

# 追従モデル尤度に基づく 車両挙動クラスタリング手法

柳原 正実<sup>1</sup>

<sup>1</sup>正会員 首都大学東京大学院 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢1-1)

E-mail: yanagihara@tmu.ac.jp

追従挙動に代表される車両挙動は、走行する道路の構造や時々刻々変化する周囲の交通状況、ドライバーの個人属性、その時々ドライバーの思考等の影響下にあり、多様な様相がみられる。一般的な交通ミクロシミュレーション等では、多様な様相を表現するため複数の下位モデルもしくは複数のパラメータセットの導入している。このことを前提に、本稿ではあらかじめ定めた数のグループに複数車両の時々刻々の挙動を分類するクラスタリング手法を提案する。本手法はクラスタ数とモデル形のみを仮定し、EMアルゴリズムを用いてモデルパラメータ値を更新しながら時々刻々の車両挙動データを分類する。提案する手法を実車両挙動データに適用した結果、追従モデルの構造に合致した車両挙動と、その他の要因の影響が大きい車両挙動の2つに2分することができた。

**Key Words** : driving behavior, car following, clustering, k-means, EM algorithm

## 1. はじめに

1950年代後半以降、半世紀以上にわたり車両挙動についての研究が進められてきている。特に追従挙動に関する研究は多岐にわたり<sup>1)</sup>、ドライバーの運転挙動についての知見を深めるため、交通ミクロシミュレーション実験や交通流解析<sup>2)</sup>に利用するために数多くの追従モデルが提案されている。また近年では、観測機器の普及と技術の進歩に伴い、プローブカー、ドライブレコーダー、ビデオ画像等から詳細な車両軌跡データを得る機会が増えている。その結果、より複雑な車両挙動モデルが提案されるようになり、より高い精度でのパラメータの推定が可能となった。

交通分野における追従モデルは基本的に式(1)のような相対速度などを説明変数に持ち、反応時間を伴う後続車両の加速度を被説明変数としている。

$$\ddot{x}_{i+\tau}^f = f(\beta, \dot{x}_i^l - \dot{x}_i^f, x_i^l - x_i^f, \dot{x}_i^f, \dots) \quad (1)$$

$x_i^f$  : 時刻  $t$  における後続車両位置

$x_i^l$  : 時刻  $t$  における先行車両位置

$\ddot{x}_i^f, \dot{x}_i^f$  : 車両位置の1,2回微分(速度, 加速度)

$\tau$  : 反応時間パラメータ

$\beta$  : モデルパラメータベクトル

近年では、式(1)のモデル関数  $f$  に複雑な構造を持つものが多数提案されてきている。追従挙動を決定づける要因として走行する道路の構造や時々刻々変化する周囲の交通状況等<sup>4)</sup>が考慮され、それらをモデル式に反映させたためにモデル構造が複雑化している。さらに、ドライバーの個人属性とその時々ドライバーの思考等<sup>5)</sup>、直接観測することが困難である因子も追従挙動を決定づける要因となりうる。直接観測することが困難である因子が存在する場合、モデルのキャリブレーションは困難になる。既存のモデルでは、モデルパラメータの分布や潜在状態を確率的に扱うことによって直接観測することが困難な因子の影響をモデルに反映させている<sup>7)</sup>。

既存の複雑な構造を持つ追従モデルには、モデルパラメータに関して線形である比較的簡易な下位モデルを式(2)のように複数組み合わせたもの<sup>8)</sup>が多い。各モデル関数  $f^k$  は、それぞれ対応する異なる車両挙動の様相を扱うものであるといえる。

$$\ddot{x}_t^f = \begin{cases} f^1(\beta_1, \dot{x}_{t-\tau_1}^l - \dot{x}_{t-\tau_1}^f, \dots) & \text{if } \dots \\ f^2(\beta_2, \dot{x}_{t-\tau_2}^l - \dot{x}_{t-\tau_2}^f, \dots) & \text{if } \dots \\ \vdots & \vdots \end{cases} \quad (2)$$

$\tau_k$  : 下位モデル  $k$  の反応時間パラメータ

$\beta_k$  : 下位モデル  $k$  のパラメータベクトル

異なる車両挙動の様相を扱うモデルを提案している研究に加え、走行条件によってモデルパラメータが異なることを示したもの<sup>9)</sup>や車両間の挙動の違いが重要であることを示唆する既存研究も存在している。これらの研究を踏まえると、精度の高い交通流の分析結果を得るためには、異なる複数の車両挙動の様相を扱う必要があるといえる。しかし、直接観測することが困難である車両挙動の様相という因子と走行条件や個人属性との関係について、様相の種類の数についての実証的な分析は少ない。その理由として、複数の車両の時々刻々の挙動の中で、一つの様相として扱える車両挙動の範囲を規定する手法がほとんど構築されていなかった事、言い換えると、提案されている車両挙動の適切な分類手法がとても少ないという事実が挙げられる。車両挙動の車両挙動に対応した分類という問題自体が難しい問題であったと考えられる。例えば、10台の車両の1000m間の挙動の分類方法として、1台毎の10種類、あるいは、100m毎の10種類といったような車両挙動外の因子による方法は容易に実行できるが、車両挙動という単純な数値化が困難な因子に基づき各車両各時点の挙動が属する様相を決定することは単純な問題ではない。

車両挙動の分類結果が得られれば、多くのシミュレーションモデルや車両挙動の解析で扱われている異なる複数の車両挙動の様相についての知見が得られるであろうことが予想される。経験的に複数の車両挙動の様相を設定するのではなく、実際の車両挙動に基づいた設定をするためには、実データから得た車両挙動の分類結果に関する知見が有用であると考えられる。

以上を踏まえ、本研究では複数車両の時々刻々の挙動をあらかじめ定めた数のグループに分類するクラスタリング手法を提案する。なお、本手法はドライブレコーダーやビデオ観測データから得られる詳細な車両軌跡データを対象とした分類手法である。また、車両挙動が式(2)のような複数の下位の車両挙動モデルの組み合わせによって表現されることを前提としている。

## 2. 車両挙動のクラスタリング手法

### (1) クラスタリング手法の概要

本研究で提案するクラスタリング手法は、実車両挙動データの各車両各時点の挙動を複数の異なるグループに分類する手法である。すなわち、実車両挙動データの中の任意の一車両一時点が属するグループを決定する手法を提案している。本節では、提案するクラスタリング手法の理論的背景と計算手法について述べる。

提案する手法では、グループ数と各グループの車両挙動観測データに対する尤度関数形を仮定する。なお、各尤度関数のパラメータはクラスタリング時に決定される。また、提案する手法は、分類するグループ数があらかじめ決定しているk-means型のクラスタリング手法であり、その計算アルゴリズムとしてEMアルゴリズムを採用している。EMアルゴリズムを用いた混合分布モデルのパラメータ推定にはk-means型のクラスタリング手法としての側面が存在し<sup>10)</sup>、提案する手法においても各グループの尤度関数によって表現される混合分布を対象としたEMアルゴリズムによってクラスタリングを実行する。

### (2) EMアルゴリズムを用いたクラスタリング

EMアルゴリズムは統計モデル一般に応用可能な欠損データや潜在データを補完する手法として知られている。本研究では潜在データとしてすべての車両とすべての時点における車両挙動のグループを示す値を考慮する。具体的には車両  $n$  時刻  $t$  における車両挙動のグループが  $k$  であれば1それ以外であれば0をとる式(3)のような確率変数  $z_{n,t,k}$  を導入する。この潜在データと提案する手法を適用する対象である観測データ  $\mathbf{y}$  を合わせた式(4)で示す完全データ  $\mathbf{x}$  の対数尤度関数  $LL_c$  は式(5)のようにあらわされる。対数尤度関数  $LL_c$  は任意の一車両一時点における車両挙動の属するグループが既知である場合の車両挙動モデルの尤度である。なお、各車両挙動モデルのパラメータ  $\theta_k$  以外に各グループの車両挙動が観測される確率もパラメータ  $\pi_{ntk}$  として扱う。

$$\{z\}_{n,t,k} = z_{ntk} = \{0,1\} \quad (3)$$

$$\mathbf{x} = (\mathbf{y}, \mathbf{z}) \quad (4)$$

$$\begin{aligned} LL_c(\theta|\mathbf{x}) &= \sum_{n,t} \log(\pi_{ntk} f_k(\mathbf{y}_{nt}|\theta_k)) | z_{ntk} = 1 \\ &= \sum_{n,t,k} z_{ntk} (\log \pi_{ntk} + \log f_k(\mathbf{y}_{nt}|\theta_k)) \end{aligned} \quad (5)$$

- $\mathbf{x}$  : 完全データベクトル
- $\mathbf{y}$  : 観測データベクトル
- $\mathbf{z}$  : 潜在データベクトル
- $\boldsymbol{\theta}$  : 全パラメータベクトル
- $\boldsymbol{\theta}_k \subset \boldsymbol{\theta}$  : グループ  $k$  の  
車両挙動モデルのパラメータベクトル
- $\pi_{ntk} \in \boldsymbol{\pi}$  : 各グループの車両挙動が観測される  
確率 (モデルパラメータの1つ)
- $f_k(\cdot)$  : グループ  $k$  の車両挙動モデルの尤度

式(5)で示した完全データに対する対数尤度関数  $LL_c$  に関して、推定パラメータが  $\boldsymbol{\theta}^{(m)}$  となる場合の条件付き期待値  $Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(m)})$  は式(6)のようにあらわされる。EMアルゴリズムでは、この対数尤度関数の期待値の極大点が尤度関数の極大点と一致することを利用してパラメータを求める。このとき各グループの車両挙動が観測される確率もパラメータ  $\pi_{ntk}$  として計算されるため、極大点を求めると同時に各グループへの確率的な分類が実行される。

$$\begin{aligned}
 Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(m)}) &= E[LL_c(\boldsymbol{\theta}) | \mathbf{y}, \boldsymbol{\theta}^{(m)}] \\
 &= \sum_{n,t,k} E[z_{ntk} | \mathbf{y}, \boldsymbol{\theta}^{(m)}] \log \pi_{ntk} \\
 &\quad + \sum_{n,t,k} E[z_{ntk} | \mathbf{y}, \boldsymbol{\theta}^{(m)}] \log f_k^{(m)}(\mathbf{y}_{nt} | \boldsymbol{\theta}_k)
 \end{aligned} \tag{6}$$

$\boldsymbol{\theta}^{(m)}$  : 繰り返し計算  $m$  回目の  
パラメータベクトル

式(6)における潜在データ  $z_{ntk}$  の期待値  $w_{ntk}^{(m)}$  はベイズの定理による事後確率の評価より、式(7)で求めることができる。この期待値は推定パラメータが  $\boldsymbol{\theta}^{(m)}$  となる場合の条件付きの統計量である。このときの計算過程はEMアルゴリズムにおいてE (Expectation)-Stepと呼ばれている。

E-step :

$$\begin{aligned}
 w_{ntk}^{(m)} &= E[z_{ntk} | \mathbf{y}, \boldsymbol{\theta}^{(m)}] \\
 &= \frac{\pi_{ntk}^{(m)} f_k^{(m)}(\mathbf{y}_{nt} | \boldsymbol{\theta}_k^{(m)})}{\sum_l \pi_{ntl}^{(m)} f_l^{(m)}(\mathbf{y}_{nt} | \boldsymbol{\theta}_l^{(m)})}
 \end{aligned} \tag{7}$$

式(7)で求めた期待値  $w_{ntk}^{(m)}$  を定数とみなすと、対数尤度関数の期待値  $Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(m)})$  の最大値を求める式(8)の計

算は比較的容易になる。この計算過程はE-Stepと同様、M (Maximization)-Stepと呼ばれている。EMアルゴリズムは式(7)、式(8)のE-StepとM-Stepを繰り返し計算することで、尤度関数の極大点にパラメータを収束させるアルゴリズムである。このアルゴリズムでは繰り返し計算の中で尤度関数が非減少となることが数学的に証明されており、解の収束が保障されている。

M-step :

$$\boldsymbol{\theta}^{(m+1)} = \arg \max_{\boldsymbol{\theta}} Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(m)}) \tag{8}$$

式(6)の右辺の対数尤度は各グループの車両挙動が観測される確率の項と、各グループの対数尤度の項の和となっており、それぞれ別のパラメータを持つことから、これら2つの項を個別に最大化することで期待値  $Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(m)})$  の最大値を求めることができる。前者の最大化では、式(9)の最大化問題を解き、式(10)の関係式を得る。後者、各グループの対数尤度の項の最大化に関しては、各グループのモデルパラメータ  $\boldsymbol{\theta}_k$  が独立であれば、式(11)で示した  $w_{ntk}^{(m)}$  の重み付の尤度最大化問題を各グループについて解けばよい。

$$\boldsymbol{\pi}^{(m+1)} = \arg \max_{\boldsymbol{\pi}} \sum_{n,t,k} w_{ntk}^{(m)} \log \pi_{ntk} \tag{9}$$

s.t.

$$\sum_k \pi_{ntk} = 1 \quad \forall n, \forall t$$

$$\pi_{ntk}^{(m)} = w_{ntk}^{(m-1)} \tag{10}$$

$$\boldsymbol{\theta}_k^{(m+1)} = \arg \max_{\boldsymbol{\theta}_k} \sum_{n,t,k} w_{ntk}^{(m)} \log f_k^{(m)}(\mathbf{y}_{nt} | \boldsymbol{\theta}_k) \tag{11}$$

### (3) ガウス分布誤差を持つ追従モデルへの適用

提案する手法を適用するにあたり、グループ数と各グループの車両挙動観測データに対する尤度関数形を仮定する必要がある。ここで仮定する尤度関数の例として、ガウス分布の誤差を持つ式(12)のような追従モデル式の尤度関数を取り上げ、以降ではその計算過程について論じる。なお、この追従モデル式は反応遅れ  $\tau_k$  を伴った説明変数  $\mathbf{y}_n(t - \tau_k)$  とパラメータ  $\boldsymbol{\theta}'_k$  に関する線形式である。

$$\mathbf{a}_{ntk} = \boldsymbol{\theta}'_k{}^T \mathbf{y}_n(t - \tau_k) + \mu_k + \varepsilon \tag{12}$$

- $a_{ntk} \in \mathbf{y}_{nt}$  :  $t$  時点における加速度
- $\mathbf{y}_n(t - \tau_k) \in \mathbf{y}_{nt}$  : 時間  $\tau_k$  の遅れを伴う  
加速度説明変数
- $\mu_k \in \boldsymbol{\theta}_k$  : 加速度定数パラメータ
- $\boldsymbol{\theta}'_k \in \boldsymbol{\theta}_k$  : 加速度線形パラメータベクトル
- $\tau_k \in \boldsymbol{\theta}_k$  : 反応遅れパラメータ
- $\varepsilon \sim N(\mathbf{0}, \sigma_k^{2(m)})$  : 誤差
- $\sigma_k^{2(m)}$  : 加速度の分散  
(確率密度パラメータ)

式(12)に示した追従モデル式の確率密度関数  $f_k^{(m)}$  は、式(13)のようにあらわされる。誤差がガウス分布であることから反応遅れパラメータ  $\tau_k$  以外の線形のパラメータは式(11)で示した重み付重回帰分析の結果として得ることができる。反応遅れパラメータ  $\tau_k$  は重回帰分析結果における適合度が最も高くなるような値を反応遅れとして適当な範囲 (0~5秒) の中で探索することで求めることができる。また、確率密度関数  $f_k^{(m)}$  には、モデルパラメータとは別に確率密度自体に関する分散パラメータ  $\sigma_k^{2(m)}$  を含む。このパラメータの値は、式(14)に従い繰り返し計算の中で更新してゆく。

$$f_k^{(m)}(\mathbf{y}_{nt} | \boldsymbol{\theta}_k) = \frac{1}{\sqrt{2\pi\sigma_k^{2(m)}}} \exp\left(-\frac{(a_{ntk} - \boldsymbol{\theta}'_k{}^T \mathbf{y}_n(t - \tau_k) - \mu_k)^2}{2\sigma_k^{2(m)}}\right) \quad (13)$$

$$\boldsymbol{\theta}_k = (\boldsymbol{\theta}'_k, \tau_k, \mu_k)$$

$$\sigma_k^{2(m+1)} = \frac{\sum_{n,t} w_{ntk}^{(m)} (a_{ntk} - \boldsymbol{\theta}'_k{}^T \mathbf{y}_n(t - \tau_k) - \mu_k)^2}{\sum_{n,t} w_{ntk}^{(m)}} \quad (14)$$

### 3. 実車両軌跡データへの適用

本節では提案したクラスタリング手法を実データに適用した1例を示し、分類結果から得られる知見について考察する。

#### (1) モデル形とクラスタ数

実データに適用するにあたり、線形式(12)の各パラメータと説明変数を具体的にデータに合わせた形で表した加速度式を式(15)に示す。用いている説明変数は対象車両の速度、前方車両との相対速度・相対距離の広く利用されているGMモデル<sup>11)</sup>でも考慮されている3種類である。

また、クラスタ数は分析を容易にするため2つに設定し、それぞれのクラスタに対する尤度関数には式(12)から導出される同一のものを設定した。

$$a_{ntk} = \theta_{k1} \dot{x}_{t-\tau_k}^n + \theta_{k2} (\dot{x}_{t-\tau_k}^l - \dot{x}_{t-\tau_k}^n) + \theta_{k3} (x_{t-\tau_k}^l - x_{t-\tau_k}^n) + \mu_k + \varepsilon \quad (15)$$

- $\boldsymbol{\theta}_k = (\theta_{k1}, \theta_{k2}, \theta_{k3}, \mu_k, \tau_k)$  : 車両挙動パラメータ
- $x_t^f$  : 時刻  $t$  における  
後続の対象車両位置
- $x_t^l$  : 時刻  $t$  における  
先行車両位置
- $\dot{x}_t^n$  : 車両速度

具体的なEMアルゴリズムによる繰り返し計算は式(7), (10), (11), (13), (14)に従う。この計算を実行するにあたりパラメータの初期値を式(16)のように与えた。各グループの車両挙動が観測される確率を各グループに対して均等に与えた場合、尤度関数が各グループに対して対称であるため、収束計算は鞍点である初期値に収束してしまうと考えられる。よって、鞍点ではない極大値に収束する可能性を高めるため、各グループの車両挙動が観測される確率を示すパラメータの値として式(16)に示したように1/3と2/3を交互に各車両・各時刻に対して定義した。なお、この初期値を0,1という極端な値とした場合、式(7)の定義からもわかるように繰り返し計算の中で値が更新されなくなる。よって、本研究では初期値に1/3と2/3の値を採用した。

$$\pi_{ntk}^{(0)} = \frac{1 + ((t+k) \bmod 2)}{3} \forall n, t, k \quad (16)$$

$$\boldsymbol{\theta}_k^{(0)} = \mathbf{0} \forall k$$

#### (2) 検証データ

本稿で検証に用いたデータは阪神高速道路1号環状線と12号守口線が合流する区間とその上流において、2005年8月30日8:49:00~9:04:00の15分間に連続する11台のビデオカメラで撮影された画像から抽出した車両走行軌跡データ<sup>11)</sup>である。当該データは0.2秒間隔で車両の位置を記録したものであり、詳細な車両挙動を分析するためには十分な時空間解像度を有しているといえる。

推定にはこの走行軌跡に含まれる車両の内、環状線側から合流部に流入しつつ同一車線を20秒以上、前方車両

が観測区域内に存在する状態で走行し続けた車両の軌跡を利用した。当該データは対象車両の車線変更を伴わないものである。ここで、前方車両と定義した車両は、対象車両と同一車線上の車両、もしくは同一車線に進入しようとする車線を移動している車両のうち、対象車両よりも下流に存在し、対象車両に最も近い車両である。最終的に抽出された車両は142台、合計3,600秒間のデータである。よって、パラメータ  $\pi_{nik}$  は2グループ×(3600 / 0.2)ステップの36,000個定義される。

EMアルゴリズムによる計算では繰り返し回数100回程度で全パラメータの更新幅が十分小さくなり計算を終了させた。なお、繰り返し1回分の計算時間は1~3秒程度であった。

### (3) 分類したグループにおけるの推定パラメータ

車両挙動のクラスタリングに伴い推定されたモデルパラメータと分類された2つのグループA,Bに関する統計量を表1に示す。

まず、2つのグループそれぞれに対応する車両挙動の割合はほぼ同一の割合となり、提案した手法によって車両挙動が2分されたことがわかる。推定されたモデルパラメータは2つのグループで大きく異なり、中でも速度と反応時間のパラメータに大きな違いが見られた。グループAはグループBと比較して相対速度と相対距離のパラメータ値が小さく定数項が大きな負の値となっており、さらに反応時間が小さいことから、説明変数以外の合流部などの影響により減速を余儀なくされている状況であると考えられる。重回帰分析における適合度も0.39と小さいことから説明変数以外の要因が影響を及ぼしている

表1 クラスタリングにおける各モデルの推定値と各グループの統計量

グループ	A	B
割合	46.0%	54.0%
重回帰 $R^2$	0.39	0.80
モデルパラメータ：		
速度 $\theta_{k1}$	0.11	-0.06
相対速度 $\theta_{k2}$	0.08	0.15
相対距離 $\theta_{k3}$	0.0024	0.0030
定数 $\mu_k$	-2.27	0.78
反応時間 $\tau_k$	0.61	2.11
平均値±標準偏差：		
加速度	-0.20±0.71	-0.27±0.43
速度	18.5±3.7	18.5±2.8
相対速度	56.6±45.3	48.0±38.8
相対距離	-0.99±2.62	-0.92±2.09

ることが示唆される。一方、グループBは相対速度と相対距離のパラメータ値が比較的大きく、速度と定数項のパラメータ絶対値が比較的小さい。加えて、重回帰分析における適合度が高いことから、グループBは従来の追従モデルの構造に合致した追従挙動を示していると考えられる。なお、すべてのモデルパラメータは有意な値として推定された。これらのモデルパラメータは2つのグループで大きく異なるものの、各グループに対応する平均速度などの統計量に関しては2つのグループ間に大きな違いは見られない。よって、統計量となっている速度や相対距離等の説明変数を用いて車両挙動を適切に分類することは難しいといえる。

上述した本稿におけるデータの分類では、追従モデルの構造に合致した車両挙動のグループBと、その他の要

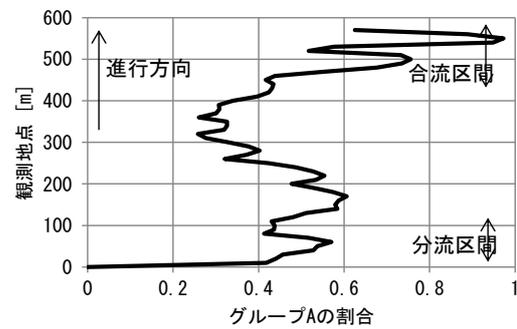


図1 各観測地点のグループAの割合

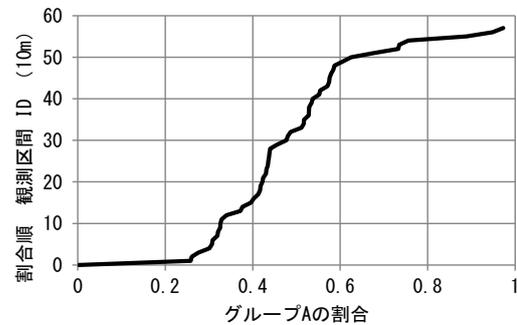


図2 観測区間別のグループAの割合

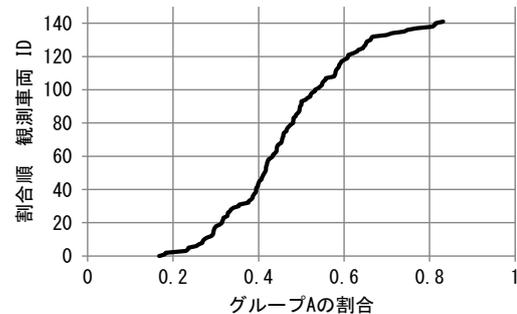


図3 車両別のグループAの割合

因の影響が大きい車両挙動のグループAに2分されたといえる。

#### (4) 分類したグループと走行位置・車両IDの関係

次に、本稿で扱った車両挙動の説明変数以外の因子と分類結果の関係について論じる。具体的には、クラスタリングによって2分されたグループそれぞれに対応する車両挙動がみられる走行位置と、各車両の挙動に対応するグループを分析する。この分析によって、車両挙動以外の因子によって車両挙動をクラスタリングできる可能性について考察する。

図1は走行位置と車両挙動のグループの関係について示したものである。図を見るとすべての分析車両は車線の移動を行っていないにも関わらず、観測区間の中における分流部と合流部においてグループAの車両挙動の割合が増加していることがわかる。グループAが外部要因の影響を受けている可能性が高いことを考慮すると、車両挙動のクラスタリングにおいて、本稿では扱っていない走行環境等の要因がグループを分ける重要な因子となりうる可能性があることが示唆されている。特に2つのグループの車両挙動の相違はモデルパラメータに表れていることから、走行環境等の要因と車両挙動モデルのパラメータとの間に深い関係性が存在する可能性が高い。

図2、図3はグループAの割合が少ない順にそれぞれ、10m毎の走行区間と車両IDを並べた図であり、走行位置と個人属性に対するグループAの分布を示しているといえる。これら2つの図より、走行区間に関するグループの分散がわずかに大きいことが読み取れるため、本稿において分析したデータの範囲内では、個人間の車両挙動の差異よりも走行位置による差異の方がわずかに大きいといえる。しかし、個人間の車両挙動の差異も十分に大きく、より精度の高い車両挙動モデルを構築するには、走行位置と個人間の差異の両方を同程度に考慮することが望ましいといえる。

#### 4. まとめ

本稿では、EMアルゴリズムを用いたk-means型の車両挙動のクラスタリング手法を提案した。提案した手法では分類する各車両挙動のモデル形と観測データに対する尤度関数を仮定する必要があり、本稿ではガウス分布の誤差を持つ線形の追従モデルを仮定した上で、実際の車両軌跡データに提案した手法を適用した。

実データにおけるクラスタリング結果では、追従モデルの構造に合致したグループと、その他の要因の影響が

大きいグループに車両挙動が2分された。同一車両内、同一区間内であっても双方のグループがある程度観測されることから、より精度の高い車両挙動モデルを構築するには、走行位置と個人間の差異の両方を同程度に考慮することが望ましいことが示唆された。また、分類された片方のグループがみられる車両の走行位置に大きな偏りがあったため、車両の走行環境が車両挙動モデルのパラメータに大きな影響を与えている可能性が示唆された。

#### 参考文献

- 1) 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.
- 2) Kometani, E., Sasaki, T. : On the Stability of TrafficFlow (Report 1), J, Oper. Res. Soc. Japan, Vol.2, No.1, pp.11-26, 1958.
- 3) Kometani, E., Sasaki, T. : On the Stability of TrafficFlow (Report 2), J, Oper. Res. Soc. Japan, Vol.2, No.2, pp.60-79, 1959.
- 4) 尾崎晴男：自動車の追従走行挙動に関する研究, 土木計画学研究・講演集, No.14(1), pp.375-380, 1991.
- 5) 柳原正実, 宇野伸宏, 嶋本寛, 塩見康博：ドライバー意図の遷移を考慮した統合型車両走行モデルの提案, 土木計画学研究・講演集, No.44, 2011.
- 6) 柳原正実, 宇野伸宏, 嶋本寛, 中村俊之：運転行動形態の推移を考慮した統合型追従モデルのコンフリクト再現性検証, 土木計画学研究・講演集, No.46, 2012.
- 7) Koutsopoulos, Haris N, Farah, Haneen : Latent class model for car following behavior, Transportation research part B: methodological, Vol.46, No.5, pp.563-578, 2012.
- 8) 楊燕, 大口敬, 井料美帆, 和田健太郎：高速道路サグ部における追従挙動モデルのパラメータ分布に関する研究, 生産研究, Vol.67, No.2 pp.119-124, 2015.
- 9) Ozaki, H. : Assistance of Drivers to Mitigate Highway Capacity Problem, Proc. of 2nd WC on ITS, pp.1727-1731, 1995.
- 10) Celeux, G., Govaert, G. : A classification EM algorithm for clustering and two stochastic versions, Computational Statistics & Data Analysis, Vol.14, Issue 3, pp.315-332, 1992.
- 11) Gazis, D. C., Herman, R., Rothery, R. W. : Nonlinear Follow-the Leader Models of Traffic Flow, Oper. Res., Vol.9, pp.545-567, 1961.
- 12) Kurauchi, F. : Queiroz, I. N. F., Iida, Y. and Higatani, A. : Traffic flow analysis using image processing technique, Proceedings of the 5th International Symposium on Highway Capacity and Quality of Service, Vol. 2, pp. 329-338, 2006.

(2015.?? 受付)

## A CLASSIFICATION BASED ON LIKELIHOOD FUNCTIONS OF CAR FOLLOWING MODELS

Masami YANAGIHARA

This paper provides a classification for car-following behaviours, that is varied and affected by surrounding environments, individual attributes, and the drivers' intentions. Several car-following models are used in general microscopic traffic simulations and car-following behaviour analysis. In order to support these studies, the provided method uses several likelihood of sub-car-following models used in some complex vehicle behavior models. EM algorithm is used for calculation of classification with some definitions of the number of groups and function forms for likelihoods of sub-models corresponding to each group.

In an empirical study with real car-trajectory data, vehicles' behaviors are classified into 2 groups of approximately the same size. The one group well matches to the car-following model and the other is affected by external factors.