

# 縦断線形による車頭時間変動の影響を評価する 階層ベイズ型季節調整法の改良

葛西 誠<sup>1</sup>・大月 崇照<sup>2</sup>・寺部 慎太郎<sup>3</sup>

<sup>1</sup>正会員 東京理科大学PD研究員 理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641)  
E-mail: kasai@rs.noda.tus.ac.jp

<sup>2</sup>非会員 東京理科大学大学院理工学研究科土木工学専攻 (〒278-8510 千葉県野田市山崎2641)  
E-mail: 7614602@ed.tus.ac.jp

<sup>3</sup>正会員 東京理科大学教授 理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641)  
E-mail: terabe@rs.noda.tus.ac.jp

サグ部等の容量上ボトルネック現象のメカニズムを明らかにするためには縦断線形が交通流へ与える影響を知らなければならない。このために、運転者属性等が一樣の交通流を生成するドライビングシミュレータ特有の技法である追従積重ね試験を実施し、このデータから縦断線形の影響のみを抽出するために階層ベイズ形式の季節調整法の適用が提案されていた。しかし、追従積重ね試験データ全体に弱く分布する縦断線形の影響を抽出できる可能性があると期待される一方で、事前分布の適切な設定の余地があることも指摘されていた。本研究は、走行位置をいわゆる季節要因とみなすことで、縦断勾配と車頭時間との関係をより議論できないか検討する。同時に、平坦路とサグとの試験データを比較することで縦断勾配の影響をより明瞭に抽出することを目指す。

**Key Words** : *capacity bottleneck, Hierarchical Bayesian estimation, longitudinal alignment, driving simulator*

## 1. はじめに

自動車専用道路等のサグ部が、容量上のボトルネック現象となり得ることが報告されてからおよそ20年が経過した<sup>1)</sup>。初期の研究を牽引したのは越<sup>2)</sup>であり、追従挙動の累積でボトルネック現象が説明されるはずであるとの見解が示され、同時に1つの追従挙動モデルが提案された。当時の限定的な観測データや経験事実を基に、現在からみても十分説得力のある構造のモデルが構築されたことは越の慧眼と言える。しかし、そこで行われたのはある種の仮説先行型モデリングであり、縦断線形の追従挙動に与える作用について天下りの仮定を置かざるを得なかった。顕在化したボトルネックに対して十分な説明力を持たせることは可能であっても、新しく顕在化したボトルネックを事前に予測できるモデルであったかは難しいところである。

時代が下り、渋滞発生回数では双壁をなしていた料金所渋滞がETCの普及によって激減し、皮肉にもサグ部等を先頭としたボトルネック現象が相対的に目立つように

なった<sup>2)</sup>。これを受け、産官学連携によるサグ部等円滑化を図る精力的な動きもみられる<sup>3,4)</sup>など、サグ部のボトルネック容量を向上させる効果的手法の立案が依然にも増して強い実務上の要請となっている。近年導入あるいは導入検討されている手法は、Adaptive Cruise Control (ACC)による円滑化<sup>3,5)</sup>やLEDペースメーカーによる速度低下抑止<sup>6)</sup>、付加車線による車線利用率均等化等が代表例<sup>7)</sup>である。とはいえ、これらは必ずしもボトルネック現象の本質を理解した上で提示されている施策とは言い切れず、喫緊の社会的要請に応えようとする対症療法とみておくのが相当と思われる。真に効果的な施策に接近するためには、追従挙動モデルを基本とした既往のアプローチ<sup>8,9)</sup>の改良もさることながら、全く新規の視点から現象を理解しようとする努力も同時に必要と考えられる。

そのような、新規の方法はモデル化とデータ取得の両面に配慮する必要があるだろう。前者に対する工夫は、1)追従挙動モデルを媒介したボトルネック現象のモデリングでも良いが、縦断線形の影響について仮説先行ではない方法でモデルに組み込むこと<sup>10)</sup>、2)追従挙動モデル

を媒介することに拘らない方法<sup>11)13)</sup>，である。後者のデータ取得については、1)実路観測データを採用する方法、2)Driving Simulator(DS)を活用する方法、の2つがあり得る。特に後者は、縦断線形が交通流に及ぼす影響についてのみ議論できるデータ取得方法が成立すると期待される<sup>14)</sup>。なお、巨視的かつ集計されたデータとして車両感知器データももちろん有力な情報源であり、ここからも重要な結果が示されている<sup>15)16)</sup>が、本論文では個々の車両を単位とする微視的なモデル化の工夫に焦点を絞る。

追従挙動のモデル化に依らない方法としては、いくつかの試行例<sup>11)13)</sup>がある。例えば葛西<sup>13)</sup>は、DSならではの特性を活かし、交通流に与える縦断線形の影響のみを抽出することを意図した「追従積重ね試験<sup>14)</sup>」を行い、ここから得られたデータを階層ベイズ形式<sup>17)</sup>で書かれる季節調整法の問題として扱う事例を紹介している。ここでは、追従モデルへのあてはめを諦める代わりに1対の追従ペアに分解せず、サグ部全体から受ける車頭時間の変動の大きさをデータ全体から抽出するフレームとして当該分析手法を適用してみることに主眼を置いていた。ただし、データセットの方法、すなわちトレンド成分、季節変動成分を何と対応させるかに検討の余地が残されていた。また、追従積重ね試験を行ったコースは、いずれも実際に容量上のボトルネックとして知られているサグの縦断線形を模して造られているため、コース間の違いよりも被験者個体差が影響の大きいとの解釈も可能であった。そこで、縦断勾配変化のない平坦路もコースとして導入し、付加的にもう1つのサグコースを新設することで、サグ間の違いがみられるか観察することとする。

## 2. ドライビングシミュレータによる追従積重ねデータ取得方法

折に触れてDSを用いた追従積重ね試験の方法については報告している<sup>11)13)</sup>が、実験の概念を簡単にまとめておく。さらに、新しく設けたコースの概要に触れる。

追従積重ね試験は大口・飯田<sup>14)</sup>が開発した手法であり、車両の性能差や運転者個体差を可能な限り排除し、道路線形特に縦断線形の交通流に与える影響のみを観察できると考えられる手法である。この試験の特徴は、同一被験者が、自分の車の後ろを自分が追従することを繰り返すことにある。すなわち、先行車として投影される車の挙動は、自分自身の直前の挙動そのものである。

実験に用いるコースは全て片側2車線である。被験者は常に走行車線を走行する。追越車線には、被験者が追越意図を持たないようにするためと、渋滞直前の密度であることを被験者に感じてもらうために、33.3m間隔で複数の車両を投影させる。

実験に用いるコースとして、既往研究における課題を反映し2種類を新設する。既往研究においては、東北自動車道上り矢板IC直近下流のサグを模した「急サグ」、これよりも上り勾配が小さく、東北自動車道下り羽生PA～利根川橋に位置するサグの上り勾配と同等とする「緩サグ」の2つであった。両者がいずれも有名な顕在ボトルネックであったことも影響している可能性があるが、両者の違いが極めて明確とは言い難かった<sup>13)</sup>。したがってボトルネックになるか自明ではないサグとして、緩サグよりも上り勾配が小さい「緩々サグ」を設ける。さらに、縦断勾配が0である平坦路も比較のために設ける。これら新設コースとあわせ試験に用いるコースは、「コース①(平坦路)」「コース②(緩々サグ)」および「コース③(緩サグ)」の3種類とする。これらの縦断線形を図-1に示す。

1人の被験者には、2種類のコースにてそれぞれ追従積重ね試験を行ってもらう。追従積重ね回数は1コースにつき概ね20回である。取得されたデータをTime-space図としていくつか示しておく(図-2～図-7)。コース②(緩々サグ)の走行データである図-3、図-5、およびコース③(緩サグ)および図-7では、共通して縦断曲線区間(サグ底)で減速が発生し、上り坂部で車頭距離が広がっている傾向がみられる。一方で、コース①(平坦路)の走行データ(図-2、図-4、図-6)ではそのような傾向はみられない。

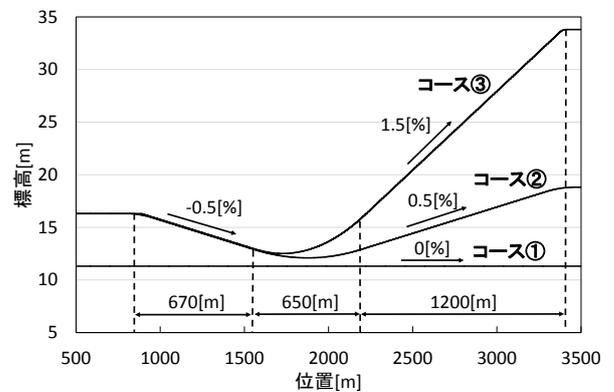


図-1 追従積重ね実験に使用するコースの縦断線形

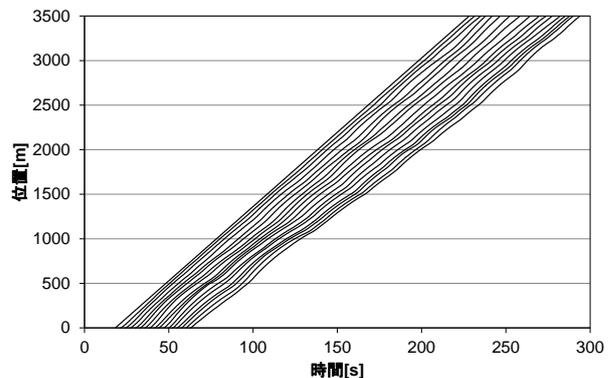


図-2 被験者C-01 コース①(平坦路) time-space図

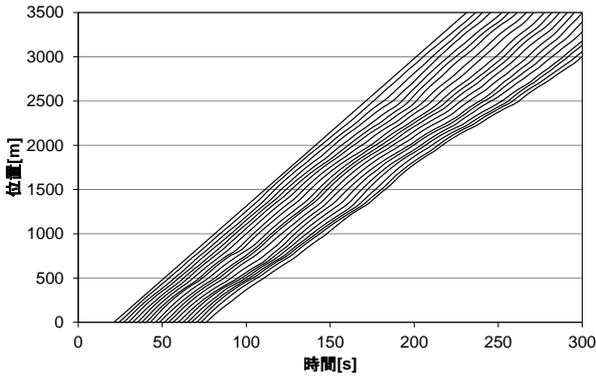


図-3 被験者 C-01 コース② (緩々サグ) time-space 図

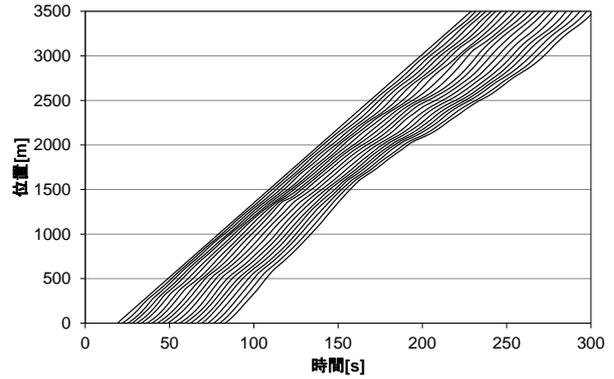


図-7 被験者 D-06 コース③ (緩サグ) time-space 図

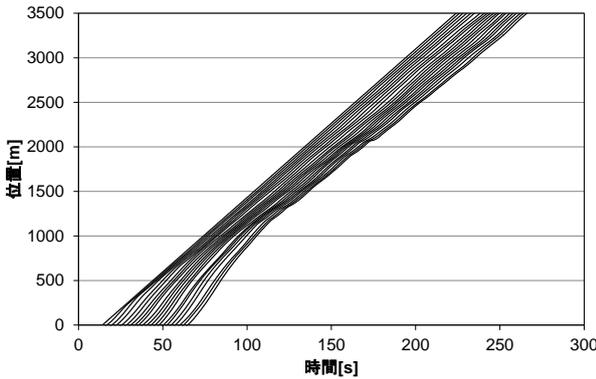


図-4 被験者 C-02 コース① (平坦路) time-space 図

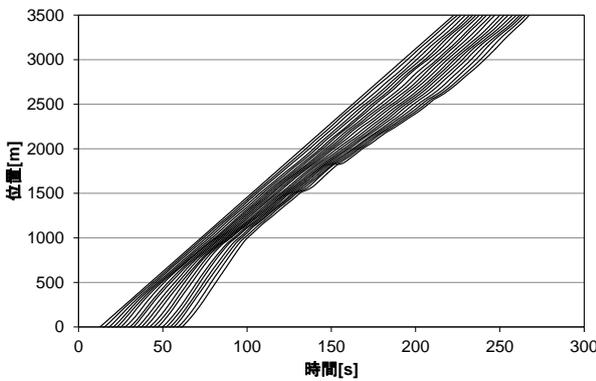


図-5 被験者 C-02 コース② (緩々サグ) time-space 図

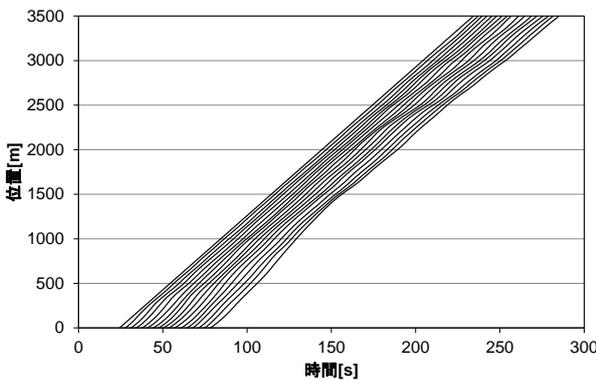


図-6 被験者 D-06 コース① (平坦路) time-space 図

### 3. 階層ベイズ型季節調整法

#### (1) 階層ベイズ型季節調整法の適用の動機

追従挙動のモデル化に依らずに縦断線形の影響を調べたいとする動機については、文献<sup>13)</sup>にて詳述されているが、要点を示すと以下の通りとなる。

大口・中村<sup>2)</sup>や、大口<sup>9)</sup>が近年の成果も踏まえまとめた見解に基づく、サグがボトルネックとなる理由は、縦断勾配の極めて緩やかな変化であろうと現時点では考えられている。交通密度が十分高くなってくると、内側車線の利用率が高くなり、大きな車群が形成されるようになる。この状態でサグに差し掛かると、縦断勾配変化の影響で速度の微小擾乱、換言すれば車頭時間の微小擾乱が生じる。これがきっかけとなって車頭時間増大波の上流増幅伝播が生じ、この状態で上流から継続して大きな需要が到着すると継続した渋滞が生成されるとされる<sup>9)</sup>。

ただし、車両1個単位の挙動データを元にこの車頭時間の微小擾乱を検出するのは、その擾乱が極めて小さいために、少なくともリアルタイムに検出するには難しいとも言及されている<sup>9)</sup>。

このような車頭時間の微小擾乱がサグによってどのように異なっているかを、1対の追従ペアのデータに分解し追従モデルへのあてはめを行わずに、同一の運転特性から構成されるとみなせる追従積重ね試験データ全体を用いて比較できる方法として、階層ベイズ型の季節調整法<sup>17)21)</sup>を適用する。

まず、追従積重ねデータを車頭時間データの配列へと変換し、そのデータに対して階層ベイズ型季節調整法を適用する。既往の試行例では、追従回をトレンド成分、同一時刻を季節要因とみなして事前分布を構成していた<sup>13)</sup>。もちろん事前分布の構成法には可能性があることも指摘されており、走行位置と追従積重ね回数の2軸で整理されたデータ行列を用いることも一案であった<sup>13)</sup>。

さらには、トレンド成分を走行位置とし、追従回毎に同一位置から同じ影響を受けると仮定しても良いはずである。以下ではこの仮定に従って事前分布を構成する。

なお、第2章によって取得されたデータは10m毎に離散化されている。したがって、車頭時間データは図-8のように走行位置と追従積重ね回数をラベルとして整理されているとみればよい。

車頭時間の実測データ列：

$$\mathbf{y} = [y_{1,1}, y_{1,2}, \dots, y_{1,m}, y_{2,1}, y_{2,2}, \dots, y_{2,m}, \dots, y_{i,j}, \dots, y_{n,1}, y_{n,2}, \dots, y_{n,m}]^t \quad (1)$$

を考える。  $i$  は先行車からの走行順（追従回と呼ぶこととする）、  $j$  は車両進行方向に動く添え字である。  $m$  は車両進行方向のサンプル数、  $n$  は総追従積重ね回数である。

実測車頭時間  $y_{i,j}$  は、次のようにトレンド成分  $T_{i,j}$ 、季節変動成分  $S_{i,j}$ 、不規則変動成分  $I_{i,j}$  に分解できるとする：

$$y_{i,j} = T_{i,j} + S_{i,j} + I_{i,j} \quad (2)$$

以下、推定されるべき未知パラメータ  $T_{i,j}$  と  $S_{i,j}$  をまとめて

$$\boldsymbol{\theta} = [T_{1,1}, T_{1,2}, \dots, T_{1,m}, T_{2,1}, T_{2,2}, \dots, T_{2,m}, \dots, T_{i,j}, \dots, T_{n,1}, T_{n,2}, \dots, T_{n,m}, S_{1,1}, S_{1,2}, \dots, S_{1,m}, S_{2,1}, S_{2,2}, \dots, S_{2,m}, \dots, S_{i,j}, \dots, S_{n,1}, S_{n,2}, \dots, S_{n,m}]^t \quad (3)$$

と書く。

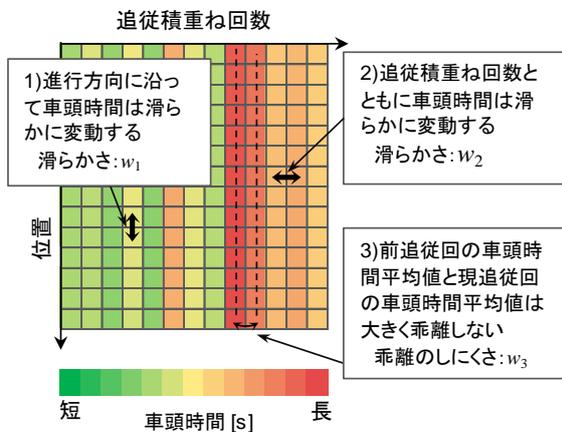


図-8 事前分布の設定

(1) 事前分布の設定

a) トレンド成分：車両進行方向に沿った車頭時間変動の滑らかさ

車両進行方向に沿って（10mピッチで）車頭時間が滑らかな変動を示すと仮定する。これがトレンド成分に相当する。トレンド成分が滑らかであるほど  $T_{i,j}$  の2階階差が0に近づくため、以下のような正規分布で滑らかさを表現する：

$$p_{1i,j} = \frac{1}{\sqrt{2\pi}w_1} \exp\left\{-\frac{(T_{i,j-1} - 2T_{i,j} + T_{i,j+1})^2}{2w_1^2}\right\} \quad (4)$$

ここに、  $w_1$  はトレンド成分の滑らかさを表す量であり、推定すべき量である。

b) 季節変動成分：同じ走行位置における車頭時間の類似性

同じ走行位置において、同一被験者が何回目の追従走行であっても車頭時間が似た値をとることを意味する。

位置  $j$  において、前追従回  $i-1$  と現追従回  $i$  の階差が0に近ければ近いほど滑らかなので、以下の正規分布にて表現する：

$$p_{2i,j} = \frac{1}{\sqrt{2\pi}w_2} \exp\left\{-\frac{(S_{i-1,j} - S_{i,j})^2}{2w_2^2}\right\} \quad (5)$$

ここに、  $w_2$  は季節変動成分の滑らかさを表す量である。

c) 前追従回と現追従回での車頭時間の平均値の乖離のしにくさ

前追従回  $i-1$  での全車の車頭時間の平均値は、現追従回  $i$  のそれから大きく乖離しないと考えられるため、

$$p_{3j} = \frac{1}{\sqrt{2\pi}w_3} \exp\left\{-\frac{\sum_{i=1}^n (S_{i-1,j} - S_{i,j})^2}{2w_3^2}\right\} \quad (6)$$

ここに、  $w_3$  は平均値からの乖離の程度を表し、前追従回から現追従回までの季節変動成分平均値の乖離のしにくさを意味する。

上記の滑らかさを司る3変数  $w_1, w_2, w_3$  は、階層ベイズ型のモデルでは事前分布を支配するパラメータという意味で、ハイパーパラメータと呼ばれる。以下、まとめて  $\mathbf{w} = (w_1, w_2, w_3)^t$  と表す。

事前分布  $p_{prior}(\boldsymbol{\theta} | \mathbf{w})$  は、上記の3種類の同時確率として表される：

$$P_{prior}(\boldsymbol{\theta} | \mathbf{w}) = \prod_{j=2}^{m-1} \left\{ \left( \prod_{i=2}^{n-1} p_{1,i,j} p_{2,i,j} \right) p_{3,j} \right\} \quad (7)$$

(2) データ分布

残差  $I_{i,j}$  が標準偏差  $\sigma_d$  の正規分布に従うとすると、

$$p_{data}(\mathbf{y} | \boldsymbol{\theta}, \sigma_d) = \left( \frac{1}{\sqrt{2\pi}\sigma_d} \right)^{(m-2)(n-2)} \cdot \exp \left[ -\frac{1}{2\sigma_d^2} \sum_{j=2}^{m-1} \sum_{i=2}^{n-1} \{y_{i,j} - (T_{i,j} + S_{i,j})\}^2 \right] \quad (8)$$

と表せる。これをデータ分布と呼ぶ。  $\sigma_d$  も未知量でありハイパーパラメータである。

ハイパーパラメータ  $\sigma_d, \mathbf{w}$  は、周辺尤度：

$$L(\sigma_d, \mathbf{w}) = \int p_{data}(\mathbf{y} | \boldsymbol{\theta}, \sigma_d) p_{prior}(\boldsymbol{\theta} | \mathbf{w}) d\boldsymbol{\theta} \quad (9)$$

を最大とするような値として推定される。Akaike<sup>19)</sup>は、式(9)を基に統計量  $ABIC = -2 \log L(\sigma_d, \mathbf{w})$  を定義し、これを最小とするようなハイパーパラメータを推定すればよいとしている。

ABIC を最小とするハイパーパラメータ  $\sigma_d, \mathbf{w}$  を  $\hat{\sigma}_d, \hat{\mathbf{w}}$  と表すと、これの下でパラメータ  $\boldsymbol{\theta}$  はベイズの定理より事後確率：

$$p_{posterior}(\boldsymbol{\theta} | \mathbf{y}) = \frac{p_{data}(\mathbf{y} | \boldsymbol{\theta}, \hat{\sigma}_d) p_{prior}(\boldsymbol{\theta} | \hat{\mathbf{w}})}{\int p_{data}(\mathbf{y} | \boldsymbol{\theta}, \hat{\sigma}_d) p_{prior}(\boldsymbol{\theta} | \hat{\mathbf{w}}) d\boldsymbol{\theta}} \quad (10)$$

を最大とするような値として推定される。

上記のように事前分布およびデータ分布として正規分布を仮定するとき、式(10)は最小二乗推定の問題に帰着する。ABICを最小化するハイパーパラメータ値は数値的に求めざるを得ず<sup>17),20)21)</sup>、Simplex法<sup>22)</sup>を適用する。ある仮定されたハイパーパラメータ値の下で式(10)を解きABICを求め、さらにABICを改善する可能性があるハイパーパラメータを逐次的に求めていくこととなる。

4. 適用結果

ABIC最小化によってハイパーパラメータを推定した結果を表-1~表-3に示す。表中、ABICは事前分布の妥当性とデータへの適合の両方を同時に評価している量と考えて良い。

(1) 推定結果全体の傾向

ハイパーパラメータ  $\sigma_d / w_1$  は、トレンド成分の滑らかさを意味する。値が大きいほど、進行方向に沿って車頭時間がより滑らかに変動する。  $1/w_2$  は、値が大きいほど、ある走行位置について、前追従回と現追従回との間で車頭時間が変動しにくいことを示している。

表-1 被験者 C-01~C-09 のハイパーパラメータ推定結果

	被験者	総追従積重ね回数(n)	$\sigma_d / w_1$	$1/w_2$ [s <sup>-1</sup> ]	$1/w_3$ [s <sup>-1</sup> ]	ABIC	残差二乗和 [s <sup>2</sup> ]
コース① 平坦路	C-01	16	0.18	3.48	1.16	-1134.7	20.89
	C-02	20	0.48	1.59	1.04	-598.9	111.64
	C-03	18	0.25	2.55	1.07	-892.0	41.03
	C-04	20	0.28	2.35	1.12	-1036.5	50.22
	C-05	18	0.15	3.98	1.15	-1138.4	18.30
	C-06	19	0.18	3.48	1.16	-1331.3	23.65
	C-07	20	0.28	2.35	1.12	-1119.7	49.40
	C-08	19	0.31	2.23	1.11	-767.6	58.68
	C-09	19	0.37	1.89	1.06	-805.8	72.82
コース② 緩々サグ	C-01	20	0.14	4.32	1.21	-1632.5	15.35
	C-02	20	0.41	1.78	1.10	-748.5	86.98
	C-03	20	0.20	3.17	1.09	-1382.9	28.75
	C-04	20	0.28	2.35	1.12	-1103.1	49.56
	C-05	20	0.14	4.32	1.21	-1348.7	16.24
	C-06	20	0.18	3.48	1.16	-1102.5	26.05
	C-07	20	0.29	2.29	1.06	-901.6	55.63
	C-08	20	0.25	2.55	1.07	-942.9	44.76
	C-09	20	0.31	2.23	1.11	-909.9	59.75

表-2 被験者 D-01～D-08 のハイパーパラメータ推定結果

	被験者	総追従積重ね回数(n)	$\sigma_d / w_1$	$1 / w_2$ [s <sup>1</sup> ]	$1 / w_3$ [s <sup>1</sup> ]	ABIC	残差二乗和 [s <sup>2</sup> ]
コース① 平坦路	D-01	16	0.21	3.04	1.16	-1010.0	27.05
	D-02	16	0.27	2.50	1.10	-726.0	41.86
	D-03	16	0.32	2.10	1.09	-657.4	53.93
	D-04	16	0.13	4.57	1.14	-1116.7	12.70
	D-05	18	0.25	2.55	1.07	-1081.8	39.35
	D-06	16	0.25	2.55	1.07	-1004.6	35.83
	D-07	13	0.46	1.61	1.08	-488.8	75.19
	D-08	19	0.27	2.50	1.10	-992.8	46.04
コース③ 緩サグ	D-01	20	0.18	3.48	1.16	-1191.0	25.60
	D-02	19	0.24	2.67	1.14	-1001.2	39.42
	D-03	17	0.52	1.48	1.06	-489.3	107.84
	D-04	20	0.09	6.05	1.18	-1462.9	8.43
	D-05	20	0.23	2.81	1.09	-1189.3	37.56
	D-06	20	0.20	3.17	1.09	-1336.5	29.01
	D-07	17	0.34	2.07	1.05	-732.6	60.63
	D-08	20	0.27	2.50	1.10	-1061.5	47.68

表-3 被験者 E-01～E-08 のハイパーパラメータ推定結果

	被験者	総追従積重ね回数(n)	$\sigma_d / w_1$	$1 / w_2$ [s <sup>1</sup> ]	$1 / w_3$ [s <sup>1</sup> ]	ABIC	残差二乗和 [s <sup>2</sup> ]
コース② 緩々サグ	E-01	18	0.28	2.35	1.12	-864.8	47.16
	E-02	20	0.37	1.89	1.06	-830.5	75.93
	E-03	20	0.25	2.55	1.07	-1201.1	42.53
	E-04	20	0.17	3.60	1.10	-1276.1	23.03
	E-05	20	0.22	2.87	1.10	-1023.5	35.38
	E-06	18	0.19	3.26	1.14	-1268.5	24.16
	E-07	20	0.37	1.89	1.06	-874.5	75.27
	E-08	18	0.39	1.88	1.06	-598.1	78.80
コース③ 緩サグ	E-01	18	0.24	2.67	1.14	-846.2	38.76
	E-02	20	0.37	1.89	1.06	-707.8	77.79
	E-03	20	0.28	2.35	1.12	-971.6	50.86
	E-04	20	0.14	4.10	1.13	-1248.4	17.97
	E-05	21	0.22	2.87	1.10	-1427.4	34.35
	E-06	17	0.16	3.74	1.18	-1030.4	19.04
	E-07	17	0.31	2.23	1.11	-743.0	53.44
	E-08	17	0.42	1.73	1.04	-673.6	80.87

概ね、 $1/w_2$  が大きければ、ある地点において車頭時間が受ける影響が追従回に依らず似ていると思ってよいだろう。すなわち、これは（先行車等の他の要因以外の）縦断勾配から当該被験者が影響を受けやすいと考えることもできそうである。

$1/w_3$  が大きいほど、前追従回りの車頭時間平均値と現追従回りの車頭時間平均値とが乖離しにくいことを意味している。したがって、追従回毎の（走行毎の）ランダムネスが小さいことを意味しているように思われる。

## (2) トレンド成分：進行方向への滑らかさを表すハイパーパラメータ推定値

上記を踏まえつつ、表-1を解釈してみよう。例えば、被験者C-01の $\sigma_d / w_1$ は、コース①（平坦路）の方がコース②（緩々サグ）よりも大きい。このことは、コース①（平坦路）の方が相対的に進行方向に沿って車頭時間が変動しにくいことを意味している。縦断勾配変化の全くないコースで車頭時間が変化しにくいことは直観的にも受け入れられる結果である。他の被験者C-02～C-09に

ついてみると、被験者C-07を除いてコース①（平坦路）が大きいかまたは同等であり、概ね被験者によらず一般的に見られる傾向と思われる。

表-2をみても、 $\sigma_d/w_1$ は被験者D-03を除いてコース①（平坦路）の方がコース③（緩サグ）よりも大きいか同等となっており、平坦路の方がトレンド成分が滑らかであることを意味している。

なお、表-3からコース②（緩々サグ）とコース③（緩サグ）のどちらがよりトレンド成分が滑らかであるか、すなわちどちらのコースの縦断線形の影響がより平坦路に近いかを読み取れる可能性も期待できるが、一見したところハイパーパラメータ値の出現傾向に特段の傾向は見られない。この点については今後の検証が待たれる。

**(3) 季節変動成分：同一位置での車頭時間変動の大きさを表すハイパーパラメータ推定値**

$1/w_2$ の意味を解釈するために、 $1/w_2$ の値の大きい被験者C-01のコース①（平坦路）の季節変動成分（図-9左側）と、 $1/w_2$ の値の小さい被験者C-02のコース①（平坦路）の季節変動成分（図-10左側）を比較する。図-9左側は比較的濃淡のない図であるが、それに対して図-10左側は追従回10回目程度から20目にかけて横にいくつか濃く着色されている線がみられる。ある位置において、追従積重ね回数が増すごとに車頭時間の季節変動成分も増加していることが、 $1/w_2$ が小さいこととして反映していると考えられる。

**(4) 年平均の乖離の小ささを：前追従回と現追従回の手頭時間平均値の乖離を表すハイパーパラメータ推定値**

$1/w_3$ も、図-9左側と図-10左側の違いを反映していると考えられる。前追従回と現追従回の手頭時間平均値の差は、図-9左側の方が小さいように見え、実際に $1/w_3$ のハイパーパラメータは被験者C-01のコース①（平坦路）（図-9左側）の方が大きく推定されている（表-1）。

もっとも、図-9の左右のコンター図は類似しており、図-10の左右も類似の傾向である。コース間の差よりも被験者個体差の影響の方が強いように思われる。

そこで、もう1例を提示して議論してみよう。表-2のハイパーパラメータ推定結果を参照し、コース①（平坦路）とコース③（緩サグ）の $1/w_2$ の推定値の差が比較的大きな被験者D-06の季節変動成分を図-11に示す。図-11左側は被験者D-06のコース①（平坦路）の季節変動成分、図-11右側は被験者D-06のコース②（緩々サグ）の季節

変動成分である。平坦路（図-11左側）では季節変動成分は濃淡がないが、緩サグ（図-11右側）ではいくつかの位置で季節変動成分が大きく推定されている。これが縦断勾配の影響の違いではないかと推測される。

ただし、季節変動成分はいずれの被験者についても極めて小さなオーダーとして推定されており、例えば図-11右側では最大値はおよそ0.03秒である。縦断線形が車頭時間に与える影響は微小であると想像されることを考慮しても、小さすぎる感は否めず、今後の精査が必要と思われる。

ただし、ここでのハイパーパラメータは技術上点推定値として推定せざるを得ず、両コースにおける値の差が意味のある差であるかは慎重に判断すべきことを注意しておく。

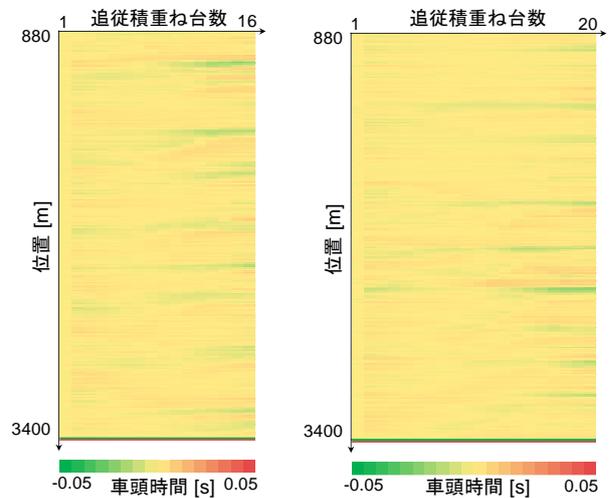


図-9 被験者 C-01 の季節変動成分 左：コース①（平坦路） 右：コース②：（緩々サグ）

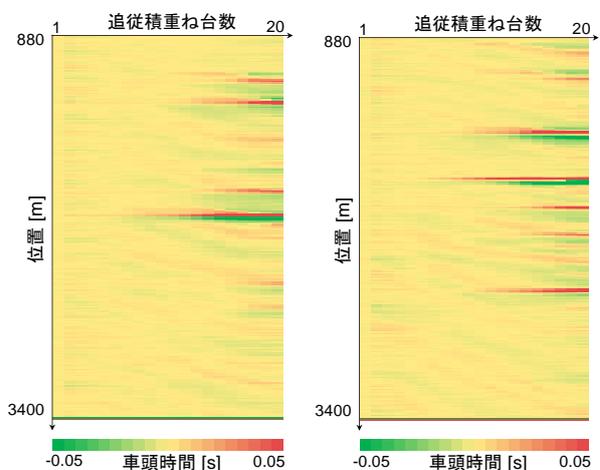


図-10 被験者 C-02 の季節変動成分 左：コース①（平坦路） 右：コース②：（緩々サグ）

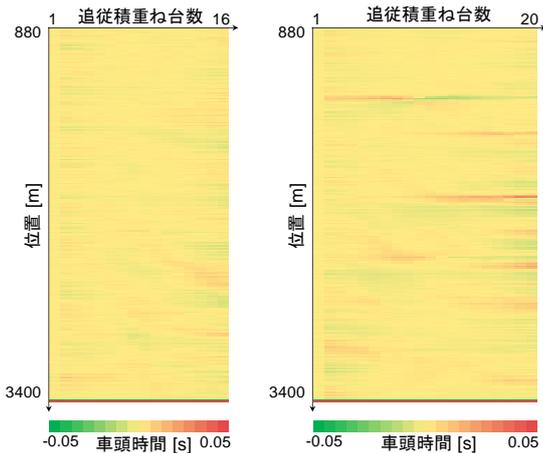


図-11 被験者 D-06 の季節変動成分 左：コース①（平坦路）  
右：コース③（緩サグ）季節変動成分

## 5. おわりに

本論文は、ドライビングシミュレータを用いて同一被験者により繰り返し自分自身を追従する追従積重ね試験データから、交通流に及ぼす縦断線形の影響を抽出する方法として階層ベイズ型の季節調整法を適用した。同様の手法はこれまで試行しているが、何を事前分布として設定すべきかについて他の可能性がいくつか指摘されており<sup>13)</sup>、本研究はそのうちの1つを検証したことに相当する。

本稿での狙いは、進行方向に沿って車頭時間の変動がどの程度であるかをトレンド成分として、また車頭時間へのある位置固有の影響を季節変動成分とみなし、それぞれの成分の変動の大きさを見積もるところにあった。提案手法は追従積重ね試験データを1対の追従挙動データに分解し追従挙動モデルへ当てはめることなく、積重ね試験データ全体から縦断線形の影響を抽出する方法である。得られた知見を以下にまとめる：1)平坦路に比べてサグでは進行方向に沿って車頭時間の変動が大きい傾向にあること、2)車頭時間に与える走行開始位置から同一の位置における固有の影響を季節変動成分としてみなすと、その季節変動成分は縦断勾配の影響を拾っている可能性があること、3)ただし、縦断勾配の影響のオーダーそのものは微小であること、である。このことは、縦断線形の交通流に与える影響は極めて微小であり、このような小さいオーダーの縦断勾配の影響を加味した追従モデルを構築することは相当困難ではないかと思わせる結果である。もっとも、これは分析結果が十分に妥当で

あることが保証されなければ断言できないことではある。

階層ベイズ法を適用する際の事前分布の設定法については、ここで示した以外の方法の可能性も当然残されている。特に、被験者の個体差をハイパーパラメータとして設定可能であれば、明示的に個体差と道路線形の影響を分離することができると思われる。このような幅広いデータ解析手法の適用によって、見落とされているが本質的であろうと思われるボトルネック生成要因を検証していくことが重要である。

**謝辞：**本研究はJSPS 科研費(No. 25820247)の補助を受け実施された研究において取得されたデータを活用し、JSPS 科研費(No.15K18138)課題の一部として実施されたものである。また実践的ITS研究委員会(土木学会・技術推進機構)からの受託研究の予算を一部活用している。本田技研工業(株)小野浩氏からは長期にわたりドライビングシミュレータに関する技術的アドバイスをいただいている。ここに記して感謝の意を表する。

## 参考文献

- 1) 越正毅：高速道路のボトルネック容量，土木学会論文集，No.371/IV-5，pp.1-7，1986.
- 2) 大口敬，中村英樹：日本における交通容量・サービスの質に関する研究の概観と展望，土木学会論文集 D3，Vol. 67，No. 3，pp.217-229，2011.
- 3) 鈴木一史，山田康右，堀口良太，岩武宏一：高速道路サグ部渋滞対策に資する ACC の将来性能と渋滞緩和効果，交通工学論文集，Vol.1，No.2，pp.B\_60-B\_67，2015.
- 4) [http://www8.cao.go.jp/cstp/sangakukan/sangakukan2014/10kokkou\\_1.pdf](http://www8.cao.go.jp/cstp/sangakukan/sangakukan2014/10kokkou_1.pdf)
- 5) 大口敬：高速道路における交通渋滞緩和策の最新動向，自動車技術，Vol.67，No.10，pp.11-16，2013.
- 6) 遠藤元一，中川浩，深瀬正之，橋本弾：東京湾アクアラインの渋滞対策について，交通工学論文集，Vol.1，No.4，pp. B\_1-B\_8，2015.
- 7) 大口敬：高速道路単路部渋滞発生解析—追従挙動モデルの整理と今後の展望—，土木学会論文集，No.660/IV-49，pp.39-51，2000.
- 8) Ozaki, H.: Reaction and anticipation in the car-following behavior, *Proceedings of 12th International Symposium on Transportation and Traffic Theory*, pp. 349-366, 1993.
- 9) Goni Ros, B., Knoop, V. L., Shiomi, Y., Takahashi, T., van Arem, B. and Hoogendoorn S. P.: Modeling traffic at sags, *International Journal of Intelligent Transportation Systems Research*, (online first), 2014.
- 10) Kasai, M., Shibagaki S. and Terabe S.: Application of Hierarchical Bayesian estimation to calibrating a car-following model with time-varying parameters, *Proceedings of the 2013 IEEE Intelligent Vehicles Symposium*, pp.870-875, 2013.
- 11) Kasai, M., Shibagaki S. and Terabe S.: Extracting characteristics of traffic flow in bottlenecks with exchange interactions in time headway, *Proceedings of the 17th Interna-*

- tional IEEE Conference on Intelligent Transportation Systems*, pp.3144-3150, 2014.
- 12) 葛西誠, 大月崇照, 寺部慎太郎: 単路部交通流の特性を抽出するための車頭時間ダイナミックモデル, 土木計画学研究・講演集, Vol.50, 6pages, 2014.
  - 13) 葛西誠: ドライビングシミュレータ追従積重ね試験と階層ベイズ法による縦断線形の影響の抽出, 土木学会論文集 D3, Vol.71, No.5 (審査中)
  - 14) 大口敬, 飯田克弘: 高速道路サグにおける追従挙動特性におけるドライビング・シミュレータ技術の適用性, 交通工学, Vol.38, No.4, pp.41-50, 2003.
  - 15) 稲野晃, 中村英樹, 内海泰輔: 複数ボトルネックを含む高速道路区間における渋滞現象の確率的解析, 高速道路と自動車, Vol.52, No.1, pp.19-29, 2009.
  - 16) Xing, J., 宇佐美純二, 福島賢一, 佐藤久長: 潜在的ボトルネック交通容量の推定及び交通容量の確率分布を用いた年間の渋滞予測検討, 土木計画学研究・論文集, Vol.27, No.5, 2010.
  - 17) 石黒真木夫, 松本隆, 乾敏郎, 田邊國士: 統計科学のフロンティア 4 階層ベイズモデルとその周辺, 岩波書店, 2004.
  - 18) Akaike, H. and Ishiguro, M.: Trend estimation with missing observations, *Annals of the Institute of Statistical Mathematics, Part B*, Vol.32, pp.481-488, 1980.
  - 19) Akaike, H.: Likelihood and the Bayes procedure, *Trabajos de Estadística Y de Investigación Operativa*, Vol.31, pp.143-166, 1980.
  - 20) 田邊國士: ベイズモデルと ABIC, オペレーションズ・リサーチ: 経営の科学, Vol.30, No.3, pp.178-183, 1985.
  - 21) 田中輝雄, 田邊國士: ベイズの方法によるデータのあてはめ, 数理解析研究所講究録, Vol.483, pp.86-111, 1983.
  - 22) S.L.S.ジャコビ, J.S.コワリク, J.T.ピゾ (関根智明訳): 非線形最適化問題の反復解法, 培風館, pp.81-84, 1976.

(2015.7.31 受付)

IMPROVEMENT OF APPLICATION OF HIERARCHICAL BAYES ESTIMATION  
TO MEASUREMENT OF INFLUENCE OF LONGITUDINAL GRADIENT ON  
TIME HEADWAY

Makoto KASAI, Takaaki OTSUKI and Shintaro TERABE