

フィードバック原理に基づく交通状態推定手法を応用した高速道路上起終点旅行時間の推定

鈴木 宏典¹・中辻 隆²

¹正会員 Dr. Eng., (財)日本自動車研究所 安全・情報研究部 (〒305-0822 茨城県つくば市苜間2530)

²正会員 工博 北海道大学大学院助教授 工学研究科 (〒060-8628 札幌市北区北13西8)

高速道路上の起終点(OD)旅行時間を推定する新手法を提案した。各道路区間の交通状態を感知器からのフィードバック作用により推定し、区間旅行時間の時空間的な合計によってOD旅行時間を推定した。筆者らは現在までニューロカルマンフィルタ(NKF)を用い、交通状態を推定せずにOD旅行時間を直接推定する手法を提案してきた。今回既存のNKFによる手法と新提案手法を用いてOD旅行時間を推定した結果、新提案手法が精度の高い推定を行うことを確認した。さらに提案手法を実際の高速道路単路部へ適用した結果、密に感知器を設置することにより混雑状態を含めた広範な交通状態の推定が可能となる見通しを得た。これらの数値計算結果から、OD旅行時間推定に対する提案手法の実用化へ向けての課題を整理した。

Key Words : OD travel time, feedback estimator, macroscopic traffic flow model, Kalman filter

1. はじめに

現在日本国内では交通情報の提供方法が多様化しており、ドライバはカーナビゲーションシステム、VICS、携帯電話等を通じて運転中においてもリアルタイムに交通情報を収集できるようになってきた。特に交通渋滞情報を提供するに当たり、木村¹⁾は交通感知器からのデータとコンピュータによる交通流シミュレーションモデルを利用した交通状態の動的推定及び予測の必要性を指摘している。また、国内では道路交通法改正に伴って、民間業者による交通状態予測情報の提供が可能となり、頻繁な交通情報提供による交通混雑緩和への期待が高まっている。

このような背景の中、筆者らはこれまでにマクロ交通流モデルとカルマンフィルタを組み合わせ、高速道路上の交通状態を推定・予測する研究を行ってきた^{2)~4)}。すなわち、高速道路上に設置された交通感知器データから動的な交通状態をフィードバック原理に基づいて推定するために、カルマンフィルタの状態・観測方程式をマクロ交通流モデルにより表現し、精度の高い推定結果を得ることを実際の数値計算により示してきた。

しかしながら、Pourmoallem and Nakatsuji^{3), 4)}の既存研究では比較的定常的な交通状態の推定に対してはカルマンフィルタの有用性が実証されているも

の、木村¹⁾が指摘するような車線閉塞等の突発的事象に起因する著しい交通混雑状態の推定は未だ行われていない。また、ドライバが最も必要とする交通情報は交通状態の推定値のみではなく、出発前に予想される目的地到着までの起終点所要時間(OD旅行時間)情報であると位置づけられている^{5), 6)}。筆者らは感知器データから直接的にOD旅行時間及びOD旅行時間と相互に関連するOD交通量を推定することを目的とし、ニューラルネットワークとカルマンフィルタを統合した手法(ニューロカルマンフィルタ)の提案を行ってきている^{7)~10)}。しかし、構築した推定モデルはプロトタイプとして開発されたものであるため、その適用は線的道路網に限られており、後述するように実用化の前に解決すべき課題点も残されている。

本研究では、ニューロカルマンフィルタを用いた直接的なOD旅行時間推定手法に代わり、“カルマンフィルタによる交通状態の推定”に関する研究の応用として、交通状態の推定値に基づいてOD旅行時間を推定する試みを行う。既存研究^{3), 4)}の結果から、カルマンフィルタにより一定の精度を保つ交通状態の推定が可能となることが示されており、提案手法によるOD旅行時間推定精度の向上が期待される。

本稿は以下に示す章により構成される。第2章では既存のニューロカルマンフィルタを用いた直接的

なOD旅行時間推定手法の概略を説明し手法の課題点を整理する。第3章ではマクロ交通流モデルとカルマンフィルタの組み合わせによる交通状態の推定手法及びOD旅行時間の間接的な推定手法を簡略に説明する。第4、5章では数値計算を通してカルマンフィルタによる交通状態の推定及び、推定値に基づいたOD旅行時間の推定を行い、既存のニューロカルマンフィルタを用いたOD旅行時間推定手法との比較を行う。ここでは、仮想高速道路での車線閉塞に伴う混雑状態をシミュレートした場合のデータを用いる。第6章では、提案した手法により実際の高速道路上での交通状態推定を行い、第4、5章での数値計算結果と併せて、提案手法のOD旅行時間推定に対する実用化へ向けた課題を整理する。最終章にて、本研究のまとめを行う。

2. ニューロカルマンフィルタを用いた既存のOD旅行時間推定手法

ニューロカルマンフィルタ(Neural-Kalman Filter: NKF)モデルは、Pourmoallem and Nakatsuji⁴⁾によって初めて提唱され、交通状態の動的推定に応用された。一般にカルマンフィルタは、観測可能な“観測変量”から直接観測不可能な“状態変量”を動的に推定する手法であり、状態変量の時間的変化を表す“状態方程式”と、状態変量と観測変量との相関関係を示す“観測方程式”により構成される。Pourmoallem and Nakatsuji⁴⁾は、人工ニューラルネットワーク(Artificial Neural Network: ANN)モデルを用いて状態・観測方程式を表現することにより、両方程式の非線型ダイナミクスを表現可能であることを示し、かつ状態・観測方程式の線形化に伴う係数マトリックスの煩雑な計算を容易に行うことを可能にした。

Suzuki and Nakatsuji⁹⁾は、NKFを改良し感知器データからフィードバック原理に基づいてOD旅行時間及びOD交通量を推定するモデルを提案した。起点を出発する前に予想されるOD旅行時間/OD交通量は直接観測することは極めて困難であるため、これらを状態変量とし、感知器から得られるデータ(地点交通量及び地点速度)を観測変量として状態変量の推定を行った。本稿では、NKFモデルを簡略に説明し、さらにNKFの課題点を整理する。

(1) NKFモデル

まず、カルマンフィルタの状態・観測方程式を、関数 f, g を用いて式(1)及び(2)に示すように定義する。

$$z(k+1) = f[z(k)] + \varphi(k) \quad (1)$$

$$y(k) = g[z(k)] + \phi(k) \quad (2)$$

ここに、

k : タイムステップ

$z(k)$: 状態変量 (OD旅行時間)

$y(k)$: 観測変量 (地点交通量及び地点速度)

$\varphi(k)$: システム誤差

$\phi(k)$: 観測誤差

ここで、関数 f, g はそれぞれ、OD旅行時間の時間変化を記述するANNモデル及び、OD旅行時間と地点交通量/地点速度の関係を示すANNモデルを構成する。本研究にて用いるANNモデルは、三層構造(入力・中間・出力層)を持ち、各層のニューロン同士の結合により隣り合う層のつながりが保たれる。入力層から入力した信号 x_i は、結合係数 w 及びオフセット θ を用い、式(3)により y_k として出力される。ここで、関数 f は式(4)に定義されるsigmoid関数、 u_0 は関数 f の傾きである。ANNモデルに関しては、Dougherty¹¹⁾; Dougherty and Kibby¹²⁾やFaghri and Hua¹³⁾に詳しい。

$$y_k = f \left[\sum_j W_{jk} \cdot f \left(\sum_i W_{ij} x_i + \theta_j \right) + \theta_k \right] \quad (3)$$

$$f(x_i) = 1 / (1 + \exp[-2(x_i - 0.5/u_0)]) \quad (4)$$

ANNモデルの学習はBackpropagation法により行う。出力値 y_k に対して教師データ z_k を呈示し両者の誤差 $(z_k - y_k)$ を出力層から入力層へ逆伝播させることにより、誤差を最小にするように学習を行う。感知器データからNKFを利用してOD交通量とOD旅行時間の同時推定する手法、あるいはマクロ交通流モデルによる精度向上への寄与等に関しては、Suzuki and Nakatsuji⁷⁻¹⁰⁾の既存研究に詳しい。

(2) NKFの課題点

NKFは状態変量の変数の非線型性の再現が可能であるという特徴を持つ⁹⁾が、OD旅行時間やOD交通量推定への実用化の前に解決すべき課題も残されている。

a) ANNモデル構造の大きさに関する課題

Suzuki and Nakatsuji⁷⁻¹⁰⁾の既存研究では、OD旅行時間とOD交通量を直接カルマンフィルタの状態変量と定義したため、大きな道路網ではODペアが膨大となり、必然的にANNモデルの構造も大きくなる。このため、ANNモデルの学習に膨大な時間を要し、用意すべきANNモデル学習用のデータセットも膨大な数となる。例えば、三層ANNモデルのニューロンの数が、それぞれの層で $l-m-n$ 個であるとすると、この時、全ニューロンの結合数は $m(l+n)$ 個

である。しかしながら、状態変数(ODペアの数=ニューロンの個数)が2倍、3倍…に増加すると、結合数は $4m(l+n)$ 個、 $9m(l+n)$ 個…と指数関数的に増加し、ANNモデルの学習時間及び学習用データセット数に大きな影響を及ぼす。

b) 推定精度に関する課題

一般的にカルマンフィルタの状態・観測方程式は完全に解析的に定義されている必要がある。しかしながら、OD旅行時間とOD交通量をNKFによって推定する場合には、状態・観測方程式を完全に解析的に定義することは極めて困難である。またカルマンフィルタの状態方程式を、ANNモデルという非線型回帰モデルによって定義しているため、交通状態や感知器の設置数、感知器の位置によってOD旅行時間/OD交通量の推定精度が低くなる場合もある。

c) NKFのパラメータ調整に関する課題

Suzuki and Nakatsuji⁷⁾らの既存研究の中で、NKFはANNモデルのパラメータ調整が複雑であり、微妙なパラメータの変化により推定値がセンシティブに反応する、という課題も指摘されている。

3. 交通状態推定に基づくOD旅行時間推定

上記NKFの課題点を踏まえ、本研究では交通状態の動的推定に関する研究の一環として、NKFに代わる新しいOD旅行時間推定手法を提案する。すなわち、マクロ交通流モデルによってカルマンフィルタの状態・観測方程式を完全に解析的に記述し、感知器データから交通状態(密度、空間平均速度、地点交通流量及び地点速度)を推定すると共に、この交通状態の推定結果に基づいてOD旅行時間を間接的に推定することを試みる。この場合、a) 状態・観測方程式が解析的に記述されている、b) 状態変数の数がODペア数に替わり、道路区間の交通状態となるため、大きな道路網では状態変数の次元数を小さくすることが出来る、という利点がある。

(1) マクロ交通流モデル^{14), 15)}

本研究で用いるマクロ交通流モデルは、「流量保存則」と「圧縮性流体の運動方程式」に基づく「高次項モデル(High Order Model)」である。高次項モデルは、密度、速度、交通量という3つの交通変数を決定するためにq-k-v式と併せて3つの式が完備され、速度に関する実験的・経験的考察に基づいた式を用いているため、k-v(k-q)式に基づく単純マクロモデルに比べて、高速道路上における交通流の表現能力に優れていることが明らかにされている¹⁶⁾⁻¹⁸⁾。図-1




図-1 高速道路のセグメント分割

に示すように、対象とする高速道路を均質な道路区間(セグメント)に分割し、時間間隔 Δt における定常性を仮定して、式(5)~(9)に定義するように、各道路区間の密度、空間平均速度、地点交通流量及び地点速度を動的に計算する。

はじめに、諸物理量を以下に定義する。

- k : タイムステップ
- i : 道路区間番号
- Δt : シミュレーション時間間隔(sec)
- ΔL_i : 区間 i の距離(km)
- $c_i(k)$: 区間 i , 時刻 k での密度(台/km:veh/km)
- $v_i(k)$: 区間 i , 時刻 k での空間平均速度(km/h)
- $q_i(k)$: 区間 i , 時刻 k での地点交通流量(台/時:vph)
- $w_i(k)$: 区間 i , 時刻 k での地点速度(km/h)
- $r_i(k)$: 区間 i , 時刻 k でのランプ流入量(vph)
- $s_i(k)$: 区間 i , 時刻 k でのランプ流出量(vph)
- V_f : 自由走行速度(km/h)
- c_{max} : 渋滞密度(veh/km)
- l, m : 追従理論における感度パラメータ
- N : 道路区間数
- M : 観測地点数

$$c_i(k+1) = c_i(k) + \frac{\Delta t}{\Delta L_i} [q_{i-1} - q_i + r_i - s_i]_{(k)} \quad (5)$$

$$v_i(k+1) = v_i(k) + \frac{\Delta t}{\tau} [V(c_i) - v_i]_{(k)} + \frac{\Delta t}{\Delta L_i} [v_i(v_{i-1} - v_i)]_{(k)} + \frac{v}{\tau} \frac{\Delta t}{\Delta L_i} \left[\frac{c_i - c_{i+1}}{c_i + \kappa} \right]_{(k)} \quad (6)$$

ここに、 $V(c_i)$ は均衡状態での「密度-速度」関係から式(7)により計算される速度である。また、 τ, v, κ はマクロ交通流モデルのパラメータである。

$$V(c_i) = V_f \left[1 - (c_i / c_{max})^\gamma \right]^{1-m} \quad (7)$$

各区間の地点交通流量及び地点速度は、重み係数 α により、それぞれ次式で定義される。

$$q_i(k) = [\alpha \cdot c_i v_i + (1-\alpha) \cdot c_{i+1} v_{i+1}]_{(k)} \quad (8)$$

$$w_i(k) = [\alpha \cdot v_i + (1-\alpha) \cdot v_{i+1}]_{(k)} \quad (9)$$

式(5)~(9)が、高速道路上の交通流をダイナミックに表現するためのマクロ交通流シミュレーションモデルを構成する。高次項モデルは、具体的には、

a) ドライバが前方（下流）における密度変化を感知しその密度に対して予め速度を調整する項(式(6)右辺第3項)を含む, b) ドライバが密度変化の事前検知により予め速度を調整する際の時間遅れを考慮する項(式(6)右辺第2項)を含む, という特徴を持つ。

(2) カルマンフィルタによる交通状態推定手法^{2),3)}

前述したように, カルマンフィルタは, 観測可能な観測変量から直接観測不可能な状態変量をフィードバック原理に基づき動的に推定する手法である。少なくとも現状の高速道路に整備されている車両感知器のみでは, 密度 $c_i(k)$ 及び空間平均速度 $v_i(k)$ を直接観測することは極めて困難であるため, 密度及び空間平均速度を状態変量とし, 地点交通量 $q_i(k)$ 及び地点速度 $w_i(k)$ の観測変量から間接的に状態変量を推定する。カルマンフィルタを構成する状態方程式は, 式(5)及び(6)によって解析的に定義され, また観測方程式は同様に式(8)及び(9)により表現される。ここで, ベクトル・マトリックスにより状態・観測方程式を再定義する。

$$\mathbf{x}(k+1) = \mathbf{A}(k)\mathbf{x}(k) + \mathbf{B}(k)\mathbf{u}(k) + \mathbf{b}(k) + \Gamma\varphi(k) \quad (10)$$

$$\mathbf{y}(k) = \mathbf{C}(k)\mathbf{x}(k) + \mathbf{d}(k) + \phi(k) \quad (11)$$

ここに,

$\mathbf{x}(k)$: 状態変量 (= $[c_1 v_1, \dots, c_N v_N]^T$)

$\mathbf{y}(k)$: 観測変量 (= $[q_1 w_1, \dots, q_M w_M]^T$)

$\mathbf{u}(k)$: 制御変量

$\mathbf{A}(k), \mathbf{B}(k), \mathbf{C}(k)$: 係数マトリックス

$\mathbf{b}(k), \mathbf{d}(k)$: 定数項

$\Gamma\varphi(k), \phi(k)$: システム誤差, 観測誤差

この再定義により, マクロ交通流モデルを応用した, カルマンフィルタによる交通状態の推定が可能となる。係数マトリックスは状態・観測方程式(10)及び(11)を, それぞれ状態変量 $\mathbf{x}(k)$, 制御変量 $\mathbf{u}(k)$, 観測変量 $\mathbf{y}(k)$ で偏微分することにより計算される。

カルマンフィルタを用いた交通状態推定は, 以下の手順により行う。

Step 0 : 時刻 $k=0$ とし, 状態変量の初期値 $\hat{\mathbf{x}}(0)$ 及び, 推定誤差の分散行列の初期値 $\mathbf{P}(0)$ を与える。

Step 1 : 時刻 $k-1$ において, 式(5)~(9)を用いたマクロ交通流シミュレーションにより状態変量の1ステップ先の予測値 $\hat{\mathbf{x}}(k)$ を計算する。

Step 2 : 同様に, 観測変量の推定値 $\hat{\mathbf{y}}(k)$ を計算する。ここで, $\hat{\mathbf{x}}(k)$ 及び $\hat{\mathbf{y}}(k)$ は, 式(10)及び(11)の左辺をそれぞれ計算することに相当する。

Step 3 : $\hat{\mathbf{x}}(k)$ に対する誤差分散行列 $\mathbf{M}(k)$ を式(12)により計算する。

$$\mathbf{M}(k) = \mathbf{A}(k-1)\mathbf{P}(k-1)\mathbf{A}'(k-1) + \Gamma\Phi\Gamma' \quad (12)$$

Step 4 : Kalman gain $\mathbf{K}(k)$ を式(13)により計算する。

$$\mathbf{K}(k) = \mathbf{M}(k)\mathbf{C}'(k)[\mathbf{C}(k)\mathbf{M}(k)\mathbf{C}'(k) + \Psi]^{-1} \quad (13)$$

Step 5 : 時刻 k において, 実際の観測変量 $\mathbf{y}(k)$ を感知器により観測する。

Step 6 : 観測変量の実測値 $\mathbf{y}(k)$ と推定値 $\hat{\mathbf{y}}(k)$ の差分とKalman gain $\mathbf{K}(k)$ から, 式(14)を用いて状態変量の予測値 $\hat{\mathbf{x}}(k)$ を $\hat{\mathbf{x}}(k)$ に修正し, これを時刻 k での状態変量の推定値とする。

$$\hat{\mathbf{x}}(k) = \hat{\mathbf{x}}(k) + \mathbf{K}(k)[\mathbf{y}(k) - \hat{\mathbf{y}}(k)] \quad (14)$$

Step 7 : $\hat{\mathbf{x}}(k)$ に対する誤差分散行列 $\mathbf{P}(k)$ を式(15)により更新する。

$$\mathbf{P}(k) = \mathbf{M}(k) - \mathbf{K}(k)\mathbf{C}(k)\mathbf{M}(k) \quad (15)$$

Steps 1より**7**までを逐次繰り返すことにより, 交通状態の推定を行う。ここに, Φ 及び Ψ はシステム誤差及び観測誤差の分散行列である。

(3) OD旅行時間の推定アルゴリズム

OD旅行時間は, 各道路区間の区間旅行時間(リンク旅行時間)を時間的かつ空間的に足しあわせることにより計算される。まず, 各道路区間の空間平均速度 $v_i(k)$ がカルマンフィルタによって逐次推定できるため, 区間距離を $v_i(k)$ で除すことにより, リンク旅行時間を算出する。次に, Originとなる道路区間 i 及びDestinationの道路区間 j を設定すると($i < j$), $i-j$ 間のOD旅行時間 $T_{ij}(k)$ はリンク旅行時間の時間的な合計により, 式(16)により計算する。

$$T_{ij}(k) = T_{i,j-1}[k - T_{j-1,j}(k)/\Delta t] + T_{j-1,j}(k) \quad (16)$$

4. シミュレーションによる数値計算

今回提案した「交通状態の動的推定に基づいた間接的なOD旅行時間の推定手法」の有用性を検証するために, 仮想道路を想定して数値計算を行い, 「NKFによる直接的な旅行時間の推定手法」との比較を行う。さらに, 今回提案する手法に関しては, 感知器数の変化がOD旅行時間の推定精度に与える影響を定量的に把握する試みも行う。第2章(2)に述べたように, NKFによる直接推定では大規模道路網を対象とすることが困難なことから, 図-2に示したような小さな仮想道路を対象とする。また, 非混雑・混雑状態を含めた広範な交通状態でのOD旅行時間推定を行い, 推定精度を議論する必要があることから, 仮想の交通データを用いることとする。

(1) 仮想高速道路の設定

仮想高速道路は、図-2に示すような5.0 kmの2車線高速道路とし、これを等間隔(500m)の10個の道路区間に分割する。全道路区間の始端・終端に感知器を設置し(合計11個所)、地点交通量 $q_i(k)$ 及び地点速度 $w_i(k)$ を1分毎に計測する。

仮想高速道路上の交通流シミュレーションによる仮想データは、OD旅行時間推定の評価に用いるマクロ交通流モデルとは完全に独立であることが肝要であるため、筆者の一人が構築したstochasticなミクロ交通流モデル¹⁹⁾を用いることとする。本ミクロ交通流モデルは、追従理論に基づいて0.1秒毎に個々の車両の加速度、速度、位置を計算するタイムスキャニング方式のモデルであり、基本的なモデルの仕様は、Yang and Koutsopoulos²⁰⁾のモデルを参考としている。乗用車・大型車共に10種類のドライバパターンを入力するものであり、その入力項目は、反応時間、車両長、最大加速度、通常減速度、希望車速、希望最大車頭時間、希望最小車頭時間である。首都高速道路神奈川線上り線・浜川崎ランプを挟む4.6 kmの区間において、実際の感知器により観測されたデータを基にモデルの現況再現性を確認した結果、2個所の観測地点における地点交通量及び地点速度の平均誤差は、それぞれ約8%、6%であった。この結果から、少なくとも図-2に示すような規模の小さい仮想道路においてはモデルの妥当性はあると判断し、本ミクロ交通流モデルによりシミュレートされる仮想データを用いることとした。

(2) ミクロ交通流モデルによる仮想データ

以下に示す条件に基づいた仮想高速道路上におけるシミュレーションを、異なる10種類のランダムシードを用いて行い、10回のシミュレーションにより得られる感知器データ及びOD旅行時間の平均値をそれぞれ“実際の感知器データ”及び“ターゲットOD旅行時間”とし、このデータを交通状態推定及びOD旅行時間推定のためのチェックデータとする。

- ・車両の流入は道路区間No.1の始端のみで行う。
- ・シミュレーション時間は90分とする。
- ・流入量は式(17)によって与えられる一定値とする。

$$q_0(k) = 3000 \text{ (台/時/2車線)} \quad (17)$$

- ・シミュレーション開始から25分後に2車線の内左側1車線が閉塞し、同35分後に解除する。
- ・車線閉塞は道路区間No.10の終端から下流250m地点を起点とし、同350m地点を終点とする100mの区間とする。




図-2 仮想高速道路

(3) 交通状態推定に基づく間接的なOD旅行時間推定手法 (提案手法: 手法A)

間接的なOD旅行時間の推定は、a) カルマンフィルタによる交通状態の推定と、b) 交通状態の推定値に基づくOD旅行時間の推定という二つのステップに分けられる。この提案手法を「手法A」とした。図-2に示すように4つ($i=0,3,7$ and 10)、6つ($i=0,1,3,5,7$ and 10)及び全て($i=0-10$)の観測地点で感知器を利用した場合についてOD旅行時間の推定を行う。例えば、首都高速道路においては感知器が200~300m毎に設置されているが、運用上その半分程度の数の感知器を利用すると仮定した場合には、約400~600m程度毎に感知器を利用できると考え、500m毎の感知器設定(全地点)を仮定した。さらに、このうち必ずしも全ての感知器が利用できないことを考慮し、約500m, 1000m, 1500m, 2000mのような感知器間隔を含む場合を想定して、図-2に示すような4地点及び6地点の配置とした。推定手順は以下に示す通りである。

Step A1: 道路区間No.1の始端より3,000(台/時/2車線)の流入割合で、マクロ交通流モデルを用いた90分のシミュレーションを開始する。

Step A2: シミュレーション中、第4章(2)にて得られた1分毎のチェックデータ(実際の感知器データ)をそれぞれの観測点において逐次検知することにより、カルマンフィルタを利用した動的な交通状態の推定を行う。

Step A3: 全道路区間の空間平均速度 $v_i(k)$ を推定し、第3章(3)に示したアルゴリズムにより道路区間No.1からNo.10までのOD旅行時間を推定する。この推定されるOD旅行時間と第4章(2)にて得られるチェックデータ(ターゲットOD旅行時間)を比較する。この場合、状態変量のベクトル表現は

$$x(k) = [c_1 v_1, c_2 v_2, \dots, c_{10} v_{10}]^T$$

となり、観測変量は以下のように定義される。

$$y(k) = [q_0 w_0, q_3 w_3, q_7 w_7, q_{10} w_{10}]^T \quad (4 \text{ 地点})$$

$$y(k) = [q_0 w_0, q_1 w_1, q_3 w_3, q_5 w_5, q_7 w_7, q_{10} w_{10}]^T \quad (6 \text{ 地点})$$

$$y(k) = [q_0 w_0, \dots, q_{10} w_{10}]^T \quad (\text{全地点})$$

(4) NKFによる直接的なOD旅行時間推定手法（既存手法：手法B）

NKFを利用したOD旅行時間推定では、交通状態を推定せずに感知器データから直接的にOD旅行時間を推定する。手順は以下に示す通りである。

Step B1：ミクロ交通流モデルを用い、第4章(2)に示した方法により、Artificial Neural Network(ANN)モデル学習用のデータセットを用意する。ただし、道路区間No.1の始端からの流入量は正規乱数を用いて式(18)によって与え、さらにミクロ交通流モデルのランダムシードを変化させてシミュレーションを行うことにより、チェックデータとは異なるANNモデル学習用のキャリブレーションデータを得る。この場合のキャリブレーションデータは、OD旅行時間 $z(k)$ 及び、全観測地点 ($i=0-10$)を想定した感知器データ $y(k)$ である。

$$q_0(k) = 3000 + \theta \text{ (台/時/2車線)} \quad (18)$$

Step B2：Step B1にて得られたキャリブレーションデータを用い、式(1)及び(2)に定義した状態・観測方程式を構成する三層ANNモデルの学習を行う。それぞれのANNモデルにおける入力・中間・出力層のニューロンの個数は、それぞれ、1-1-1及び1-1-22であり、ニューロンの結合数は、2個及び23個である。キャリブレーションデータ数は、本研究の場合70個であり、少なくともニューロン結合数の3倍以上であるため、学習を行うに当たり十分なデータセット数と考えられる。

Step B3：チェックデータ（実際の感知器データ）を逐次1分毎に検知することにより、NKFを用いて直接的にOD旅行時間を推定する。手法Aと同様に、推定されるOD旅行時間とチェックデータ（ターゲットOD旅行時間）を比較する。

この場合、状態・観測変量のベクトル表現はそれぞれ以下に示す通りとなる。

$$z(k) = [T_{1,10}]^T, \quad y(k) = [q_0 w_0, \dots, q_{10} w_{10}]^T$$

NKFのパラメータ調整に関しては、未だ確立された方法が検討されていないため、“Try and Error”により行う。まず、式(4)に定義されたsigmoid関数 f の傾き u_0 を、0.5から1.5の範囲で0.1刻みで増加させ、計算されるOD旅行時間推定値の平均誤差が最小に

なる傾きを抽出する。次に、抽出された傾きから0.1を引いた値と0.1を加えた値の間で、さらに0.01刻みで傾きの値を増加させ、OD旅行時間推定値の平均誤差が最小になる傾きを抽出する。最後に、抽出された傾きを固定したまま、オフセット θ を0.1から1.0の間で0.1刻みで増加させ、OD旅行時間推定値の平均誤差が最小となる時の傾きとオフセットを最適なパラメータと仮定する。

5. 数値計算結果

(1) 交通状態の推定結果

手法Aによる間接的なOD旅行時間推定においては、まずカルマンフィルタによる交通状態の推定が必要となる。交通状態の推定を評価する際には、推定される各道路区間の密度及び空間平均速度が実際の状態をどの程度精度良く表現できているか、を検証することが望ましいが、前述したように密度及び空間平均速度を1分毎に計測することは極めて困難である。したがって、カルマンフィルタによる交通状態の推定に利用しなかった観測地点(check point)における観測変量(地点交通量及び地点速度)の推定値が、チェックデータ（実際の感知器データ）をどの程度精度良く再現できているか、を定量的に評価することにより、カルマンフィルタによる交通状態の推定精度を議論する。本研究におけるcheck pointは、道路区間No. 2, 4, 6, 8, 9である。

交通状態推定結果の例として、道路区間No.2, 6, 8における地点交通量/地点速度の時系列変化を図-3~8に示す。ここで、○印はミクロ交通流モデルから得られたチェックデータ（実際の感知器データ）(Target)、点線及び実線は、それぞれ4地点(OP4)、6地点(OP6)の場合のカルマンフィルタによる推定値である。これらの図より以下のことがわかる。

- ・カルマンフィルタの利用により、多少の例外を除き、いずれの地点においても車線閉塞に起因する混雑した交通状態の推定が可能となる。
 - ・何れの観測変量についても、6つの観測地点の感知器データを利用する場合が4つの観測地点の場合に比べて、精度の高い交通状態の推定結果を生む。
 - ・図-6に示す道路区間No.6の地点速度の推定値は、渋滞が解消した後地点速度が増加に転じる際にターゲット値に比べて若干速度が低い状態が続く。
 - ・道路区間No.8では、図-7~8に示すように地点交通量/地点速度ともに、渋滞流の伝播を推定する際に数分のタイムラグ(遅れ時間)が生じている。
- 図-9~10に全てのcheck point ($i = 2, 4, 6, 8 \text{ and } 9$)にお




図-3 地点交通量の比較(道路区間 No. 2)




図-7 地点交通量の比較(道路区間 No. 8)




図-4 地点速度の比較(道路区間 No. 2)




図-8 地点速度の比較(道路区間 No. 8)




図-5 地点交通量の比較(道路区間 No. 6)




図-9 各Check PointにおけるRMSE値の比較(地点交通量)




図-6 地点速度の比較(道路区間 No. 6)




図-10 各Check PointにおけるRMSE値の比較(地点速度)

ける地点交通量及び地点速度の平均自乗誤差(Root Mean Square Error: RMSE)を計算し、4つ(OP4)及び6つの観測地点(OP6)を設けた場合のRMSE値を比較する。観測地点数が何れの場合についても、カルマンフィルタはその理論上、状態変量の誤差の平均値を零にし、かつ誤差の分散を最小にように状態変量の推定を行っている。カルマンフィルタは常に最適推定を行うものの、感知器が4つの場合においては、6つの場合と比較して感知器からフィードバックされる情報量が不足しているため、状態変量の推定誤差が大きくなっているものと判断される。また、check point 8及び9の顕著な誤差は、前述したような渋滞感知の時間遅れによる影響が見掛以上に大きな誤差を与えたと判断される。

これらの結果から、a)カルマンフィルタによって車線閉塞に起因する混雑した交通状態の推定も可能であること、b)観測地点数の増加により交通状態の推定精度が改善されることが定量的に評価された。

(2) OD旅行時間推定結果

図-11に、手法A(カルマンフィルタを利用した交通状態推定に基づく間接的な旅行時間推定手法)と、手法B(ニューロカルマンフィルタ(NKF)による直接的な旅行時間推定手法)によるOD旅行時間の推定結果を比較する。図中○印はマイクロ交通流モデルによるターゲットのOD旅行時間であり、各手法によるOD旅行時間推定値がターゲットのOD旅行時間をどの程度再現できているのかを比較する。手法Aに関しては、観測地点数を4地点(手法A:OP4)、6地点(手法A:OP6)及び全地点(手法A:All)に設定した場合についてそれぞれの結果を比較する。また、各手法によるOD旅行時間推定のRMSE値を図-12に示す。

図-11~12より理解できる点は、以下の5点である。

- ・手法A(OP4)によるOD旅行時間の推定値は、混雑時(Time=約30-40min.)及び混雑解消(Time=約40-50min.)後のほとんどの時間においてターゲット値に比べて概ね高い値を示す。
- ・手法A(OP6)はターゲットのOD旅行時間に対して混雑時(Time=約30-40min.)に過大な推定を行うが、混雑解消過程(Time=約40-50min.)においては、手法A(OP4)と比べて精度の高い推定値を生む。
- ・手法A(All)は他の手法と比べて高い精度のOD旅行時間を推定し、手法A(OP4, OP6)に見られる混雑時及び混雑解消時の過大推定が軽減されている。
- ・手法B(NKF)は手法Aとは対照的に混雑時(Time=約30-40min.)におけるOD旅行時間の推定値がターゲット値に比べて低く、渋滞解消(Time=約40-50min.)後のOD旅行時間減少過程における再現性




図-11 OD旅行時間推定結果の比較




図-12 OD旅行時間推定におけるRMSE値の比較

にやや劣っている。

- ・手法A(All)が最も精度の高いOD旅行時間推定を行い、交通状態の推定を伴わない手法B(NKF)に比べて、推定精度が約53%高くなっている。

(3) OD旅行時間推定結果に対する考察

- ・手法A(OP6, OP4共)によりOD旅行時間が過大推定となる原因は、例えば図-6に示すように道路区間No.6において渋滞解消後の地点速度が過小推定されること、図-8に示すように道路区間No.8において渋滞流検知に時間遅れが生じていることによるものと判断される。これは感知器データの情報量不足により、急激な交通状態の変化に対してカルマンフィルタのフィードバック機能が十分に機能していないことが原因と考えられる。感知器データからの情報量を増加させるために、全観測地点を用いてOD旅行時間推定を行った場合には、手法A(OP6, OP4共)による結果と比較して、OD旅行時間の過大推定は軽減され、推定精度も向上している。これは、OD旅行時間推定に際し、十分な情報量が得られたことを示すものである。
- ・手法AによるOD旅行時間推定においては、観測地点数が4、6地点の場合ではその推定が十分であるとは言えず、特に4地点の場合では、手法B(NKF)に比べてOD旅行時間の推定精度が低くなる。カルマンフィルタを利用してOD旅行時間の

推定を行う際には、観測地点数を可能な限り増加させることが重要であると考えられる。一定以上のOD旅行時間推定精度を確保するためにどの程度の観測地点数が必要か、についてはその数を理論的に求める手法は確立されていないが、少なくとも本数値計算例の場合には、500m毎の感知器導入により(手法A:All)、一定以上のOD旅行時間の推定精度が確保されると考えられる。この点に関しては、第6章に示す実際の高速道路の交通状態推定結果を参考に、更なる考察を行いたい。

- ・手法BによるOD旅行時間推定結果が他の手法に比べて低くなった原因としては、ANNモデルの学習データ不足、パラメータ調整による問題が考えられる。これらの点に関しては今後の課題としたい。

6. 提案手法の実用化へ向けた課題

本稿にて新しく提案したOD旅行時間推定手法は、まず可能な限り多くの感知器データを利用し交通状態を正確に推定することが重要となる。本章では、提案手法の大規模高速道路網への適用を検討するための第1段階として、まず新たに実際の高速道路単路部における交通状態の推定を行い、第5章での数値計算結果と併せて、OD旅行時間推定に対する提案手法の実用化へ向けた課題を整理する。

(1) 対象道路区間の概要

対象とする高速道路は首都高速神奈川線3号狩場線より、数箇所の流入・流出ランプを含む狩場集約料金所から本牧ジャンクション手前まで約7.2 kmの線の道路区間とした。本道路区間には27地点において感知器が設置されているが、第5章の数値計算結果から約500m毎に感知器が設置されるようにマクロ交通流モデルのセグメント分割を行った(図-13)。図-13中実線矢印は13の観測地点、点線矢印はcheck point、×印は感知器の利用が不可能な地点である。

数値計算に利用するデータは、1996年2月20日(火)05:01~11:00の6時間の間に、対象道路区間に設置されている感知器によって1分毎に計測された地点交通量及び地点速度データとする。

(2) 交通状態推定手順

Step 1:道路区間No.1(狩場料金所)及び、他の流入ランプから実際に感知器により計測された流入割合で、マクロ交通流モデルを用いた6時間のシミュレーションを開始する。

Step 2:シミュレーション中、13の観測地点において




図-13 首都高速神奈川3号狩場線 道路セグメント分割図

計測された1分毎の地点交通量/地点速度を逐次検知することにより、第5章と同様にカルマンフィルタを利用した動的交通状態の推定を行う。

(3) 交通状態の推定結果

交通状態の推定結果を示す例として、図-14~15にcheck point(道路区間No.11)における地点交通量と地点速度の推定値を、それぞれの実測値と比較した。推定値、実測値共に、10分間の移動平均値を示しており、6時間のシミュレーションにおける地点交通量及び地点速度の平均誤差(RMSE)は、それぞれ470(台/時:vph)、7.1(km/h)であった。1996年2月20日(火)には、実際に道路区間No.13付近において07:15~08:14の約1時間に、2車線のうち1車線が閉塞していた。図-14~15は、カルマンフィルタが約1時間の車線閉塞に伴う混雑した交通状態の推定を再現していることを示している。また、1つのcheck pointにおける評価のみでは不十分と考え、第5章と同様の手法により道路区間No.1~15までのOD旅行時間の推定も行った。しかしながら、比較すべき実際のOD旅行時間は計測されていない。ここでは、あくまでも約7.2 kmの道路区間全体における交通状態の再現性を評価する目的において、以下に示す方法によりOD旅行時間の参考値を算出した。まず対象道路区間に設置されている全ての感知器(27地点)を利用し、隣り合う2つの感知器同士で地点速度の平均値を計算する。これを2つの感知器間におけるセグメントの空間平均速度と仮定し、第3章(3)のアルゴリズムによりこの空間平均速度を合計した値をOD旅行時間の参考値とした。図-16にOD旅行時間の推定値及び参考値を示す。

OD旅行時間の参考値は、あくまでも約7.2 kmの道路区間全体における交通状態の再現性を評価するために参考として計算したものであり、OD旅行時間の推定値との比較を行うものではない。参考として両者の平均誤差(RMSE)を計算すると、2.9分となった。当然ながら、図-16からはOD旅行時間の推定




図-14 地点交通量の比較(道路区間 No. 11)




図-15 地点速度の比較(道路区間 No. 11)




図-16 OD旅行時間の参考値と推定値

精度の議論は出来ないが、1つのcheck pointに限らず、少なくとも7.2 kmの実際の高速道路区間における何れの地点においても交通状態の推定が確実に行われていることが推察できる。

これらの結果より、流入・流出を含む実際の高速道路単路部においても、密に(今回の数値計算結果では約500m毎)感知器を設置することにより、混雑状態を含めた広範な交通状態を推定する見通しを得ることができた。

(4) 実用化へ向けた課題点の整理

a) 感知器の設置間隔に関して

首都高速道路を例にとると、実際に200-300m毎に感知器が設置されており、マクロ交通流モデルのセグメント長も同程度の距離に設定することが望ましいが、大規模な道路網でのOD旅行時間推定を今後

検討すべきことを考慮し、計算時間短縮の目的によりシミュレーションタイムステップを10秒に設定すると、セグメント長は約500m程度必要となる²⁾。この距離は、全感知器数の半分程度を利用することとなり、感知器のメンテナンス等で全感知器が利用できないことを考慮すると、実際の運用上も妥当であると判断できる。

最適な感知器間隔及び数を理論的に導く方法は未だ検討されていないが、少なくとも第5、6章の数値計算からは約500m毎の感知器設置により、一定の精度を確保できる交通状態推定及びOD旅行時間推定が可能になるものと考えられる。実際の大規模道路網において500m毎の感知器設置が妥当な値であるかどうかの検討は、今後の適用事例に委ねたい。

b) 対象とする道路網の大きさと推定単位に関して

対象とする道路網に関しては段階的に考慮するものとし、例えば、首都高速神奈川線全域(総延長67.3 km)→首都高速道路全域(同263.4km)→都市間高速道路網(同約600~1,000km)の順に検討を行うことが考えられる。感知器間隔を約500m程度とすると、例えば首都高速道路全域では約550個の道路区間及び感知器データが必要となる。推定単位を1~5分毎程度と想定した場合、550個の道路区間及び感知器数を扱う上での計算速度やメモリ容量等を検討し、実運用上の問題点を整理する必要がある。参考として、首都高速神奈川3号狩場線(約7.2km)において、約6時間の交通状態推定及びOD旅行時間推定を推定単位1分で行った場合の実計算速度は約1.53(s)であった(Pentium III 550MHz, メモリ容量128MB)。

c) 対象とするODペアに関して

ODペアに関しては、需要(OD交通量)の多い複数のODペアを選択することが望ましく、現状でどのODペアについてそのOD交通量がどの程度であるのかを具体的に調査する必要がある。例えば都市間高速道路に関しては通行券によりOD交通量の把握が可能となっており、現状のOD交通量を把握するためのデータ提供方法の確立が望まれる。

d) 交通データの収集・整備・提供に関して

交通データに関しては、例えばProbe車の利用により、感知器が不足するような箇所(感知器間の距離が500mを超えるような場所)での交通情報(Up-Link data)の収集、OD旅行時間の計測に関する検討を図る必要があると考えられる。今後は、本提案手法によるOD旅行時間推定精度の議論を図るために、感知器データや、実配備が検討されているProbe車からのUp-Linkデータ、あるいは都市間高速道路については通行券データによるOD旅行時間データの収集・整備・提供方法の確立が望まれる。

7. おわりに

筆者らは、車両感知器データが有する情報量を最大限引き出すべく、カルマンフィルタを利用してフィードバック的に高速道路上の交通状態(密度、空間平均速度、地点交通量、地点速度)やOD交通量・OD旅行時間をダイナミックに推定する研究に従事してきている。本研究においては、マクロ交通流モデルとカルマンフィルタを組み合わせることで交通状態を推定した後に、その推定値に基づいてOD旅行時間を間接的に推定する手法を新たに提案した。

本提案手法の有用性を検討するために、仮想道路及び実高速道路において簡単な数値計算を行い、仮想道路での数値計算では、著者らがこれまで開発を行ってきたニューロカルマンフィルタ(NKF)を用いた直接的なOD旅行時間推定手法との比較を行った。今回の数値計算では、NKFを用いた手法が大きな道路ネットワークに対応していないことを考慮し、小さな道路ネットワークを比較の対象とした。また、混雑・非混雑状態を含めた広範な交通状況でのOD旅行時間推定を行う必要があることから、仮想の交通データを用いるものとした。数値計算の結果、以下に示すような知見を導くことができた。

- ・カルマンフィルタとマクロ交通流モデルの利用により、渋滞のない定常的な交通状態のみではなく、車線閉塞に伴う混雑した交通状態も感知器データによるフィードバック作用によって、推定することが可能である。特に、実際の高速道路単路部において、約500m毎に設置された感知器からのフィードバックを行った場合においても、車線閉塞に伴う交通混雑状態を推定できることが示された。
- ・カルマンフィルタを利用した交通状態の推定及び交通状態推定値に基づいたOD旅行時間を推定する際には、観測地点数が多いほど精度の高い推定結果が得られる。少なくとも約5.0 kmの単路道路区間において500m毎に感知器を設置することにより、一定の精度を確保できるOD旅行時間の推定が可能になると考えられる。
- ・仮想道路での数値計算においては、提案手法によるOD旅行時間の推定精度が、NKFを利用した既存手法による推定精度を上回る。この理由として、a)マクロ交通流モデルによってカルマンフィルタの状態・観測方程式が数学的かつ解析的に定義されていること、b)交通状態を示す4つの状態変量(密度、空間平均速度、地点交通量、地点速度)の中でも、特にOD旅行時間推定に影響を及ぼす空間平均速度が正確に推定されることが挙げられる。マクロ交通流モデルはそのモデルの構造上、カル

マンフィルタを適用可能な形となっており、結果として感知器からの観測データのフィードバックを受けながら逐次交通状況の最適推定値を算出することが出来る。少なくとも、「カルマンフィルタを適用し、感知器からのフィードバックを受けながら状態変数の更新が可能である」という点は、ミクロ交通流モデルに勝る特性である。また、高次項を有するマクロ交通流モデルは、その構造がやや複雑なこともあって従来あまり用いられてこなかったが、過去10年来にわたる構造特性や感度特性に関する研究成果^{16)・18)}から、動的な解析に有望な手法として認識されてきており今後の広範な利用が期待されている。

本研究においては、ランプからの流入・流出のない単純な仮想道路区間及び、流入・流出のある実際の高速道路単路部において数値計算を行ったのみであり、一概に提案手法の有用性を評価できるとは限らない。今後は、第6章(4)に述べた課題を検討することにより、実際の大規模高速道路網のOD旅行時間推定に対して本手法を適用し、提案手法の有用性を検討したい。一方では、OD旅行時間と密接な関連を持つOD交通量の推定に際しては、NKFを利用した手法に頼らざるを得ないのが現状であり、NKFの問題点の改良によってOD交通量及びOD旅行時間推定に対する実用的モデルの構築も検討したい。

わが国の交通管制システムにおいては、車両感知器が密に設置されていること、同時にその維持管理に優れた計測データの品質が高いことを特色としている。しかしながら、その一方で計測されているデータの持つ情報が十分に活用されている状況にあるとは言えない。提案手法は、第6章(4)に述べた課題点を検討する必要があるものの、感知器データを最大限に活用し、コンピュータプログラムとしてのマクロ交通流モデルとカルマンフィルタを応用することにより簡便にOD旅行時間を推定することが可能である。また、Probe車からのUp-Linkデータによる交通状態やOD旅行時間の推定に対して比較的容易に対応可能であることも将来の管制システムとして有望な一面である。本提案手法により、ITSによる交通混雑緩和を念頭に置いた、早期実現可能な交通情報提供システムの確立が期待される。

謝辞：本研究を行うにあたり、実際の高速道路路上における感知器データ提供の便宜をお取り計らい頂きました。首都高速道路公団・交通管制部の方々に対し、ここに記して謝意を表します。

参考文献

- 1) 木村昌司: 提言: 動的交通予測の動向と課題, 交通工学 Vol.36, No. 3, 交通工学研究会, pp. 4-5, 2001.
- 2) 中辻 隆, 加来 照俊: 車両感知器データを直接利用したマクロ交通流シミュレーションの交通状態量の推定精度に関して, 土木計画学研究・講演集 Vol. 16(1), 土木学会, pp. 115-120, 1993.
- 3) Pourmoallem, N. and Nakatsuji, T.: A multiple section method for estimating real-time traffic states on freeway, *Proceedings of Infrastructure Planning and Management*, Vol. 18(2), JSCE, pp. 377-380, 1995.
- 4) Pourmoallem, N. and Nakatsuji, T.: A Neural-Kalman Filtering method for estimating traffic states on freeway, *Journal of JSCE*, No.569/IV-36, JSCE, pp. 105-114, 1996.
- 5) Ben-Akiva, M., Palma, A.D. and Kaysi, I.: Dynamic network models and driver information systems, *Transportation Research-A*, Vol.25A(5), pp. 252-266, 1991.
- 6) Polydoropoulou, A., Ben-Akiva, M. and Kaysi, I.: Influence of traffic information on drivers' route choice behaviour, *Transportation Research Record 1453*, Transportation Research Board, pp. 67-75, 1994.
- 7) Suzuki, H., Nakatsuji, T. and Tanaboriboon, Y.: Model development for the estimations of origin-destination (O-D) travel time and flow on freeways, *Proceedings of 6th Conference on Application of Advanced Technologies in Transportation Engineering*, Singapore, (CD-ROM), 2000.
- 8) Suzuki, H., Nakatsuji, T., Tanaboriboon, Y. and Takahashi, K.: An application of a Neural-Kalman Filter for dynamic estimation of O-D travel time and flow with the different number of traffic detectors, *Journal of Infrastructure Planning and Management*, Vol.17, JSCE, pp. 947-956, 2000.
- 9) Suzuki, H., Nakatsuji, T., Tanaboriboon, Y. and Takahashi, K.: Dynamic estimation of origin-destination travel time and flow on a long freeway corridor: Neural Kalman Filter, *Transportation Research Record 1739*, Transportation Research Board, pp. 67-75, 2000.
- 10) Suzuki, H.: Simultaneous estimation of dynamic origin-destination (O-D) travel time and flow using Neural-Kalman Filter technique with the macroscopic traffic flow simulation model, *A Dissertation Submitted in Partial Fulfilment of the Requirements for the Degree of Doctor of Engineering*, Asian Institute of Technology, Bangkok, Thailand, 2001.
- 11) Dougherty, M. S.: A review of neural networks applied to transport, *Transportation Research-C*, Vol. 3C(4), pp. 247-260, 1995.
- 12) Dougherty, M. S. and Kibby, H. R.: The use of neural networks to recognise and predict traffic congestion, *Traffic Engineering and Control*. Vol. 34 (6), pp. 311-314, 1993.
- 13) Faghri, A. and Hua, J.: Evaluation of artificial neural network applications in transportation engineering, *Transportation Research Record 1358*, Transportation Research Board, pp.71-80, 1992.
- 14) Papageorgiou, M., Blosseville, J. M. and Hadj-Salem, H.: Macroscopic modelling of traffic flow on the Boulevard Peripherique in Paris, *Transportation Research-B*, Vol. 23B(1), pp. 29-47, 1989.
- 15) Papageorgiou, M., Blosseville, J. M. and Hadj-Salem, H.: Modelling and real-time control of traffic flow on the southern part of Boulevard Peripherique in Paris: Part I: Modelling, *Transportation Research-A*, Vol. 24A(5), pp. 345-359, 1990.
- 16) Gartner, N., Mahmassani, H.: Traffic flow theory : A state-of-the-art report, (URL=<http://www.cta.ornl.gov/cta/research/trb/tft.html>)
- 17) Michalopoulos, P.M., Yi, P. and Lyrintzis, A.S.: Development of an improved high-order continuum traffic flow model. *Transportation Research Record, 1365*, pp. 125-132, 1992.
- 18) Lebacque, J. P. and Lesort, J.B.: Macroscopic traffic flow models: A question of order, *Proceedings of 14th International Symposium on Transportation and Traffic Theory*, pp. 3-25, 1999.
- 19) Suzuki, H. and Nakatsuji, T.: Effect of adaptive cruise control on congested freeway traffic flow with lane closure, *Proceedings of 8th World Congress on Intelligent Transport Systems*, Sydney, Australia, (CD-ROM), 2001.
- 20) Yang, Q. and Koutsopoulos, H. N.: A microscopic traffic simulator for evaluation of dynamic traffic management systems, *Transportation Research-C*, Vol. 4C(3), pp 113-129, 1996.
- 21) Cremer, M.: *Der Verkehrsfluß auf Schnellstraßen*, Springer-Verlag Berlin Heidelberg New York, 1979.

(2001.6.19 受付)

A NEW APPROACH TO ESTIMATE FREEWAY OD TRAVEL TIME BASED ON DYNAMIC TRAFFIC STATES ESTIMATION USING FEEDBACK ESTIMATOR

Hironori SUZUKI and Takashi NAKATSUJI

A new algorithm was proposed for estimating origin-destination (OD) travel time on a freeway corridor. Traffic conditions were dynamically estimated by Kalman filter combined with the macroscopic traffic flow model. OD travel time was then estimated based on the optimal estimates of traffic states. The authors have been proposing an alternative approach to estimate OD travel times by Neural-Kalman Filter (NKF). Two numerical examples showed that a) the new algorithm gave more accurate estimate of OD travel time, comparing to the existing approach by the NKF, and that b) dense allocation of traffic detectors enabled the traffic states estimation on actual freeway corridor with the appropriate estimation precision. Further developments for applying the proposed algorithm to large freeway networks were finally summarised through the results of two numerical analyses.