

車線変更軌跡の確率的予測モデル

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確率的な運転行動予測モデルを提案し、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、ドライバは予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秒程度に亘って行われる車線変更の軌跡を、17.6m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、ドライバ毎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 Prediction Model of Lane-Change Trajectories

YOSHIHIRO NISHIWAKI,^{†1} CHIYOMI MIYAJIMA,^{†1}
NORIHIDE KITAOKA^{†1} and KAZUYA TAKEDA^{†1}

A signal processing approach for predicting 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 17.6m

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。交通事故による死者数は減少傾向にあるとはいえ、2007年には約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¹⁰⁾、ドライバ毎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確率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、ドライバ毎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確率的に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、ドライバ毎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み合わ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

^{†1} 名古屋大学大学院 情報科学研究科
Graduate School of Information Science, Nagoya University

究では困難であった，20 秒程度の時間に亘る車両挙動の予測も容易に実現可能である．

提案法は，2 つの部分から構成される．第 1 の部分は，ドライバの運転性向に起因する車両の動的特性の統計的性質を隠れマルコフモデル (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，状態毎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，状態毎に信号 $x[n]$ 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 $\{x[n]\}_{n=1,\dots,N}$ 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毎の特性を反映した車両軌跡の仮説群が生成される．

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に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，ドライバ毎の車間距離 - 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，ドライバにとって自然な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，始めに 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．

次節から提案手法と評価について述べる．2 節と 3 節では，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 節で述べる．最後に 5 節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 1 に示すとおり周辺車両のインデックスで， $i = 1$ は走行車線の先行車両， $i = 2$ 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 (走行方向) と横方向の位置を示す．車線変更行動の時間区間 $n = 1, \dots, N$ は，図 1 に示すように V0 (自車両) と V2 の前方向の位置が等しい (車両が並んだ) 時を開始時点，V0 の横方向の位置が最小となった




図 1 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. 1 Lane change trajectory and geometric positions of surrounding vehicles. V0 is the vehicle changing lanes.

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 1 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．提案するモデルでは，それぞれの状態が次の 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．

$$\mathbf{v} = [x_0, x_1, x_2, y_0, \Delta x_0, \Delta y_0, \Delta^2 x_0, \Delta^2 y_0]^t \quad (1)$$

これらの変数群の結合確率は，信号とその時間微分との関係を確率的に表現する相平面上で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．

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接続で与えられると考えられる．HMM を用いる利点は，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。

なお、車両軌跡を生成するためには、進行方向の移動距離 x_0 と横方向の移動距離 y_0 が必要である。しかし、進行方向の移動距離 x_0 は単調に増加するため、i.i.d. プロセスとしてモデル化することは妥当でない。そこで、車両の進行方向の動きに対応する変数として進行方向の速度 x_0 を用いた。また、周辺状況に応じた車両軌跡を生成するために周辺車両の速度 x_1, x_2 を変数群に加えた。

更に、次式で計算される動的特徴量によって高次の時間微分を変数群に加えた。

$$\Delta x[n] = \frac{\sum_{k=-K}^K k \cdot x[n-k]}{\sum_{k=-K}^K k^2} \quad (2)$$

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。文献 13) の最尤信号生成アルゴリズムで示されるように、動的特徴量を用いることで、生成されるサンプル間の動的な変動が考慮された、より自然な信号が生成される。

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 $v[n]$ の平均ベクトル μ_j と共分散行列 Σ_j が HMM の各状態 $j = 1, 2, 3$ 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 HMM を用いた車両軌跡生成法

後述の実験において示すように、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。例えば、ドライバー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、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」）毎の継続時間長 $\{d_j\}$ の仮説を生成する。

最初に車線変更時間 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_j 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。

$$d_j = \left\lceil \frac{\xi_j N}{\sum_{s=1}^S \xi_s} \right\rceil \quad (3)$$

ここで、 ξ_j は区間 $(0, 1]$ の一様分布に従う確率変数である。また、 $\lceil \cdot \rceil$ 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_j 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。一旦、状態継続長の仮説群が決まれば、HMM を用いた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 (A.1 参照) により尤もらしい車両軌跡信号が生成できる。この過程を繰り返すことで学習したドライバーの特徴を捉えた車両軌跡の仮説群が生成される。

3. 車両軌跡の選択

前節では、車線変更時間や状態毎の継続時間を仮定することで、ドライバー毎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。一方、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、ドライバーが危険と感じる車間距離は、ドライバーや方向によって異なると考えられる。このような、周辺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した関数を、「ハザードマップ」と呼ぶ。ドライバー毎にハザードマップを構築することで、生成された車線変更軌跡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。

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、当該方向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。従って、周辺車両 V_i 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。

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

ここで、 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 は認知距離 $\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i$ の平均値を示す。

$$\alpha_i = \frac{\log(0.05) - \log(0.95)}{\min\{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i\} - \mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i} \quad (5)$$

$$\beta_i = \overline{\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i} \quad (6)$$

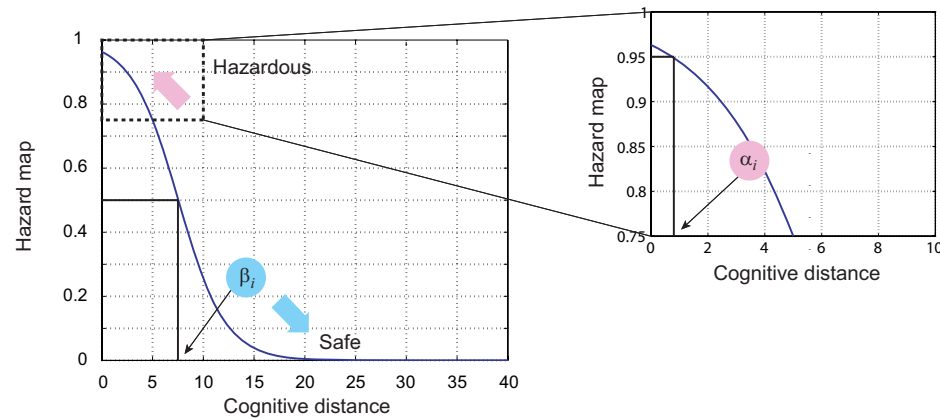


図2 ハザードマップのパラメータ
 Fig.2 Parameters of a hazard map.

ハザードマップのパラメータを示す概念図を図2に示す。

ハザードマップ \mathcal{M} は $[0, 1)$ の値を取り、値が大きいほどドライバー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、

$$\Pr \{ \mathbf{r} | \text{safe/unsafe} \} \propto \exp \left\{ -\frac{1}{2} \mathbf{r}^t \mathbf{A} \mathbf{r} \right\} \quad (7)$$

相対距離が与えられた条件下での安全な状態である事後確率 $\Pr \{ \text{safe} | \mathbf{r} \}$ として見ることができる。従って、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。

$$\mathcal{M}' = \sum_i \frac{\lambda_i}{1 + \exp \{ \alpha_i (\mathbf{r}_i^t \mathbf{R}_i^{-1} \mathbf{r}_i - \beta_i) \}} \quad (8)$$

時刻 n での周辺車両の位置 $\mathbf{r}_i[n]$ が決まれば、 \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生成された各車両軌跡を比較することができる。また、車両軌跡の仮説群の中で最小値をとる車両軌跡が最適な車両軌跡として選択される。

4. 評価

4.1 データ収集及び実験条件

ドライビングシミュレータを用いて、2名のドライバーに対してそれぞれ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、160ms毎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112.4km/hの速度で走行していた。また、追越車線には、速度が82.8~127.4km/h、連続する2台の車間距離が85~315mの条件で車両群が走行しており、ドライバー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3に2名のドライバー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。例えば、平均してドライバーBはドライバーAよりも車線変更時に時間をかけ、第一状態(周辺車両の確認、車線変更の準備)に時間を要しない傾向にある。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(20回が学習、10回が評価)。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 $2K = 320\text{ms}$ で計算した。HMMの学習にはHTK¹⁵⁾を用いた。

実験では、始めに20個の車線変更時間 N をサンプリングし、次に式(3)に基づいてそれぞれ20組の状態継続長 $\{d_j\}$ をサンプリングし、合計400の状態継続時間の組み合わせに対してHMMから車両軌跡仮説を生成した。最後に、最適な車両軌跡を選択するために、式(8)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、本研究では車両速度 x_i, y_i は一定であるという条件を仮定した。

4.2 実験結果

2名のドライバーの学習したHMMの各状態の結合確率を図4に示す。HMMが車線変更での運転行動の違いをモデル化できていることが確認できる。図5に示すハザードマップ \mathcal{M}' はドライバーの車両間隔に対する感度の違いを示している。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6と図7にそれぞれ示す。このモデルは20秒間の長さの車両軌跡(おおよそ600mの走行)を予測しているが、ドライバー毎に自然な軌跡が予測されており、2名のドライバーで予測された車両軌跡は明らかに異なっている。ま




図 3 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. 3 Lane-changing time and its most probable state distribution calculated by the trained HMM.

た、最尤信号生成アルゴリズムに比べて、モンテカルル法を用いることでより自然な車両軌跡が生成されていることが確認できた。

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。

$$D(i, j) = \min \begin{cases} D(i-1, j) \\ D(i-1, j-1) \\ D(i, j-1) \end{cases} + \frac{1}{I+J-1} \left(\frac{(x_0[i] - \hat{x}_0[j])^2}{\sum_{n=1}^I x_0^2[n]} + \frac{(y_0[i] - \hat{y}_0[j])^2}{\sum_{n=1}^J y_0^2[n]} \right) \quad (9)$$

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 8 に示す。DTW は $D(0, 0) = 0$ から始まり $D(I, J)$ まで計算される。 $-10 \log_{10}(D)$ を信号対歪比 (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 DTW を評価尺度として用いた。

生成された車両軌跡仮説群の中で最も予測精度のよい車両軌跡の平均 SDR を図 9 に示す。生成手法としてモンテカルル法を用いた場合、最尤信号生成アルゴリズムにより生成さ

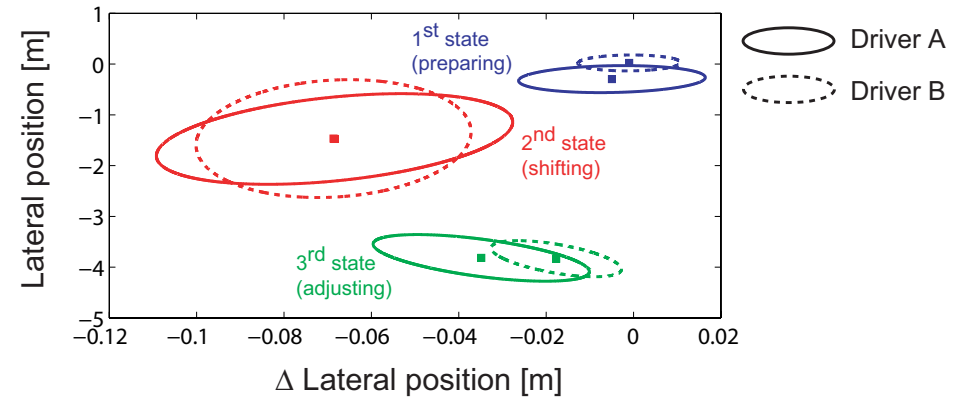


図 4 HMM の各状態における車両軌跡特徴量の結合確率 (Δy と y のみのプロット)

Fig. 4 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.

れた軌跡に比べ SDR が 6.7% 向上したことから、長期間の車両軌跡生成におけるモンテカルル法の有効性が確認された。

また、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の SDR を図 10 に示す。異なるドライバのモデルを用いた場合に SDR が 8.4% 低下したことから、提案モデルがドライバ毎の車線変更時の特性を特徴づけていることが確認された。

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。その平均の RMSE は 17.6m であった。これは、おおよそ 600m 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

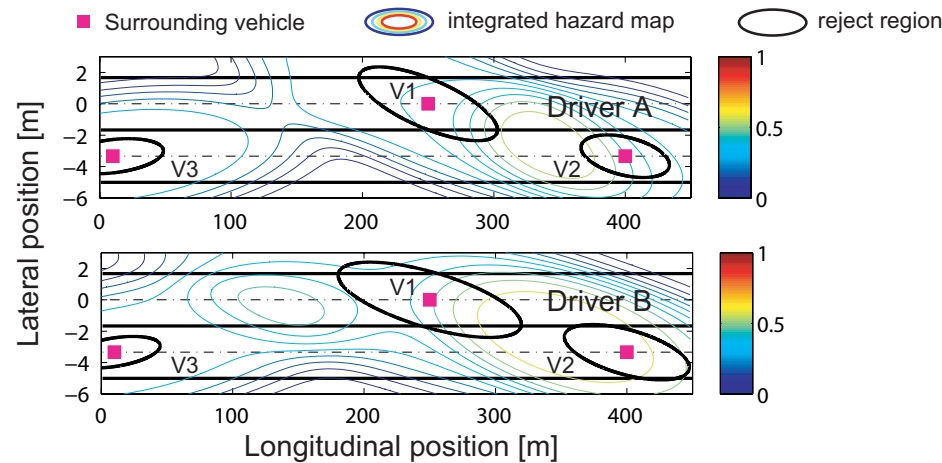


図5 周辺車両が同じ位置にある場合の学習したハザードマップ

Fig.5 Trained hazard maps of two drivers when the same geometric positions of surrounding vehicles are given.

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、HMMによる仮説生成過程とハザードマップによる選択過程を統合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

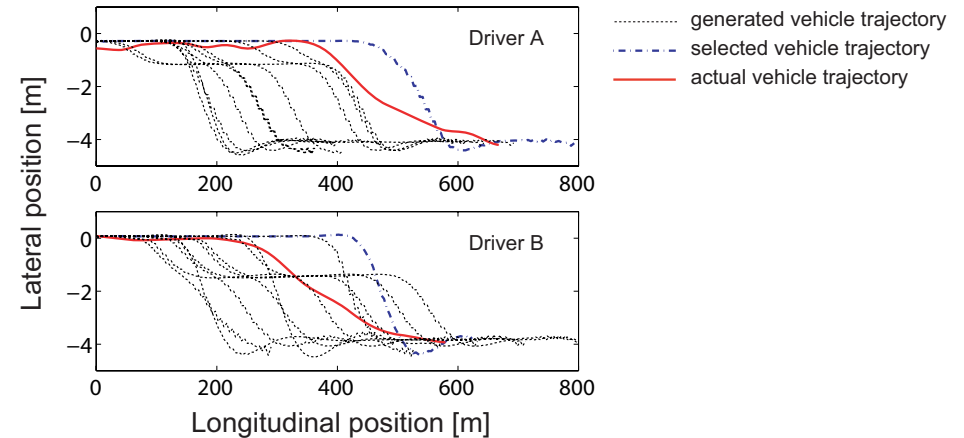


図6 最尤信号生成アルゴリズムを用いた場合の生成された車両軌跡

Fig.6 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.

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. of 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. of 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 on fusion of advanced ACC and lane keeping, *Proc. of 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. of 2004 IEEE Intelligent Vehicles Symposium*, pp. 943-944 (1994).
- 8) Chee, W. and Tomizuka, M.: Vehicle lane change maneuver in automated highway

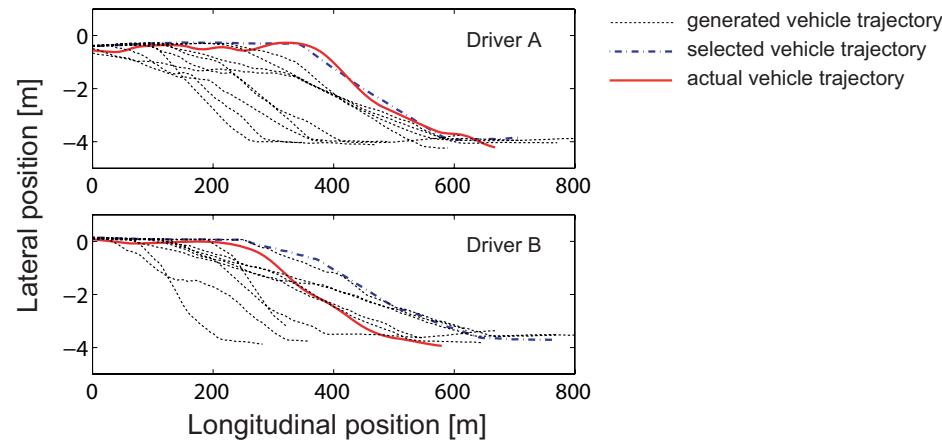


図7 モンテカルロ法を用いて生成された車両軌跡

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

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. of the 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. of 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. of 2008 IEEE Intelligent Vehicles Symposium*, pp. 1086-1092 (2008).
- 12) Rabiner, L.R.: A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, *Proc. of the 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. of 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. of 2008 IEEE*

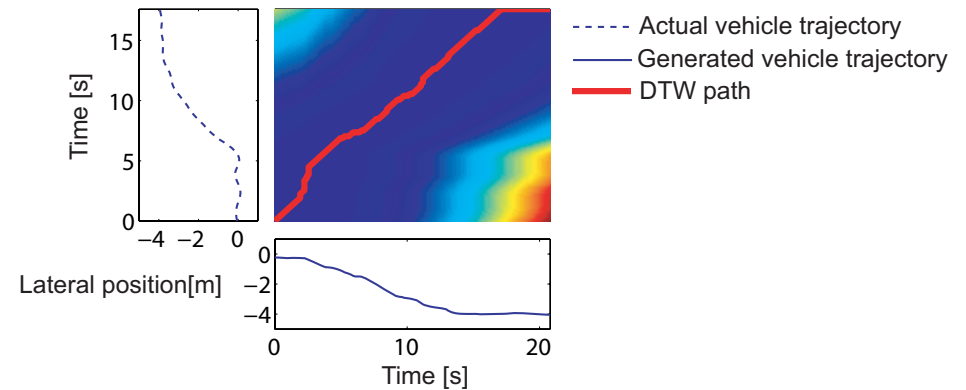


図8 実際の車両軌跡と生成された車両軌跡間のDTWの計算例

Fig.8 Example of the DTW recursion between the actual and generated vehicle trajectories.

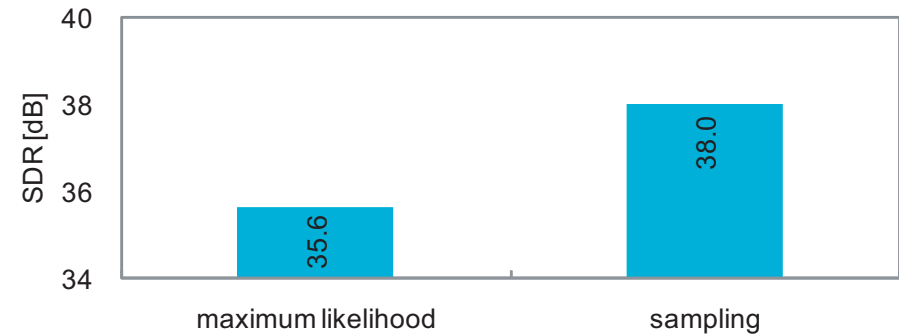


図9 最尤信号生成アルゴリズム(左)とモンテカルロ法を用いた場合(右)の最も予測精度の良い車両軌跡の平均SDR

Fig.9 Average SDRs of the best trajectory by the maximum likelihood signal synthesis algorithm (left) and the sampling method (right).

- 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 Ap-*

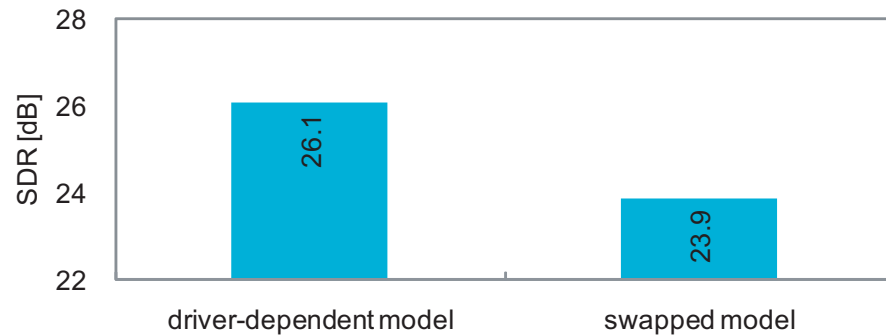


図 10 ドライバ依存のモデルを用いた場合 (左) と他人のモデルを用いた場合 (右) の選択された車両軌跡の平均 SDR

Fig. 10 Average SDRs of the selected trajectory by the models of the same driver (left) and the different driver (right).

proach, 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 $\{v[n]\}_{n=1, \dots, N}$ を生成することができる. ここで, それぞれの標本 $v[n]$ は一時刻前の標本 $v[n-1]$ 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) 繰り返し処理

M 次元の確率変数からなる一般的なシステムの場合, 1 回の繰り返し処理は 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:

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

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 $\{v[n]\}_{n=1, \dots, N}$ 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.