連し合ってシミュレーション結果に影響するため、その調整は難しく、これまでは熟練した技術者が試行錯誤的に調整する必要があり、多大なコストがかかる作業であった。

古川ら¹⁾の研究では、最急降下法によるパラメータ調整手法を提案している。この手法では、単純化した道路網についてのパラメータ調整が可能である。しかし、互いに影響する複数のボトルネックとなるリンクがある道路網では、渋滞発生順に各ボトルネックのパラメータを推定するなど、他のボトルネックの影響を排除してパラメータ推定を進める方法が必要になる。

本論文では、自律的にパラメータを調整する手法を提案し、シミュレーション実験により、その有効性を示す。ニューラルネットワークモデルを交通流シミュレータの同定モデルとして利用し、他のボトルネックの影響を含む、パラメータと交通状態の非線形な関係を学習させ、学習後のニューラルネットワークモデルの逆伝播計算によりパラメータを推定する。ボトルネック毎の学習の進捗に従って、パラメータの変化量を調節して学習データを再生成し、学習を続けることにより、自律的にパラメータを推定する。

2. 交通流シミュレータ

本論文で扱うシミュレータはマクロ型交通流シミュレータであり、車両群を流体としてモデル化する。利用される道路網モデルは道路リンクとノード、デポから構成される(図1)。

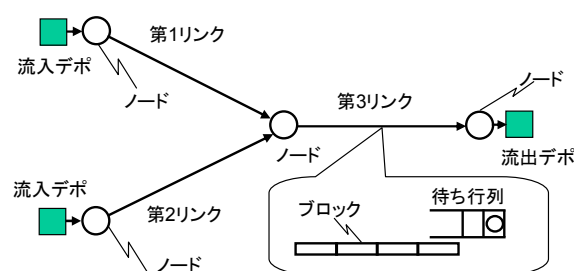


図1 道路網モデルの構成

道路リンクは道路単路部のモデルであり、リンク長と自由走行速度、交通容量を属性として持つ。道路リンクは、リンクを更に複数に分割したブロックと待ち行列から構成される。ブロック長は $V \times \Delta t$ (V は自由走行時の速度[km/h]、 Δt はサンプリング時間[h])に設定されており、リンク上を自由走行速度で走行する車両はサンプリング時間毎に次のブロックに進む。待ち行列はリンク終端に存在する。最終ブロックを走行し終えた車両が、流出量の制限により、流出できない場合に待ち行列に並ぶ。サンプリング時間当たりの流出量はリンクの交通容量、及び下流側リンクの流入可能量に制限され、それを超える車両台数が流出しようとする、超えた分の車両が待ち行列に蓄積される。リンクの流入可能量はリンク上の車両台数上限値から実際の車両台数を引いた値である。

ノードはリンク間を結合する機能を持つ。長さは無く、流入側リンクから流入した車両はすぐに流出側リンクに流出する。合流部では合流比を保持しており、この合流比に従って、各リンクからの流入車両台数が決定する。

デポは道路網と外部との間で車両のやり取りをする機能を持つ。デポには、外部から車両を流入させる流入デポと、外部に車両を流出させる流出デポがある。どちらもノードに結合し、ノードを通して車両の流入、流出を行う。流入デポからの車両流入は、下流側リンクの流入

*キーワード：交通流シミュレータ、パラメータ調整、ニューラルネットワーク

**非会員、工修、東芝ソリューション(株)

(東京都府中市片町3-22、TEL:042-345-6434、

E-mail:Kano.Makoto@toshiba-sol.co.jp)

***正員、工博、東京大学生産技術研究所

可能量を超えていても必ずリンクに入力されることにする。車両の発生台数は、流入デポ毎に時系列で与えられる。

シミュレーション結果として、デポの流入量、流出量、ノードの流入量、流出量、リンクの平均旅行時間、累積流入量、累積流出量、待ち行列数などが時系列で出力される。本論文では、シミュレーション結果の交通状態のうち、各リンクの平均旅行時間、累積流出量が実交通で観測された値に一致するように、道路網モデルのパラメータとして、リンクの交通容量を調整する。この交通容量はリンクの形状によって決定し、時刻や交通状態によって変化しないとする。

3. パラメータ推定手法

(1) パラメータ推定システムの構成

提案するパラメータ推定手法を実現するシステムのブロック図を図2に示す。本システムは、推定対象である交通流シミュレータと、この交通流シミュレータの同定モデルから構成され、利用場面によって学習モードとパラメータ推定モードになる。

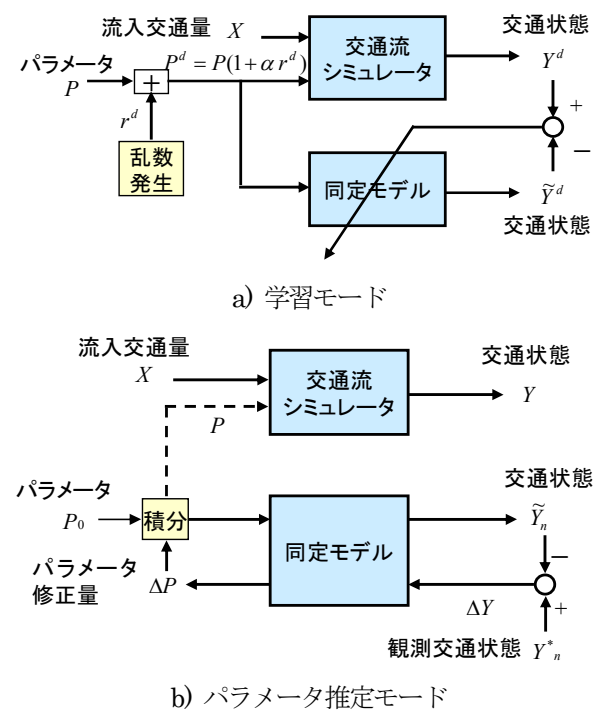


図2 パラメータ推定システム

(2) 同定モデル

同定モデルは交通流シミュレータの入出力関係を模擬するモデルである。交通流シミュレータには、流入交通量の時系列データ $X = (X_0, X_1, \dots, X_N)$ と道路網モデルのパラメータ P が入力され、交通状態の時系列データ $Y = (Y_0, Y_1, \dots, Y_N)$ が出力される。しかし、同

定モデルは、パラメータ P と交通状態 Y の関係を捉えることが目的であり、流入交通量 X は実交通で観測されたデータに固定するので、道路網モデルのパラメータ P だけを同定モデルの入力信号とする。また、出力信号は、予め決められた時刻の交通状態だけを出力することにより、同定モデルの入出力次元数を小さくし、モデルを単純化する。

この同定モデルの機能要件として、

1. パラメータ P を入力すると、道路網モデルのパラメータが P の場合のシミュレーション結果である交通状態 Y が正しく出力されること
2. 同定モデルにより出力された交通状態 \tilde{Y} と実交通で観測された交通状態 Y^* との誤差 ΔY を入力すると、同定モデルの逆方向計算によって、交通流シミュレータが持つ道路網モデルのパラメータの修正量 ΔP が計算できること

が挙げられる。本研究では、これらの要件を満たすモデルとして、階層型ニューラルネットワークを採用する。ニューラルネットワークは、人の脳の神経回路網のモデルであり、その大きな特徴は学習能力を持つことである。交通流シミュレータが持つ道路網モデルのパラメータ P を入力信号、そのパラメータ時のシミュレーション結果の交通状態 Y を教師信号とする学習データ (P, Y) を例示することにより、その入出力関係を学習することができる(図2-a)。

また、予測された交通状態と実交通で観測された交通状態との誤差からパラメータの修正量を求める誤差逆伝播計算ができ、パラメータから交通状態を予測する順方向計算とこの逆伝播計算を繰り返すことにより、パラメータを調整することができる(図2-b)。

(3) チューニングの手順

提案するパラメータチューニングシステムの処理手順を図3に示す。

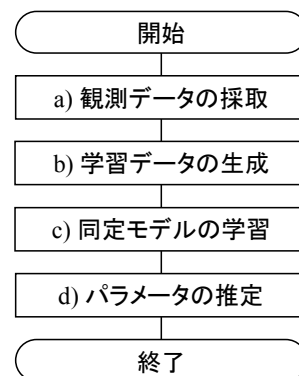


図3 処理手順

提案するシステムでは、同定モデルであるニューラル

ネットワークの学習を行う必要があり、そのための観測データ採取、学習データ生成を行い、最後にパラメータの推定を行う。ここでは、この手順に沿って説明する。

a) 観測データの採取

シミュレーション対象である道路網上で、渋滞が発生する時間帯の流入交通量の時系列データ X と交通状態の時系列データ Y^* を採取する。

b) 学習データの生成

交通流シミュレータが持つ道路網モデルのパラメータ P と、シミュレーション結果の交通状態 Y との関係を同定モデルが学習するには、パラメータの値を変化させ、そのときのシミュレーション結果の交通状態を学習データとして学習する必要がある。

交通流シミュレータが持つ道路網モデルのパラメータの値を、既定値 P を中心に乱数値を加算する。

$$P^d = P \times (1 + \alpha R^d)$$

ここで P^d は第 d 番学習データのパラメータ値、 α は乱数幅を表す定数、 R^d は $[-1, 1]$ の一様乱数値である。このパラメータ P^d と、実交通で観測された流入交通量 X を交通流シミュレータに入力し、取得される交通状態 Y^d とのペア (P^d, Y^d) ($d = 1, 2, \dots, M$) を学習データとする。

c) 同定モデルの学習

同定モデルのニューラルネットワークはサブネットワークが並列にならんだ構造になっており、1つのサブネットワークが1道路リンクに対応している(図4)。サブネットワークには、パラメータとして道路リンクの交通容量が入力され、交通状態としてリンク平均旅行時間、累積流出量(20分)が出力される。サブネットワーク間にも結合リンク(破線)を持つことにより、他の道路リンクの交通容量の影響を学習することができる。

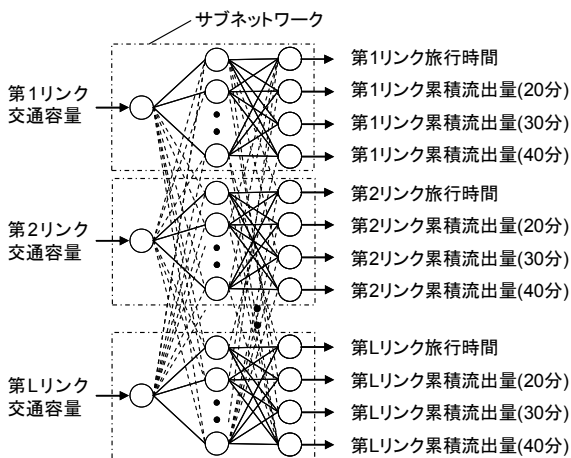


図4 同定モデルの構造

学習データ (P^d, Y^d) ($d = 1, 2, \dots, M$) の入力信号

であるパラメータ P^d を同定モデルに入力し、ニューラルネットワークの順方向計算により交通状態 \tilde{Y} が計算される。

$$y1_i^d = P_i^d \quad (i = 1, 2, \dots, N1),$$

$$y1_{N1+1}^d = 1.0,$$

$$x2_j^d = \sum_{i=1}^{N1+1} w1_{i,j} y1_i^d,$$

$$y2_j^d = 1 / \{1 + \exp(-x2_j^d)\} \quad (j = 1, 2, \dots, N2),$$

$$y2_{N2+1}^d = 1.0,$$

$$x3_k^d = \sum_{j=1}^{N2+1} w2_{j,k} y2_j^d,$$

$$\tilde{Y}_k^d = \sigma_k x3_k^d + \overline{y3_k} \quad (k = 1, 2, \dots, N3).$$

ここで $y1_i^d$ は第1層 i 番ユニットの出力値、 $w1_{i,j}$ は第1層 i 番ユニットから第2層 j 番ユニットへの結合荷重値、 $x2_j^d$ は第2層 j 番ユニットの入力値、 $y2_j^d$ は第2層 j 番ユニットの出力値、 $w2_{j,k}$ は第2層 j 番ユニットから第3層 k 番ユニットへの結合荷重値、 $x3_k^d$ は第3層 k 番ユニットの入力値、 $\overline{y3_k}, \sigma_k$ は交通状態 \tilde{Y} の k 番要素の平均値と標準偏差値である。 $N1, N2, N3$ は各層のユニット数を表す。

次に、学習計算式を表す。まず、誤差関数 E を以下のように定義する。

$$E = \frac{1}{2} \sum_{d=1}^M \sum_{k=1}^{N3} \left(\frac{\tilde{Y}_k^d - Y_k^d}{\sigma_k} \right)^2.$$

学習計算では、この誤差関数値を減少させるように結合荷重値が修正される。

$$\begin{aligned} dw2_{j,k} &= -\varepsilon \frac{\partial E}{\partial w2_{j,k}} = -\varepsilon \sum_{d=1}^M \frac{\partial E}{\partial x3_k^d} \frac{\partial x3_k^d}{\partial w2_{j,k}} = -\varepsilon \sum_{d=1}^M \left(\frac{\tilde{Y}_k^d - Y_k^d}{\sigma_k} \right) y2_j^d, \\ dw1_{i,j} &= -\varepsilon \frac{\partial E}{\partial w1_{i,j}} = -\varepsilon \sum_{d=1}^M \sum_{k=1}^{N3} \frac{\partial E}{\partial x3_k^d} \frac{\partial x3_k^d}{\partial y2_j^d} \frac{\partial y2_j^d}{\partial x2_j^d} \frac{\partial x2_j^d}{\partial w1_{i,j}} \\ &= -\varepsilon \sum_{d=1}^M \sum_{k=1}^{N3} \left(\frac{\tilde{Y}_k^d - Y_k^d}{\sigma_k} \right) w2_{j,k} y2_j^d (1 - y2_j^d) y1_i^d. \end{aligned}$$

ここで ε は学習係数である。

この順方向計算と学習計算が繰り返され、パラメータ P と交通状態 Y の関係を学習する。

d) パラメータの推定

ニューラルネットワークの学習を十分に行った後、パラメータ推定を行う。パラメータの初期値 P_0 が同定モデルに入力され、ニューラルネットワークの順方向計算によって交通状態 \tilde{Y} が計算される。誤差関数 E を以下のように定義する。

$$E = \frac{1}{2} \sum_{k=1}^{N3} \left(\frac{\tilde{Y}_k - Y_k^*}{\sigma_k} \right)^2$$

逆伝播計算では、誤差関数値が減少するように、入力信

号であるパラメータの修正量 ΔP が計算される。

$$\begin{aligned} \Delta P_i &= -\gamma \frac{\partial E}{\partial P_i} = -\gamma \sum_{j=1}^{N_2} \sum_{k=1}^{N_3} \left(\frac{\partial E}{\partial x_{3,k}} \frac{\partial x_{3,k}}{\partial y_{2,j}} \right) \frac{dy_{2,j}}{\partial x_{2,j}} \frac{\partial x_{2,j}}{\partial y_{1,i}} \\ &= -\gamma \sum_{j=1}^{N_2} \sum_{k=1}^{N_3} \left(\left(\frac{\tilde{Y}_k - Y_k^*}{\sigma_k} \right) w_{2,j,k} \right) y_{2,j} (1 - y_{2,j}) w_{1,i,j}. \end{aligned}$$

ここで γ は修正係数で正の小さな値である。パラメータの値が修正される($P = P + \Delta P$)。この順方向計算と逆方向計算を、予測交通状態 \tilde{Y} が実交通で観測された交通状態 Y^* に十分近づくまで繰り返される。最終的に、予測交通状態 \tilde{Y} が実交通の交通状態 Y^* に十分近づいた時のパラメータが推定パラメータ P として、交通流シミュレータに送信される。

(4) 二段階学習

リンクの交通状態は、そのリンクの交通容量の影響を最も大きく受ける。そのため、サブネットワーク内の結合荷重値の大きさが大きく、サブネットワーク間の結合荷重値は小さくなる。しかし、サブネットワーク間の結合があるニューラルネットワークでは、あるリンクの交通状態に対して、同じリンクの交通容量なのか、他のリンクの交通容量なのかの区別が無い。そのため、遠く離れたリンクであっても、偶然に学習データの交通容量の変化が自リンクの交通容量の変化に近いと、その間の結合荷重値が大きな値を持ってしまふことが考えられる。

そこで、まずはサブネットワーク間の結合は変更しない条件で学習を行い、サブネットワーク内の結合を優先して十分学習し、次に、サブネットワーク間の結合を付加して追加学習を行うことにより、自リンクの交通容量との結合荷重を十分大きくし、それだけでは学習できない成分については、他リンクからの入力を使って予測するように学習する。

(5) 乱数幅の調整

学習データの生成では、パラメータの全要素を同時にランダムに変化させるため、学習データの教師信号である交通状態は他のリンクのパラメータの影響を受け、自リンクのパラメータに対する交通状態にはばらつきが発生する。すると、ニューラルネットは正しく学習できず、パラメータの推定もうまくできなくなる。

しかし、リンクによっては周囲のリンクの影響を受けないものがある。それは周囲のリンクより交通容量が小さく、最初に渋滞になるリンクである。そのリンクでは、学習誤差が小さく、精度良くパラメータを推定できる。

そこで、学習誤差が小さいリンクでは、パラメータの推定値を中心値とし、乱数幅が小さくなるように、誤差値に合わせて乱数幅を調整して学習データを生成し直す。

すると、そのリンクから影響を受けていた周囲のリンクのばらつきが小さくなり、そのリンクについても学習誤差が小さくなり、パラメータ推定が正しく行われるようになる。

このように、学習誤差の大きさによって乱数幅を調整し、学習データを生成し直すことを繰り返すことにより、他のリンクの影響を受けるリンクについても、順々に学習データのばらつきを小さくすることができ、推定精度を高くしていくことができる。

4. 実験

パラメータ推定システムのシミュレーション実験を行う。実験では、道路リンクの交通容量をパラメータ、道路リンクの平均旅行時間、決められた時刻の累積流出量を交通状態とする。

(1) シミュレーション条件

a) 道路構造

シミュレーション対象とする道路構造は、4リンクから構成される分岐合流道路である(図5)。各リンクの特性は表1の通りである。この交通容量がパラメータの真値であり、この値を推定する。




図5 分合流部(4リンク)

表1 道路リンクの特性

リンクID	1	2	3	4
リンク長[km]	5.0	5.0	5.0	5.0
自由速度[km/h]	60.0	60.0	60.0	60.0
交通容量[Veh/h]	2500.0	1200.0	1000.0	1800.0

リンク内の車両台数の上限値を $3\mu L/V$ とする。ここで、 L はリンク長[km]、 μ はリンク交通容量[Veh/h]である。

分岐部の分流比率は、分岐先のリンクの平均旅行時間を利用した確率モデル(ロジットモデル)によって動的に決定する。リンク1からリンク2,3に分岐する場合の分流比率の確率モデルは以下のようになる。

$$Ro_{2,n} = \frac{\exp(-\theta T_{2,n})}{\exp(-\theta T_{2,n}) + \exp(-\theta T_{3,n})} = \frac{1}{1 + \exp(-\theta(T_{3,n} - T_{2,n}))},$$

$$Ro_{3,n} = \frac{\exp(-\theta T_{3,n})}{\exp(-\theta T_{3,n}) + \exp(-\theta T_{2,n})} = 1 - Ro_{2,n}.$$

ここで $Ro_{2,n}, Ro_{3,n}$ は分流比率、 $T_{2,n}, T_{3,n}$ は時刻 $n\Delta t$ にリンク 2、リンク 3 を流出した車両の平均旅行時間である。 θ は感度パラメータである。

b) 流入量

第 1 リンクへの流入量を図 6 に示す。始めの 4 分間は 2700Veh/h で、その後は徐々に減少する。




図6 第 1 リンクへの流入量

c) ニューラルネットの構造

第 1 リンクから第 4 リンクまでがサブネットワークに割り付けられており、リンクの交通容量を入力信号として、平均旅行時間と 20 分後、30 分後、40 分後の累積流出量を出力信号とする(図 7)。

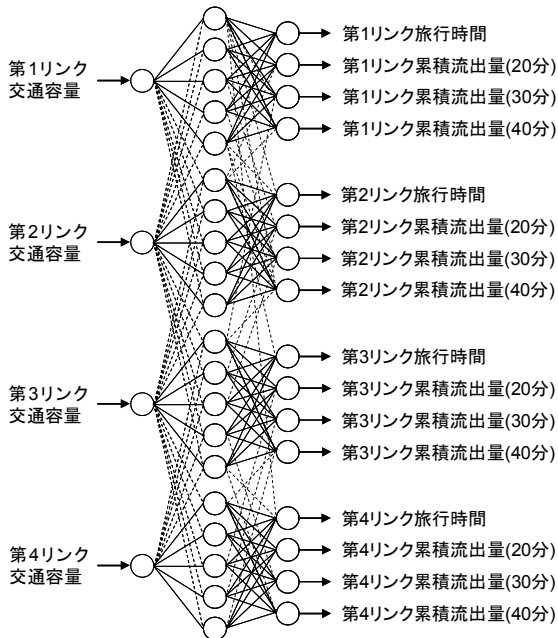


図7 ニューラルネットの構造

(2) 同定モデルの学習

a) 学習データの生成

各リンクの交通容量の真値を中心に $\pm 20\%$ の範囲の一樣乱数で交通容量を設定し、先述した流入量を発生させ

たシミュレーション結果の、リンク交通容量を入力信号、平均旅行時間と 20 分後、30 分後、40 分後の累積流出量を教師信号とする学習データを 100 セット生成する。

b) 学習結果

以下の手順に従い二段階学習と乱数幅調整を実施した。

- ① サブネットワーク間の結合は変更しない条件で、真値を中心に $\pm 20\%$ の範囲の一樣乱数値を加算した交通容量を設定した学習データを利用し 5,000 回の学習を実施。
- ② サブネットワーク間の結合も含め、① と同一の学習データを使い 5,000 回の追加学習を実施。
- ③ 推定値を中心に、サブネットワークの誤差値から乱数幅を決定し学習データを生成する方法で、1,000 回の学習毎に学習データを更新しながら 5,000 回の学習を実施。

学習曲線を図 8 に示す。横軸は学習回数、縦軸はサブネットワーク単位の誤差二乗和の値である。また、学習回数が 0 回、5,000 回、10,000 回、15,000 回の時の誤差二乗和の値を表 2 に示す。

学習回数 5,000 回で急に誤差が減少しているのは、サブネットワーク間結合の学習が開始され、他の道路リンクの交通容量でしか説明できない成分が学習できたためである。また、学習回数 10,000 回で誤差が減少しているのは、学習データの乱数幅が狭くなり、他のリンクの影響による散らばりが小さくなったためである。




図8 学習曲線


表2 サブネットワーク単位の誤差二乗和

学習回数	第1リンク	第2リンク	第3リンク	第4リンク	合計
0	4.01E+00	4.01E+00	4.01E+00	4.01E+00	1.60E+01
5,000	7.62E-02	1.42E+00	6.48E-01	2.69E-01	2.41E+00
10,000	4.88E-02	3.46E-01	1.89E-01	5.38E-02	6.37E-01
15,000	2.79E-03	3.01E-03	1.58E-04	1.35E-04	6.10E-03


5,000 回、10,000 回、15,000 回学習後の、学習データに対する予測結果のうち、第 2 リンクについての結果を図 9 に示す。

横軸はリンクの交通容量、縦軸は交通状態の予測値と教師信号の値である。5,000 回学習後では、旅行時間の教師信号が大きくばらついているが、ニューラルネットの出力は追従できていない。10,000 回学習後では、ばらつきに対して追従できるようになっている。これはサブネットワーク間結合も含めて学習したためである。15,000


回学習後では、リンク容量の範囲が狭くなり、ばらつきも小さくなっている。これは他のリンクについてもリンク容量の乱数幅が小さくなったためである。教師信号の点と予測値の点がほぼ重なり、ニューラルネットの学習が良くできていることが分かる。



1) 5,000 回学習後



2) 10,000 回学習後



3) 15,000 回学習後

図9 交通状態の予測結果

(3) パラメータ推定

次に、15,000 回学習後のニューラルネットを利用し、リンクの交通容量を推定した結果を図 10に示す。横軸はパラメータの修正回数であり、縦軸はパラメータ推定値である。パラメータの初期値は全て 1,000 であり、約 3,600 回の修正でほぼ真値に収束し停止している。

5,000 回学習後、10,000 回学習後、15,000 回学習後のパラメータ推定結果の値と誤差率を表 3 に示す。

表 3 パラメータ推定結果

学習回数	第1リンク		第2リンク		第3リンク		第4リンク		平均誤差率
	推定容量	誤差率	推定容量	誤差率	推定容量	誤差率	推定容量	誤差率	
5000	2564.13	2.6	1258.64	4.9	1000.93	0.1	1783.74	0.9	2.1
10000	2529.32	1.2	1204.15	0.3	992.00	0.8	1786.71	0.7	0.8
15000	2503.842	1.54E-01	1200.045	3.77E-03	999.9554	4.46E-03	1799.857	7.95E-03	4.25E-02

5,000回学習後、10,000回学習後、15,000回学習後と、学習回数が進むにつれてパラメータの推定誤差は減少し、15,000回学習後では、平均誤差率0.04%にまで精度高くパラメータを推定していることが分かる。




図10 推定結果

5. まとめ

本論文では、自律的にパラメータを調整する手法として、ニューラルネットにより構築された同定モデルの逆伝播計算による推定手法を提案し、シミュレーション実験により、その有効性を示した。サブネットワーク内の結合の学習、サブネットワーク間の結合も含めた学習と2段階に分けて学習する方法、また、学習誤差値に合わせて、乱数幅を調整し学習データを再生成する方法を提案し、複数リンクが相互に影響する場合でも、高精度にパラメータを推定できることを示した。

今後は、本手法を実際の広域な道路網に適用することを考え、シミュレーション結果の交通状態の中から、パラメータ推定に有効な交通状態を出力信号として選択する方法、サブネットワークが表現する対象を、1リンクから、複数リンクからなる小領域に拡張する方法を提案、検証実験を行う。

参考文献

- 1) 古川誠、桑原雅夫、赤羽弘和、吉井稔：交通流シミュレータ実用化に向けたパラメータチューニング作業の自動化 第19回交通工学研究発表会論文報告集, pp.57-60, 交通工学研究会, 1999.