

都市高速合流部を対象とした 統計的旅行時間予測手法

坂井 勝哉¹・日下部 貴彦²・朝倉 康夫³

¹学生会員 東京工業大学 大学院理工学研究科土木工学専攻 (〒152-8552 東京都目黒区大岡山2-12-1)
E-mail:k.sakai@plan.cv.titech.ac.jp

²正会員 東京工業大学助教 大学院理工学研究科土木工学専攻 (〒152-8552 東京都目黒区大岡山2-12-1)
E-mail:t.kusakabe@plan.cv.titech.ac.jp

³正会員 東京工業大学教授 大学院理工学研究科土木工学専攻 (〒152-8552 東京都目黒区大岡山2-12-1)
E-mail:asakura@plan.cv.titech.ac.jp

既存の統計的旅行時間予測モデルを基にして、ジャンクションを先頭とする渋滞を対象とした旅行時間予測モデルを構築した。具体的には、需要とボトルネック容量が一定であるという先行研究のモデルでなされていた仮定を緩和した。1日の中では需要が変動するが、1日を複数の時間帯に区切り、それぞれの時間帯では需要が一定と仮定した。ボトルネックである合流部では、合流する相手路線の混雑状況によって合流比率が変動すると仮定し、相手路線が渋滞している場合とそれ以外の場合でボトルネック容量がそれぞれ一定であるとしてモデルを構築した。実データを用いたモデル精度の検証分析では、旅行時間の点推定と区間推定を行った。点の推定精度については満足できるものである一方、幅をもたせた予測については課題が残された。

Key Words : *Travel time prediction, Prediction interval, Junction, Bayesian probability*

1. 序論

サグや合流などといった道路線形によるボトルネック地点が原因となり、日々渋滞が発生している。渋滞の発生状況を利用者へ知らせることは、利用者が経路選択を行う上で重要であり、旅行時間情報のニーズは高い。利用者へ旅行時間情報を提供するためには、ある区間を通過するための旅行時間を予測することが必要とされる。ボトルネックを要因とした渋滞は毎日繰り返し起こっており、旅行時間へ大きく影響を及ぼしているため、毎日の渋滞を対象とした予測を行うことは重要であると考えられる。

旅行時間予測手法として、主に交通流をモデル化したシミュレーションに基づく方法と、過去のデータに基づいた統計的方法がある。交通流シミュレーションに基づく方法として、宗像ら¹⁾や白石ら²⁾は、リアルタイムに観測されたデータを入力値とした手法を開発している。統計的方法として、舟橋ら³⁾は、VICISデータを用いた手法、割田ら⁴⁾や松本ら⁵⁾は、車両感知器データを用いた手法を提案している。また、中村ら⁶⁾や三輪ら⁷⁾は、蓄積データに加えてプローブデータを用いた手法を提案してい

る。シミュレーションによる手法は、入力変数が多く複雑である一方、統計的手法はシンプルで扱いやすいという利点がある。Weiら⁸⁾のモデルは、パラメータが1つであり利用しやすい上に、ボトルネックの性質が考慮されている。このモデルでは、ボトルネック容量が一定と仮定しているため、サグ部などのようにボトルネック容量が比較的安定している箇所へ適用することは可能であるが、ジャンクションなどの合流部では、ボトルネック容量が相手路線の混雑状況によっても左右され、予測をするためにはその要因を取り入れる必要があるだろう。

本研究の目的は、ボトルネック容量が一定であると仮定していた先行研究のモデルを改良することで、ジャンクションなどの合流部がボトルネックとなって渋滞が発生する区間を対象として、旅行時間予測の方法を構築し、モデルの予測精度について分析する。

2. 旅行時間予測モデル

この章では、旅行時間予測モデルについて述べる。第1節では、Weiら⁸⁾によるモデルの導出を示し、そこで用

いられている変数の特徴について述べる。第2節では、そのモデルの問題点の解決策について述べ、第3節で本研究のモデルについて述べる。

(1) 先行研究のモデル

現在、高速道路会社によって利用者へ提供されている旅行時間情報は、瞬間旅行時間 (ITT ; Instantaneous Travel Time) であり、ある時刻の検知器から読み取れる速度データに基づいて算出された値である。ITTを算出する区間を検知器の設置されている n 個の小区間に分け、ある小区間 m の区間長を l^m 、検知器による時刻 t の小区間 m での観測速度を v^m とする。ITTは、観測された速度で小区間を通過するのにかかる時間の同時刻単純和として次式で求められる。

$$ITT_t = \sum_{m=1}^n \frac{l^m}{v_t^m} \quad (1)$$

しかし、実際に利用者が経験する実旅行時間 (RTT ; Real Travel Time) は、渋滞長の変化によってITTとは異なる。例えば、渋滞が延伸している場合には、ITTよりもRTTのほうが大きくなるだろう。

Weiら⁹⁾は、ITTをモデルの入力値として、RTTを予測値として出力する統計モデルを構築している。そのモデルを用いることにより、ITTをそのまま予測値とするよりも精度良く予測できることを確認している。以下では、Weiらによるモデルの誘導を示す。

1ボトルネックの単路部で、ボトルネックが最下流部にある区間を考える。自由流区間と渋滞流区間の速度がそれぞれ安定していると仮定すれば、ある車両の旅行時間は、自由流区間と渋滞流区間のそれぞれをどれだけ走行するのかが決まる。図-1より、時刻 t に対象区間へ流入した車両が渋滞末尾へ到達するまでの時間 gap_t を考えれば、時刻 t の実旅行時間 RTT_t はITTを用いて次のように表すことができる。

$$RTT_t = ITT_{t+gap_t} \quad (2)$$

ITT_{t+gap_t} は ITT_t とは異なる値であり、その原因は「 gap_t の時間差があること」と「 gap_t の間に交通状況 (渋滞長) が変化すること」の2つである。交通状況 (渋滞長) の変化は、渋滞長の延伸 (収縮) 速度を用いて記述できるが、検知器データから求めるのは困難であるため、交通状況の変化を表す指標としてITTの時間変化率 C を次のように定義している。

$$C_t = \frac{ITT_t}{ITT_{t-1}} \quad (3)$$

C_t は時刻 t のITT変化率を表す。この指標は、「 $C>1$ 」ならば渋滞が延伸していることを意味しており、「 $C<1$ 」ならば逆を意味する。以上より、 ITT_{t+gap_t} と ITT_t の関係は

次のように書ける。

$$ITT_{t+gap_t} = f(C_t, gap_t) \cdot ITT_t \quad (4)$$

ここに、関数 $f(\cdot)$ は未知の関数である。

式(2)と式(4)より、

$$RTT_t = f(C_t, gap_t) \cdot ITT_t \quad (5)$$

また、時刻 t に対象区間へ流入した車両が渋滞末尾へ到達するまでにかかる時間 gap_t は、図-2.1より、対象区間の始点から渋滞末尾までの距離 x を自由流区間の速度 V_{free} と渋滞延伸速度 \bar{v}_{extent} の和で除して算出される。

$$gap_t = \frac{x}{V_{free} + \bar{v}_{extent}(C_t)} \quad (6)$$

渋滞延伸速度 \bar{v}_{extent} は、渋滞長の変化率を表す C_t の関数である。ゆえに、 gap_t は、 x と C_t の関数であると考えられ、

$$gap_t = gap_t(x, C_t) \quad (7)$$

であり、関数 $f(C_t, gap_t)$ は次のように書き直せる。

$$f(C_t, gap_t) = F(C_t, x) \quad (8)$$

ゆえに、ITTとRTTの関係は次式で表すことができる。

$$RTT_t = F(C_t, x) \cdot ITT_t \quad (9)$$

式(9)は、「ITTの時間変化率 C 」と「対象区間の始点から渋滞末尾までの距離 x 」の値の組み合わせ毎にITTとRTTの比例定数 $F(C, x)$ を変えてRTTを予測することを意味する。具体的には、過去の観測データから C と x の値の組み合わせが共通のサンプルを抽出し、ITTとRTTの組の線形回帰分析により、パラメータ $F(C, x)$ を推定するというものである。このモデルは、旅行時間を点推定するモデルである。

坂井ら¹⁰⁾は、このモデルを拡張して予測値の性能を表す幅を持たせた旅行時間予測手法を提案している。従来の点の予測値に加えて、ある一定の確率で観測されると想定される幅を情報として負荷することで、利用者へ予測の確からしさを情報提供できると考えられている。

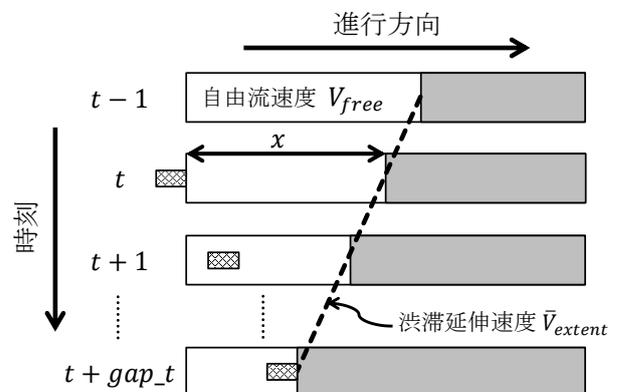


図-1 交通状況 (渋滞長) の時間変化

(2) 既存モデルの適用範囲

第1節で示したWeiらのモデルを用いて予測を行うには、パラメータ $F(C,x)$ の推定、および、予測を行うためには、ITTを計算するための速度データが必要とされる。そのため、都市高速のように検知器が一定間隔で備え付けられている区間を想定したモデルである。ボトルネックをモデル化して交通流の性質を定式化している上に、パラメータがひとつでありシンプルなモデルである。

一方で、このモデルでは、渋滞長の伸び率が一定であるという仮定をおいているため、需要が短時間に変動したり、インシデントの発生等によりボトルネック容量が変動したりすれば、渋滞長の伸び率が変動し、モデルの精度が低下する可能性が考えられる。例えば、ボトルネック容量が増えた場合、モデルの予測値よりも実際の旅行時間は小さくなると考えられる。

(3) 本研究のモデル

前節で述べた先行研究の問題点を改善するために、本研究では次のようなモデルの改良を行う。

- ・ 1日の中での需要変動への対応
- ・ 合流部でのボトルネック容量の変動への対応

1日の中で需要は変動していることが想定される。需要の変動を考慮するために、1日をいくつかの時間帯に区切り、それぞれの時間帯毎に需要が一定であると考えられる。上流から流れてくる交通量を直接観測し、その需要で場合分けを行うこともできるが、需要の観測を行う場所と時刻の整合性を取るのが困難であるため、時間帯毎に場合分けを行う。

ボトルネック容量を直接観測するのは困難であるため、ボトルネック容量の違いによって直接的に場合分けを行うことは難しい。ジャンクションなどの合流部では、合流する相手路線の交通状態によって合流比率が異なり、ボトルネック容量が変動することが想定される。つまり、相手路線が渋滞しているかどうかによってボトルネック容量が異なると考えられる。例えば、相手路線が渋滞していれば、合流比率が下がりボトルネック容量は小さくなるだろう。本研究では、相手路線が渋滞しているか否かによって場合分けを行うが、簡単のため、合流の直上流部分の速度で渋滞しているかどうかを判別する。

統計モデルを用いる場合に、場合分けの数が多くなるとひとつの場合あたりに使えるデータ数が少なくなり、モデルパラメータを推定するためのデータが不足する可能性が考えられる。本モデルへの対処方法として、坂井ら¹⁰⁾はモデルの入力値となる2変数 C,x の間に統計的な独立性を仮定する手法を提案している。この手法を用いることにより、データ数が少ない場合でもモデルパラメータを推定できる。しかし、モデルの適合性を示す数値である的中率（実際の旅行時間が予測旅行時間に含まれる

確率）が低下するという問題も確認されており、的中率について確認する必要がある。

以上をまとめると本研究のモデルで行う仮定は次の3つである。

- ・ 1日をいくつかの時間帯に区切り、それぞれの時間帯では需要が一定であるとみなす。
- ・ 合流する相手路線が渋滞しているか否かを合流直上流部の速度を用いて判別し、それぞれの場合においてボトルネック容量が一定であるとみなす。
- ・ モデルの入力変数である「ITTの時間変化率 C 」と「対象区間の始点から渋滞末尾までの距離 x 」が統計的に独立であるとみなす。

a) 実旅行時間のモデル

RTTとITTの関係を表すモデル式は次の通りである。

$$RTT_i(ITT = ITT_i, C = C_i, x = x_i, u = u_i, s = s_i) = F_{C,x,u,s} \cdot ITT \quad (10)$$

式(10)は、観測されたITTに、 C , x , u , s の値の組み合わせによって決まるパラメータ $F_{C,x,u,s}$ を乗ずることにより、旅行時間の予測値を求めることができることを意味している。 RTT_i は時刻 t に予測対象区間へ流入した車の予測旅行時間であり、 ITT_i は時刻 t の瞬間旅行時間である。 C_i は時刻 t のITT変化率であり、 τ を検知器の観測周期としたとき

$$C_i = \frac{ITT_t}{ITT_{t-\tau}} \quad (11)$$

と定義される。 x_i は時刻 t の予測対象区間の始点から渋滞末尾までの距離である。 u_i は時刻 t が含まれる時間帯を表し、 s_i は時刻 t に合流する相手路線が渋滞しているか否かを示す値である。モデルパラメータである $F_{C,x,u,s}$ は、式(12)で示すように、 C , x , u , s の値の組み合わせ毎に異なる確率関数 $p(F|C,x,u,s)$ に従う確率変数であると定義する。

$$F_{C,x,u,s} \sim p(F|C,x,u,s) \quad (12)$$

ここで、 F が与えられたとき C と x が条件付独立であると仮定すると、式(12)の右辺は次のように変形できる。

$$p(F|C,x,u,s) \propto \frac{p(F|C,u,s)p(F|x,u,s)}{p(F)} \quad (13)$$

b) パラメータ推定方法

パラメータ $F_{C,x,u,s}$ に従う確率関数 $p(F|C,x,u,s)$ を算出する方法を示す。 u と s は時間帯および渋滞の有無を示す変数であるため、離散値である。 C , x , F は連続値であるが、実際の道路へモデルを適用する際には、いくつかの階級に区切り、離散化する。蓄積された検知器データによって算出される時刻毎のデータセット $[ITT_t, RTT_t, C_t, x_t, u_t, s_t]$ を、 u と s の値および C と x の階級値の組み合わせ毎に分割し、分割されたデータセット毎に、 F_t ($=RTT_t/ITT_t$) を算出する。パラメータに従う確率関数 $p(F|C,x,u,s)$

を求めるために必要な3つの確率関数 $p(F|C,u,s)$, $p(F|x,u,s)$, $p(F)$ は、それぞれ以下のように求める。

ある時間帯 (u^d) で、相手路線が渋滞している α していない (s^e) ときにITTの変化率がある値 (C^a) である場合、パラメータ $F_{C,u,s}$ がある値 (F^r) をとる数をカウントしてその頻度を確率に置きかえる。つまり、 u^d , s^e , C^a が観測されているとき、 F^r が生起する確率 $p(F^r|C=C^a,x=x^b)$ は次のように求められる。

$$p(F^r | C = C^a, u = u^d, s = s^e) = \frac{\sum_t \delta_{F^r, C^a, u^d, s^e}(F_t, C_t, u_t, s_t)}{\sum_t \sum_{F^r \in Z} \delta_{F^r, C^a, u^d, s^e}(F_t, C_t, u_t, s_t)} \quad (14)$$

$$\delta_{F^r, C^a, x^b}(F, C, x) = \begin{cases} 1 & \text{if } F = F^r, C = C^a, u = u^d, s = s^e \\ 0 & \text{otherwise} \end{cases} \quad (15)$$

ここに、 Z は F の階級値の全体集合である。

同様に、ある時間帯 (u^d) で、相手路線が渋滞している α していない (s^e) ときにデータセットを x の階級値毎に分割すると、 x^b が観測されているときに F^r が生起する確率は次のように求められる。

$$p(F^r | x = x^b, u = u^d, s = s^e) = \frac{\sum_t \delta_{F^r, x^b, u^d, s^e}(F_t, x_t, u_t, s_t)}{\sum_t \sum_{F^r \in S} \delta_{F^r, x^b, u^d, s^e}(F_t, x_t, u_t, s_t)} \quad (16)$$

$$\delta_{F^r, x^b, u^d, s^e}(F, x, u, s) = \begin{cases} 1 & \text{if } F = F^r, x = x^b, u = u^d, s = s^e \\ 0 & \text{otherwise} \end{cases} \quad (17)$$

最後に、 F^r が生起する確率 $p(F^r)$ は次のように求められる。

$$p(F^r) = \frac{\sum_t \delta_{F^r}(F_t)}{\sum_t \sum_{F^r \in Z} \delta_{F^r}(F_t)} \quad (18)$$

$$\delta_{F^r}(F) = \begin{cases} 1 & \text{if } F = F^r \\ 0 & \text{otherwise} \end{cases} \quad (19)$$

c) 旅行時間予測方法

利用者へ情報提供を行うことを想定し、旅行時間の予測値 (旅行時間の中央値) と、幅をもたせた予測値 (旅行時間に対する予測区間) を算出する方法を示す。本研究では、過去のデータからモデルパラメータの分布を求めて、それに観測されたITTを乗ずることで、旅行時間の分布形を求めている。情報提供を行うことを想定し、モデルから出力される旅行時間の分布形の中央値を予測値とし、5%ile値～95%ile値を予測区間とする。

パラメータ $F_{C,u,s}$ が C , x , u , s の値の組み合わせ毎に異なる分布に従い、その中央値を $F_{C,u,s}^{med}$, 95%ile値を $F_{C,u,s}^{upper}$, 5%ile値を $F_{C,u,s}^{lower}$ とする。式(10)より、時刻に時間帯と合流する相手路線の渋滞の有無が u_t , s_t であるとき、観測される ITT_t , C_t , x_t を用いて、旅行時間の中央値 RTT_t^{med} は、

$$RTT_t^{med} = F_{C_t, x_t, u_t, s_t}^{med} \cdot ITT_t \quad (20)$$

と推定される。予測区間の上限値 RTT_t^{upper} は、

$$RTT_t^{upper} = F_{C_t, x_t, u_t, s_t}^{upper} \cdot ITT_t \quad (21)$$

であり、予測区間の下限値 RTT_t^{lower} は、

$$RTT_t^{lower} = F_{C_t, x_t, u_t, s_t}^{lower} \cdot ITT_t \quad (22)$$

である。よって、幅をもたせた旅行時間予測として、時刻 t の予測旅行時間の予測区間(PI ; Prediction Interval)は次のように出力される。

$$PI = [F_{C_t, x_t, u_t, s_t}^{lower} \cdot ITT_t, F_{C_t, x_t, u_t, s_t}^{upper} \cdot ITT_t] \quad (23)$$

3. 実データを用いた分析

この章では、モデルの性質を分析するために、実データを用いて予測を行って精度の検証を行う。第1節では、分析に使用したデータについて述べる。第2節では、実際の旅行時間に対してモデルがどの程度の精度を持っているかを評価できるように、評価指標を定義する。第3節では、評価指標を用いてモデルの推定精度について分析する。

(1) 使用データ

対象区間は、図-2で示されている阪神高速3号神戸線 上り7.0KPから阿波座ジャンクションまでの約7kmとする。この区間にはおよそ500m間隔で図中に●で示されているように16箇所に検知器が設置されており、5分間隔で、交通量・速度・占有率のデータが取得されている。この区間の最下流部である阿波座ジャンクションが、合流によるボトルネックである。

2004年4月1日午前0時0分から2010年3月31日午後11時55分までの平日 (年末年始, ゴールデンウィーク, 盆を除く) に取得されたデータを使用する。このうち、時速0km/hが含まれているデータは、ITTが無限大となり、解析に用いることが適切ではないため除去する。残りのデータから、モデルの適用範囲を満たすものを抽出する。

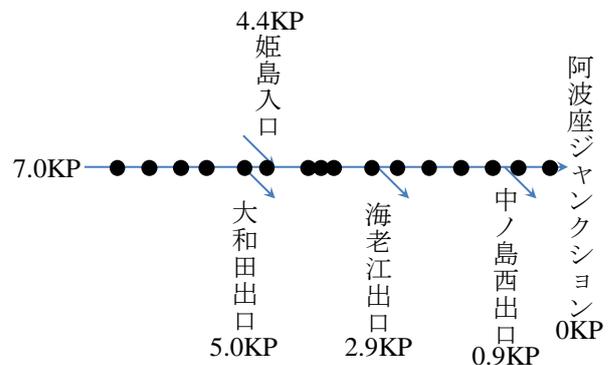


図-2 予測対象区間

具体的には、最下流部のボトルネック部分から渋滞が延伸している104,487組のデータを抽出した。ここでは、簡単のため、渋滞の定義を時速30 km/h以下とした。検知器によって取得された5分毎の速度データを用いて、 ITT , RIT , C , x を算出する。なお、 RIT の算出にはタイムスライス法を用いた。

モデルの再現性を検証するために、「パラメータを推定するためのデータ」と「モデルの精度を検証するためのデータ」に分ける。2004年4月から2007年3月までに取得された61,633組のデータをパラメータの推定に用いて、2007年4月から2010年3月までの42,854組のデータをモデルの再現性を検証するために用いる。

ITT の変化率 C は連続値なので、パラメータ推定用データ数が等しくなるように10個の階級に分ける。対象区間の始点から渋滞末尾までの距離 x は、検知器の速度データをもとに渋滞区間を判別して算出するため、検知器が30 km/h以下の速度を観測すれば、その検知器の支配区間全体が渋滞しているとみなす。つまり、 x は設置されている検知器の数である18通りの値をとりうる離散的な変数である。時間帯を示す u は離散的な値とし、6時から23時55分までを3時間毎に区切る。なお、0時から5時55分までの時間帯は、パラメータ推定用データの中で渋滞しているデータが1組しかなかったため、対象から外す。

図-3は、相手路線がの渋滞の有無および時間帯で場合分けしたそれぞれのパラメータ推定用データ数の分布を示している。非渋滞時よりも渋滞時のデータ数のほうが多く、9:00-20:55の時間帯では、非渋滞時よりも渋滞時のほうが圧倒的に多くのデータが蓄積されている。21:00-23:55の時間帯に観測されたデータ数は、非渋滞時に47組、渋滞時に35組しかなく、パラメータを推定するためにはかなり少ない。

(2) 評価指標

この節では、旅行時間の予測値と予測区間の評価指標について定義する。

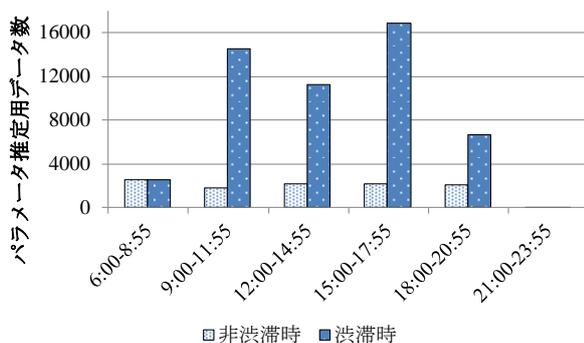


図-3 パラメータ推定用データ数の分布

a) 予測値の評価指標

予測値の精度が良いか悪いかを判断するために、実際に観測された旅行時間に対するモデルから出力される旅行時間の誤差を確認する。モデルとしての評価を行うために、複数時刻で予測を行った場合の誤差を総合的に判断できる指標として「平均絶対値誤差 (MAE: Mean Absolute Error)」を用いる。MAEを以下のように定義する。

$$MAE = \frac{1}{n} \sum_{i=1}^n |RTT_i^{med} - RTT_i| \quad (24)$$

ここに、 n はサンプル数、 RTT_i は時刻 i に観測された実旅行時間である。

b) 予測区間の評価指標

この項では、幅をもたせた旅行時間予測を行うモデルを評価するための指標を2つ定義する。旅行時間を幅を持たせて予測した場合に、それを評価することを考えると、幅の中に実際の旅行時間が入るかどうかという的中率と、いかに幅を狭く予測できるかということがモデルに要求される。そのため、以下では、モデルが出力する幅の中に実際の旅行時間がどの程度の確率で入るのかという指標と、モデルから出力される幅がどの程度の大きさなのかという指標を定義する。

本研究では、過去に蓄積されたデータからモデルを用いて旅行時間の5%ile値と95%ile値を推定し、90%の確率で観測されると予測される旅行時間の幅を推定する。幅が大きい場合は、旅行時間がいくらになるのかわからないということを意味している。逆に、幅が小さい場合には、旅行時間がどのくらいになるのかを想定できるため、有意な予測であるといえる。つまり、幅は「予測の質」を意味しており、小さいほど質の良い予測といえることができる。予測の質をモデルベースで評価するための指標として、モデルから出力される旅行時間幅の平均 (MPIL; Mean Prediction Interval Length)を用いる。MPILは次式で定義される。

$$MPIL = \frac{1}{n} \sum_{i=1}^n (RTT_i^{upper} - RTT_i^{lower}) \quad (25)$$

次に、予測された幅の中に、実際に観測される旅行時間が入る確率、すなわち予測の的中率 (PICP: Prediction Interval Coverage Probability)を用いて評価する。PICPが大きければ、実際に観測される実旅行時間が予測区間の中に入る確率が高い、すなわち、予測が当たりやすいことを意味する。しかし、PICPが大きいかからといって良い予測であるとはいえない。その理由として、予測区間の大きさを広げれば広げるほどPICPも大きくなることが挙げられる。例えば、予測区間の幅を無限大にすればPICPは1.00であり、100%の確率で予測が的中することになる。しかし、この予測は旅行時間が全くわからないことを示しているのと同様であり、良い予測であるとはいえない。本研究では、実際の旅行時間が予測区間の中に90%の確

率で入るような幅をモデルによって出力する。そのため、PICPが0.90に近い値をとるほど適合度の高いモデルといえる。

(3) 結果

この節では、前節で定義した指標を用いて点の予測値と幅を持たせた予測値を検証し、モデルの精度を分析する。

a) 予測値の評価

図-4は、実際に観測された旅行時間に対するモデルから出力された予測値のMAEを示している。渋滞時の21:00-23:55を除き、どの時間帯もおおむね1分程度であり、利用者から期待されている精度を満たしていると考えられる。

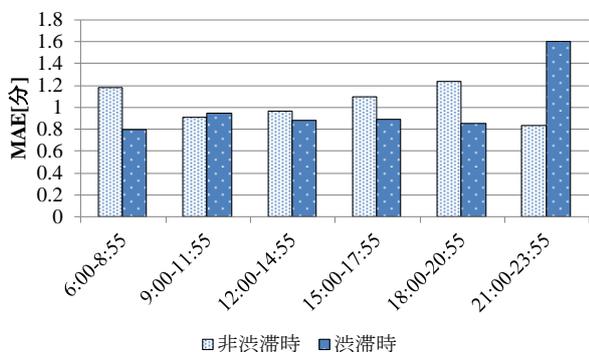


図-4 MAE

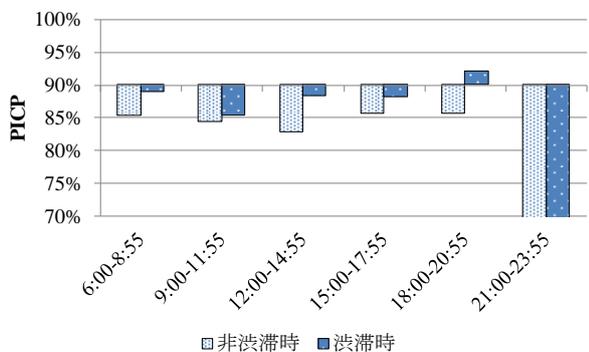


図-5 PICP

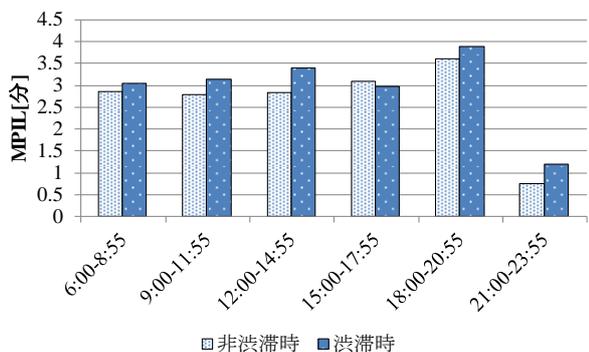


図-6 MPIL

b) 予測区間の評価

図-5は、実際に観測された旅行時間がモデルから出力された予測区間に含まれた割合 (PICP) を示している。本研究では、実際の旅行時間が90%の確率で入ると想定される予測区間をモデルによって求めているため、PICPが90%に近いほうが良いモデルであると言える。モデルの入力変数間に統計的独立性を仮定すれば、PICPが低下するということが先行研究¹⁰⁾で示されており、実際に、本モデルのPICPは基準である90%を下回る場合が多い。21:00-23:55の時間帯を除いて、基準から7%の誤差に収まっている。しかし、21:00-23:55の時間帯では、非渋滞時も渋滞時もPICPが20%程度になった。この原因として、データ数が少なかったことが考えられる。推定用データ数が少ないためにパラメータ推定結果が不安定になったことも考えられるが、検証用データ数が少なかったことも影響していると思われる。

図-6は、モデルから出力される予測区間幅の平均 (MPIL) を示している。18:00-20:55の時間帯で一番MPILが大きくなっており、予測の質が低いことがわかる。つまり、この時間帯は予測区間の幅が大きくなること示されており、利用者にとって利用しにくい予測になるということである。21:00-23:55の時間帯でMPILが小さくなっているが、PICPが小さかったため、予測の質が良いとは言えない。つまり、幅を小さく予測しすぎて当たらない予測が出力されてしまった。

4. 結論

需要の変動を考慮するために、時間帯毎に区切り場合分けを行った。また、ボトルネック容量の変動を考慮するために、合流する相手路線が渋滞しているか否かによって場合分けを行った。これらは、既存モデルの仮定を緩和してモデルの適用範囲を拡大することを意味する。

実データを用いた分析では、点の予測値に対する予測精度には問題がないことがわかった。しかし、幅をもたせた予測区間に対する精度分析では、データ数が少ない21:00-23:55の時間帯で予測区間の幅がかなり小さく推定され、的中率が小さくなった。

今後の課題として、今回の研究では、時間帯に分けることと相手側路線の交通状態によって分けることを同時に行い分析を行ったが、時間帯に分けた場合と相手側路線の交通状態によって分けた場合のそれぞれの場合について分析を行うとともに、時間帯と相手側路線の交通状態についても独立性を仮定することで結論で述べたデータ数が少なくなる問題を解決できないかを検討する予定である。

参考文献

- 1) 宗像恵子, 田村勇二, 割田博, 白石智良: 首都高速道路におけるリアルタイム予測シミュレーションの開発, 第 29 回交通工学研究発表会論文集, pp.293-296, 2009.
- 2) 白石智良, 桑原雅夫, 堀口良太: リアルタイム予測交通流シミュレーションシステムの開発, 土木計画学研究・講演集, Vol.30, CD-ROM, 2004.
- 3) 舟橋賢二, 西村茂樹, 堀口良太, 赤羽弘和, 桑原雅夫, 小根山裕之: VICS 蓄積データを用いた旅行時間短期予測手法に関する研究, 土木計画学研究発表会講演集, Vol.27, CD-ROM, 2003.
- 4) 割田博, 森田綽之, 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, 交通工学研究発表会論文報告集, Vol.24, pp.129-132, 2004.
- 5) 松本幸正, 鈴木忠英, 松井寛: 都市間高速道路における車両感知器を用いた所要時間推定モデルの特性比較, 第 6 回 ITS シンポジウム 2007Proceedings, p.p.119-124, 2007.
- 6) 中村英樹, 王鋭: 車両感知器とプローブデータを組み合わせた旅行時間推定手法の実証分析, 第 2 回 ITS シンポジウム 2003Proceedings, pp.283-288, 2003.
- 7) 三輪富生, 境隆晃, 森川高行: プローブカーデータを用いた経路特定手法と旅行時間推定に関する研究, 第 2 回 ITS シンポジウム 2003Proceedings, pp.277-282, 2003.
- 8) 三輪富生, 多和田雄介, 山本俊行, 森川高行: 速度変化情報を用いた予測旅行時間の更新手法の検討, 第 3 回 ITS シンポジウム 2004Proceedings, pp.451-456, 2004.
- 9) Wei, C., Iryo, T. and Asakura, Y. : Implementation of Short-Term Travel Time Prediction Model on Urban Expressway, *International Journal of ITS Research*, 7(2), pp. 101-108, 2009.
- 10) 坂井勝哉, 日下部貴彦, Chong WEI, 朝倉康夫: 旅行時間予測値の性能に関する統計分析, 土木計画学研究発表会, Vol.44,2011.

(2012. 8. 3受付)

STATISTICAL MODEL OF TRAVEL TIME PREDICTION CORRESPONDING TO FLUCTUATION OF BOTTLENECK CAPACITY ON JUNCTION

Katsuya SAKAI, Takahiko KUSAKABE and Yasuo ASAKURA