

# ベイズ統計に基づいた非定常交通流のための所要時間予測手法\*

## A Method to Predict Travel Time for Non-stationary State Flow Based on Bayesian Statistics\*

葛西誠\*\*・宮田浩充\*\*\*・寺部慎太郎\*\*\*\*・内山久雄\*\*\*\*\*

By Makoto KASAI\*\*・Hiromitsu MIYATA\*\*\*・Shintaro TERABE\*\*\*\*・Hisao UHIYAMA\*\*\*\*\*

### 1. はじめに

交通需要マネジメント(Travel Demand Management)の一部である経路変更や交通手段変更の成立は、合理的判断を促すための利用者への交通情報提供が鍵を握ると考えられている。情報提供装置の開発および活用のみならず、提供される交通情報の質を向上させること、特に所要時間情報の精度の良い予測が必要である。

所要時間予測手法は近年数多くの研究例があり、特に時系列解析手法の応用、人工ニューラルネットワークの適用が目を引く。これらは日常的な所要時間予測に対しては十分な精度を有するとされるが、交通事故や落下物による道路障害によって通常の交通流状態とは異なる場合(これを非定常交通流と呼ぶことにする)には対応できないとされる。

非定常交通流状態における所要時間予測方法として、事前に見積もられた所要時間分布を、道路上の事象の観測によって改訂する、古典的なベイズ定理を応用する方法<sup>1)</sup>が提案されているが、所要時間増大時に過小推計傾向が見られることが課題であった。本研究はこの克服を目的とし、所要時間事前分布の設定方法の吟味を行なう。

本論文の構成は以下の通りである。2.にて既往の所要時間予測手法を概観・整理し、その中でも突発事象等発生時に対応可能性を持つとされるベイズ定理を用いた手法の概要と問題点を3.にて言及する。4.ではこの問題点の克服を目的とした所要時間事前分布構成法を新たに提案し、5.にてこの効果を議論する。6.はまとめである。

### 2. 既往の所要時間予測手法

所要時間予測手法としては、大別してモデル指向型、データ指向型に分類できよう。モデル指向型としては、

\* キーワーズ: 交通流, 交通管理

\*\* 正会員, 博(工), 東京理科大学 理工学部 土木工学科  
(千葉県野田市山崎2641, TEL: 04-7124-1501 EXT:4058,  
E-mail: kasai@rs.noda.tus.ac.jp)

\*\*\* 非会員, 修(工), (株)横浜銀行

\*\*\*\* 正会員, 博(工), 東京理科大学 理工学部 土木工学科

\*\*\*\*\* フェロー員, 工博, 東京理科大学 理工学部 土木工学科

所要時間生起のモデル構造の骨格は予め仮定される。データ指向型は、所要時間生起モデルを陽に仮定せず、データのみに基づいて予測を行なうものである。

モデル指向型の代表例としては、線形時系列モデル<sup>2)</sup>(AR Model: Auto-Regressive Model), 非定常時系列モデル<sup>3)</sup>(ARIMA Model: Auto-Regressive Integrated Moving Average Model), 人工ニューラルネットワークモデル<sup>4)</sup>等が挙げられる。これらは、予測の対象を日常的な交通流としており、交通流が通常とは異なる状態での有効性は保証されない。非定常時系列モデルであるARIMAモデルについても、一階差分が定常時系列でなければならぬ以上、交通事故発生などによる突発的な所要時間変化には対応し得ないと指摘されている。

データ指向型のモデルとしては、予測当日の所要時間変動パターンと類似の過日のパターンを抽出する、いわゆる割田ら<sup>5)</sup>のパターンマッチング法、k-nearest neighbors法<sup>6)</sup>などが知られる。これらは車両感知器データの蓄積を活用できる点で優れた方法であるが、交通事故など突発事象発生時には対応し難いために、割田らの方法を拡張したベイズ定理法が提案されている<sup>1)</sup>。これは、パターンマッチングによって道路上の事象発生を区別せずに所要時間の事前分布を与え、交通事故等の道路障害発生情報もたらされると同時にベイズの定理に従って所要時間分布がより尤もらしくなるよう改訂する方法である。しかし、首都高速三郷線を対象とした検証によれば、所要時間が比較的大きい時間帯に過小推計傾向のあることが認められ、この原因解明および改良は今後の課題とされた。

### 3. ベイズ定理を用いた所要時間予測方法

Kasai *et al.*<sup>1)</sup>の方法によれば、所要時間の事前分布は割田らのパターンマッチング手法を元に構成される(図-1)。以下、これを「既往法」と呼ぶ。予測当日2時間前から現在時刻までに(これを「マッチング時間帯」と称する)観測されている所要時間履歴に対し、過日の同時間帯の所要時間履歴のうち類似のデータを抽出する。マッチング時間帯に対し、当日の履歴と過日の履歴の中等誤差  $R$  を求め、 $R \leq 20$  [min]を満たすパターンのみを抽

出するものとする。抽出されたパターンは等しい重みで積み重ねられ、正規化され事前分布として用いられる。

ベイズ定理を用いるために、所要時間と道路上の事象との同時確率を予め与える。ここでは5分間車両感知器過去データによる頻度分布によって同時分布を構成するものとする。

例えば同時分布表は表-1のように整理される。所要時間は10分毎の階層に区分されており、交通事故の有無、降水の有無とのクロス集計表を構成している。\$c\_i\$ は所要時間\$10i\$分台である事象、\$x\_1, \bar{x}\_1\$ はそれぞれ交通事故有、交通事故無、\$x\_2, \bar{x}\_2\$ は降水有、降水無を意味する。

さて、いま、現時刻の道路上の状況を観測したとする。この観測結果の下での所要時間分布を、ベイズ定理によって得る。例えば、所要時間事前分布が一様分布であるとしよう。このときに、事故有\$x\_1\$、降雨無\$\bar{x}\_2\$という事象が観測されたとすると、所要時間10分台の事後確率\$p(c\_1 | x\_1, \bar{x}\_2)\$は、以下のように求められる：

$$\begin{aligned}
 p(c_1 | x_1, \bar{x}_2) &= \frac{p(x_1, \bar{x}_2 | c_1)p(c_1)}{\sum_{k=1}^{16} p(x_1, \bar{x}_2 | c_k)p(c_k)} \\
 &= \frac{(3.13 \times 10^{-2} / 43.7 \times 10^{-2}) \cdot 6.25 \times 10^{-2}}{\frac{3.13 \times 10^{-2}}{43.7 \times 10^{-2}} \cdot 6.25 \times 10^{-2} + \dots + \frac{0.07 \times 10^{-2}}{43.7 \times 10^{-2}} \cdot 6.25 \times 10^{-2}} \\
 &= 2.27 \times 10^{-2} \quad (1)
 \end{aligned}$$

既往法の検証結果を以下に示す。首都高速道路6号線三郷JCT～江戸橋JCT (図-2) を対象に、2004年9月の所要時間予測を試みたものである。過日データとして(データベースとして)用いたのは2004年1年間の車両感知器データから変換される所要時間データ、所要時間と観測事象との同時確率分布は、所要時間データと道路障害データ2004年9月1ヶ月分を用いて作成される。

対象区間に15分後に流入するドライバーにとっての予測所要時間分布の期待値(予測値)と、実際に要した所要時間の期待値(実績値)との関係を図-3に示す。1つの点が車両感知器の時間集計単位5分間に対応する。

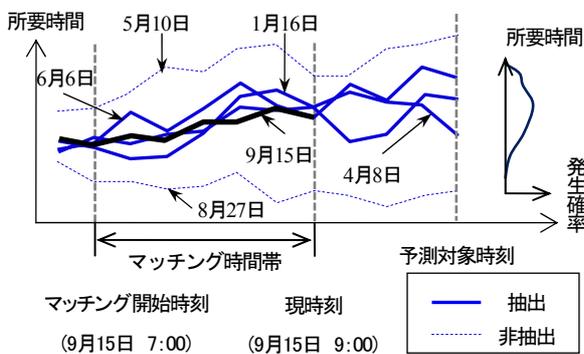


図-1 既往法の事前分布設定方法

ベイズ改訂後も、実績値が120分を超えるときに、推計値が大幅に実績値を下回る場合のあることが示される。

Miyata *et al.*<sup>7)</sup>の検証によれば、こうした状況は事前分布

表-1 所要時間と観測事象の同時分布の例

所要時間 [min]	$x_1$ $, x_2$ [%]	$\bar{x}_1$ $, \bar{x}_2$ [%]	$x_1$ $, \bar{x}_2$ [%]	$\bar{x}_1$ $, \bar{x}_2$ [%]	計 [%]	
$c_1$	10 - 20	0.19	0.57	3.13	3.98	43.7
...	...	...	...	...	...	...
$c_5$	50 - 60	0.05	0.59	0.13	6.23	6.99
$c_6$	60 - 70	0.23	0.79	0.16	4.32	5.50
$c_7$	70 - 80	0.09	0.96	0.31	3.10	4.47
...	...	...	...	...	...	...
$c_{16}$	160 - 170	0.00	0.00	0.07	0.00	0.07
	計[%]	1.68	6.37	6.66	85.31	100.0

$x_1$ : 交通事故有,  $\bar{x}_1$ : 交通事故無

$x_2$ : 降水有,  $\bar{x}_2$ : 降水無

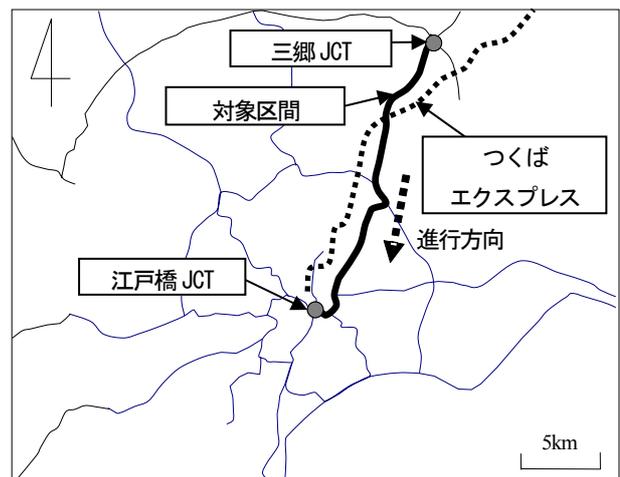


図-2 予測対象区間

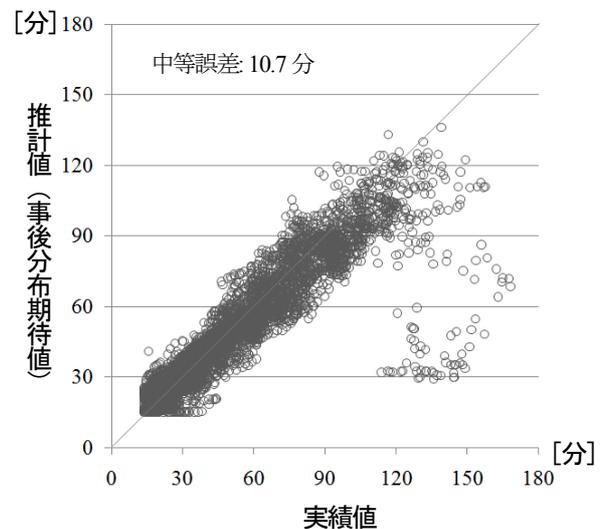


図-3 既往法による事後分布期待値と実績値の比較

を構成する過去データが極端に不足している場合、すなわち、予測当日の所要時間変動パターンと類似の変動を示す過日のデータが極端に少ない場合に生じていることが確認されている。これは、事前分布の設定に工夫が必要であることを意味する。

#### 4. 事前分布設定の再考

事前分布を構成する方法を改良しよう。既往法では以下の点が不自然である。1) マッチング時間帯において予測当日のパターンに対し中等誤差が20分を超える過日のパターンは一切抽出されず、非定常予測に必要な交通事故等の突発事象発生時所要時間パターンが意に反して事前分布から排除される可能性のあること、2) 抽出された過日のパターンは、当日のパターンとの類似度に拘わらずすべて等しい重みで事前分布を構成すること、である。

よって、抽出にあたって予測当日のパターンと過日*i*のパターンの類似度 $s_i$ なる尺度を設け、類似度によって重みを付け事前分布を構成する方法を以下に提示する。

類似度尺度の基本的考え方は次のようである。マッチング時間帯を対象として、予測当日の所要時間パターンと過日*i*の所要時間パターンの中等誤差 $r_i$ が小さいほど、互いに「似ている」と考える。この性質を満足するものとして指数関数を採用する。すなわち次式に従う：

$$s_i = \lambda e^{-\lambda r_i} \quad (2)$$

なお、 $\lambda$ は未定乗数である。これを今後類似度関数と呼ぶ。マッチング用データベースに登録されている日数を*N*とすると、過日*i*のデータの抽出重み $p(h_i)$ は次のように与えられる：

$$p(h_i) = \frac{s_i}{\sum_k s_k}, \quad (i, k = 1, 2, \dots, N) \quad (3)$$

図-4は、類似度によって重みをつけ抽出する概念をしたものである。線の太さが重みに相当する。以下、これを「新手法」と呼ぶ。

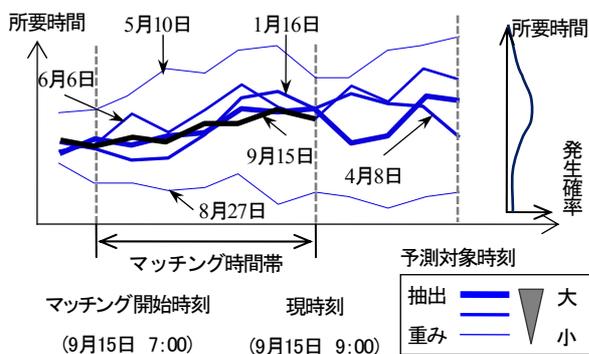


図-4 新手法の事前分布設定方法

#### 5. 検証

2004年9月を対象に、4.で示した事前分布構成法を採用し、予測を行なう。予測対象区間は既往法と同様に図-2で示した首都高三郷JCT～江戸橋JCT間とする。

ベイズ改訂の方法は3.で述べた方法を踏襲する。

##### (1) 対象期間全体にわたる精度検証

1時間後流入を想定し、所要時間予測値と実績値との関係を図-5、図-6に示す。図-5は、予測値として事前分布の期待値、すなわち道路上の事象観測によるベイズ改訂を行なわない場合（これを「改訂前」とする）であり、図-6はベイズ改訂を行なった場合（これを「改訂後」とする）である。既往法の結果である図-3と図-4および図-5とを比較して、実績所要時間20分を超える場合に見られる過小推計傾向が是正されていることが確認される。

また、改訂前（図-5）と改訂後（図-6）とを比較すると、実績値120分以上の場合において改訂前推計値が実績値に対してやや小さい値をとる傾向を示すが、改訂後の推計値は実績値に接近している様子がみとれる。これは改訂前後で新事前分布設定方法を採用することでベイズ改訂の効果も発揮できることを示唆していよう。なお、所要時間予測にあたり、事前分布構成のため用いる類似度関数に含まれる未知数 $\lambda$ を決定する必要があるが、本稿では簡易的にベイズ改訂後の事後分布期待値と実績値との自乗和を最小化するようパラメータ推計した結果、 $\lambda = 0.636 [\text{min}^{-1}]$ を得ており、このときの推計値と実績値との中等誤差は、図-6に示すとおり、5.78分である。

##### (2) 時系列での比較

検証期間のうち、代表的な所要時間変動を示す日として2004年9月27日を選定し、実績値、事前分布期待値、事後分布期待値の時系列比較を行なう。

図-7は既往法による結果、図-8は新手法による結果である。いずれも、流入1時間予測の場合であり、実測値を緑、事前分布期待値（改訂無）を青、事後分布期待値（改訂有）を赤で示す。既往法（図-7）では、10時～12時にかけて実績値より事前分布期待値が大幅に下回っており、ベイズ改訂後の事後分布期待値をもってしても実績値に十分接近しているとはいえない。一方で改良法によれば、事前分布期待値の大幅な下落は確認できず、さらに、ベイズ改訂によって事後分布期待値が実績値に接近している傾向が9時台に顕著に見られる。

なお、図-7および図-8中の黒線は、Kullback-Leibler情報量であり、事前分布と事後分布の形状の相違を示す量である。これらの図では、ベイズ改訂によって両分布が

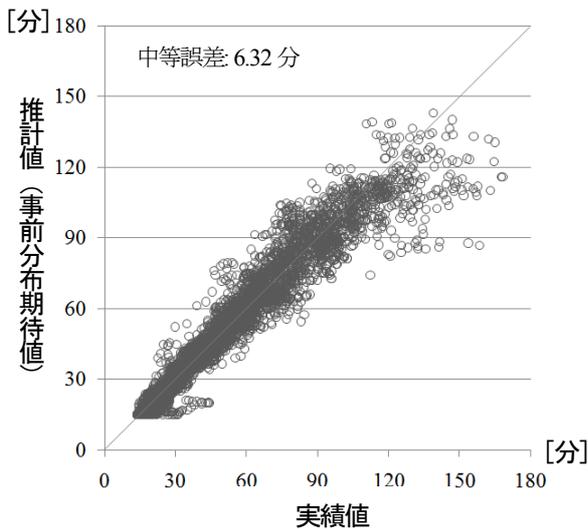


図-5 新手法による事前分布期待値と実績値の比較

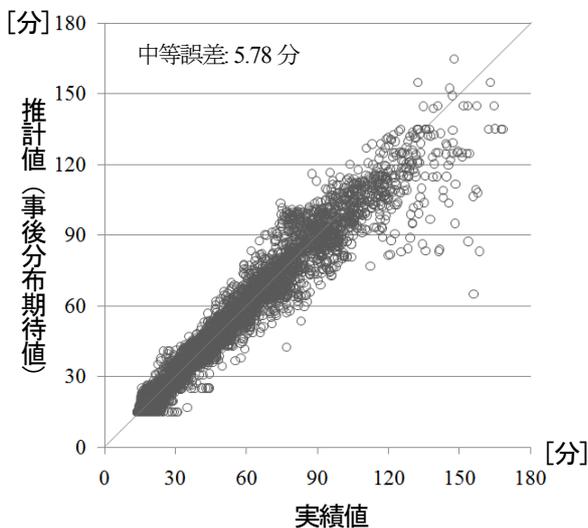


図-6 新手法による事後分布期待値と実績値の比較

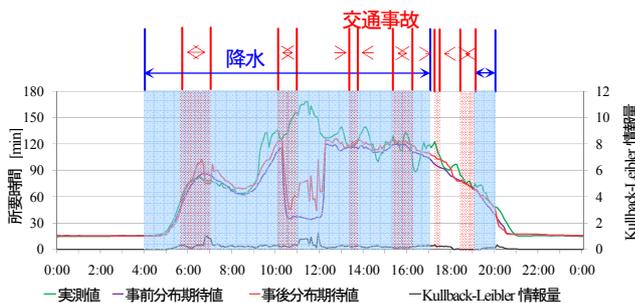


図-7 既往法による推計結果(2004年9月27日)

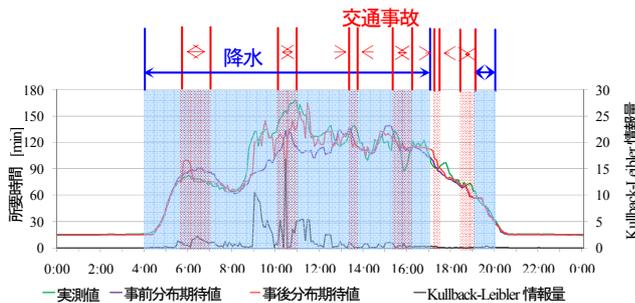


図-8 新手法による推計結果(2004年9月27日)

大きく異なっている時刻ほどKullback-Leibler情報量が大きく示される。ベイズ改訂によって予測値が実績値に十分接近している時間帯に同情報量が大きくなっている傾向が見られ、このことからベイズ改訂は予測精度向上に効果のあることを意味している。

## 6. おわりに

本研究は、日常的な交通状況のみならず交通事故などの突発事象発生時にも有用な所要時間予測方法として有望であるベイズ改訂法について、その精度向上を目指したものである。割田らのパターンマッチングを援用した既往の事前分布構成法を改良し、当日の所要時間変動パターンとの過日のそれとの類似度によって重み付き抽出事前分布とする方法によって予測精度向上が図れることを示した。

本ベイズ改訂法は、所要時間データと道路上の観測事象データさえ存在すれば適用でき、膨大に蓄積されているものの有効に利用されているとは言い難い車両感知器データや道路障害データの簡単かつ有用な活用法の1つとして、意義深いものと考えられる。採用する道路上の観測事象の種類の拡大や吟味によって精度向上の可能性があり、この意味で、将来性の高く、拡張性に優れた方法と言えるであろう。

謝辞：本研究は高速道路関連社会貢献協議会から研究助成を受けた。ここに記して関係各位に謝意を表する。

## 参考文献

- 1) Kasai, M., Rokutan, M. and Uchiyama, H.: An Application of Bayesian Statistics to Estimating Travel Time on an Urban Expressway, *Proceedings of the 15th World Congress on ITS NEW YORK 2008*, 10pages, 2008.
- 2) Huang, L. and Barth, M.: A Novel Loglinear Model for Freeway Travel Time Prediction, *Proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems*, pp.210-215, 2008.
- 3) Billings, D. and Yangt, J.: Application of the ARIMA Models to Urban Roadway Travel Time Prediction - A Case Study, *2006 IEEE International Conference on Systems, Man, and Cybernetics*, pp.2529-2534, 2006.
- 4) van Hinsbergen, C.P.IJ., van Lint, J.W.C. and van Zuylen, H.J.: Bayesian committee of neural networks to predict travel times with confidence intervals, *Transportation Research Part C*, Vol.17, pp.498-509, 2009.
- 5) 割田博, 森田純之, Edward Chung, 田中淳: パターンマッチングを用いた所要時間予測手法の研究, 第24回交通工学研究発表会論文報告集, pp.129-132, 2004.
- 6) Zou, N., Wang, J. and Chang, G.: A Reliable Hybrid Prediction Model for Real-time Travel Time Prediction with Widely Spaced Detectors, *Proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems*, pp.91-96, 2008.
- 7) Miyata, H. Terabe S., Kasai M. and Uchiyama H.: Factors Affecting Travel Time Predicted by Bayesian Statistics, *Proceedings of the 16th World Congress on Intelligent Transport Systems*, 8pages, 2009.