情報処理学会論文誌　Vol. 51　No. 1　131–140 (Jan. 2010)

確率的手法を用いた車線変更軌跡のモデル化

西脇 由博[†1]　宮島 千代美[†1]
北岡 教英[†1]　武田 一哉[†1]

個々のドライバの運転傾向とそのゆらぎを表現する，統計的信号処理に立脚する運転行動モデルを提案し，車線変更時の車両軌跡のモデル化に適用した．提案法では，ドライバはあらかじめ様々な車両軌跡を想定し，それらの中から最も好ましい軌跡を交通環境に応じて選択すると仮定し，2 つの処理により運転軌跡を生成する．第 1 の処理では，車両位置とその時間変化の時系列をモデル化する隠れマルコフモデルにより，ドライバの運転傾向が表現され，第 2 の処理では周辺車両に対する車間距離分布により，ドライバの車両間隔特性が表現される．隠れマルコフモデルから高い確率で生成される車両軌跡の仮説群を生成し，それらの中からドライバの車両間隔特性を最も高い確率で満たす軌跡を選択することで，与えられた初期条件，周辺車両配置に対して，ドライバの特性に応じた車両軌跡が予測される．評価実験の結果，20 秒程度にわたって行われる車線変更の軌跡を，17.6 m の二乗平均平方根誤差で予測することが可能であること，ドライバごとの特性を適切に表現する軌跡が生成されていることが確認され，提案法の有効性が明らかになった．

A Stochastic Approach for Modeling Lane-change Trajectories

Yoshihiro Nishiwaki,[†1] Chiyomi Miyajima,[†1]
Norihide Kitaoka[†1] and Kazuya Takeda[†1]

A signal processing approach for modeling vehicle trajectories during lane-change maneuvers is discussed. Since individual driving habits are not deterministic processes, we model vehicle trajectories using a stochastic method. The proposed model consists of two parts: a dynamic system represented by a hidden Markov model and a cognitive distance space derived from a range distance distribution for surrounding vehicles. The first part models the local dynamics of vehicular movements and generates a set of probable trajectories. The second part selects an optimal trajectory by stochastically evaluating the distances from surrounding vehicles. Experimental evaluation shows that the model can predict the vehicle trajectory at given traffic conditions with a 17.6 m prediction error for two different drivers.

1. はじめに

自動車交通の安全性や効率は社会に大きな影響を与えている．交通事故による死亡者数は減少傾向にあるとはいえ，2007 年には日本で約 6,000 人が交通事故により死亡しておりその社会的損失は計り知れない[1)]．さらに，石化エネルギーの不足も交通死亡事故と同様に，自動車交通に関連する深刻な社会問題である．衝突未然安全技術やハイブリッド自動車の開発など，これらの問題の解決に貢献する自動車車両技術の開発が進められている[2)–4)]．

一方，自動車交通の主体である「ドライバ」の行動に関する工学的なモデルの研究は車両の物理挙動モデルの研究[5)–9)] に比べて遅れており，ドライバ状態の理解や運転操作の予測といった，ドライバを中心とした安全性や効率に関する技術の普及は進んでいない．関連した研究として，Danielsson らは，与えられた車両の周囲車両の動きを数秒間の範囲で予測する方法を報告しているが[10)]，ドライバごとの運転行動の違いは考慮されておらず，モデルの性能も定量的には評価されていない．Althoff らは，車両や歩行者の存在確率を統計的にモデル化し，数秒先の衝突可能性について議論しているが[11)]，同様にドライバの個人性は考慮されておらず，定量的な予測性能評価も行われていない．物理法則に従う車両の挙動と異なり，人間の運転行動は確定的でないため，ドライバの個人性を定量的に扱うためには，主に制御理論に立脚した従来研究に統計的なアプローチを導入することが必要であると考えられる．

そこで本論文では，ドライバごとの車両軌跡の違いを統計的にモデル化し，初期条件と周囲状況に応じて車線変更の軌跡を予測する方法を提案する．提案する方法では，車両軌跡を表す統計モデルのパラメータが，観測された走行データ群から，最大尤度規範に基づいて学習可能であり，ドライバごとのモデルを容易に構築することができる．さらに提案法では，隠れマルコフモデル（HMM: Hidden Markov Model）を用いることにより，車線変更のような複数の運転状態の組合せにより構成される運転行動であっても，状態間の遷移を陽に観測することなくモデルパラメータを推定することが可能である．このため従来の研究では困

†1 名古屋大学
Nagoya University

© 2010 Information Processing Society of Japan

難であった，20 秒程度の時間にわたる車両挙動の予測も容易に実現可能である．

提案法は，**図 1** に示す 2 つの部分から構成される．第 1 の部分は，交通流とドライバ自身の運転性向に起因する車両の動的特性の統計的性質を HMM によりモデル化する．車線変更は，「周辺車両の確認」，「車線の移動」，「移動先車線での交通流への適応」といった複数状態から構成されるため，単一の動的特性だけで記述することは困難である．さらに，その状態間の明確な境界は観測できない．HMM はそのような確率的な状態遷移をモデル化することが可能であり，EM アルゴリズムを用いることで，状態間の遷移境界が与えられなくても，状態ごとのモデルパラメータを学習することが可能である[12]．さらに，状態ごとの信号 $x[n]$ とその時間微分 $\Delta x[n]$ との結合確率密度と状態遷移系列が与えられれば，最も確からしい信号系列 $\{x[n]\}_{n=1,\cdots,N}$ を計算することができる[13]．すなわち，この過程ではドライバごとの運転特性を反映した車両軌跡の仮説群が生成される．

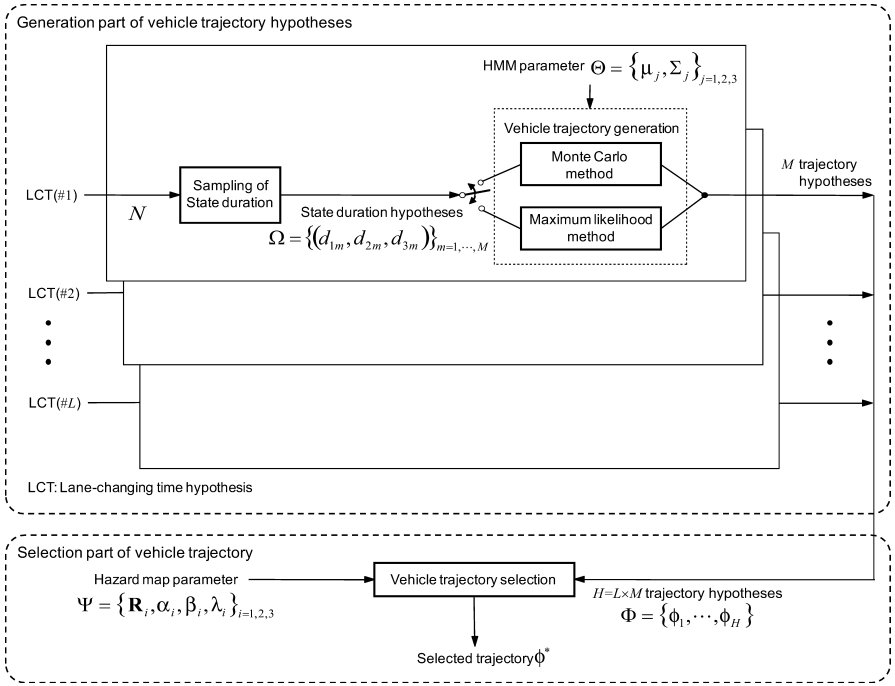

図 1　車両軌跡生成の枠組み
Fig. 1　Framework of the lane change trajectory generation.

第 2 の部分は，周辺車両に対する車間距離に応じて危険を感じるドライバの認知的な特性よって特徴づけられる．ここでは通常走行下で観測された周辺車両と自車両との車間距離の分布によって，ドライバごとの車間距離—危険認知特性（以下，ハザードマップと呼ぶこととする）がモデル化される．ハザードマップを用いることで，ドライバごとの運転特性を反映した車両軌跡群の中から車両環境に応じて適切な車両軌跡を選択することが可能になる．最終的に 2 つを統合することでドライバの特性を考慮した車両軌跡生成アルゴリズムを提案する．すなわち，初めに HMM の各状態の確率分布をサンプリングすることで車両軌跡の仮説群を生成し，認知的なハザードマップによって最適な車両軌跡を選択する．

次章から提案手法と評価について述べる．2 章と 3 章では，HMM を用いた生成モデルと認知的なハザードマップをそれぞれ議論する．本手法の実験的な評価は 4 章で述べる．最後に 5 章で結論と今後の課題について述べる．

2.　HMM を用いた車両軌跡の生成

2.1　車両軌跡データ

走行方向と横方向の車両の位置を，$x_i[n]$，$y_i[n]$，その速度をそれぞれ $\dot{x}_i[n]$，$\dot{y}_i[n]$ とする．ここで，$i = 1$，2，3 は，**図 2** に示すとおり周辺車両のインデックスで，$i = 1$ は走行

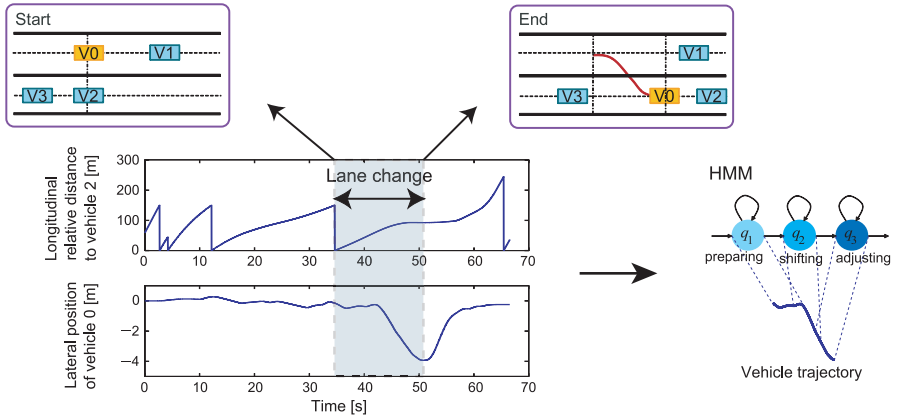

図 2　車線変更時の車両軌跡と周辺車両の幾何学的配置（V0 が車線変更を行う車両）
Fig. 2　Lane change trajectory and geometric positions of surrounding vehicles. V0 is the vehicle changing lanes.

© 2010 Information Processing Society of Japan

車線の先行車両，$i=2$ は追越車線の先行車両，$i=3$ は追越車線の後方車両をそれぞれ示す．$i=0$ は自車両を表し，$(x_0[n], y_0[n])$ はそれぞれ自車両の縦方向（進行方向）と横方向の位置を示す．車線変更行動の時間区間 $n=1,\cdots,N$ は，図 2 に示すように V0（自車両）と V2 の進行方向の位置が等しい（車両が並んだ）ときを開始時点，V0 の横方向の位置が最小となった時点（最も右に移動した時点）を終了時点とした．

2.2　隠れマルコフモデル

図 2 に示すように車線変更の準備，移動，調節の 3 つの異なる段階をモデル化するために 3 状態の HMM により車両軌跡のモデル化を行った．車線変更時の車両軌跡は，いくつかの異なる動的性質を持つ軌跡の連接で与えられる動的システムであると考えられる．HMM を用いることの利点は，これらの部分軌跡間の境界を陽に与えなくても各部分軌跡に対応するパラメータを学習できる点である．提案するモデルでは，交通流とドライバ自身の運転性向に起因する車両の動的特性の統計的性質が，次に示す 8 次元の走行観測信号 $\mathbf{v}$ の結合確率として特徴づけられる．

$$\mathbf{v} = [\dot{x_0}, y_0, \Delta\dot{x_0}, \Delta y_0, \Delta^2\dot{x_0}, \Delta^2 y_0, \dot{x_1}, \dot{x_2}]^t \tag{1}$$

これらの変数群の結合確率は，信号とその時間微分（動的特徴量）との関係を確率的に表現する相平面に対応付けることができ，車線変更軌跡の動的な性質を表現すると考えられる．本研究では，結合確率を多次元ガウス分布を用いて表現した．

まず，走行観測信号 $\mathbf{v}$ は，自車両の進行方向速度 $\dot{x_0}$ と横方向位置 y_0 からなる基本位置変数を基に構成される．ここで，基本位置変数として，進行方向位置ではなく速度を用いたが，これは，進行方向位置は車線変更を通じてつねに前方に移動（単調増加）しており，位置が減少することは物理的に不自然であるにもかかわらず，位置を確率変数として扱いサンプリングを行うことで，進行方向とは逆の方向に進むサンプルが生じてしまう場合があるためである．

さらに，基本位置変数に対して，次式に示す 1 次動的特徴量（$\Delta\dot{x_0}$，Δy_0）および，2 次動的特徴量（$\Delta^2\dot{x_0}$，$\Delta^2 y_0$）を加えることで，2 次遅れまでを考慮した動的システムとして車両軌跡をモデル化することが可能となる．

$$\Delta x[n] = \frac{\displaystyle\sum_{k=-K}^{K} k \cdot x[n-k]}{\displaystyle\sum_{k=-K}^{K} k^2} \tag{2}$$

ここで，K は動的特徴量計算時の窓幅を，$x[n]$ は時刻 n における信号をそれぞれ示す．なお，2 次動的特徴量は，式 (2) において $x[n]$ の代わりに $\Delta x[n]$ を適用することで得られる．これらの動的特徴量を用いることで，文献 13) の最尤信号生成アルゴリズムで示されるように，生成されるサンプル間の動的な特性が考慮され，単に平均ベクトルを出力するような生成系列ではなく，平均ベクトル間を滑らかにつなぐ信号が生成される．一方，先行車 2 台の速度（$\dot{x_1}$，$\dot{x_2}$）は，それぞれのレーンの平均的な交通流の速度を考慮するために走行観測信号の変数群に加えた．

最終的に，観測された車両軌跡データを用いて HMM を学習することで，車両軌跡の変数群 $\mathbf{v}[n]$ の平均ベクトル μ_j と共分散行列 Σ_j が HMM の状態 $j=1$，2，3 に対して推定される．一方，車線変更時間 N の分布は，車両軌跡とは独立にガウス分布でモデル化する．

2.3　車両軌跡仮説群の生成

後述の実験において示すように，提案モデルにおいて車両軌跡の形状は，HMM と車線変更の継続時間によって支配される．たとえば，ドライバが車線変更を短い時間で行う場合，一般に急峻な形状の車両軌跡が用いられる．そこでまず，図 1 に示すように，学習された車線変更時間の分布を以下の方法によりサンプリングし，車線変更を構成する状態（「周辺車両の確認」，「車線の移動」，「移動先車線での交通流への適応」）ごとの継続時間長の M 個の仮説群 $\Omega = \{(d_{1m}, d_{2m}, d_{3m})\}_{m=1,\cdots,M}$ を生成する．

初めに車線変更時間 N の仮説を，観測データに基づき学習した車線変更時間の分布をサンプリングすることで生成し，得られた N に対して，状態継続長 d_{jm} を次式に示すように一様分布からサンプリングすることで得る．

$$d_{jm} = \left\lceil \frac{\xi_{jm} N}{\sum_{s=1}^{S} \xi_{sm}} \right\rceil \tag{3}$$

ここで，ξ_{jm} は区間 $(0,1]$ の一様分布に従う確率変数である．また，$\lceil . \rceil$ は天井関数を，$S=3$ は HMM の状態数をそれぞれ示す．車線変更時間 N と状態継続長 d_{jm} は実際にはポイント数であるが，図示する際には秒単位で表示していることに注意されたい．いったん，状態継続長の仮説群 Ω と車線変更直前の走行観測信号 $\mathbf{v}[0]$ が決まれば，HMM のパラメータ $\Theta = \{\mu_j, \Sigma_j\}_{j=1,2,3}$ を用いて，最尤信号生成アルゴリズム[13),14)] あるいはモンテカルロ法（付録 A.1 参照）により学習したドライバの特徴をとらえた M 個のもっともらしい車両軌跡の仮説群が生成できる．この操作を L 回繰り返すことで，$H = L \times M$ 個の車両軌跡の仮説群 $\Phi = \{\phi_1, \cdots, \phi_H\}$ が得られる．ここで，ϕ は 1 つの車両軌跡仮説を示す．

© 2010 Information Processing Society of Japan

3. 車両軌跡の選択

前章では，状態ごとの継続時間を仮定することで，HMM を用いてドライバごとの特性に応じた車両軌跡群を生成することができることを示した．しかし，周辺車両状況が与えられた実際の交通環境の下では，実現可能な車両軌跡は限定される．すなわち，生成された車両軌跡群のうち，周辺車両の極端に近くを通過する軌跡が利用されることはない．このように，ドライバが危険と感じる車間距離は，ドライバや方向によって異なると考えられる．このような，周囲車両との間の車間距離と認知される危険度との関係をスコアリングした関数を，「ハザードマップ」と呼ぶ．ドライバごとにハザードマップを構築することで，HMM から生成された車線変更軌跡仮説群の中から周囲交通状況に適した軌跡を選択することができる[⋆1]．

提案手法において，ハザードマップ $\mathcal{M}(\mathbf{r}_i)$ は周囲の車両との相対距離 $\mathbf{r}_i = [x_i - x_0, y_i - y_0]^t$ の分布に基づいて構成される．まず，通常走行を観測したデータを利用するなどにより，相対距離 $\mathbf{r}_i$ の分散共分散行列 $\mathbf{R}_i$ を計算することができる．次に，走行を通じて車間距離の変動が少ない場合，当該車両に対して車間距離の感度がより高いと考え，車間距離の認知的な指標として，観測された相対距離ベクトルの二次形式を，分散共分散行列の逆行列 $\mathbf{R}_i^{-1}$ を重み行列として計算したものを利用した．したがって，周辺車両 Vi に対するハザードマップ $\mathcal{M}(\mathbf{r}_i)$ は次式で計算される．

$$\mathcal{M}(\mathbf{r}_i) = \frac{1}{1 + \exp\left\{\alpha_i \left(\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i - \beta_i\right)\right\}} \tag{4}$$

ここで，**図 3** に示すように，α_i は学習データに対して計算した認知距離 $\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i$ の最小値が，ハザードマップの 5%分布値に対応するように定義された最小の安全距離を示すパラメータである．また，β_i を認知距離 $\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i$ の平均値が，ハザードマップの 50%分布値（中央値）に対応するように定義する．

$$\mathcal{M}\left(\min\{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i\}\right) = 0.95 \tag{5}$$

$$\mathcal{M}\left(\overline{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i}\right) = 0.5 \tag{6}$$

⋆1 車両軌跡仮説群の生成では交通流に車両軌跡を適応させるために周辺車両の速度を用いた．一方，ハザードマップでは周辺車両までの距離を用いており，車両軌跡の生成部と選択部でそれぞれ異なる周辺車両の情報を利用している．

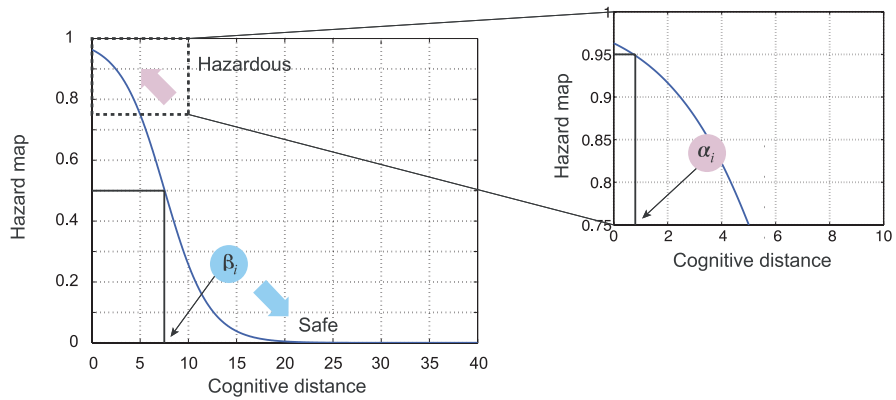

図 3　ハザードマップのパラメータ
Fig. 3　Parameters of a hazard map.

ハザードマップのパラメータ α_i と β_i は，式 (5)，(6) を α_i と β_i に関して解くことで，式 (7)，(8) のように推定される．

$$\alpha_i = \frac{\log(0.05) - \log(0.95)}{\min\{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i\} - \overline{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i}} \tag{7}$$

$$\beta_i = \overline{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i} \tag{8}$$

ハザードマップ $\mathcal{M}$ は $[0, 1)$ の値をとり，値が大きいほどドライバはより危険な状況にいることを示している．このことから，車線変更を通して $\mathcal{M} > 0.95$ となる車両軌跡の仮説は危険な車両軌跡として棄却することとした．

ハザードマップ $\mathcal{M}$ は，尤度が次のような二次形式指数関数で与えられるとき，

$$\Pr\{\mathbf{r}|\text{safe/unsafe}\} \propto \exp\left\{-\frac{1}{2}\mathbf{r}^t \mathbf{A} \mathbf{r}\right\} \tag{9}$$

相対距離が与えられた条件下での危険な状態である事後確率 $\Pr\{\text{unsafe}|\mathbf{r}\}$ として見ることができる．したがって，3 台の周辺車両のどれか 1 台に対して自車両が危険な状態にある確率，すなわち和事象の確率として，ハザードマップはそれぞれの周辺車両に対して求められた確率を重み λ_i で統合することで得られる．

$$\mathcal{M}' = \sum_i \frac{\lambda_i}{1 + \exp\left\{\alpha_i \left(\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i - \beta_i\right)\right\}} \tag{10}$$

© 2010 Information Processing Society of Japan

ドライバによって前方を重視する場合や後方を重視する場合など対応の仕方にばらつきがあると考えられるが，重み λ_i はこれらの重視する度合いを表している．ただし，本研究では後述の実験条件であるように，これらの重みを等しいものとし，最適な重みを推定しているわけではない点に注意されたい．時刻 n での周辺車両の位置 $\mathbf{r}_i[n]$ が決まれば，ハザードマップのパラメータ $\Psi = \{\mathbf{R}_i, \alpha_i, \beta_i, \lambda_i\}_{i=1,2,3}$ を基に $\mathcal{M}'$ は各時刻に対して計算され，その値の平均値を求めることで，図 1 に示す車両軌跡仮説群の生成部で得られた車両軌跡仮説群 Φ を評価することができる．最終的に，車両軌跡の仮説群の中でハザードマップ $\mathcal{M}'$ を最小とする最も安全な車両軌跡が最適な車両軌跡 ϕ^* として選択される．

4. 評　　価

4.1 データ収集および実験条件

ドライビングシミュレータを用いて，2 名のドライバに対してそれぞれ 30 回の車線変更を収録した．ドライビングシミュレータは 2 車線の高速道路を模擬しており，160 ms ごとに自車両と周辺車両のデータを収録することができる．車線変更開始時に自車両は各収録の平均で 112.4 km/h の速度で走行していた．また，追越車線には，速度が 82.8〜127.4 km/h，連続する 2 台の車間距離が 85〜315 m の条件で車両群が走行しており，ドライバは可能ならばいつでも好きなタイミングで，先行車両を追い越すために，追越車線に車線変更をするように指示されていた．また，30 回の収録は周辺車両の配置や速度を同一条件にして行った．

図 4 に 2 名のドライバの車線変更時間とその最尤状態継続長分布を示す．状態継続長分布は車線変更行動を特徴づける．たとえば，平均してドライバ B はドライバ A よりも車線変更に時間をかけ[⋆1]，車線変更全体に対して第 1 状態（周辺車両の確認，車線変更の準備）が占める時間の割合が小さい傾向にある[⋆2]．

提案手法を，30 回の走行の 3-fold クロスバリデーションによって評価した．つまり，20 回の走行で HMM とハザードマップを学習し，残り 10 回で評価を行う実験を 1 人あたり 3 通り（30 回），2 名の合計で 60 回行った．HMM の各状態を，車両軌跡の変数群 $\mathbf{v}[n]$ を確率変数として持つガウス分布によってモデル化した．また，車両軌跡の変数群の動的特徴量 Δ を窓幅 $2K = 320$ ms で計算した．HMM の学習には HTK [15] を用いた．

実験では，初めに各ドライバの車線変更時間のガウス分布から $L = 20$ 個の車線変更時間

⋆1 ただし，5%の有意水準を満たしておらず，統計的に有意な差ではない．
⋆2 5%の有意水準を満たし，統計的に有意な差が認められた．ただし，後述の実験では，状態継続長は一様分布からサンプリングされており，この差は軌跡生成には反映されていない．

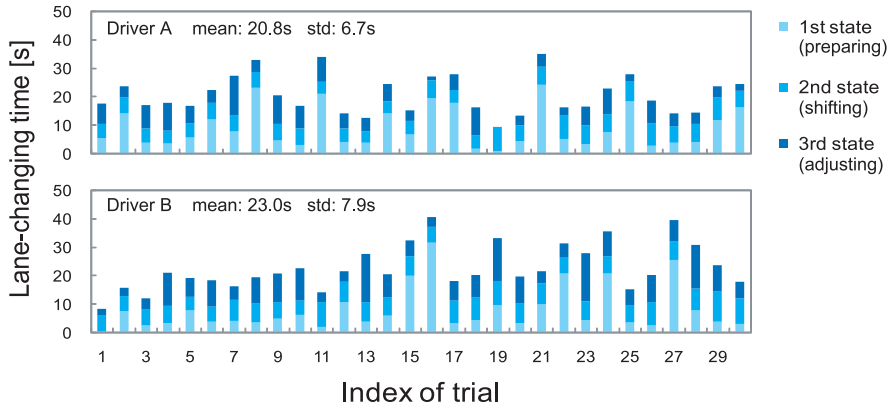

図 4　車線変更時間と学習した HMM から計算される最尤状態継続長分布
Fig. 4　Lane-changing time and its most probable state distribution calculated by the trained HMM.

をサンプリングし，次に式 (3) に基づいてそれぞれ $M = 20$ 組の状態継続長をサンプリングし，HMM から合計 $H = 400$ の車両軌跡からなる車両軌跡仮説群 Φ を生成した．最後に，最適な車両軌跡 ϕ^* を選択するために，式 (10) で示されるように 3 つのハザードマップを等しい重み $\lambda_{1,2,3} = 1/3$ で 1 つのハザードマップに統合して用いた．なお，車線変更中の周辺車両との相対距離を得るために周辺車両の動きを得る必要があるが，本研究では車線変更中の周辺車両速度 $\dot{x}_i$，$\dot{y}_i$ は一定であるという条件を仮定し，次式で周辺車両位置を計算した．

$$x_i[n] = x_i[n-1] + \dot{x}_i \cdot \Delta T \tag{11}$$

$$y_i[n] = y_i[n-1] + \dot{y}_i \cdot \Delta T \tag{12}$$

ここで，$\Delta T = 0.16$ s はサンプリング周期を示す．

生成手法の有効性を評価するため，2 つの評価実験を行った．1 つ目の実験では，車両軌跡仮説の生成方法を評価する．この実験では，状態ごとの継続時間長（d_{1m}，d_{2m}，d_{3m}）に従い，最尤軌跡を計算する方法とモンテカルロ法を用いてサンプリングを行う方法とを比較する．実際の車両軌跡との間の最小誤差と平均誤差により，車両軌跡仮説群 Φ の評価を行った．2 つ目の実験では，生成された車両仮説群に対してハザードマップを適用することで選択した車両軌跡 ϕ^* を，実際の車両軌跡と比較評価し，ドライバ依存のモデルがドライバごとの運転特性を反映した車両軌跡を生成しているかを検証した．

© 2010 Information Processing Society of Japan

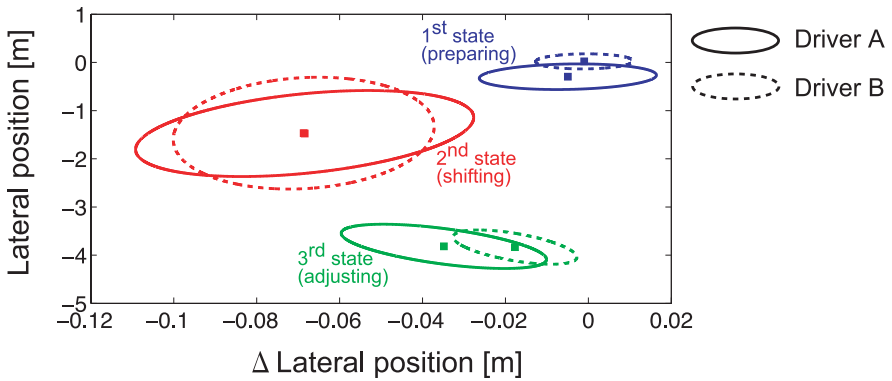

図 5　HMM の各状態における車両軌跡特徴量の結合確率（Δy と y のみのプロット）

Fig. 5　Joint pdfs of trajectory variables trained for each state of two drivers (only plotted for Δy and y). The square shows the mean and the contour represents the 'one sigma' boundary.

4.2　実験結果

学習した 2 名のドライバの HMM の各状態の結合確率分布の 1 シグマ境界を**図 5** に示す．第 3 状態の横方向の動的特徴量の分布において，ドライバ A の平均値がドライバ B の平均値より絶対値で大きいなど，ドライバごとに異なるパラメータが学習されていることが分かる．車線変更終了直前 5 秒間の横方向速度の平均はドライバ A，B でそれぞれ，0.19 m/s，0.13 m/s であり，両者の間には 2.2%の有意水準で有意差が認められた．このように HMM が車線変更での運転行動の違いを実際にモデル化できていることが確認できる．**図 6** に示すハザードマップ $\mathcal{M}'$ はドライバの車両間隔に対する統計的性質の違いを示している．たとえば，ドライバ B はドライバ A に比べハザードマップの等高線が緩やかであるなど，同一の周辺車両配置においても両者の違いが見られる．

ここで，平均的な車線変更時間である 20 秒の車両軌跡において最尤信号生成アルゴリズムとモンテカルロ法を用いて生成された車両軌跡を**図 7** と**図 8** にそれぞれ示す．おおよそ 600 m の走行を予測しているが，ドライバごとに異なる軌跡が予測されている．

さらに定量的に評価するために，生成された車両軌跡と実際の車両軌跡の違いを正規化された二乗誤差を局所的な距離として持つ動的計画法（DTW: Dynamic Time Warping）を用いて評価した．

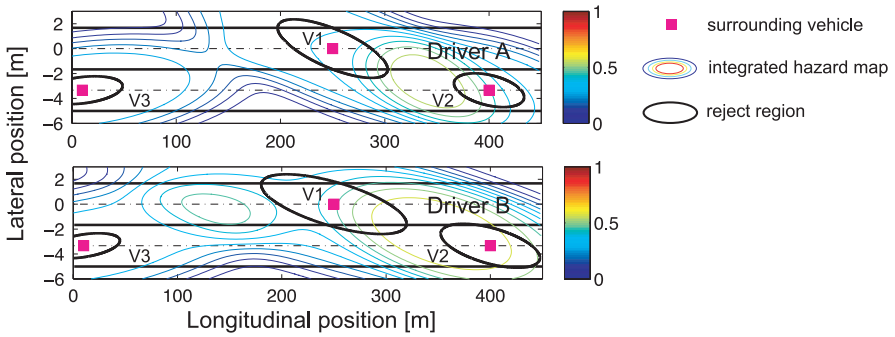

図 6　周辺車両が同じ位置にある場合の学習したハザードマップ

Fig. 6　Trained hazard maps of two drivers when the same geometric positions of surrounding vehicles are given.

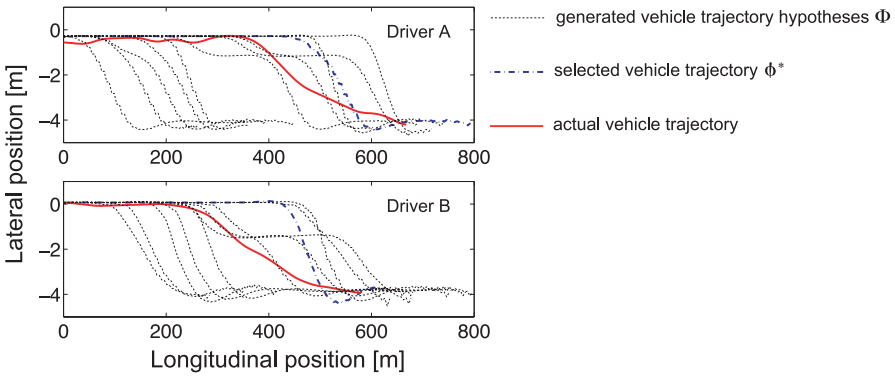

図 7　最尤信号生成アルゴリズムを用いた場合の生成された車両軌跡

Fig. 7　Examples of the generated (dotted lines) and the selected (a broken line) trajectories for maximum likelihood signal synthesis algorithm. The actual trajectory observed under the given condition is also plotted by a solid line.

$$D(i,j) = \min \begin{cases} D(i-1,j) \\ D(i-1,j-1) \\ D(i,j-1) \end{cases} \tag{13}$$

© 2010 Information Processing Society of Japan

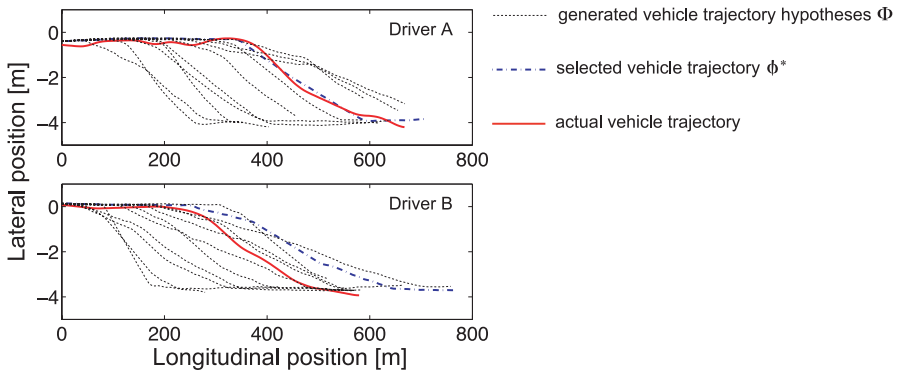

図 8　モンテカルロ法を用いて生成された車両軌跡

Fig. 8　Examples of the generated (dotted lines) and the selected (a broken line) trajectories for sampling method. The actual trajectory observed under the given condition is also plotted by a solid line.

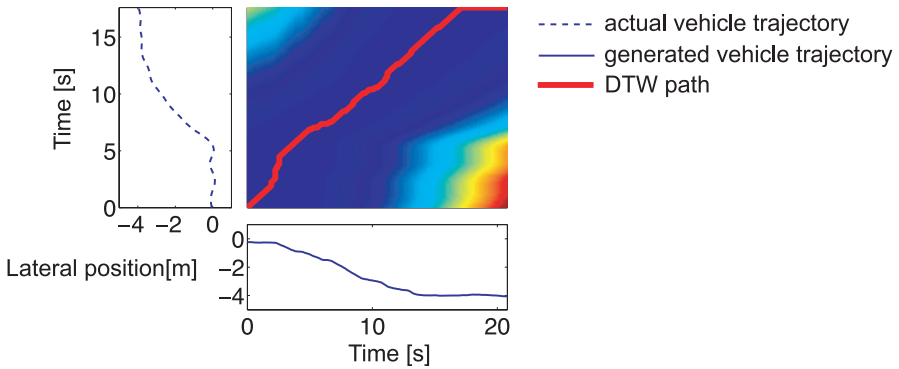

図 9　実際の車両軌跡と生成された車両軌跡間の DTW の計算例

Fig. 9　Example of the DTW recursion between the actual and generated vehicle trajectories.

$$+\frac{1}{I+J-1}\left(\frac{(x_0[i]-\hat{x}_0[j])^2}{\sum_{n=1}^{I}x_0^2[n]}+\frac{(y_0[i]-\hat{y}_0[j])^2}{\sum_{n=1}^{I}y_0^2[n]}\right)$$

ここで I と J は実際の車両軌跡と生成された車両軌跡の信号長を示す．DTW の計算例を**図 9** に示す．DTW は $D(0,0)=0$ から始まり $D(I,J)$ まで計算される．$-10\log_{10}(D(I,J))$ を

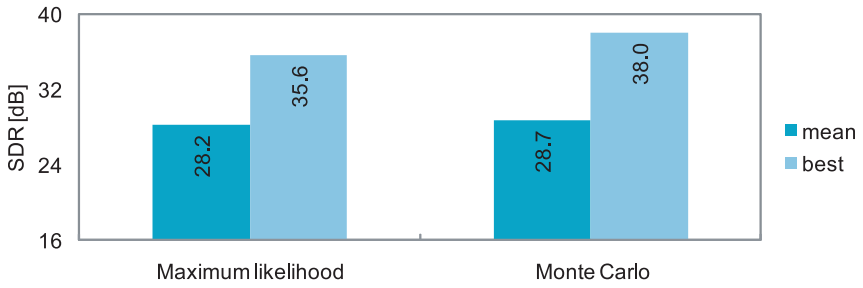

図 10　最尤信号生成アルゴリズム（左）とモンテカルロ法を用いた場合（右）の最も実際の車両軌跡と類似した車両軌跡の平均 SDR（best）と車両軌跡仮説群全体の平均 SDR（mean）

Fig. 10　Average SDRs of the best trajectory (best) and all trajectory hypotheses (mean) by the maximum likelihood signal synthesis algorithm (left) and the sampling method (right).

信号対歪比（SDR: Signal to Deviation Ratio）として予測精度の評価に用いた．生成された車両軌跡と実際の車両軌跡は信号長が異なるために $D(I,J)$ を評価尺度として用いた．

1 つ目の実験では，2 つの軌跡生成手法を用いた場合の生成された車両軌跡仮説群 Φ のうちで最も実際の車両軌跡と類似した車両軌跡（最小誤差の車両軌跡）の平均 SDR（60 回の評価の平均）と車両軌跡仮説群全体の平均 SDR（400 仮説 × 60 回の評価の平均）を**図 10** に示す．車両軌跡全体の平均誤差では両者の間に差が見られない．次に，そもそも実際の車両軌跡と類似した車両軌跡が仮説群に含まれていないと最終的な性能が達成できないと考え，2 つの軌跡生成手法を最小誤差のみで評価する．生成手法としてモンテカルロ法を用いた場合，5%の有意水準を満たさないもの，最尤信号生成アルゴリズムにより生成された軌跡に比べ最小誤差の平均 SDR が 6.7%向上した．この結果から，車両軌跡仮説群の生成において，モンテカルロ法が最尤法と同等以上の性能を持つ可能性が高いと考えられるが，今後，より大量のデータを用いて検証する必要がある．

2 つ目の実験では，軌跡生成手法としてモンテカルロ法を用い，最終的に得られる最適な車両軌跡 ϕ^* の評価を行い，提案モデルがドライバごとの車線変更時の動的特性を表現できているか検証した．ドライバごとの動的特性が反映されていることを確認するために，ドライバ A のモデルをドライバ B の車両軌跡を生成する際に用いた場合（逆もまた同様）の選択された車両軌跡 ϕ^* の平均 SDR（60 回の評価の平均）を**図 11** に示す．異なるドライバのモデルを用いた場合，両者の平均 SDR 間に，有意水準 2.4%で有意差が認められたことから，ドライバ依存の提案モデルがドライバごとの車線変更時の動的特性を特徴づけている

© 2010 Information Processing Society of Japan

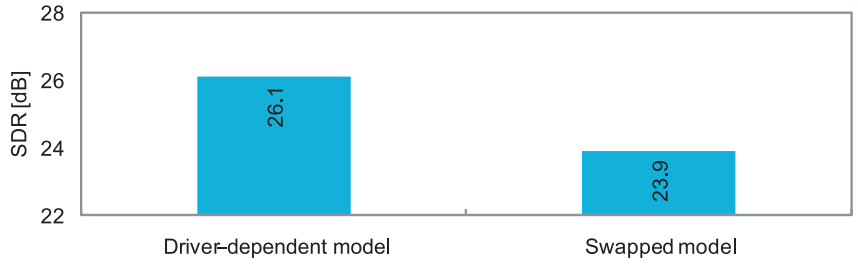

図 11　ドライバ依存のモデルを用いた場合（左）と他人のモデルを用いた場合（右）の選択された車両軌跡の平均 SDR

Fig. 11　Average SDRs of the selected trajectory by the models of the same driver (left) and the different driver (right).

ことが確認された．

また，実際の車両軌跡と生成された車両軌跡の信号長が等しい場合（$I = J$）についても予測精度を評価した．$I = J$ の場合，二乗平均平方根誤差（RMSE: Root Mean Square Error）を計算することができる．RMSE（60 回の評価の平均）は 17.6 m であった．これは，おおよそ 600 m 程度の車両軌跡を観測信号を用いずに初期値とドライバモデルのみで予測する条件下では良好な予測精度と考えられる．以上のことから長期間の車両軌跡を予測する提案手法の効果が確認された．

5. ま と め

本論文では，運転行動モデリングの確率的な枠組みを提案した．ドライバの癖や認知的な車両間隔特性が，HMM や幾何学的な関数を用いてモデル化された．車両軌跡の仮説群を HMM から生成し，幾何学的な関数を用いて選択することで，おおよそ 20 秒間の車線変更の車両軌跡が初期条件を与えるだけで予測可能なことを確認した．モデルパラメータは統計的な基準に基づいて学習されるため，運転の個人性を学習データから簡単に特徴づけることができる．

基本的な評価実験により，提案モデルが良好な精度で個人性を反映した車両軌跡を生成できることを確認した．しかしながら，様々な課題が依然として残っている．まず，大量のデータを用いたモデルの分析的または定量的な検証が必要である．さらに，モデルは実走行環境で収録された運転データを用いて評価されるべきである．また，状態継続長分布と HMM とハザードマップの間には何らかの関係があると考えられ，それらを統合し，関係性を分析することも重要な課題である．

謝辞　本研究の一部は戦略的情報通信研究開発推進制度（SCOPE）の助成を受けている．関係各位に感謝いたします．

参 考 文 献

1) National Police Agency Traffic: Road Traffic Accidents in 2008 (online). http://www.npa.go.jp/toukei/koutuu48/Month.pdf (accessed 2009-04-06)
2) An, P.E. and Harris, C.J.: An intelligent driver warning system for vehicle collision avoidance, *IEEE Trans. Syst., Man, Cybern. A*, Vol.26, No.2 (1996).
3) Onken, R.: DAISY, an adaptive, knowledge-based driver monitoring and warning system, *Proc. Vehicle Navigation and Information Systems Conference*, pp.3–10 (1994).
4) Gong, Q., Li, Y. and Peng, Z.R.: Computationally Efficient Optimal Power Management for Plug-in Hybrid Electric Vehicles Based on Spatial-Domain Two-Scale Dynamic Programming, *Proc. 2008 IEEE International Conference on Vehicular Electronics and Safety*, pp.90–95 (2008).
5) Brackstone, M. and McDonald, M.: Car-following: A historical review, *Transportation Research, Part F*, Vol.2, No.4, pp.181–196 (1999).
6) Fritz, H., Gern, A., Schiemenz, H. and Bonnet, C.: CHAUFFEUR Assistant: A driver assistance system for commercial vehicles based n fusion of advanced ACC and lane keeping, *Proc. 2004 IEEE Intelligent Vehicles Symposium*, pp.495–500 (2004).
7) Ishida, S. and Gayko, J.E.: Development, evaluation and introduction of a lane keeping assistance system, *Proc. 2004 IEEE Intelligent Vehicles Symposium*, pp.943–944 (1994).
8) Chee, W. and Tomizuka, M.: *Vehicle lane change maneuver in automated highway systems*, Publication of PATH project, ITS, UC Berkeley, UCB-ITS-PRR-94-22 (1994).
9) Wenzel, T.A., Burnham, K.J., Williams, R.A. and Blundell, M.V.: Closed-loop driver/vehicle model for automotive control, *Proc. 18th International Conference on Systems Engineering* (*ICSEng'05*), pp.46–51 (2005).
10) Danielsson, S., Petersson, L. and Eidehall, A.: Monte carlo based threat assessment: Analysis and improvements, *Proc. 2007 IEEE Intelligent Vehicles Symposium*, pp.233–238 (2007).
11) Althoff, M., Stursberg, O. and Buss, M.: Stochastic reachable sets of interacting traffic participants, *Proc. 2008 IEEE Intelligent Vehicles Symposium*, pp.1086–1092 (2008).

© 2010 Information Processing Society of Japan

12) Rabiner, L.R.: A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, *Proc. IEEE*, pp.257–286 (1989).
13) Tokuda, K., Yoshimura, T., Masuko, T., Kobayashi, T. and Kitamura, T.: Speech parameter generation algorithms for HMM-based speech synthesis, *Proc. ICASSP*, pp.1315–1318 (2000).
14) Nishiwaki, Y., Miyajima, C., Kitaoka, N., Terashima, R., Wakita, T. and Takeda, K.: Generating lane-change trajectories of individual drivers, *Proc. 2008 IEEE International Conference on Vehicular Electronics and Safety*, pp.271–275 (2008).
15) Young, S., Evermann, G., Gales, M., et al.: *The HTK Book* (*for HTK version 3.4*), Entropic Labs and Cambridge University (2006).
16) McClellan, J.H., Schafer, R.W. and Yoder, M.A.: *DSP First: A Multimedia Approach*, Prentice Hall (1998).

付　　録

A.1　モンテカルロ法を用いた車両軌跡の生成

車両軌跡はランダムにサンプリングされた車線変更時間 N と状態継続長 $\{d_j\}$ の仮説に基づき，HMM の各状態の確率分布に対してギブスサンプリングを適用することで生成される．ギブスサンプリングはマルコフ過程を仮定しており，信号系列 $\{\mathbf{v}[n]\}_{n=1,\cdots,N}$ を生成することができる．ここで，それぞれの標本 $\mathbf{v}[n]$ は一時刻前の標本 $\mathbf{v}[n-1]$ に依存した確率分布から生成されることに注意されたい．ギブスサンプリングを用いた信号生成過程を以下に示す．

(Step1) 初期化

初期標本を与え，時間のインデックス $n=1$ とする．

(Step2) 繰返し処理

M 次元の確率変数からなる一般的なシステムの場合，1 回の繰返し処理は 1 つの確率変数の標本抽出を M 回行うことで達成される．

$$
\begin{aligned}
x_n^1 &\sim f\left(x^1 \mid x_{n-1}^2, x_{n-1}^3, \cdots, x_{n-1}^M\right)\\
x_n^2 &\sim f\left(x^2 \mid x_n^1, x_{n-1}^3, \cdots, x_{n-1}^M\right)\\
&\vdots\\
x_n^M &\sim f\left(x^M \mid x_n^1, x_n^2, \cdots, x_n^{M-1}\right)
\end{aligned}
$$

ここで $f(\cdot)$ は確率密度関数を示す．

(Step3) 収束判定

生成されたサンプル数が所望するサンプル数と同じであれば終了し，そうでなければ Step2 が $n=n+1$ に対して繰り返される．

HMM の第 1 状態の確率分布をサンプリングする場合，車線変更直前の観測信号が初期標本として用いられる．一方，それ以降の HMM の状態の確率分布からサンプリングする場合は，直前の HMM の状態の確率分布からサンプリングされた最後の標本を初期標本として用いる．HMM の各状態の確率分布をサンプリングした後，生成された信号系列 $\{\mathbf{v}[n]\}_{n=1,\cdots,N}$ は N/S 点（各状態に割り当てられる平均的なサンプル数）の遅延補償移動平均フィルタ[16]を用いて平滑化される．

(平成 21 年 4 月 14 日受付)
(平成 21 年 10 月 2 日採録)

西脇　由博

平成 17 年名古屋大学工学部電気電子情報工学科卒業．平成 19 年同大学大学院情報科学研究科メディア科学博士前期課程修了．同年博士後期課程進学．主として運転行動のモデル化・生成の研究に従事．

宮島千代美

平成 8 年名古屋工業大学知能情報システム学科卒業．平成 10 年同大学大学院博士前期課程修了．平成 13 年同博士後期課程修了．同在学中，平成 10〜13 年日本学術振興会特別研究員．平成 13 年名古屋工業大学知能情報システム学科助手．平成 15 年同大学大学院情報工学専攻助手．同年名古屋大学大学院情報科学研究科助手．平成 19 年同助教．博士（工学）．主として運転行動信号処理，マルチモーダル音声情報処理に関する研究に従事．IEEE，自動車技術会，電子情報通信学会，日本音響学会各会員．

© 2010 Information Processing Society of Japan

北岡　教英（正会員）

平成 4 年京都大学工学部情報工学科卒業．平成 6 年同大学大学院修士課程修了．同年（株）デンソー入社．平成 9〜12 年豊橋技術科学大学大学院博士後期課程在学．平成 13 年豊橋技術科学大学情報工学系助手．平成 15 年同講師．平成 18 年名古屋大学大学院情報科学研究科助教授．平成 19 年同准教授．博士（工学）．平成 19 年 Nanyang Technologycal University（Singapore）visiting assosiate professor．主として音声認識，音声対話，音声インタフェースに関する研究に従事．ISCA，電子情報通信学会，日本音響学会，人工知能学会各会員．

武田　一哉（正会員）

昭和 60 年名古屋大学大学院工学系研究科修士課程修了．ATR 自動翻訳電話研究所，KDD（現 KDDI）研究所を経て，平成 7 年名古屋大学工学部助教授，平成 15 年より同大学大学院情報科学研究科教授．音声データベース，音声対話システム，音響信号処理，行動信号処理等の研究に従事．本学会 SLP 研究会主査，日本音響学会理事，電子情報通信学会論文誌（和文 D）編集長等を歴任．

© 2010 Information Processing Society of Japan