

カルマンフィルタを用いた所要時間推定手法の提案*

Dynamic Travel Time Estimation Using Kalman Filter*

宮田 輝星**・宮城 俊彦***

By Kisei MIYATA **・Toshihiko MIYAGI***

1. はじめに

ある2地点間の旅行時間予測は、実際の走行から得た所要時間データをもとに統計的に分析する静的な予測や現在の高速道路で導入されているような、逐次得られる交通情報を基礎データとして行う予測が主流である。しかし、前者では交通混雑などの交通条件に対して柔軟な対応ができず、また後者では個人の走行特性を考慮していないことや、加えて一般道を含む道路網全体に適用する事は財源等の制約から実現が困難であるという問題がある。これらは、静的な予測、および集権的・組織的な予測手法での限界とも言える。

そこで本研究では、動的かつ自律的な所要時間予測手法、すなわち自動車が外部から交通情報を受信することなく、自身の走行中に逐次記録された情報に基づき、起点から終点までの旅行時間の事前予測を動的に行う手法を提案する。具体的にはまず、車両挙動に Newell の追従モデルを仮定し、状態空間モデルを作成する。GPS 受信機によって逐次入手した走行データに加え、前方との車間距離を測定するセンサーを装備している状況を仮定し、走行データとして用いている。これら走行データをもとに本モデルの構造パラメータ推定を行い、構築されたモデルにカルマンフィルタを適用することにより、走行中のダイナミックな状態推定・予測が行える。カルマンフィルタを用いた追従モデルパラメータの推定は Ranjitkar ら¹⁾によって行われているが、Newell モデルのパラメータ推定については行われていない。

本研究では、Newell モデルを適用した際の観測値再現性の検証、および提案するモデルの予測性能について明らかにしたうえで、これを利用した到着時間予測手法の提案を行う。

*キーワード：交通流、交通情報、経路選択、情報処理

**非会員、工学、東北大学院情報科学研究科

(E-mail:miyata@plan.civil.tohoku.ac.jp)

***正会員、工博、東北大学院情報科学研究科

(宮城県仙台市青葉区荒巻字青葉 6-6-6、

TEL:022-795-7495、

E-mail:toshi_miyagi@plan.civil.tohoku.ac.jp)

2. モデルの構築

(1) Newell の追従モデル

Newell²⁾の追従モデルは、定常流におけるミクロな車両挙動をモデル化したものであり、追従走行する車両が前方の車両と同じような形状の走行軌跡を描くように行動し、その際に時間的ズレ τ と空間的ズレ d が生じるものとしている。すなわち、

$$l_n(t + \tau_n) = l_{n-1}(t) - d_n \quad (1)$$

$l_n(t)$: 時刻 t における車両 n の原点からの走行距離

τ_n, d_n : ドライバー n の追従特性を表すパラメータ

ここで τ は従来¹⁾の追従モデルにおける反応時間とは異なるものであるに注意する必要がある。

また、車頭距離 $s_n(t)$ はパラメータ τ_n, d_n を用いて次式で表せる。

$$s_n(t) = d_n + \tau_n v_n(t) \quad (2)$$

$v_n(t)$: 時点 t での車両 n の速度、

$s_n(t)$: 車頭距離




図1 Newell の追従モデルにおける走行軌跡図

また、式(1)は次のように表せる。

$$l_n(t + \tau_n) = l_n(t) + \tau_n v_n(t + T_n) \quad (3)$$

$$\cong l_n(t) + \tau_n v_n(t) + T_n a_n(t) \quad (4)$$

式(1)と(3)より

$$v_n(t + T_n) = \frac{1}{\tau_n} [l_{n+1}(t) - l_n(t)] - \frac{d_n}{\tau_n} \quad (5)$$

ここで T_n は、従来の追従モデルにおける反応時間に対応するものであり、"Relaxation time"と呼ばれている。式 (3), (4), (5) から

$$T_n a_n(t) = \frac{1}{\tau_n} [l_{n-1}(t) - l_n(t)] - \frac{d_n}{\tau_n} - v_n(t) \quad (6)$$

これが Newell の追従モデルにおける車両挙動を表す式であり、加速度 $a_n(t)$ が追従パラメータ τ_n, d_n に依存していることが分かる。

パラメータ τ_n, d_n はドライバー n の走行特性を表すものであり、一意に表すことができない。本研究では、実験走行データをもとにこれらの未知パラメータ τ_n, d_n の推定を行う手法としてカルマンフィルタを用いる。

(2) カルマンフィルタによる状態推定・予測

時刻 t における観測値ベクトルを $y(t)$ 、状態変数ベクトルを $x(t)$ とおくと、線形定常確率システムは以下の式で表せる。

$$\langle \text{状態推移式} \rangle \quad x(t+1) = Ax(t) + \omega(t) \quad (7)$$

$$\langle \text{観測式} \rangle \quad y(t) = Hx(t) + v(t) \quad (8)$$

A, H はシステム行列、また $\omega(t), v(t)$ は誤差ベクトルであり、それぞれ平均 0、分散共分散行列 Q, R をもつガウス白色雑音である。

$$\begin{aligned} p(\omega) &\sim N(0, Q) \\ p(v) &\sim N(0, R) \end{aligned} \quad (9)$$

カルマンフィルタ³⁾は、上記の線形確率システムの状態推定値 $\hat{x}(t)$ を、推定誤差の分散が最小となるように与えるものである。ここで、状態変数の初期値 $x(0)$ と誤差ベクトル ω, v にはガウス分布が仮定されているため、観測値 y に基づく状態 x の最小分散推定値 \hat{x} が条件付き期待値 $E[x|y]$ に等しくなる。したがって、推定の際には $\omega, v = 0$ としてよく、時刻 t における状態の予測値 $\hat{x}(t+1|t)$ 、推定値は以下のカルマンフィルタ・更新アルゴリズムにより逐次得られる。

(3) Newell モデルの状態空間表現

$x(t)$ を状態変数ベクトル、 $y(t)$ を観測ベクトルとし、Newell の追従モデルをもとに、以下のような変数を設定する。ここで、 $l_n(t), v_n(t), a_n(t)$ はそれぞれ時刻 t における車両 n の出発点からの走行距離、速度、加速度、 d_n は追従特性パラメータである。

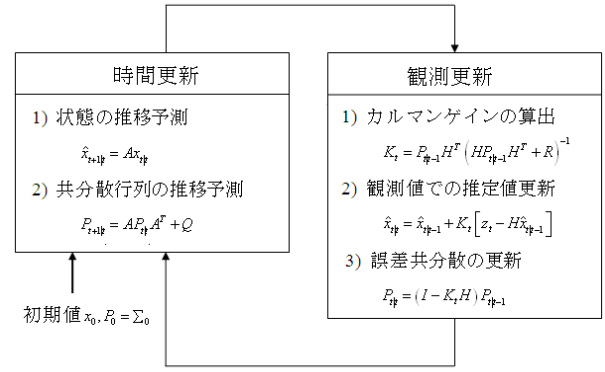


図2 カルマンフィルタ・アルゴリズム

$$x(t) = \begin{bmatrix} l_n(t) \\ v_n(t) \\ a_n(t) \\ l_{n-1}(t) \\ v_{n-1}(t) \\ d_n(t) \end{bmatrix}, \quad y(t) = \begin{bmatrix} l_n(t) \\ v_n(t) \\ s_n(t) \end{bmatrix} \quad (10)$$

また、離散時間における3次の運動力学モデル

$$l_n(t + \Delta t) = l_n(t) + \Delta t v_n(t) + \frac{1}{2} \Delta t^2 a_n(t) \quad (11)$$

を用い、Newell の追従モデルを状態空間表現したものは以下の式で表せる。ただし、GPS データの更新間隔が1秒毎であることを考慮して、 $\Delta t = 1$ として扱っている。

$$\text{状態推移式} \quad x(t+1) = A x(t) + \omega(t);$$

$$\begin{bmatrix} l_n(t+1) \\ v_n(t+1) \\ a_n(t+1) \\ l_{n-1}(t+1) \\ v_{n-1}(t+1) \\ d_n(t+1) \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1/2 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & -1/T_n & -1/T_n & 0 & 1/\tau_n T_n & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 \\ 0 & 1 - \tau_n/T_n & (1 - \tau_n)/T_n & 0 & 1/T_n & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} l_n(t) \\ v_n(t) \\ a_n(t) \\ l_{n-1}(t) \\ v_{n-1}(t) \\ d_n(t) \end{bmatrix} + \omega(t) \quad (12)$$

$$\text{観測式} \quad y(t) = Hx(t) + v(t)$$

$$\begin{bmatrix} l_n(t) \\ v_n(t) \\ a_n(t) \\ s_n(t) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & \tau_n & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} l_n(t) \\ v_n(t) \\ a_n(t) \\ l_{n-1}(t) \\ v_{n-1}(t) \\ d_n(t) \end{bmatrix} + v(t) \quad (13)$$

3. パラメータ推定

(1) 使用するデータ

定常カルマンフィルタでは、システム行列を既知のものとして更新を行うが、今回はシステム行列の成分に未知パラメータ τ, T が含まれており、事前に設定することができない。そのため、本研究では実走行データをもとに未知パラメータ τ, T を含むシステム行列 A, H, Q, R の推定を行うものとする。

なお今回使用する走行データを入手するため、GPSを装備した2台の車両による追従走行実験を行った。これは、ある固定された1つの経路を複数回往復し、位置・速度等の走行データを記録した。この実験データをもとに車等間隔を算出し、基礎データとして用いてシステム構造パラメータ A, H, Q, R をEMアルゴリズムによって推定した。

(2) EMアルゴリズムによる最尤パラメータ推定

EMアルゴリズムは、可観測な不完全データ集合 $Z = \{z_1, z_2, \dots, z_N\}$ から、その確率密度関数 $p(z, x; \theta)$ の尤度の期待値を最大にするパラメータ θ を推定する方法であり、以下の2つのステップを反復させることで推定を行う。なお、対数尤度 $L(\theta)$ は以下の式で表せる。

$$L(\theta) = \sum_{k=1}^N \ln p(z_k | x_k; \theta) \quad (14)$$

<E-step>

$Z = \{z_1, z_2, \dots, z_N\}$ と $\theta^{[k]}$ の下での、 $p(z_k, x_k; \theta)$ の尤度の条件付き期待値 $Q(\theta; \theta^{[k]})$ を求める。

$$\begin{aligned} Q(\theta; \theta^{[k]}) &= E[L(\theta) | Z; \theta^{[k]}] \\ &= \sum_{k=1}^N E[\ln p(z_k, x_k; \theta) | Z; \theta^{[k]}] \end{aligned} \quad (15)$$

<M-step>

尤度の条件付き期待値 $Q(\theta; \theta^{[k]})$ を最大にする θ を求める。

$$\theta^{[k+1]} = \arg \max_{\theta} Q(\theta; \theta^{[k]}) \quad (16)$$

システム行列 A, H の推定値から追従パラメータ τ, T を算出し、またモデルによる状態推定値からパラメータ d の推定を行う。推定結果は下表に示す。

表1 追従モデルのパラメータ推定値

	d	τ	T
平均値	6.4571	1.9550	1.0920
標準偏差	7.7383	0.8462	0.6858
変動係数	1.1984	0.4328	0.6280
先行研究 ^{1),4)} による推定値	6.06~	1.06~	1.07~
	9.56	1.74	1.13

得られた追従パラメータ τ, d はAhnら⁴⁾の推定値と

若干の乖離はあるが、これは実験条件の違いによる影響だと考えられる。反応時間 T については、Newellモデルでは $T = \tau/2$ であるとされているが、今回の推定値はそれに近い値となり、さらにシステム行列 A, H についてはほぼ理論値通りの値となった。以降ではこのパラメータをもとに状態推定を行う。

また、パラメータ τ, T を状態変数に組み込み、拡張カルマンフィルタ(EKF)を適用した場合のパラメータ推定も行ったが、状態推定値が著しく安定せず、信頼できるパラメータ推定結果が得られなかった。

4. モデル再現性の検証

(1) 1秒毎にデータ更新を行う場合

推定されたパラメータを使用したモデルが、どの程度観測値を再現できるかを検証する。なお、データ更新区間は1秒毎とし、パラメータ推定に使用した走行データとは異なるデータを使用している。

下図は、構築したモデルにより速度分布、および走行軌跡図の再現を行い、観測値、推定値、1期・3期・5期先予測値を記したものである。いずれの予測値も誤差10 km/h以内に収まっており、推定値に関してはほぼ正確に再現できているといえる。

(2) 5秒毎にデータ更新を行う場合

次に、データ更新区間を5秒毎にし、更新頻度を減少させた場合の速度分布図、および走行軌跡図の再現性を調べる。なお、データ更新区間 Δt が変化したことにより、新たに推定し直したシステム構造パラメータ A, H, Q, R を用いている。

図5からわかるように、データ更新区間が大きくなると速度予測精度が大きく減少する一方で、走行軌跡図については十分な再現性を確認できた。




図3 速度分布図の再現 (1秒毎データ更新)

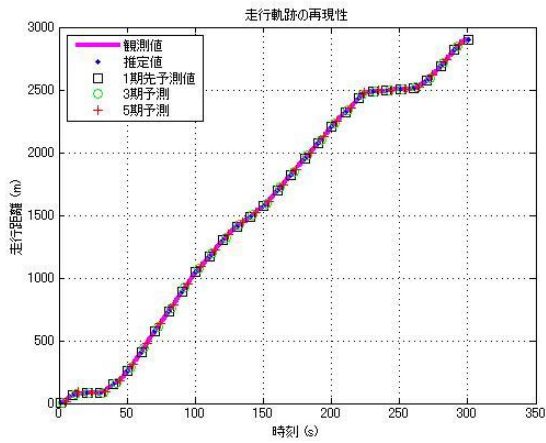


図4 走行軌跡図の再現 (1秒毎データ更新)




図5 速度分布図の再現 (5秒毎データ更新)

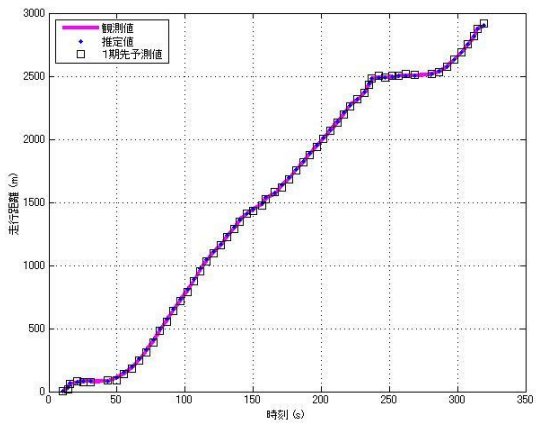


図6 走行軌跡図の再現 (5秒毎データ更新)

5. 所要時間予測手法

過去に一度だけ走行した経験がある経路について、外部から交通情報を受信することはなく、過去の走行経験と走行中に逐次得られるデータのみをドライバーが持

っているとする。また、交通流は定常であるとする。以上の状況設定のもとで、目的地までの所要時間 TT を予測する方法について考える。

今回、自らの走行データを逐次入手できるため、現地地点 l_{now} より先の区間で走行する速度 v_{pre} が分かれば、目的地までの所要時間 TT が予測できる。

$$TT(t) = [l_d(t) - l_{now}(t)] / v_{pre}(t) \quad (17)$$

ただし、 l_d : 出発地から目的地までの距離

l_{now} : 出発地から現在地までの走行距離

この予想走行速度 $v_{pre}(t)$ を過去の経験と走行中に得られる情報から学習していく必要がある。ここで、現在の走行における平均速度を $v_{now,t}$ としたとき、予想走行速度 $v_{pre}(t)$ を次式で与える。

$$v_{pre}(t) = \alpha v_{past}(t) + \beta v_{kalman}(t) + (1 - \alpha - \beta) v_{now}(t) \quad (18)$$

ここで、 v_{past} は現地点から目的地までの区間で過去に経験した速度の平均値、 v_{kalman} はカルマンフィルタによる速度の予測値、 α, β は学習パラメータである。このパラメータは学習効率や予測性能に大きく影響を与える。

6. おわりに

本研究では、走行中に逐次得られるデータをもとにダイナミックな状態推定・予測を行うモデルを構築し、頻繁なデータ更新が見込める状況下では十分な再現性・予測性が得られる事がわかった。しかし、走行中に状態推定等を行うことを考えれば、更新頻度が低下した際にも十分な予測性能を保つ必要があるため、より柔軟なモデルを構築する必要がある。

今後は学習理論と関連させた所要時間予測手法への拡張が考えられる。

参考文献

- 1) Ranjitkar Prakash, Takashi Nakatsuji and Akira Kawamura: Experimental analysis of car-following dynamics and traffic stability, Transportation Research Board, No. 1934, pp. 22-32, 2005
- 2) G. F. Newell: A simplified car-following theory: a lower order model, Transportation Research Part B 36, pp.195-205, 2002.
- 3) 片山徹：新版応用カルマンフィルタ，朝倉書店，2000.
- 4) Soyoung Ahn, Michael J Cassidy, and Jorge Laval : Verification Simplified Car-Following Theory, Transportation Research Part B 38 pp.431-440, 2004.