

# 特集 人の流れを考慮した危険予知について\*

## On Risk Prediction Considering People Flow

笹木美樹男  
Mikio SASAKI

関本義秀  
Yoshihide SEKIMOTO

The people flow data is defined as the time series of events each of which is composed of a spatio-temporally interpolated attribute set for every single minute such as “identification number, date, time, position, gender, age, address, occupation, purpose and traffic means” on the basis of public investigations. By utilizing the databases, it would become possible to predict when and where people will be encountered, even if the sensing and the communication systems are extremely degraded. In this article, we propose some statistical learning methods to predict the human appearance in any spatio-temporal points.

Key words : Risk prediction, People flow, Spatio-temporal trajectory, Pedestrian forecast, Confidence, Data assimilation

### 1. はじめに

交通安全における危険予知とは事故発生につながる様々な要因を未然に検出し、ドライバや歩行者の事故回避行動が極力容易かつ円滑になることを目指すものである。従来、これは過去の事故発生事例をもとに人間がトレーニングを行うことで実践されてきた。しかし、その実践は必ずしも保障されない。そこで近年、多種多様なセンシング機構を用いて危険を回避するシステムが開発されようとしている。これらは車室内要因の解析と車室外要因の解析の2つに大別できる (Fig. 1)。中でも最重要とされてきたのが車室内のヒューマンエラーの検出であるが、いまだなお未解決の技術課題を多く抱えている。

一方で、事故発生に至るプロセスを事故発生報告書などから考察すると、最終的に車室内ヒューマンエラーが直接原因とされていても、その背後では実は複数の車室外要因が複合して回避困難な状況を作り出しているケースが少なくない。そこで、本稿では車室外要因に注目し、特に事故発生に直接関連する「人の流れ」に焦点を当てて危険予知システムを提案する。

### 2. 関連動向

従来、車室外要因に注目した危険予知システムとはドライバから見て数秒以内の事象を予測するものであり、自車の動きはほぼ運動方程式に従うと仮定していた<sup>1)</sup>。その条件下で車両や歩行者の動きを予測するため、センシング性能は100%近い認識率が前提となっ

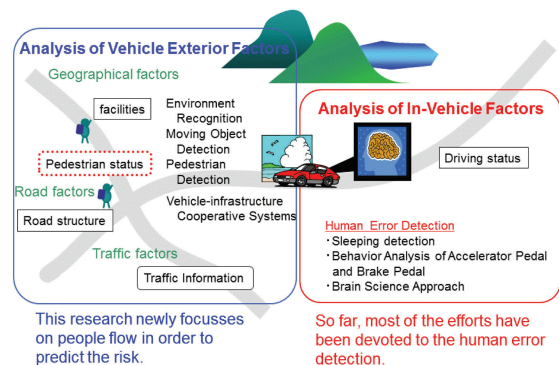


Fig. 1 Overview of risk prediction

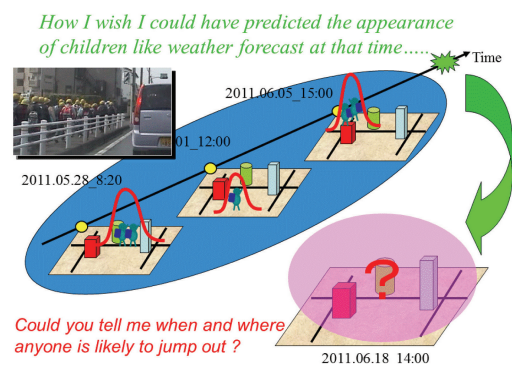


Fig. 2 Concept of pedestrian forecast.

ている。ところが現状の車外環境認識技術は高速走行であるほど認識率が劣化し、遠方や隠れのある対象物では更に認識は困難となる。従って車両単独では、数秒以内であっても死角から出現する歩行者や隠れ・不鮮明のある画像内の歩行者、数百メートル以上先の歩行者、更には交差点の右左折を介した先の交通事象に

\*2013年7月22日 原稿受理

関しては全く対処不能であった。

これに対し、近年ではインフラ協調やプローブカーにおいて無線通信を利用することで自車周辺ではわからないような死角あるいは少し先の交通事象が把握可能になりつつある。しかし、これらは必ずしも安定して利用できるわけではないため、インフラが未整備であるエリアやプローブカーの通過台数が極めて少ないエリアでは危険予知は期待できない。また、無線通信の瞬時の性能劣化も安定した危険予知の妨げとなる。

Sasakiらはセンシング系と通信系を連携させ、歩行者の出現を天気予報のように予報するシステムを提案した (Fig. 2)<sup>2)3)</sup>。ここではまず、車載カメラや定点カメラ、携帯電話などから得た歩行者の発生頻度に関する情報をセンターやカーナビの記憶装置に集積する。次にその時空間分布を学習して、想定する時間帯に所定の対象区間内で出現する歩行者の頻度を予測する。

Sasakiらの危険予知の対象を時間軸で3段階に分け、成立要件、判断要因および応用形態をまとめるとTable 1のようになる。“ちょっと先”と“だいふ先”は対応する未来に対する予測の恩恵のみならず、リアルタイム時の精度向上という重要な役割もある。すなわち、収集すべき情報の取得可能性や演算時間の猶予から考えて、なるべく早い段階から予知動作を行っておくことが最終的にリアルタイム時の危険予知を安定化させるであろうことが推察される。この中で特に重要な判断要因である「人の流れ」に関してSasakiらはまだ時系列の特徴を学習するには至っていない上に、人の移動目的や職業、年齢、性別、交通手段などの歩行者属性に関するデータの利用も行っていなかった。

予測モデルという観点では、ニューヨークを対象として開発されたNYBPM<sup>4)</sup>は交通網や職業、年齢、移動目的に関する膨大な計測データに基づいて時刻、曜日、季節の変化までも予測できるように設計されている。だが、汎用性や交差点レベルのミクロな時空間分解能は期待できず、更新や保守も多大なコストを要する。

他方、応用分野では近年、欧米を中心としてLDM (Local Dynamic Map) という地図情報システムが提案されている<sup>5)</sup>。この中で、動的に歩行者や車両の動きを取り入れていこうというコンセプトが提案されており、本研究でめざす危険予知を実装可能なシステムが空間情報科学の視点でまとめられようとしている。

以上の動向を踏まえて、本稿では過去の人の流れのデータや走行予定経路周辺のセンシングデータを利用

Table 1 Target of our research

	Target Time of Prediction =>	Conventional	Our Research	
		Real time (≦10 sec)	Soon (≦30 min)	Future (≦1 year)
Technical Requirements	Sensing	recognition rate is almost 100%	multi-point observation, recognition rate ≧ 70%	
	Communication	ultra hi-speed, ultra reliability	hi-speed, hi-reliability	
Judgment Factors	Surrounding Vehicles	velocity	type, number, velocity, motion	
	Geographical Factors	?	facilities, natural geographical shape	
	Road Structure	gradient, curvature rate	gradient, curvature rate, branch, road width, lane, road network	
	City Structure	?	sight, scene, skyscraper, multi-level crossing	
	Human Attributes	location	date and time, place, age, gender, job, purpose, address, traffic means	=> <b>People Flow</b>
Application	Cruise Control	speed control	drive plan, route plan	
	Information Assist	warning, display	caution, forecast	
	Control	control of body and equipments	improvement of accuracy when real time	

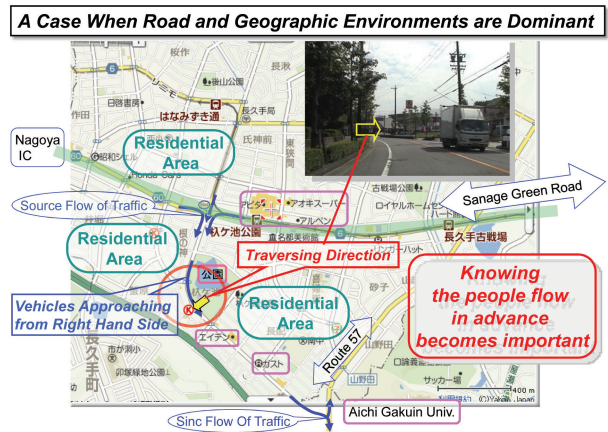


Fig. 3 Risk occurrence caused by the exterior factors.

することにより、センシングや通信が劣悪の場合でも、ちょっと先の歩行者の出現を予測することが可能なシステムを提案する<sup>6)</sup>。特に、走行経路上で遭遇する歩行者の数と属性を予測し、危険予知につなげる。

### 3. 危険度と人の流れ

#### 3.1 車室外要因による危険の発生

車室外要因による危険発生の一例をFig. 3に示す。ここでは住宅街に囲まれた公園に面した凸形状の道路が2つの幹線道路を接続し、駅、ショッピングセンター、大学、レストランを結ぶ。このため図中丸枠内は比較的交通量が多い上に、公園側から道路を横断して向かいのコンビニに行く(矢印方向)際に右側の接近車両を検知しづらい。また、ドライバ側から見ても歩行者を未然に検出することは困難である。このように、人の流れと道路環境や集客施設との関係が危険の潜在的要因でありながら、事故集計時点でドライバ側のヒューマンエラーと処理されるケースが少なくない。

### 3.2 人の流れ

人の流れデータとは、公的調査で得られた「識別番号、日時、位置、性別、年齢、住所、職業、目的、交通手段」を1分間隔で時空間内挿した時系列データである。これは、1998年東京を皮切りに全国主要都市に拡大され、近年では海外にも展開されている。現在、東京大学空間情報科学研究センターではこの人の流れデータのデータベースを公開しており、東京大学の提供するWeb APIによって検索できる<sup>7)8)9)10)</sup>。例えば1998年の東京圏では約72万人、2001年の中京圏では約26万人を対象として公的に調査されたパーソントリップデータをもとに人の流れデータが作成されている。ここで得られる位置情報の時系列と共に記載される各人の属性(年齢、性別、職業、目的地、利用交通機関など)も産業的観点において非常に有用である。

しかしアンケートによる大規模調査は数年に一度、2日程度しか実施できないため、そこで得られるデータだけでは交通機関や道路事情、都市建造物の変容などを考慮した人の流れまでも予測することは困難である。そのため、主として都市計画や交通機関の整備、消費者行動予測といったマクロ的な応用に用いられ、危険予知のようなミクロ的な応用には用いられなかった。

一方で近年、携帯電話やプローブカーにより、リアルタイムに近い人の流れデータが自動収集可能になりつつある。しかし、プライバシーやセンシング精度、調査範囲、データ密度などに課題が残されている。

そこで、人の流れデータで得られる予測モデルをリアルタイムのスパースデータに同化させる研究が急速に注目されている。本稿ではその準備段階として人の流れデータのみから予測モデルを構築し、想定する時空間上で算出した予測値を、人の流れデータや現地計測データと比較することでその有効性を評価する。

### 3.3 人の移動経路と時空間軌道

単純に考えれば、走行予定経路を表す時空間軌道の周辺で人出現頻度が高いほど危険である。しかし、実際には単なる時空間距離以外に次のような要因がある。

- 1) 信号機、ガードレール、陸橋、高速道路など
- 2) ビル、マンション、オフィス、壁、塀など
- 3) 高架、立体交差、地下道、集客施設など
- 4) 周辺の道路状況や視界環境

これらの要因により、人出現頻度だけでは例えば以下のような場合の危険度を正しく表現できない。

- ① 歩行者は少ないが想定外の飛び出しがある

- ② 距離は近いが、2) に歩行者が居る
- ③ 歩行者が侵入できない場所である
- ④ 横断歩道や信号機など交通施設が充実している

このような事例を経験と類推により列挙することも一つの方策であるが、想定外のケースまで網羅することは困難である。そこで、本稿ではそれらの上位概念として認知と回避に着目する。

### 3.4 認知と回避に注目した危険度

運転者が想定しないような人の出現を「認知困難」と解釈すれば、それらは以下の要因に起因する。

- A) 想定困難な人出現特性
  - 1) 出現統計が運転者にとって未知
  - 2) 出現統計のモデリングが困難(住宅街など)
- B) 認知困難な周囲環境(死角、隠れなど)
- C) 認知困難または予想困難な歩行者挙動

ここで、認知困難という状況を生み出すのは、「認知対象側(歩行者など)」と「認知する側(ドライバ)」の両方が作用した結果と考えられる。しかし、実際は認知困難の大半が運転者側のヒューマンエラーとして処理される。ところが現実には、仮にドライバが完璧であっても回避できない状況が存在する。例えば直前の子供の飛び出しなどがそれに相当する。そこで、危険度 $R$ を人との遭遇確率 $R_0$ と衝突確率 $R_1$ の積として定義する：

$$R = R_0 R_1 \quad (1)$$

いま、 $R_1$ を人( $P$ )、車( $I$ )、ドライバ( $D$ )の各々で認知( $P$ )と回避( $A$ )の可能性を考慮したモデルで表すと、

$$R_1 = 1 - w_{safe} (p_{P(P,P)} p_{A(P,P)} \cdot p_{P(V,P)} p_{A(V,P)} \cdot p_{P(D,P)} p_{A(D,P)})^T \quad (2)$$

となる。但し、 $p_{Z(X,Y)}$ は $X$ が $Y$ を $Z$ できる確率である。また、 $w_{safe}$ は正規化荷重係数ベクトルであり、第4成分はPVD以外の状況要因(環境や施設など)で安全が確保できる確率を表す。

$R_1$ の定量化についてはセンシング、行動モデル、経路推定、地理・道路・施設要因などの考慮が必要である。これらは今後の研究課題とし、本稿ではまず人との遭遇確率 $R_0$ に対応する人出現頻度を予測する。

### 3.5 多元的な規定

人の経路を規定する要因としてはまず人属性(性別、年齢、住所、職業、目的、交通手段)が考えられる。特に、職業(学生、会社員、主婦など)は日常的な移動経路の推定において必要な基本行動を規定する。

次に考えられる要因は地域のクラス（住宅街，駅前，商店街など）である。すなわち，異なる地域でも同じクラスであれば共通して使える特性があると仮定する。これが有効ならばある地域で獲得した予測特性を他の地域にも適用でき，学習量の不足を補うことができる。

Fig. 4は東京圏（98年）の主要駅周辺1km四方に存在する通勤・通学者の数の時間変化を示す。各エリアの時間変化パターンは，駅を基点としてクラス分類できる可能性があることが容易に推察される。

人の流れデータは時空間軌道として解釈でき，Fig. 5のように可視化される。この人の時空間軌道群と想定する走行予定経路との間の時空間距離があるしきい値以下となるリンクを抽出するとFig. 6ようになる。過去の人の流れをそのまま予測特性として利用するならばこれが最も簡単な予測結果となる。しかし，データ取得の日付，曜日，季節，年の違いを考慮するためには予測関数を定義し，十分な規模の人の流れデータを学習させる必要がある。




Fig. 4 Temporal changes of the number of commuting people at the major local spots in Tokyo in 1998

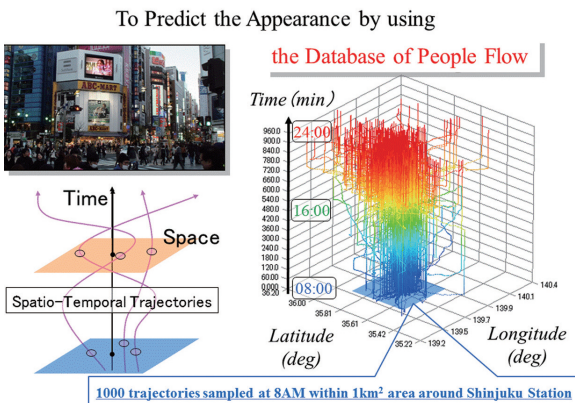


Fig. 5 Database of spatio-temporal trajectories.

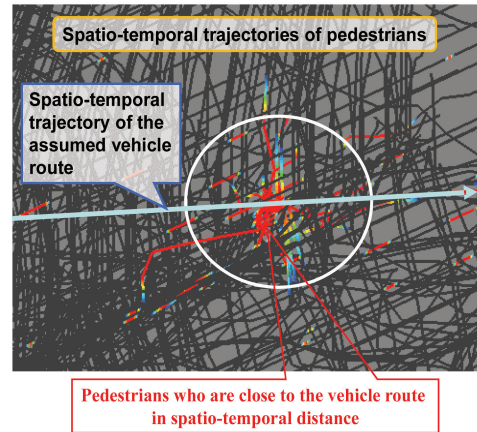


Fig. 6 Spatio-temporal trajectories and risk degree.

## 4. 人の流れデータに基づく予測

### 4.1 時空間軌道の獲得

人の流れデータを学習するには，人の識別番号PIDを選択する必要がある。ここでは，ある時刻 $T_{sample}$ に所定のエリア中心Oから1km四方の空間範囲に存在するPIDをリストアップする。次に，各PIDの位置座標（経度と緯度）の時系列をエリア中心からの差分値で表現する。これが時空間軌道であり， $2T$ 次元の行ベクトル $\mathbf{X}_k$  ( $k=1, \dots, K$ )で表す。このとき行方向は $t.u.$  (time unitの略)を単位とする時間軸を表し， $T$ 列の差分経度情報と $T$ 列の差分緯度情報を1行に並べる：

$$\mathbf{X}_k = (\mathbf{X}_k^{lon} \mathbf{X}_k^{lat}) = (X_{k,1}^{lon}, \dots, X_{k,T}^{lon}, X_{k,1}^{lat}, \dots, X_{k,T}^{lat}) \quad (k=1, \dots, K) \quad (3)$$

但し， $1[t.u.] = md[\text{min}]$ とする。従って状態行列 $X$  ( $K \times 2T$ )は次式で表される：

$$X = [\mathbf{X}_1^T \mathbf{X}_2^T \dots \mathbf{X}_K^T]^T \quad (4)$$

今回， $T_{sample} = 480[\text{min}]$ ， $T = 480[t.u.]$ ， $md = 2$ とした。

### 4.2 学習

人の流れデータに含まれる人属性は数量化理論に基づき，[年齢，性別，職業，目的，交通手段]の各項目値の合計で約70次元の2値ベクトルを構成する（01年中京圏の場合）。この人属性が人出現の確信度を構成すると仮定し，その確信度が時間と位置を説明変数として推定されるというモデルを考える。すなわち，確信度行列 $Y$  ( $K \times L$ )は一般的に

$$Y = f(X) \quad (5)$$

と表現され，特に $f$ を線形回帰で表現すれば

$$Y = XB \quad (6)$$

となる。但し $B$ は回帰係数行列 ( $2T \times L$ )である。

この $B$ を最小2乗推定で求めると、

$$B = (X^T X)^{-1} X^T Y \quad (7)$$

となる。これがエリア中心周辺を通る $K$ 人の時空間軌道群 $X$ を学習して得た予測特性となる。

### 4.3 予測


想定する新たな時空間軌道群 $X_{new}$ における人出現頻度 $Y_{new}$ を予測する基本式は次のようになる：

$$Y_{new} = X_{new} B \quad (8)$$


ここで、 $X_{new}$ は走行経路、走行速度、人確信度の積分範囲などの予測条件により変化する。いま、予測対象とする時空間点 $Q_m$ を通過する $K_m$ 個の移動経路群を $W_m$ とする。 $Q_m$ における人出現頻度の推定値は $W_m$ 中の各経路について時刻 $T_{m1}$ から $T_{m2}$ の時間範囲で $H$ 次元の人属性の確信度 $c(t, x)$ を積算することで算出される。 $Q_m$ で遭遇する人の確信度は次式で算出できる：

$$\begin{aligned} \tilde{C}_{ALL}(m, x) &= \sum_{h=1}^H \tilde{C}_h(m, x) \\ \tilde{C}(m, x) &= \int_{t_m - \Delta T_m}^{t_m + \Delta T_m} \int_{x \in W_m} c(t, x) dx dt \end{aligned} \quad (9)$$

ところが (6) 式に基づけば $W_m$ に属する軌道は $2T$ 次元ベクトルであるにもかかわらず、予測時には現在までのデータしか利用できない。過去の人の流れデータを利用するとしても $T[t.u.]$ にわたるトラッキングが必要となる。そこで、①道路情報と人の流れデータから



(a) Eight directional model of human trajectory.



(b) Prediction considering the difference of arrival time.

Fig. 7 Model of prediction.

最尤経路を推定する、②経路モデルを設定する、などの方策が考えられる。本稿では②において以下の8方向モデルを用いる。

いま、 $Q_m$ における車両進行方向に対して等間隔で8方向の傾き角 $\theta^{(l)}$  ( $l=0, \dots, 7$ )の直線経路を想定する (Fig. 7)。その空間範囲は時間範囲を $\pm 4$ 分 (この中で離散時間点を2分間隔で設定) とし、人の移動速度は2分で0.001度 (時速約2.7km) とする。これにより (9) 式を離散化すると、

$$\tilde{C}(m, x) = \sum_{k=-2}^2 \frac{1}{\sqrt{2\pi}\sigma_{Vtime}} \exp\left(-\frac{2k^2}{\sigma_{Vtime}}\right) C(m+2k, x) \quad (10)$$

となる。しかし依然として $2T$ 次元すべてを用意することは困難である。そこで、 $B$ において $W_m$ に対応する時刻 $m$ 周辺の次元のみを有効成分とし、他の成分を零とする $B_m$ を作用させることで近似解を求める。(10) 式の各次元の人属性について次式を計算する：

$$\begin{cases} C(m, x) = B_m^T x + \sum_{l=0}^3 \left\{ b_{1,m-2}^{(l)} \left(1 + \frac{g_{2,m+2}^{(l)}}{g_{1,m-2}^{(l)}}\right) + b_{2,m-2}^{(l)} \left(1 + \frac{g_{1,m+2}^{(l)}}{g_{2,m-2}^{(l)}}\right) \right\} \\ b_{j,m-2}^{(l)} = \frac{B_m^T x}{8\sqrt{2\pi}\sigma_{Ptime}}, g_{j,m}^{(l)} = B_m^T x_{j,m}^{(l)} \\ x_{j,m}^{(l)} = x - \cos(j\pi)\Delta x [\cos\theta^{(l)}, \sin\theta^{(l)}] \\ \Delta x = \sigma_{Ptime} [\text{min}] \times v_p [m / \text{min}] \end{cases} \quad (11)$$

なお、今回、 $\sigma_{Ptime}=2, \sigma_{Vtime}=2$ とした。

### 4.4 学習時刻のサンプリング

(7) 式の  $(X^T X)^{-1}$  の正則化条件  $K \geq 2T$  に対応する 960 人以上のデータがある時刻に 1km 四方のエリアで人の流れデータから収集することは、よほどの密集地でないかぎり困難である。そこで、 $K$  の下限値を低く抑えるために以下の方針に基づき、サンプリング密度  $\rho$  で学習時刻をサンプリングすることを考える。

- A) 走行時間帯では  $\rho$  を高くする
- B) 走行時間帯外は  $\rho$  を低くするが極力零は避ける
- C) 移動する人が多い時間帯やその前後の変化点 (駅の待ち時間など) で  $\rho$  を上げる
- D) 長時間滞留する箇所では  $\rho$  を下げる

$\rho$  の有効な設定パターンはエリア特性に依存する。

### 4.5 予測特性の切り替え

予測における空間分解能を上げるため、(7) 式の予測特性 $B$ を走行経路中のサブエリアごとに切り替えることを考える。このためにはあらかじめ小規模のサブエリアごとに学習を行っておく。

いま、走行経路上のある時間区間 $[m_{start}, m_{goal}]$ を上記

サブエリア  $A_i$  に対応させれば、人の流れデータから得る走行経路上の擬似真値  $g_{i,m}$  と人出現度の予測値  $c_{i,m}$  の区間内総和はそれぞれ次のようになる：

$$G_i = \sum_{m=m_{start}}^{m_{goal}} g_{i,m}, \quad C_i = \sum_{m=m_{start}}^{m_{goal}} c_{i,m} \quad (12)$$

走行経路に沿って隣接するサブエリア  $A_i$  と  $A_{i+1}$  について個別の回帰計算によりそれぞれ学習特性  $B_i$  と  $B_{i+1}$  が求まるものとする、 $C_i$  と  $G_i$  の間には  $A_i$  に依存する正規化係数  $\gamma_i$  が存在し、次式が仮定できる：

$$\sum_{m=m_{start}}^{m_{goal}} \gamma_i c_i(m) = \gamma_i \sum_{m=m_{start}}^{m_{goal}} c_i(m) = \gamma_i C_i = G_i \quad (13)$$

よって、区間総和が  $G_i$  に等しくなるように正規化した確信度は次式で表される：

$$\hat{c}_i = \gamma_i c_i = \frac{G_i}{C_i} c_i \quad (14)$$

#### 4.6 予測結果の評価指標

予測した遭遇確率  $R_0$  と Ground Truth (以下、GT) との間で時空間形状に関する類似度を時系列相関で算出し、第1の評価指標とする。一方で危険予知の目的に立ち返れば、人の出現頻度よりも出現の有無を表す論理値に注目することも重要である<sup>3)</sup>。そこで、走行経路上の各時空間点での論理的一致度の平均値を論理予測率と呼び、第2の評価指標とする。

## 5. 実験と考察

### 5.1 中京圏 (2001年)

2001年10月に中京圏26万人を対象として調査した結果をもとに作成された人の流れデータベース01CHUを用い、Fig. 8の愛知県長久手市のエリアについて予測実験を行った。一方で予測結果をより最新のデータと比較するため、図中の12スポットについては2011年12月5日に交通量の現地計測を行った (Fig. 9)<sup>6)</sup>。具体的には各スポットで {道路の上下線×進行方向} の4方



Fig. 8 Test area and the assumed vehicle route.

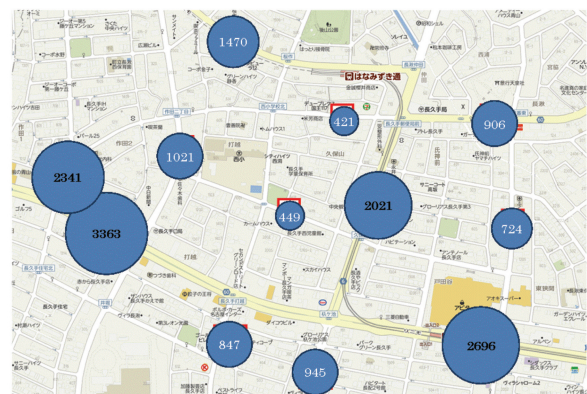


Fig. 9 Total traffic volume over 12 hours for pedestrians and bicycles

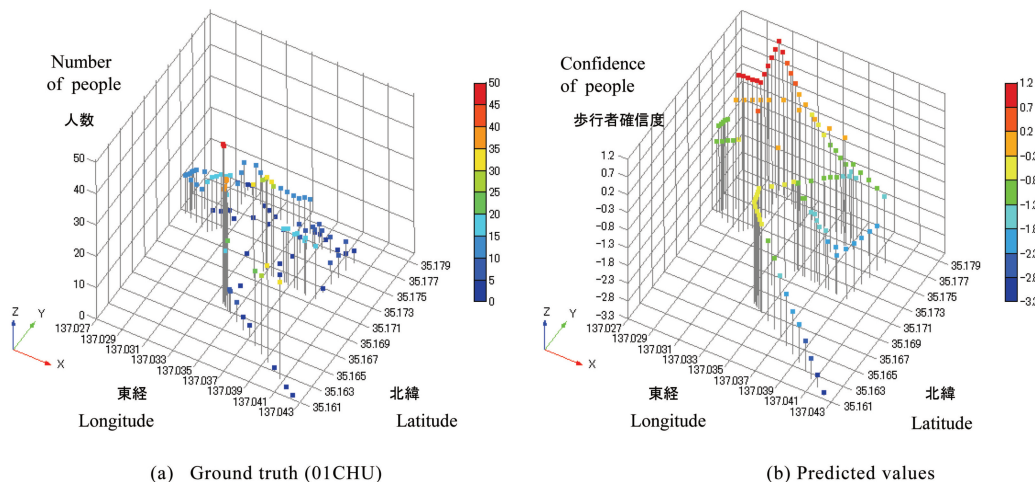


Fig. 10 Experimental results of prediction on the assumed vehicle route in Nagakute.

向について歩行者と自転車を7時から21時の14時間にわたり15分単位で計測し、性別と年代（学生・一般・高齢者）の情報を付与した。

01CHUで学習対象とする人のサンプル時刻は午前8時0分とし、上記12スポットを中心に1km四方の空間範囲でPIDリストを作成した。次に、各リストに対応する時空間軌道群のデータ行列 $X$ と人属性による確信度行列 $Y$ から(7)式に従って回帰係数 $B$ を算出した。但し、 $\rho=30$  [sample/hour] (固定)とし、共分散行列 $X^T X$ に微小な対角成分を付加することで正則化した。Fig. 8中の矢印で示した走行経路に沿って移動時間200分で各リンク毎に等速直線運動を仮定し、2分間隔100個の離散時空間点について人確信度を算出する。

走行予定経路上の時空間点を中心として $L[m]$ 四方の矩形領域内に存在する人のPIDを人の流れデータから検索し、人数を計数することで人確信度のGT値とした。今回、 $L=250$ と設定した。

Fig. 10(a)(b)は走行開始時刻が午前8時の場合の出現人数の真値（01CHUから算出）と人確信度の予測値である。予測特性は長久手市杖ヶ池エリアで獲得した回帰係数行列に固定した。このような真値と予測値の比較を様々な条件で行い、最適な予測モデルを模索する。

Fig. 11は同じ走行経路で走行開始時刻（8時から22時までの2時間毎）と学習スポット（12か所）を変化させた場合の予測率（時系列相関と論理予測率）を示す。比較のための真値は01CHUから算出した。時系列相関の最高値は0.602であり、走行経路のほぼ中心に位置するスポット番号6で学習した予測特性で得られる。走行開始時刻による変動は比較的少なかった。論理予測率は駅周辺のスポットで高く（最高値0.89）、住宅地周辺では低い。小学校周辺では通学時間帯で高い値を示すが、その他の時間帯では低い。概して人通りが少ない時空間では予測率が低くなる傾向がある。

Fig. 12に定点予測（スポット番号11）と現地計測との比較結果を示す。最高値は時系列相関0.85、論理予測率0.96でいずれも経路上の予測（Fig. 11）を上回った。しかし時系列相関での時刻に対する安定性は低い。2001年10月と2011年12月との間の街構造の変化や小学校の一斉下校時刻の突発的変化、および高校生の試験時期との重なりなどが原因と考えられる。

### 5.2 東京圏（2008年）

2008年に東京圏60万人を対象として調査した結果から作成された人の流れデータベース08TKYを用い、田園都市線沿線（永田町～中央林間）に成瀬を加えた32

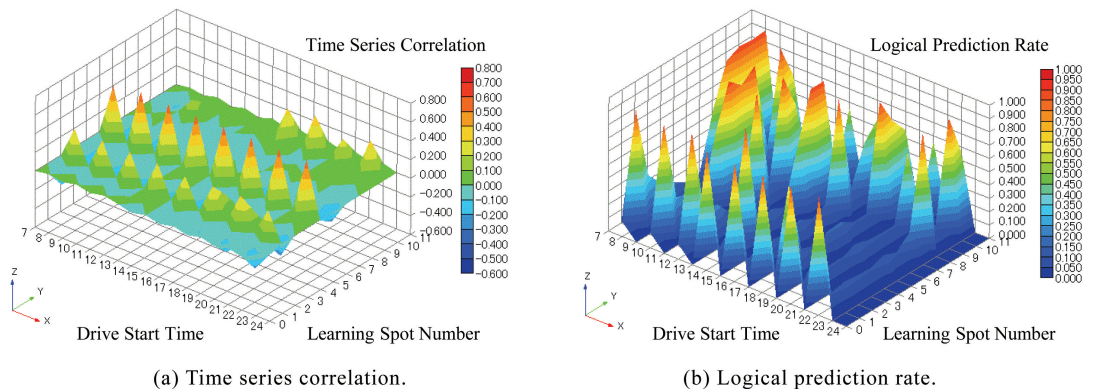


Fig. 11 Evaluation of the predicted results on the vehicle route within 01CHU.

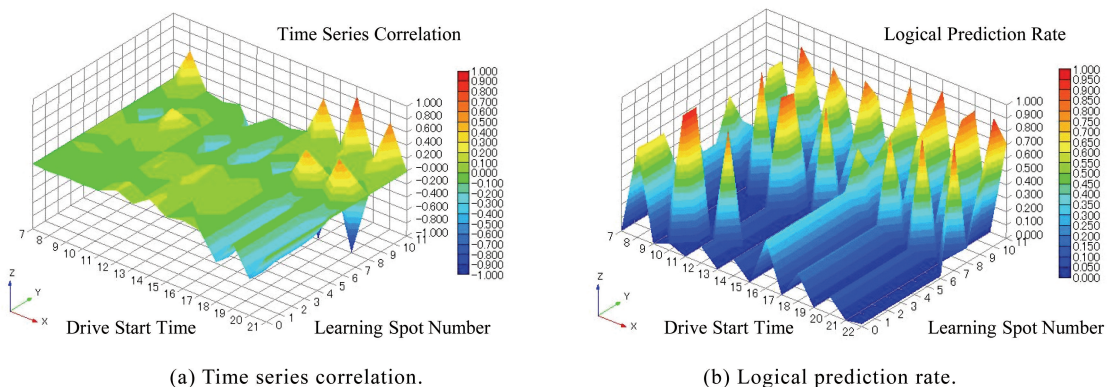


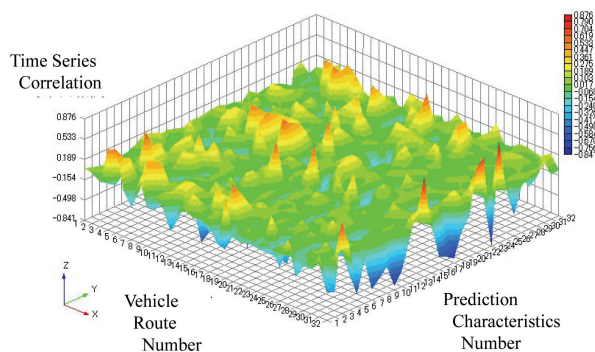
Fig. 12 Evaluation by the comparison with recent measured values on a fixed point (01CHU/spot No.11).

駅を中心とするエリアで実験を行った。

まず、午前8時0分に各駅 1km四方に存在する人の時空間軌道を学習し、予測の基本特性を獲得した。

次に、各駅を囲むエリアで仮想的な走行経路を設定し、32個の仮想走行経路に沿った走行時刻におけるGT値を08TKYの人の流れデータから獲得した。ここで、つくし野エリアを対象として $L[m]$ を変化させてGT値と予測値の時系列相関が $L=250\sim 300$ で目標値0.7[3]をクリアすることを確認し、中京圏と同様に $L=250$ をGT値の算出に用いる空間範囲とした。

以上の32個の走行経路と32個の予測特性で構成される合計 $32\times 32$ 個の交叉予測実験を計算機上でを行い、時系列相関と論理予測率を算出した (Fig. 13)。時系列相関の最高値は0.876であり、交差特性のピーク値は対角成分 (自己交差) 以外にも数多く出ている。これは、異なるエリアにも同じ予測特性が適用でき、エリアクラスを形成する可能性があることを示唆している。論理予測率に関しては走行経路による変化よりも予測特性による変化の方が大きい。予測特性の学習スポットが都心から離れるに従い、大域的には減少する傾向にある。これは長久手と同様に、人通りが少なくなるにつれて予測特性が不安定になるためと推察される。



(a) Time series correlation.

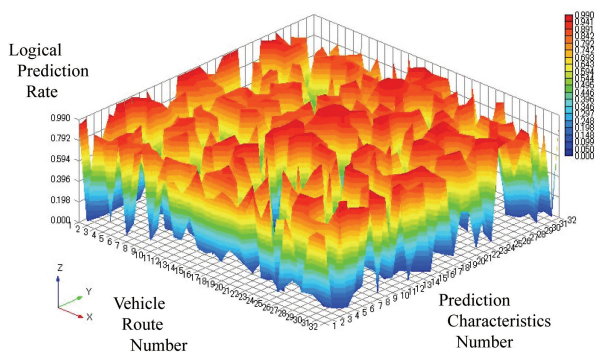


Fig. 13 Results of cross predictions on 08TKY.

### 5.3 考察

以上によれば、予測率が低下する主要原因の一つは出現頻度が低いエリア特性にある。これを解決するには少なくとも2つの方策が考えられる。第1の方策は地理、道路環境、周辺施設、人の属性や車の特性などを多角的に予測計算に組み入れることである<sup>11)</sup>。第2の方策は、走行経路上の各時空間点に近接する人の行動モデルと移動経路の候補を、今回の8方向モデルよりも高い信頼度で推定することである。この有力手法としてはパーティクルフィルタで現地観測データを人の流れデータに同化させる試み<sup>12)</sup>があり、長久手エリアを対象として経路推定の実験が進められている。

### 6. おわりに

走行経路上の危険度を予測するシステムを想定し、過去の人の流れデータから人の出現を予測する方式を提案した。今後は地理、道路環境、周辺施設、人の属性や車の特性なども考慮した多角的手法により予測率を改善していきたい。また、データ同化に基づく最適な経路推定結果を導入し、8方向モデルとの比較評価を進める予定である。一方で、交叉予測実験のさらなる解析と時空間軌道のパターン化を踏まえてエリアクラスの生成を行い、学習の効率化をめざす。

#### <参考文献>

- 1) 大濱, 國分, 高橋, 内藤, “運転者の危険感受性を考慮した走行環境の階層型危険度推定法”, 第7回情報科学技術フォーラム(FIT2008)講演論文集7(2), 369-372, 2008-08-20.
- 2) M. Sasaki, K. Muto, K. Sasaki, “Estimation of Driving Safety from On-Board Captured Scene by using Probe Image Database”, *ITST2007*, June 2007.
- 3) 笹木, “人の時空間分布を予報するシステム—実現可能性の検討—”, 信学技報ITS2010-76 (2011-03).
- 4) <http://www.nymtc.org/project/BPM/nybpmindex.html>
- 5) [www.drm.jp/research/pdf/20100630\\_drmseminar2.pdf](http://www.drm.jp/research/pdf/20100630_drmseminar2.pdf)
- 6) 笹木, 薄井, 中村, 関本, “人の流れに基づく危険予知システムに関する一提案”, 信学技報ITS2011-57 (2012-03).
- 7) 関本義秀, 菊地英一, 佐藤圭一, 秋山祐樹, “パーソントリップデータを活用した人の流れの時空間的な詳細化”, 第28回交通工学研究発表会論文集, pp.197-200, 2008.



- 8) Yoshihide Sekimoto, Ryosuke Shibasaki, Hiroshi Kanasugi, Tomotaka Usui, Yasunobu Shimazaki, "PFlow: Reconstructing People Flow Recycling Large-Scale Social Survey Data", *PERVASIVE computing*, OCTOBER-DECEMBER 2011, p.27-35.
- 9) 関本義秀, Teerayut Horanout, 柴崎亮介, "携帯電話を活用した人々の流動解析技術の潮流", 情報処理 Vol.52 No.12 Dec.2011, pp.1522-1530.
- 10) <http://pflow.csis.u-tokyo.ac.jp/>
- 11) Thaned Satiennam, "A Study on pedestrian accidents and investigation of pedestrian's unsafe conditions in Khon Kaen municipality, Thailand", *Journal of the Eastern Asia Society for Transportation Studies*, Vol.5, October 2003.
- 12) Toshikazu Nakamura, Yoshihide Sekimoto, Ryosuke Shibasaki, "Estimation of People Flow in a City Using Particle Filter with Person Trip Survey, Building Data and Traffic Count", *CUPUM 2013*, July 2013.

---

<著者>



菅木 美樹男  
(ささき みきお)  
基礎研究所 先端研究  
危険予知, 空間情報科学, 映像  
メディア理解の研究開発に従事.



関本 義秀  
(せきもと よしひで)  
東京大学生産技術研究所 准教授  
博士(工学) 2008年から「人の  
流れプロジェクト」主宰. 2011  
年6月「次世代社会基盤情報」寄  
付研究部門を立ち上げて活動中.