

特徴空間軌跡の追跡による動的交通状況予測

熊谷 正俊^{1,a)} 蛭田 智昭¹ 奥出 真理子¹ 横田 孝義²

受付日 2011年3月2日, 採録日 2011年10月3日

概要: 自動車をセンサとするプローブカーシステムを用いれば路側インフラに依存せずに交通情報を収集することが可能である。しかしながらプローブカーである車両の分布は必ずしも均一ではないため、プローブカーデータには大規模な欠損がともなう。一方、従来の交通状況予測手法は路側センサのような連続的なデータを前提としており、プローブカーデータはそのような予測手法の情報源として適さない。この問題を解決するため、特徴空間軌跡を用いた新たな交通状況予測手法を開発した。ここで述べる特徴空間はプローブカーデータ履歴の主成分分析により生成されるものであり、疎らなプローブカーデータも、特徴空間内では連続的かつ周期的な軌跡を描く。連続性と周期性は交通状況の動的予測に本質的な要素であり、現況の交通状況に相当する特徴空間座標近傍から軌跡をトレースすることで、特徴空間内での予測座標を得ることができる。この予測座標を元の交通情報データ空間に逆射影したものが、交通情報の予測値である。2,000台のプローブカーを使用した検証により、従来手法に比して予測情報のカバー率拡大と予測誤差の低減が可能であることを確認した。

キーワード: プローブカー, 交通情報, 予測

Dynamic Prediction of Traffic Congestion by Tracing Feature Space Trajectory

MASATOSHI KUMAGAI^{1,a)} TOMOAKI HIRUTA¹ MARIKO OKUDE¹
TAKAYOSHI YOKOTA²

Received: March 2, 2011, Accepted: October 3, 2011

Abstract: Floating cars can collect traffic information without roadside equipments. However, due to the non-stationary distribution of floating cars, there is large deficiency in floating-car data. It becomes disadvantage when using floating cars as a data source for prediction, since conventional prediction methods are designed to be used with a continuous data source such as roadside sensor data. In an effort to address this problem, we developed a new prediction method by tracing feature space trajectory. The feature space is given by principal component analysis on floating-car data history. Time sequence of sparse floating-car data describes continuous and cyclic trajectory in the feature space. The continuity and the cyclicity are essential for dynamic prediction, i.e., by tracing the trajectory nearby current coordinates, we can estimate predictive coordinates along the trajectory. Inverse projection of the predictive coordinates gives predictive information with no deficiency. We evaluated the method using floating-car data collected from 2,000 vehicles, and found the method enlarges the coverage of predictive information and decreases predictive error in comparison to conventional method.

Keywords: floating car, traffic information, prediction

1. 緒言

道路上の交通状況を計測するには、従来は超音波感知器やループコイル、画像センサを用いるのが一般的であった。いずれも路上に設置された固定センサであり、多大なイン

¹ 株式会社日立製作所
Hitachi Ltd., Hitachi, Ibaraki 319-1292, Japan

² 京都大学
Kyoto University, Kyoto 615-8530, Japan

a) masatoshi.kumagai.ws@hitachi.com

フラコストがかかるため、そのカバーエリアは主要道路に限られている。これに対して、GPSの普及と無線通信の発達が可能としたインフラレスの計測手段が、プローブカーシステムである [1], [2].

プローブカーは道路上を走行する自動車そのものがセンサであり、位置、速度などの車両データを、無線通信を介して交通情報センタにアップリンクする。交通情報センタでは、多数の車両から収集されたデータを道路上の速度や旅行時間を表すデータに加工し、交通情報として配信する。プローブカーとして専用の車両を走らせる場合もあるが、自家用車、タクシー、ロードサービス車両などを計測車両として活用するのが一般的である。

プローブカーの利点は新たに路上インフラの整備を必要とせず、GPSを備えた車両、無線通信回線、情報を集約する交通情報センタがあれば、交通情報の収集が可能にある。一方、実用の交通情報サービスに供するうえでは、プローブカーに特有の問題もある。それは情報収集が車両の分布に依存する点である。

たとえば日本全国に10万台のプローブカーが走行していたとしても、交通情報の更新頻度は平均して1時間に1回程度にすぎない [3]。これは一般的な路上センサの情報更新頻度が5分に1回であることと比較するとたいへん疎らなデータであり、交通状況の変化に追従できるデータ密度とはいえない。

この問題の解決にはプローブカー台数そのものを増やすという直接的な手段もあるが、情報処理の工夫による解決も可能である。その1つが特徴空間補完である [4]。特徴空間補完は、過去のプローブカーデータ履歴の主成分分析によって特徴空間を構成し、特徴空間に欠損をともなう現況データを射影/逆射影することで、欠損データをリアルタイムに推定補完する技術である。道路ネットワークの交通状況を多次元の特徴空間で表現し、現況の観測データから特徴空間座標を動的に決定することで、特徴空間の持つ相関情報に基づく推定を可能とする。

一方、交通情報サービスにおいては現況だけでなく、未来の交通状況についての予測も重要である。しかしながら既存の予測手法は欠損のない時系列データの入力を前提としているものが多く、路上センサデータに基づく予測では効果を発揮するが、欠損をともなうプローブカーデータには対応していない。

この課題に対して、欠損をともなう現況データに基づいて未来の交通状況を予測するには、大きく分けて下記3つのアプローチが考えられる。

(1) 特徴空間補完の結果を既存の予測手法の入力とする。

既存技術の組合せであり、シンプルなアプローチではあるが、補完演算による誤差に予測演算の誤差が重畳される。

(2) 従来手法の1つであるパターンマッチング予測 [1] を、

リンク単位（主要交差点間の道路区間）から、エリア単位（複数のリンク群）に拡大して用いる。すなわち、現況のプローブカーデータが収集されたリンクの交通情報をキーとして、過去の交通情報履歴を検索する。しかし、検索対象である過去の交通情報も欠損をともなうため、プローブカーデータの欠損率が80%程度になると検索のヒット率が低下し、過去の情報を参照できなくなる。

(3) 特徴空間補完で用いる特徴空間上で、過去の射影点履歴を検索する。(2)の検索空間である交通情報データ空間が欠損をともなうのに対して、特徴空間の射影点は後述のように観測データの相関成分を表すことから、欠損のない検索空間で履歴検索を行うことができる。それゆえ検索キーの減少によるヒット率の低下は起こらない。

以上の理由により本研究では(3)の方針に沿って、新たな予測手法の開発を行った。本手法は欠損をともなう交通情報を情報源として扱えることのほかに、既存の予測手法と比べて、精度や実用性の面で次の利点を持つ。

まず最もオーソドックスで実用化の事例も多い従来手法として、過去の交通情報を曜日などで分類して時間帯ごとの統計的代表値を提供する手法がある [5]。このような統計的手法はカーナビゲーション装置の組み込みデータとしての利用や、長期的な予測には有用だが、近年主流の通信型カーナビゲーションを対象としたオンラインサービスを通じて直近の交通状況をリアルタイムに予測するうえでは、現況情報を加味しないことから精度が頭打ちになる。これに対して本手法は現況情報を活用した動的予測を行うことで、予測精度の向上を図った。

動的な予測手法としては交通状況の伝搬現象に着目することで、予測精度を向上させた事例がある [6]。この手法は道路の下流～上流の区間で渋滞が伝搬する速度と強度をモデル化することで、下流で計測された渋滞による上流の交通状況の変化を予測する。ただし、これは路線が複雑に分岐しない高速道路などにおいては効果的な手法だが、広範なネットワーク構造を持つ一般道路では予測パラメータの同定が不安定になる。この問題に対して本手法では、パラメータ同定をともなう予測モデルを介することなく、特徴空間上の射影点の集合として保持された交通情報履歴から予測情報を直接生成する方法をとることで、一般道路への適用を図った。

一般道路にも適用可能な動的予測手法としては、全国規模のシミュレーションを試みている事例もある [7]。これは計算機能力の向上し続けるであろう将来において有望な技術だが、パラメータキャリブレーションなどの課題もあり、商用での実用化には至っていない。一方で本研究の立場は商用サービスにただちに適用できる技術を開発することにあり、本手法もそのような観点から、予測精度と運用

性のバランスを考慮して、シンプルなアルゴリズムと簡単なチューニングで実装できる仕様となっている。

本論文では2章でベース技術である特徴空間補完を概説したうえで、以上に述べた新手法の概念とアルゴリズムを3章で解説し、4章ではプローブカーデータを用いた精度評価の結果を示す。

2. 特徴空間補完

2.1 基本概念

ある単位エリア（地図メッシュなど）で収集されたプローブカーデータを、リンク単位の旅行時間データあるいは速度データに加工したうえで主成分分析を行う。すると複数リンクのデータが、相関を持って変化する成分と、無相関に変化する成分とに分解され、なおかつ相関のある成分ごとに単一の代表変量で表されるため、データの次元が縮退される。たとえば100リンクの旅行時間データを、10変量で代表することが可能である。

このとき本来の交通情報データは、前記代表変量を係数として、リンク間の相関関係を表す基底ベクトルを線形合成することにより、近似的に表現される。このように集約された情報表現が主成分分析による特徴空間射影である。基底は特徴空間を張る静的なベクトルであり、前記代表変量が特徴空間上で動的に変化する座標である。

さて、交通情報データを特徴空間に射影して表現することが可能である以上、逆もまた可能である。すなわち特徴空間上の1点を定め、それを逆射影すれば、当該単位エリアにおける交通状況を示すことになる。特徴空間に射影されるデータが欠損をとまう場合でも、特徴空間座標が定まるならば、逆射影されたデータはエリア全体の交通状況を表す。これが特徴空間補完の基本となる考え方であり、図1のように、

- (i) 過去のデータから特徴空間を生成し、
 - (ii) リアルタイムに計測されたデータから特徴空間上の座標を定め、
 - (iii) 特徴空間座標の逆射影によって推定情報を生成する、
- という3つのプロセスで欠損データを補完する。

図2は東京都心の交通情報データから得られた基底の例である。主成分分析は基底に明示的な意味を与えないが、第1基底から順に都心全域の交通、都心への流入出、放射状路線の交通と解釈することができる。このように特徴空間が表すのは道路ネットワーク上の交通状況の相関関係であり、特徴空間を構成する基底ベクトルは、過去のデータから統計的に決定される。見方を変えれば、リンク間の相関関係は過去データに基づく静的な統計値ではあるが、その組合せ、すなわち特徴空間上の座標を動的に決定することにより、動的な交通状況の表現と推定補完が可能になる。

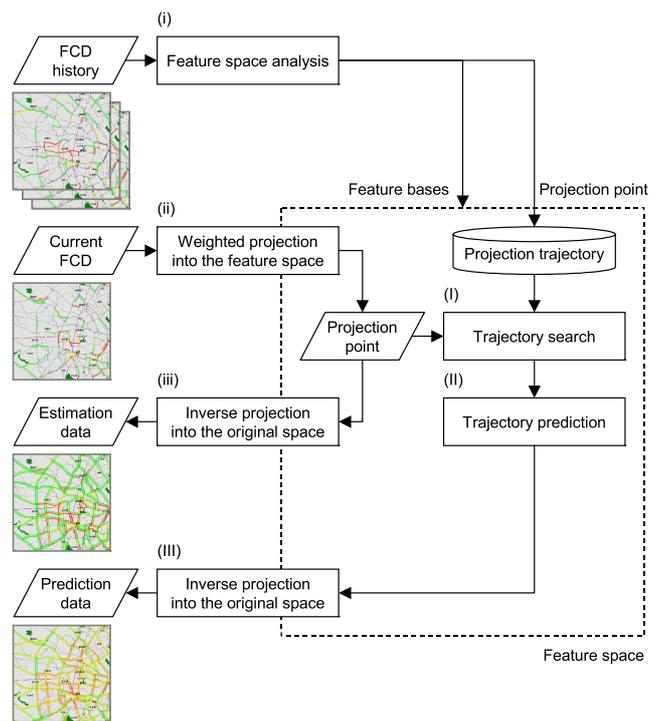


図1 プローブカーデータの補完および予測プロセス

Fig. 1 Interpolation and prediction process with floating car data.

2.2 推定補完プロセス

(i) 特徴空間の生成

路上センサで得られる欠損のないデータの場合には、特徴空間は通常の主成分分析によって生成できる。一方、プローブカーデータのように大規模な欠損を含む場合には、通常の主成分分析では演算が成立しない。そこでこのようなデータに対しては「欠損値付き主成分分析 (PCAMD)」[8], [9] と呼ばれる拡張手法を用いて、過去データからの特徴空間生成を行う。

具体的には、補完対象のエリアにおける M 本のリンクについて、 N 回にわたって計測された交通情報データを $N \times M$ 行列 \mathbf{X} で表すものとする。 \mathbf{X} の i 行目の成分を対角要素とするデータ行列 \mathbf{D}_{xi} 、重み行列 \mathbf{V} 、 \mathbf{V}_0 に対して、PCAMD はフロベニウスノルム

$$J = \sum_{i=1}^N \text{SS}(\mathbf{D}_{xi}\mathbf{V} + \mathbf{V}_0 - \mathbf{e}_M \mathbf{u}_i^T)_{D_{wi}, I} \quad (1)$$

を最小化する問題と定義される。この問題を解くことで、処理対象の交通情報データ \mathbf{X} の観測値を、誤差ノルム最小で近似できる基底のセットが得られる。すなわち交通情報データ \mathbf{X} を PCAMD で得られた基底で張られる特徴空間に射影すれば、その逆射影によって与えられるデータは元の交通情報データに対する誤差最小近似となる。

(ii) 現況データの射影

(i) で得られた基底に対して欠損のない現況データを射影する場合には、基底と現況データの内積によって、特徴空間座標は一意に決定される。一方、現況データが欠損を

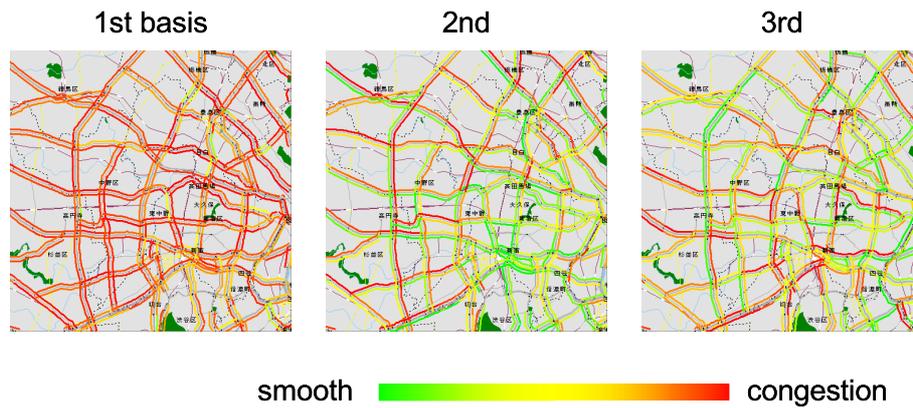


図 2 特徴空間の基底

Fig. 2 Example of the bases of the feature space.

ともなう場合には、内積による射影は不可能であり、次式による重み付け射影を用いる。

$$\mathbf{a} = (\mathbf{P}^T \mathbf{W}^T \mathbf{W} \mathbf{P})^{-1} \mathbf{P}^T \mathbf{W}^T \mathbf{W} \mathbf{x}^T \quad (2)$$

ここで、 \mathbf{P} は PCAMD で得られた基底ベクトルを並べた行列であり、 \mathbf{W} は重み付けの行列である。欠損を含む現況データ \mathbf{x} に対して、射影点 \mathbf{a} が得られる。重み付け射影は観測データの重みを 1、欠損データの重みを 0 として扱うことで、欠損データのリンクを無視し、現況データが観測されたリンクについて誤差ノルムが最小化されるように、特徴空間上の射影点を決定する。すなわち重み付け射影によって得られる特徴空間座標は、観測データに対する誤差最小ベクトルである。

ただし、ここで注意を要する事柄がある。(i) で得た特徴空間の次数にもよるが、現況データの欠損率が過度に高い場合には、重み付け射影問題を解くことができず、これが推定補完処理の可否を決める理論的な限界となる。すなわち特徴空間補完は無から有を作り出しているわけではなく、処理対象の単位エリアにおける相関のある成分の次数に基づいて、その次数を超える現況データが得られた場合に、当該エリアの交通状況が推定可能であるものとして補完データを算出する。

(iii) 逆射影による推定

(ii) の重み付け射影によって得られた特徴空間座標 \mathbf{a} を、次式により元のデータ空間へ逆射影する。

$$\hat{\mathbf{x}} = \mathbf{a}^T \mathbf{P}^T \quad (3)$$

ここで特徴空間座標 \mathbf{a} は、欠損データに対する推定を含む情報である。なぜならば、特徴空間座標は観測データに対する誤差最小近似値であるが、同時に、特徴空間が内包する相関関係に基づいて全リンクの交通状況を表している。欠損データについていえば、これは観測データとの相関で定まる値である。このことは 2.1 節で述べたとおりであり、特徴空間の持つ相関情報が観測データと欠損データを関連

付けている。よってその逆射影により、

- 現況データの観測値と
- 過去データから得られたリンク間の相関関係に基づく推定値が得られる。

3. 特徴空間軌跡による予測

3.1 基本概念

本節では先述の特徴空間補完のプロセスをベースとして、交通状況の動的予測を行う仕組みについて述べる。

図 3 は式 (2) によって得られた特徴空間上の射影点の軌跡の例である。図 2 の基底で張られた特徴空間に 1 カ月分の交通情報データを 5 分間隔で射影し、特徴空間の第 1、第 2 軸ならびに第 3、第 4 軸で構成された部分空間の座標をプロットした。垂直軸は時刻であり、0:00~23:55 の時間変化に相当する。すなわち 1 日の射影点軌跡は 0:00 の平面上から始まり、交通状況に応じて特徴空間上の座標を変えながら 23:55 の平面で終了し、再び 0:00 の平面に戻る。図 4 は図 3 の第 1 軸、第 2 軸の空間を平面に投影した図である。時刻はおおよその目安だが、1 日単位で周期的な軌跡を描くことが分かる。

主成分分析を用いると、元の交通情報データ空間におけるデータ分散の大きい順に特徴空間軸である基底が決定される。図 4 の例において特徴空間の意味を解釈すると、第 1 軸は道路ネットワーク全体の交通量を表し（正：交通量が少ない、負：多い）、第 2 軸は外縁から都心への流入流出に相当する（正：流出、負：流入）。すなわち、図 4 の射影点の変化を第 1、第 2 軸について定性的に説明すると下記のようなになる。

- 午前中は全体の交通量が増え、かつ、流入交通量が卓越するため、第 1 軸、第 2 軸ともに負の方向へと射影点が移動する。
- 昼にはいったん交通量が減り、流入出が平衡するため、射影点は第 1 軸上で正の方向に移動する。
- 午後には再び交通量が増え、かつ、夕方にかけて流出

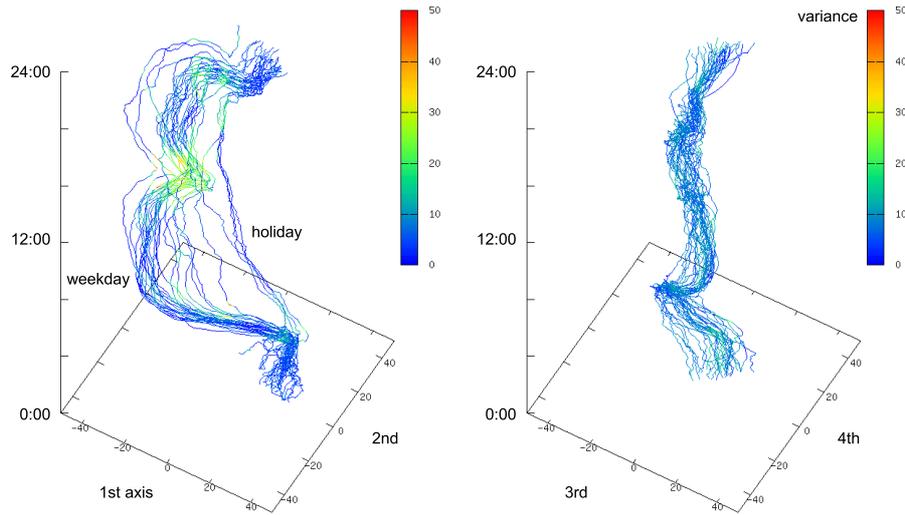


図 3 特徴空間軌跡

Fig. 3 Example of the feature space trajectory.

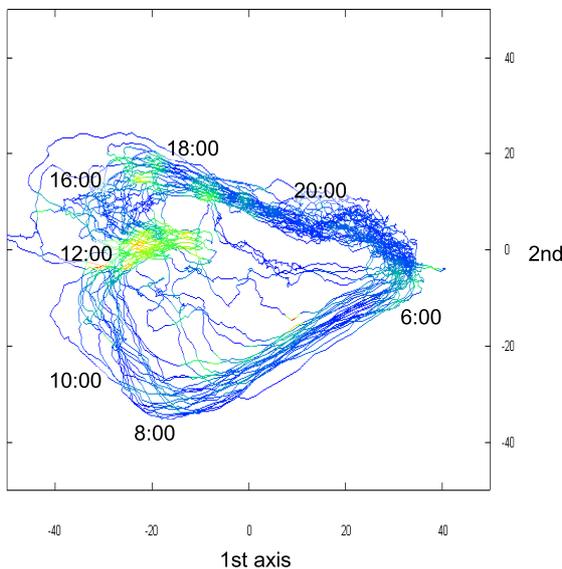


図 4 特徴空間軌跡の周期性

Fig. 4 Cyclic shape of the feature space trajectory.

交通量が卓越するため、第 1 軸で負の方向に、第 2 軸で正の方向に射影点が移動する。

ところで、リンク単体では同じような交通状況が 1 日に何度も発生するのは珍しいことではない。これはリンク単位の旅行時間や速度が、1 次元の値の増減にすぎないためである。一方、エリアとして交通状況をとらえ、特徴空間に射影することで、射影点は上述のように 1 日単位の周期的な軌跡を描く。すなわち特徴空間上のある領域に射影点が存在する場合には、その後の軌跡は過去の事象から類推可能であり、かつ、特徴空間上の座標が実際の交通状況と対応していることから、特徴空間上の軌跡の変化が予測できるならば、交通状況の変化も予測できる。これが特徴空間軌跡を用いた予測の基本概念であり、図 1 における推定補完の処理 (i), (ii), (iii) と並行して、

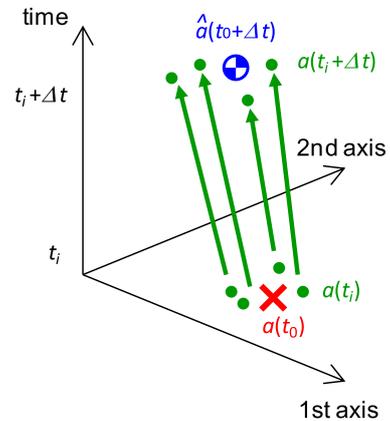


図 5 特徴空間における予測の原理

Fig. 5 Basic idea of prediction in the feature space.

- (I) 現況データの射影点近傍にある過去データの射影点履歴を検索
- (II) 検索された射影点を起点とする軌跡に基づいて未来の射影点を予測
- (III) 予測射影点を交通情報データ空間に逆射影というプロセスにより、現況データを基にして未来の交通状況を予測する。次節においては、このプロセスに沿った予測の詳細を述べる。

3.2 予測プロセス

(I) 射影点の検索

図 5 は予測の原理を示した図である。まず式 (2) によって特徴空間に射影された現況データの射影点について、図 4 のような過去の射影点の軌跡から、その近傍にある複数の射影点を検索する。具体的には、現在時刻 t_0 における射影点 $\mathbf{a}(t_0)$ に対して、過去の時刻 t における射影点 $\mathbf{a}(t)$ の距離

$$d(t) = |\mathbf{a}(t) - \mathbf{a}(t_0)| \quad (4)$$

を計算し、この距離に基づいて過去一定期間の射影点履歴をソートし、その上位 K 個の射影点 $\mathbf{a}(t_1) \sim \mathbf{a}(t_K)$ を以下の予測演算に用いる。

(II) 予測射影点の算出

現在時刻 t_0 から Δt 後の予測を行うには、(I) で得られた K 個の射影点 $\mathbf{a}(t_1) \sim \mathbf{a}(t_K)$ を起点として射影点軌跡をたどり、各射影点の Δt 後の射影点 $\mathbf{a}(t_1 + \Delta t) \sim \mathbf{a}(t_K + \Delta t)$ を得る。特徴空間上で現況の射影点 $\mathbf{a}(t_0)$ との距離が小さい、すなわち現在の交通状況と類似の状況を示す過去の射影点ほど、その後の変化も類似していると考えるならば、射影点 $\mathbf{a}(t_1 + \Delta t) \sim \mathbf{a}(t_K + \Delta t)$ を距離 $d(t_i)$ の逆数 m_i で重み付けした重心

$$\hat{\mathbf{a}}(t_0 + \Delta t) = \frac{1}{\sum m_i} \sum m_i \mathbf{a}(t_i + \Delta t) \quad (5)$$

が、過去の射影点履歴から類推しうる範囲で、現在時刻 t_0 から Δt 後の射影点として最も確かな予測値である。

(III) 予測射影点の逆射影

式 (5) で得られた予測射影点を、式 (3) と同様の演算によって交通情報データ空間に逆射影する。すなわち、

$$\hat{\mathbf{x}}(t_0 + \Delta t) = \hat{\mathbf{a}}^T(t_0 + \Delta t) \mathbf{P}^T \quad (6)$$

が交通情報の予測値である。また、予測射影点座標を用いて基底ベクトルを合成することから、この式は欠損データの推定値を算出する作用も有する。それゆえ、欠損をともなうプローブカーデータから欠損のない予測情報の提供が可能となる。

4. 予測精度の評価

以上に述べた予測手法の有効性を、プローブカーデータを用いて検証した。このデータは図 6 に示した約



図 6 評価エリア

Fig. 6 Evaluation area.

10 km × 10 km 四方の地域において一般道路約 700 リンクを走行する 2,000 台のタクシーから収集された合計 3 週間のプローブカーデータであり、情報更新周期は 5 分間、空間的な欠損率は時間帯によって 30% から 90% の範囲で変化している。検証においては、前半 2 週間のデータを射影点軌跡の生成に用い、後半 1 週間のデータを予測精度の評価に用いた。予測精度の評価は、5 分ごとにプローブカーデータを特徴空間に射影して 2 時間先の交通状況を予測し、その予測値を 2 時間後のプローブカーデータ実測値と比較するという手順で行った。この評価において特徴空間次元数は 20 次元とした。

検証結果を以下に示す。図 7 は特徴空間の上位 2 軸を切り出し、前半 2 週間のプローブカーデータの射影点軌跡をプロットしたグラフである。グラフにはデータのノイズや欠損にともなう振動が見られるが、全体としては連続的かつ周期的な軌跡を描いている。グラフの色合いは軌跡の分散を表しており、たとえば深夜のように交通状況の変化が小さな時間帯には分散が小さく、朝の通勤のように交通状況の変化が大きい時間帯には分散が大きい。

図 8 はある 1 本のリンクについて、予測値と実測値を比較したグラフであり、横軸が日時、縦軸が速度を表す。図中、実線が予測値であり、点が実測値である。一般的に、交通状況の動的予測には多少の時間遅れがともな

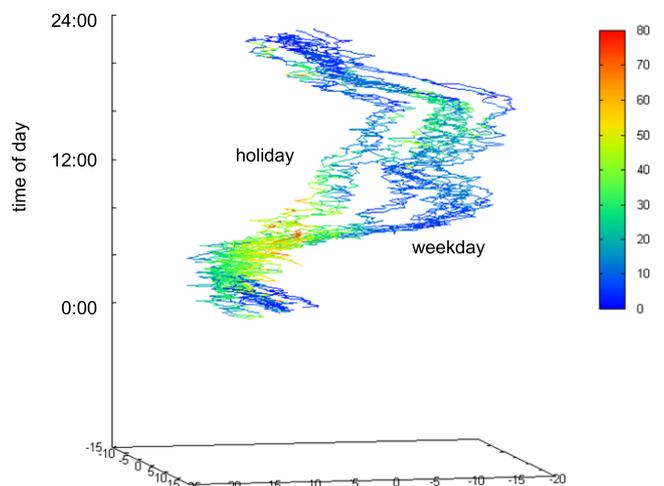


図 7 プローブカーデータの特徴空間軌跡

Fig. 7 Feature space trajectory of floating car data.

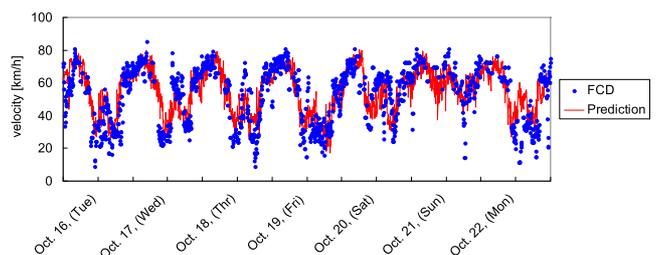


図 8 予測値と実測値の比較

Fig. 8 Comparison of prediction data and measurement data.

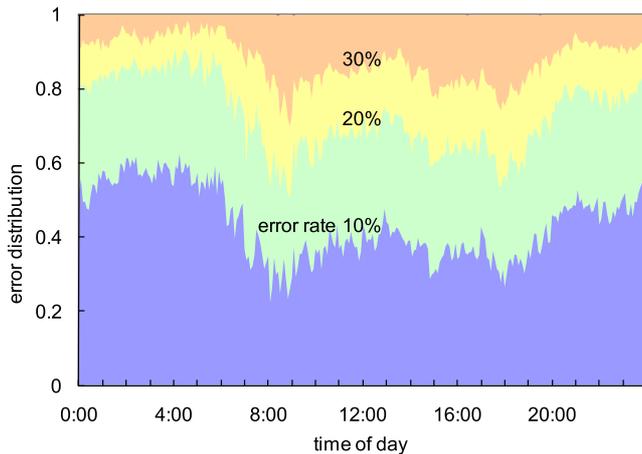


図 9 予測値の誤差分布

Fig. 9 Error distribution of prediction data.

う。なぜなら交通状況の変化がとらえられてはじめて、その変化が予測値に反映されるためである。だがグラフに示されたように、本手法による予測値は2時間先の交通状況を予測した結果にもそのような遅延が見られない。これは1リンクごとに交通状況の変化を検出するのに比べて、交通状況の空間相関を対象とすることで、その変化を鋭敏に検出できるためと考えられる。その根拠としては、0時から5時といった個々のリンク単位には交通状況の変化が小さい時間帯でも、図7において特徴空間上の射影点座標が明確に変化していることもあげられる。

プローブカーが走行した全リンクについて、検証期間の1週間を通して精度評価を行った結果が図9である。横軸は時間帯を表し、縦軸とそれに対応して塗り分けられた領域は予測誤差の累積度数分布を表す。この誤差分布からは次のことが分かる。

- 図7において軌跡の分散が大きくなる時間帯は予測誤差も大きい。
- 誤差の大きな時間帯においても、全予測データの約8割が誤差30%以下、同約7割が誤差20%以下である(誤差が30%を超えるのは10回に2回程度、20%を超えるのは10回に3回程度)。

図10は静的統計値を予測値とした場合と本手法との平均予測誤差を比較したグラフであり、細線が静的統計値、太線が本手法の予測誤差を表す。静的統計値は射影点軌跡の生成に用いたものと同期間のプローブカーデータから算出した。その算出にあたっては文献[5]の知見を参照しているが、プローブカーデータの収集期間が限られていることと欠損をとまなうことから多種多様な日種に基づく回帰分析はできないため、プローブカーデータを曜日で分類して時刻ごとに平均した値を用いた。静的統計値の平均誤差はおおむね20~30%の範囲に分布している一方、本手法による予測値の平均誤差はおおむね10~20%の範囲に分布している。また交通情報サービスに要求される精度水準に関

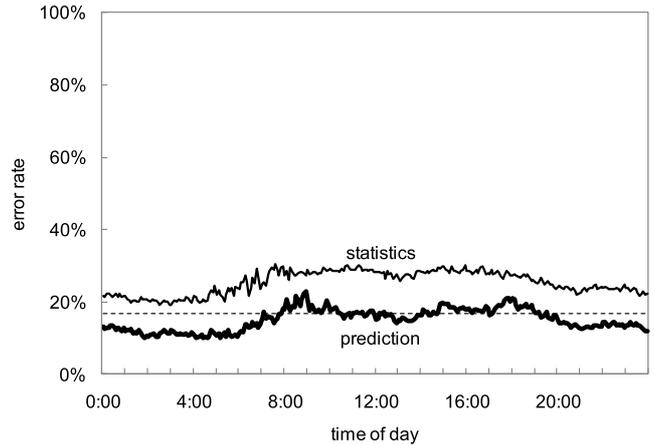


図 10 平均予測誤差の比較

Fig. 10 Comparison of the average error rate.

して、文献[10]においては現況交通情報で30分の提供値に対して ± 5 分、すなわち誤差範囲17%の精度を利用者が求めていることがアンケート結果として述べられているが、これは図10において点線で示した水準であり、本手法によりこの水準に近い範囲まで予測誤差を低減させることができた。このような予測誤差の低減には、現況情報に基づいて動的な予測演算を行うことに加えて、疎らなプローブカーデータでも交通情報の空間相関に基づいてより多くのサンプルを母集団として扱うことで、安定した予測値を算出できることが寄与したものと考えられる。

なお予測対象期間1週間、予測対象区間約700リンクに対して、本手法による予測値の時空間カバー率が100%である一方、静的統計値の時空間カバー率は66%にとどまった。これは欠損のあるプローブカーデータを統計処理する以上、生成された統計値も欠損をとまなうためである。

以上の結果を総合すると、本研究で開発した予測手法は欠損のあるプローブカーデータから欠損のない予測情報を生成することが可能であり、かつ、2時間先の交通状況を予測するに際しても、現況交通情報に求められている水準とほぼ同等の精度を達成することができる。また3.2節にそのプロセスを述べたように、本手法は複雑なチューニングを必要とせず、過大な運用コストを掛けることなく全国規模の交通情報サービスへの適用が可能である。

5. 結言

本研究では欠損をとまなうプローブカーデータを交通状況の動的予測に活用することを目的として、特徴空間射影を用いた予測手法を開発した。この手法は疎らで不連続なプローブカーデータ時系列を特徴空間に射影して得られる連続的かつ周期的な特徴空間軌跡を用い、現況の射影点を起点としてこの軌跡をトレースすることで、現況交通情報を加味した予測値を動的に算出するものである。2,000台のプローブカーデータを用いた検証により、従来手法に比

して予測情報の時空間カバー率の拡大と予測誤差の低減が可能であること、2時間先の交通状況を示す予測情報の提供において現況交通情報に求められている水準とほぼ同等の精度を達成可能であることを確認した。本手法は定常時における交通状況の変動に効果を発揮する手法だが、再現性のない突発的な交通状況の予測という課題に対しても、定常時の空間相関からの逸脱検知をトリガとして、異常な渋滞を早期に検出することで、その予測につなげられないかと考えている。

参考文献

- [1] 柘植正邦, 養父利秀: カーナビゲーションの可能性を広げる新情報提供システム, 自動車技術, Vol.58, No.2, pp.44-48 (2004).
- [2] Wang, W., Fushiki, T., Zhang, H., Kimita, K. and Mizuta, H.: A Probe Car System for Beijing, *Proc. 12th World Congress on ITS*, CD-ROM (2005).
- [3] 伏木 匠, 横田孝義, 君田和也, 熊谷正俊: 交通情報提供の更新周期を考慮したプローブカー台数算出モデルの定式化とその評価, 電気学会論文誌 D, Vol.126-D, No.6, pp.741-747 (2006).
- [4] 熊谷正俊, 伏木 匠, 横田孝義, 君田和也: 特徴空間射影によるプローブカーデータのリアルタイム補完, 情報処理学会論文誌, Vol.47, No.7, pp.2133-2140 (2006).
- [5] 熊谷正俊, 伏木 匠, 横田孝義, 佐野 豊, 鈴木研二: 全国規模の交通情報サービスを目的とする所要時間長期予測技術の開発, 情報処理学会論文誌, Vol.45, No.12, pp.2696-2705 (2004).
- [6] Yamane, K., Endo, Y. and Okude, M.: Travel Time Prediction Using Traffic Conditions Propagation Model, *Proc. 13th World Congress on ITS*, CD-ROM (2006).
- [7] 小出勝亮, 田中伸治, 飯島護久, 白石智良, 堀口良太: グリッドコンピューティングによる日本全国交通シミュレーションシステムの開発, 交通工学, Vol.46, No.3, pp.9-12 (2011).
- [8] Ruhe, A.: Numerical computation of principal components when several observations are missing, Technical Report UMINF-48, Dept. Information Processing, Umea Univ. (1974).
- [9] 高根芳雄: 制約付き主成分分析法, 朝倉書店 (1995).
- [10] 割田 博, 吉田 寛: 首都高速道路における所要時間変動特性の分析, 第 22 回交通工学研究発表会論文報告集, pp.61-64 (2002).



熊谷 正俊 (正会員)

1975年12月2日生。2002年3月東北大学大学院情報科学研究科システム情報科学専攻博士課程修了。博士(情報科学)。同年4月株式会社日立製作所入社, 日立研究所勤務。2008年Hitachi Europe SAS(フランス)駐在を経て, 交通情報サービス, ナビゲーションシステムの研究開発に従事。情報処理学会平成18年度山下記念研究賞受賞。日本機械学会会員。



蛭田 智昭

1980年8月10日生。2005年3月東北大学大学院工学研究科バイオロボティクス専攻修士課程修了。同年4月株式会社日立製作所入社, 日立研究所勤務。入社以来, 交通情報サービス, ナビゲーションシステムの研究開発に従事。平成19年情報処理学会高度交通システム研究会優秀論文賞受賞。



奥出 真理子 (正会員)

1964年8月14日生。1989年3月長岡技術科学大学大学院工学研究科電気電子システム工学専攻修士課程修了。同年4月株式会社日立製作所入社, 日立研究所勤務。車載情報システム, 交通情報サービスの研究開発に従事。電子情報通信学会, 土木学会各会員。



横田 孝義

1956年10月28日生。1984年3月東京工業大学大学院総合理工学研究科博士後期課程修了。工学博士。同年4月株式会社日立製作所入社, 日立研究所勤務。1988年米国Carnegie Mellon大学客員研究員, 以降ITS, カーナビゲーションシステムの研究開発に従事。2009年4月より京都大学工学研究科都市社会工学専攻先進交通ロジスティクス(阪神高速道路)講座教授。平成5年交通工学研究会徳岡賞受賞。土木学会, 交通工学研究会各会員。