

# プローブデータを用いた交通混雑状態のベイズ更新モデル\*

## Bayesian Update Model of Traffic Congestion Using Probe Data\*

森田英輔\*\*・朝倉康夫\*\*\*

By Eisuke MORITA\*\*・Yasuo ASAKURA\*\*\*

### 1. 背景と目的

プローブ技術による移動体観測データの特徴として、移動主体の連続的な観測に基づいて、その時空間移動軌跡を詳細に捉えられるということがある。このような特徴を活かした旅行時間情報の作成<sup>1)</sup>、<sup>2)</sup>や、交通調査システムの構築<sup>3)</sup>に関するプローブ研究が盛んに行われている。

一方、プローブ車両による移動体観測も含めて、検知器による定点観測やビデオ画像による空間観測、さらにはアンケート調査など、これまでに様々な交通調査手法が考えられてきた。その中で、調査対象に合わせてこれらのデータを効果的に組み合わせ、情報を更新していくことが重要となってくると思われる。

本研究では、ベイズ統計<sup>4)</sup>の考え方をを用いて、交通状態に関する何らかの先験情報が存在する単路区間において、プローブ観測を行うことによって、その単路区間の交通状態をより正確に把握することを目的としたベイズ更新モデルの構築を試みる。また、このモデルの精度を検証するために、実証分析を行う。

### 2. ベイズ更新モデル

ベイズ統計では、未知母数の事前分布と観測データに基づく母数の尤度とをベイズの定理で結合することにより、母数の事後分布が導出される。すなわち、事前確率と尤度から事後確率を算出するモデルである。これを交通状態の推定に適用すると、①定点観測などによる先験情報から事前確率を求める一方で、②プローブデータから尤度を求め、③それらを用いてベイズ更新を行うことにより、信頼性の高い事後確率を得ることができる。

モデルを構築していく上での前提条件として、以下の3つの仮定をおく。

仮定1: 「対象とする道路は単路区間である。」

仮定2: 「事前確率は、確定的ではない。」

仮定3: 「プローブデータは、誤差が極めて少ない。」

仮定2に関して、先験情報が1日分しか無い場合にも、

\*キーワード: 交通情報, プローブ, ベイズ統計

\*\*学生員, 神戸大学大学院自然科学研究科

(神戸市灘区六甲台町1-1, TEL078-881-1212)

\*\*\*正員, 工博, 神戸大学大学院自然科学研究科

何年分も蓄積されているような場合にも、以下に示すモデルの適用は理論的には可能である。しかし、前者の場合には事前確率が確定的に与えられることとなり、結果として意味の無い output が出てきてしまう可能性がある。そこで、事前確率はある程度の分布を持つという前提の下、モデルの構築を行うものとした。

#### (1) 変数の定義

##### a) 時空間メッシュ

時間幅  $\Delta t$ 、空間幅  $\Delta s$  で時空間をメッシュに区切り、横軸を  $t$ 、縦軸を  $s$  と離散的に定義する。これを、時空間メッシュと呼ぶ。 $\Delta t$ 、 $\Delta s$  は任意に定めることができる。以下に各変数の定義を示す。(図1)

$t$ : 時間帯 ( $t=1,2,\dots,T$ )

$s$ : リンク ( $s=1,2,\dots,S$ )

$(t,s)$ :  $t$ かつ $s$ に対応する時空間メッシュ




図1. 時空間メッシュ

##### b) 交通状態

各時空間メッシュにおける交通状態を離散的に表現する。交通状態を分類するカテゴリーの数は、任意に定めることができる。以下に、交通状態  $C(t,s)$  の定義を式で示す。

$$C(t,s)=j \quad (2.1)$$

$j$ :  $(t,s)$ の交通状態が分類されるカテゴリー ( $j=0,1,\dots,J$ )

各時空間メッシュの交通状態の組み合わせとして、対象とする道路全体の交通状態が表現される。これを、仮説  $H_i$  と定義する。理論的には、カテゴリー数が  $(J+1)$ 、時空間メッシュの数が  $(TS)$  となるので、

$$i=1,2,\dots,(J+1)^{TS} \quad (2.2)$$

となる。

交通状態の判別は、時空間メッシュ(t,s)に対応する区間速度や区間旅行時間に対して閾値を設定して行う。

### (2) 先験情報と事前確率

先験情報より仮説  $H_i$  の出現確率、すなわち事前確率  $P(H_i)$  を求める。

算出方法は、2通り考えられる。1つは、仮説  $H_i$  に着目したマクロな視点による方法である。先験情報の対象期間内に仮説  $H_i$  が出現した回数を数え上げ、その割合を求める方法である。一方、時空間メッシュ(t,s)に着目したミクロな視点による方法も考えられる。メッシュごとの交通状態の出現確率を求め、時空間メッシュ全体についてその同時確率を計算することにより、間接的に  $P(H_i)$  を求める。

先験情報の情報量が多い場合には、前者の算出方法を適用すべきである。これは、前者の方が交通現象全体を包括的に捉えており、メッシュ間の相関など様々な要素を内包していると考えられるからである。しかし、情報量が比較的少ない場合に前者を適用すると、候補となり得る仮説の数が極端に少なくなってしまう、事前確率の分布が極めて限定的になってしまう可能性がある。後者を適用すると、前者と比べて事前確率はなめらかな確率分布となる。よって、先験情報が少ない時には、後者を適用すべきだと考えることもできる。

先験情報としては、交通状態を判断できるものであればどのようなものでも適用可能である。検知器などの定点観測データ、事前に観測したプローブデータ、ドライバーの判断などのアンケートデータ、ビデオによる空間観測データなど、様々なものが利用できる。

### (3) プローブデータと尤度

プローブ車両を用いて、時空間メッシュ全体の一部について交通状態  $C(t,s)$  を観測したものを、プローブデータ  $D$  とする。プローブ車両によって直接観測できるのは、速度や旅行時間であり、このデータを用いて交通状態を判別する。

プローブデータ  $D$  を用いて、尤度を決定する。尤度  $L(H_i)$  は、仮説  $H_i$  の下で、観測データが  $D$  となる条件付き確率で定義されるので、以下の式のようになる。

$$L(H_i) = P(D|H_i) \quad (2.3)$$

本研究では、仮説  $H_i$  の中から、プローブデータ  $D$  に対してあり得ないと判断される組み合わせを除いて、残った仮説  $H_i$  のそれぞれに等確率を与えることにより、尤度を求めるものとした。尤度は式(2.3)からも明らかのように、観測データ  $D$  と密接に関連している。すなわち、プローブ車両を上手く走らせることによって尤度にピー

ク性を持たせることができると考えられる。

### (4) ベイズ更新

一般的なベイズ統計のモデル式を式(2.4)に示す。

$$P(H_i | D) = \frac{L(H_i)P(H_i)}{\sum_{i=1}^m L(H_i)P(H_i)} \quad (2.4)$$

式(2.4)に従ってベイズ更新を行い、事後確率  $P(H_i | D)$  を求める。

### (5) 例題

2×2 の時空間メッシュにおいて、ベイズ更新モデルの例を示す。交通状態は、「非渋滞」( $j=0$ )と「渋滞」( $j=1$ )の2段階で定義する。

$$T=2, S=2, J=1 \quad (2.5)$$

であるから、仮説  $H_i$  は  $2^4$ 通り考えられる。

まず、先験情報より事前確率を求める。以下の表1のように、各時空間メッシュにおける交通状態の出現確率が独立して与えられているとする。これを用いて同時確率を計算することにより、事前確率  $P(H_i)$  を算出する。

表1. 各メッシュにおける交通状態の出現確率

(t,s)	(1,1)	(1,2)	(2,1)	(2,2)
$P(C(t,s)=0)$	0.3	0.8	0.6	0.9
$P(C(t,s)=1)$	0.7	0.2	0.4	0.1

次にプローブ観測データより観測メッシュの交通状態を判別する。その結果として、

$$D : C(1,1)=1, C(1,2)=0$$

を得ることができたとする。(t,s) = (2,1)及び(2,2)のプローブ観測データは、存在しないものとする。このプローブ観測データ  $D$  を用いて、尤度  $L(H_i)$  を算出する。この例題では、表2に示すように、仮説  $H_2, H_7, H_8, H_{14}$  のみがあり得て、それぞれが等確率で発生するとしている。

最後に、事前確率  $P(H_i)$  ・尤度  $L(H_i)$  の値を用いてベイズ更新を行い、事後確率  $P(H_i | D)$  を算出する。仮説ごとに、事前確率・尤度・事後確率をまとめたものを表2に示す。また、ベイズ更新の効果を視覚的に表すために、仮説ごとに事前確率と事後確率を比較したものを図2に示す。

図2より、ベイズ更新を行うことにより、観測時の交通状態を表している可能性が高いと思われる仮説の事後確率を増加させることができた。事前確率の低い仮説については、プローブデータから判断される交通状態からみて起り得ないと考え、仮説の絞り込みができています。

## 3. 実証分析

本研究で構築したベイズ更新モデルの精度検証を行うために、阪神高速11号池田線上の4.0kpから3.0kpの区間を対象として実証分析を行う。まず、対象区間にお

表2. 計算結果

H <sub>i</sub>	C(1,1)	C(1,2)	C(2,1)	C(2,2)	P(H <sub>i</sub> )	L(H <sub>i</sub> )	P(H <sub>i</sub>   D)
H <sub>1</sub>	0	0	0	0	0.1296	0	0
H <sub>2</sub>	1	0	0	0	0.3024	0.25	0.54
H <sub>3</sub>	0	1	0	0	0.0324	0	0
H <sub>4</sub>	0	0	1	0	0.0864	0	0
H <sub>5</sub>	0	0	0	1	0.0144	0	0
H <sub>6</sub>	1	1	0	0	0.0756	0	0
H <sub>7</sub>	1	0	1	0	0.2016	0.25	0.36
H <sub>8</sub>	1	0	0	1	0.0336	0.25	0.06
H <sub>9</sub>	0	1	1	0	0.0216	0	0
H <sub>10</sub>	0	1	0	1	0.0036	0	0
H <sub>11</sub>	0	0	1	1	0.0096	0	0
H <sub>12</sub>	1	1	1	0	0.0504	0	0
H <sub>13</sub>	1	1	0	1	0.0084	0	0
H <sub>14</sub>	1	0	1	1	0.0224	0.25	0.04
H <sub>15</sub>	0	1	1	1	0.0024	0	0
H <sub>16</sub>	1	1	1	1	0.0056	0	0




図2. ベイズ更新の効果 (1)

ける過去1年間の検知器データを先験情報として利用し、事前確率を求める。次に、プローブデータを用いて尤度を計算し、ベイズ更新を行うことにより事後確率を求める。最後に、プローブ観測当日の感知器データによって、その日の真の交通状態を判別し、それをベイズ更新モデルによる計算結果と比較することで、モデルの精度について考察する。

(1) 使用データ概要

a) 検知器データ

- ・期間：2003年3月～2004年2月の平日 (238日間) 及び2001年1月25日 (木)
- ・時間帯：7:00～13:00
- ・データ項目：地点速度
- ・検知器数：5 (4.5kp, 4.1kp, 3.5kp, 3.0kp, 2.5kp)

b) プローブデータ

- ・観測回数：2回
- ・観測日時：2001年1月25日 (木)
  - ①7:00～7:50 ②9:30～9:50
- ・車両台数：48台
- ・データ収集間隔：15秒

(2) 時空間メッシュと交通状態の定義

時空間メッシュは、3 (時間方向) × 2 (空間方向) で考える。時間方向は2時間単位で3つの時間帯、空間方向は500m単位で2本のリンクを定義する。ここで、 $t=1: 7:00\sim 9:00$ ,  $t=2: 9:00\sim 11:00$ ,  $t=3: 11:00\sim 13:00$  ( $\Delta t=2$ 時間)

$$s=1: 4.0kp\sim 3.5kp, s=2: 3.5kp\sim 3.0kp (\Delta s=500m)$$

交通状態は、例題と同様に、「非渋滞 (j=0)」と「渋滞 (j=1)」の2段階で定義する。交通状態は、各時空間メッシュにおける区間平均速度に対して、速度閾値を設定することにより判別する。ここでは、阪神高速道路公団の情報提供における「渋滞」の定義より、速度閾値を30km/hに設定する。時空間メッシュ(t,s)の区間平均速度を  $v_{(t,s)}$  とすると、

$$v_{(t,s)} < 30 \Rightarrow C(t,s) = 1, v_{(t,s)} \geq 30 \Rightarrow C(t,s) = 0$$

となる。

(3) 事前確率の計算

事前確率の算出方法に関しては、マクロな視点による算出方法を適用する。

まず、感知器の地点速度データより、各時空間メッシュの区間平均速度を求める。次に、(2)の定義に従って、日ごとに各時空間メッシュの交通状態判別を行い、それらを組み合わせることにより渋滞判定ベクトル  $\beta$  を定義する。渋滞判定ベクトル  $\beta$  は、ある1日における対象時空間メッシュ全体の交通状態を表すものであり、ベイズ更新モデルにおける仮説  $H_i$  に対応する。

$$\beta = (C(1,1), C(2,1), C(3,1), C(1,2), C(2,2), C(3,2)) \quad (3.2)$$

時空間メッシュごとに渋滞判定ベクトルが同じ日を抽出し、それが全体に占める割合によって事前確率  $P(H_i)$  を求める。すなわち、

$$P(H_i) = n_{\beta} / n \quad (3.3)$$

ここで、

- $n_{\beta}$  : 渋滞判定ベクトルが  $\beta$  となる日数
- $n$  : 分析対象とする日の総数 ( $n=238$ )

以下の表4に、事前確率の算出結果を示す。また、渋滞判定ベクトルを視覚化したものの1例を、図3に示す。

(4) プローブデータによる交通状態判別

各プローブ車両について15秒間隔で取得されたデータより、15秒間における平均速度を求める。15秒間は同じ速度で走行していたと考えて、4.0kp, 3.5kp, 3.0kpの通過時刻をそれぞれ推定する。これを用いて、各車両・各時空間メッシュの区間平均速度を求める。(3)と同様に、(2)の定義に従い、観測メッシュの交通状態判別を行う。

今回は、48台のプローブ車両による観測を行ったため、時空間メッシュごとに「渋滞」・「非渋滞」それぞれ




図3. 渋滞判定ベクトル (H14)

れの交通状態に判別された車両の台数を集計した。その結果を、表3に示す。ただし、(t,s)=(3,1)及び(3,2)に関しては観測されていない。

表3において、より多くの車両が判別された方の交通状態を、プローブデータDにおける対象時空間メッシュの交通状態とする。よって、

D : C(1,1)=0, C(1,2)=0, C(2,1)=1, C(2,2)=0 となる。

#### (5) 尤度と事後確率の計算

プローブデータDより、尤度L(H<sub>i</sub>)を算出する。モデルの定義に従って、仮説H<sub>2</sub>,H<sub>5</sub>のみが生起すると判断した。さらに、事前確率P(H<sub>i</sub>)と尤度L(H<sub>i</sub>)を用いて、ベイズ更新を行い、事後確率P(H<sub>i</sub>|D)を求める。計算結果を表4にまとめて示す。また、ベイズ更新の効果を視覚的に表すために、渋滞判定ベクトルβに対応する仮説H<sub>i</sub>ごとに事前確率と事後確率を比較したものを図4に示す。

表3. プローブデータによる交通状態判別結果

	C(t,s)=0[台]	C(t,s)=1[台]
C(1,1)	41	7
C(1,2)	48	0
C(2,1)	23	25
C(2,2)	48	0

表4. 実証分析結果

H <sub>i</sub>	β						n <sub>β</sub>	P(H <sub>i</sub> )	L(H <sub>i</sub> )	P(H <sub>i</sub>  D)
	C(1,1)	C(2,1)	C(3,1)	C(1,2)	C(2,2)	C(3,2)				
H <sub>1</sub>	0	0	0	0	0	0	62	0.2605	0	0
H <sub>2</sub>	0	1	0	0	0	0	59	0.2479	0.5	0.7564
H <sub>3</sub>	1	1	0	0	0	0	46	0.1933	0	0
H <sub>4</sub>	1	1	1	0	0	0	25	0.105	0	0
H <sub>5</sub>	0	1	1	0	0	0	19	0.0798	0.5	0.2436
H <sub>6</sub>	1	0	0	0	0	0	12	0.0504	0	0
H <sub>7</sub>	1	1	1	0	0	1	3	0.0126	0	0
H <sub>8</sub>	0	0	1	0	0	1	2	0.0084	0	0
H <sub>9</sub>	0	1	1	0	1	1	2	0.0084	0	0
H <sub>10</sub>	0	0	1	0	0	0	1	0.0042	0	0
H <sub>11</sub>	1	0	1	0	0	0	1	0.0042	0	0
H <sub>12</sub>	0	1	0	0	1	0	1	0.0042	0	0
H <sub>13</sub>	1	1	1	0	1	0	1	0.0042	0	0
H <sub>14</sub>	0	1	1	0	1	0	1	0.0042	0	0
H <sub>15</sub>	0	1	0	0	1	0	1	0.0042	0	0
H <sub>16</sub>	1	1	0	0	1	0	1	0.0042	0	0
H <sub>17</sub>	1	0	0	1	0	0	1	0.0042	0	0




図4. ベイズ更新の効果(2)

表5. 各時空間メッシュの区間平均速度

(s,t)	(1,1)	(2,1)	(3,1)	(1,2)	(2,2)	(2,3)
v <sub>(s,t)</sub> [km/h]	36.86	35.52	36.25	49.19	46.81	48.88

#### (6) ベイズ更新の精度に関する考察

プローブ観測当日の検知器データを用いて、その日の真の交通状態を判別し、それをベイズ更新による計算結果と比較することで、モデルの精度について考察する。

(3)と同様に、検知器の地点速度データより各時空間メッシュの区間平均速度を求める。結果を表5に示す。

表5より、時空間メッシュ(2,1)が最も区間平均速度が低く、次に時空間メッシュ(3,1)が低いことが分かる。すなわち、モデル内で設定した速度閾値30km/hよりは速いが、この2つの時空間メッシュでは、他の時空間メッシュと比べて、渋滞が発生している可能性が高いと思われる。この結果は、ベイズ更新モデルの計算結果に現れている。最も高い事後確率を示した仮説H<sub>2</sub>は、時空間メッシュ(2,1)のみ渋滞していると判定されたケースであり、次に高い事後確率を示した仮説H<sub>5</sub>は、時空間メッシュ(2,1)と(3,1)が渋滞していると判定されたケースである。このことから、本研究で構築したベイズ更新モデルは、ある程度の適用性が確保できていると考えられる。

#### 4. 今後の課題

##### i) 交通状態の判別方法

交通状態の判別方法は、ベイズ更新モデルの計算結果に大きく影響するものと思われる。本研究では、速度閾値を用いて交通状態の判別を行ったが、正確な事後確率を算出するためには、より的確な交通状態判別方法をモデルに組み込む必要がある。

##### ii) 事前確率と尤度の定義

式(2.4)のように、事後確率の分子は事前確率と尤度の積で表されることから、どちらかの確率が0になると事後確率も0になってしまう。これによって、事前確率が高いにもかかわらず、事後確率が0になってしまうケースが見られた。このような極端な結果を招くことを防ぐためには、先験情報やプローブデータに「信頼度」の概念を導入し、事前確率と尤度に確率分布を定義することが必要であると思われる。

#### 《参考文献》

- 1) 王立暁・姜美蘭・森川高行：プローブデータとVICSデータの融合による旅行時間推計に関する研究，土木計画学研究・講演集 Vol.31, 2005
- 2) 小出勝亮・宮崎要・堀口良太・赤羽弘和：VICS情報とプローブ情報の融合手法の研究，土木計画学研究・講演集 Vol.30, 2004
- 3) 岡部博志・福田敦・石坂哲宏：プローブカーシステムを活用した開発途上国における都市交通データ収集の可能性に関する研究，土木計画学研究・講演集 Vol.31, 2005
- 4) 伊庭幸人：ベイズ統計と統計物理，岩波書店，2004