

ベイジアンネットワークを用いた車線変更時の運転行動推定モデルの研究*

手塚繁樹^{*1}, 相馬仁^{*2}, 谷藤克也^{*2}

A Study of Driver Behavior Inference Model at Time of Lane Change using Bayesian Networks

Shigeki TEZUKA^{*3}, Hitoshi SOMA and Katsuya TANIFUJI

^{*3}Niigata College of Technology
5-13-7, Kamishin'ei-cho, Nishi-ku, Niigata-shi, 950-2076 Japan

Recent years have brought hope that driving support systems tailored to the characteristics of each driver can be developed. To accomplish this, a driver model must be constructed that considers the driver's psychological function when inferring driver behavior. This paper thus proposes a method to infer driver behavior by capturing time-series steering angle data at the time of lane change. The proposed method uses a static type conditional Gaussian model on Bayesian Networks. By using this method, if the driver behavior of the subject and learned data nearness of features (norms) are below a certain level, it is possible to infer driver behavior with nearly 100% probability. Moreover, compared to the HMM models, this method reduces the rate of incorrect inference inclusion.

Key Words : Automobile, Human Interface, Reasoning, Modeling, Driver Behavior, Bayesian Networks, Hidden Markov Model, ITS, Driving Simulator

*原稿受付 2007年00月00日

^{*1}新潟工業短期大学(〒950-2076 新潟市西区上新栄町5-13-7)

^{*2}新潟大学工学部。

E-mail: tezuka@po.niigata-ct.ac.jp

1. 緒 言

近年、ITS (Intelligent Transport Systems)において、運転負荷軽減や安全性向上などのために様々な運転支援システムが開発されている。これらシステムは、ドライバの運転行動に直接支援を行うため自動車単体ではなく、人間・自動車協調システムとして設計されることが大切である。しかし、ドライバの運転技能や嗜好、癖などは、個人毎に大きく違う。そのため、平均的なドライバの運転行動に合わせて、支援方法や支援タイミングを決定したシステムは、ドライバにとって齟齬や違和感、煩わしさなどを感じてしまうことが少なくない。したがって、個々のドライバの運転行動を推定し、その結果に基づいて、支援方法や支援タイミングを決定することが重要となる。また、運転行動を推定するためには、ドライバの意図などの心理的機能を考慮したドライバモデルを構築し、そして、推定することが必要となる。

これまで、交差点などの運転行動を想定した車両の縦方向の研究⁽¹⁾⁽²⁾が多く行われて来たが、車線変更などの運転行動を想定した車両の横方向の研究は、少ない。その中でも久家ら⁽³⁾は、隠れマルコフ(HMM: Hidden Markov Model)を用いてドライバモデルを構築し、車線変更時の運転行動を推定する手法を提案した。しかし、運転行動の連続推定を行うと、操舵開始直後の領域において、誤推定が起る問題点を示した。また、運転行動の連続推定を行うためには、行動の前後関係を考慮（文脈依存性と呼ぶ）したモデルを用いることの重要性を挙げた。

そこで、本研究では、車線変更を対象に、ベイジアンネットワーク(BNs: Bayesian Networks)の中でもスタティック型条件付ガウシアンモデルを用いて、ドライバの運転行動階層モデルの一部と運転行動の文脈依存性を表現したドライバモデルの構築を行う。このドライバモデルを用いて、ドライビングシミュレータにて車線変更時の運転行動の連続推定実験を行った。その結果、被験者の運転行動と学習データとの特徴量の近さ(ノルム)が一定値以下であれば、ほぼ100%の確率で行動を推定することができ、そして、従来のHMMモデルに比べて誤推定が含まれる確率が低減する知見を得た。

2. ドライバモデルの構築

2・1 ドライバモデルと運転行動 ドライバの運転行動は、図1に示すようにいくつかの意識や技能などの心理的機能が階層をなしている⁽⁴⁾（運転行動階層モデルと呼ぶ）と考えられている。運転行動階層モデルのLevel1は、ハンドル操作などの運転操作能力であり、Level2は、道路状況を把握し対応できる能力（認知・判断など）である。それぞれの階層は、上の階層に支配されている。本研究でのドライバモデルは、これらの階層モデルに対応した構造とし、Level1とLevel2の一部の認知・判断までを対象とする。そのドライバモデルの構造は、次の条件を満たす必要がある。

- (1) Level2の認知・判断の部分は、ドライバの離散的な確率分布である内部状態と、内部状態の確率的な連鎖であると捉えて、これを表現できること。また、この内部状態は外から観測することはできない。
- (2) Level1の運転操作能力は、Level2の認知・判断に基づく確率的な運転操作であると捉えて、これを表現できること。また、運転操作量だけは外から観測することができる。

つまり、モデル構造は、離散的な確率分布である隠れ状態と、隠れ状態の確率的な連鎖、および、この隠れ状態の下での連続的な確率分布を表現できる必要がある。

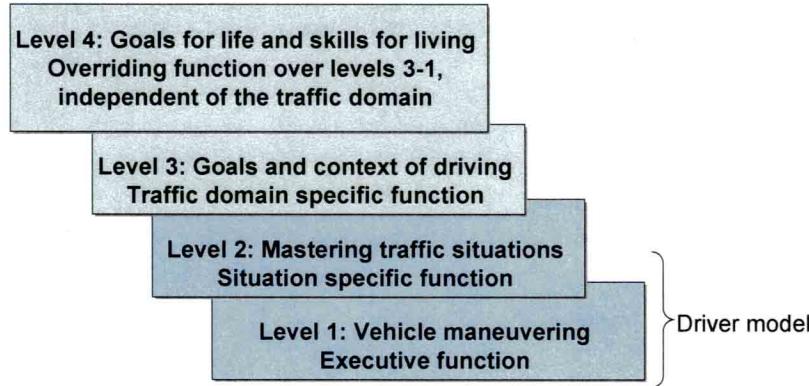


Fig.1 Hierarchical levels of driver behavior (adapted from Keskinen, 1996).

2・2 BNs とモデル構造 BNs は、パラメータ間の複雑な依存関係を非循環有向グラフで表した確率モデルであり、時系列の因果関係も扱うことができる⁽⁵⁾。この確率モデルのパラメータは、パラメータの観測値から確率分布として学習することができる。そして学習された確率モデルを用いて、観測されたパラメータ情報から求めたいパラメータの確率値、すなわち、事後確率を求めることができる。また、BNs は、従来の HMM に比べて次のような特徴を持っている⁽⁶⁾。

- (1) モデルパラメータの値自身も確率的に変動するため、一意に値を決める HMM の点推定に比べて、未知入力に対する過学習による脆弱性を大幅に緩和できる。
- (2) 連續で滑らかな特微量系列を生成することができるため、HMM の表現する一定値で不連續な特微量系列に比べて、より対象に近いモデルを提供することが可能となる。

BNs には、大きく分けてスタティック型とダイナミック型があるが、今回は、データ長 T で計測データが抽出できる、との前提でスタティック型を用いた。

運転行動階層モデル Level2 の道路状況の認知・判断部分は、離散系確率分布を表すディスクリート型ノードに割り当て、操舵判断とした。このノードは、直接観測をすることができない隠れノードとした。そして、運転行動の文脈依存性を表現するために、これらのノードを接続し、認知・判断に前後関係を持たせた。また、階層 Level1 の操作部分は、連続系確率分布を表すガウシアン型ノードに割り当て、観測された操舵角度とした。この操舵角度ノードは、先の判断ノードの下で行われたと考え、関係付を行った。このモデルは、条件付ガウシアンモデルと呼ばれ、図2に示す。図2のモデルパラメータの学習は、時系列の操舵判断状態と、その時の操舵角度データの組み合わせで学習が行われる。

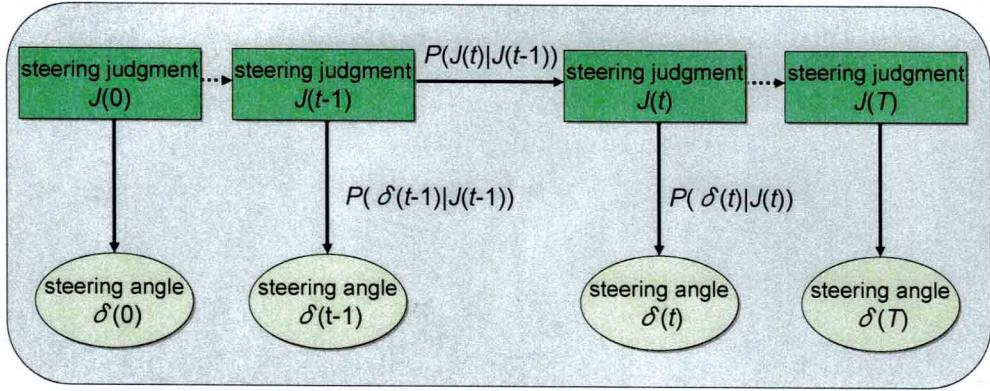


Fig.2 Driver behavior inference model at time of lane change

2・3 運転行動の推定 図2のモデルにおいて $J(t) = \{J_1(t), J_2(t), \dots, J_n(t)\}$ は、時刻 t における n 個の隠れ状態からなる操舵判断パラメータの隠れノードであり、 $\delta(t)$ は、時刻 t における操舵角度パラメータの観測値ノードである。 $P(J(t) | J(t-1))$ は、時刻 $t-1$ から時刻 t へ遷移する状態遷移確率であり、 $P(\delta(t) | J(t))$ は、時刻 t の操舵判断状態が $J(t)$ である時に操舵角度の観測値 $\delta(t)$ が得られる観測確率である。時刻 0 から t までの全ての操舵角度の観測値の系列 $\delta_{0:t}$ が得られたとすると、時刻 t の操舵判断状態 $J(t)$ の事後確率分布は、次式で推定される⁽⁷⁾⁽⁸⁾。

$$P(J(t) | \delta_{0:t}) = \alpha P(\delta(t) | J(t)) P(J(t) | \delta_{0:t-1}) \quad (1)$$

$$P(J(t) | \delta_{0:t-1}) = \sum_{J(t-1)} P(J(t) | J(t-1)) P(J(t-1) | \delta_{0:t-1}) \quad (2)$$

ただし、 α は、正規化定数である。このBNsは、“車線維持” ($J_1(t)$) と“通常右車線変更” ($J_2(t)$)，“緊急右車線変更” ($J_3(t)$) を推定する構成とすると、操舵判断の隠れノードは、 $J(t) = \{J_1(t), J_2(t), J_3(t)\}$ の 3 つの状態を持つ。また、操舵角度は、 $P(\delta(t)) = N(\delta(t); \mu, \sigma^2)$ の正規確率分布を持つと仮定する。

3. ドライビングシミュレータによる評価実験

BNsを用いたモデルによる車線変更の運転行動推定精度が、従来のHMMを用いたモデルよりも向上しているかの評価実験を、ドライビングシミュレータを用いて行った。

3・1 推定対象 車線変更場面として、車線維持 (LKN) と通常右車線変更 (LCN)、緊急右車線変更 (LCE) の 3 種類の運転行動とした。

- (1) 車線維持：被験者には知らせずに、計測者が走行車線を安定して維持していると判断した 4sec 間のデータを計測する。
- (2) 通常右車線変更：計測者からの指示に従い、やや早めに追い越し車線に車線変更を行う。
- (3) 緊急右車線変更：被験者には知らせずに、停止したバン型乗用車を自車前方に突然表示し、操舵にて追い越し車線へ緊急回避を行う。バン型乗用車の表示位置は、車速×1.5sec 前方とした。被験者には、バン型乗用車が出現したら、追い越し車線に操舵で緊急回避するようにあらかじめ教示されているが、出現タイミングは、知らされていない。

3・2 運転行動データの測定

- (1) 実験装置：実験には、モーションベースのない簡易型ドライビングシミュレータを用いた。車両運動計算および前方視野画像の生成は、それぞれ独立のPCで行われる。また、前方視野画像は、100inch

のスクリーンに投影される。車両速度や操舵角度などの車両データは、50msec 間隔で計測され PC に蓄積される。実験装置の概観を図 3 に示す。

(2) 被験者：21～25 歳の普通免許を有する 9 名（男 7 名、女 2 名）とし、被験者 1 名につき 2 回測定を行った。

(3) 走行条件：晴天で、2 車線の全長 10km の直線と緩やかなカーブ区間が繰り返し現れる高速道路の走行車線を 60km/h 前後で走行してもらいデータを収集した。



Fig.3 Driving simulator

3・3 車線変更推定 車線変更データは、図 4 に示すように操舵角度第 1 ピークまでの 4sec 間、そして、車線維持データは、安定していると思われる所 4sec 間の抽出を行った。また、このデータに含まれるカーブなどで発生するオフセットは、平均値を用いて取り除いた。図 5 に通常右車線変更、図 6 に緊急右車線変更のデータを示す。このデータを基に Leave-one-out Cross-validation 法でモデルの学習および推定評価を行った。BNs の計算処理には、U.C.Berkeley で開発された Bayes Net Toolbox (BNT)⁽⁹⁾を用いて行った。

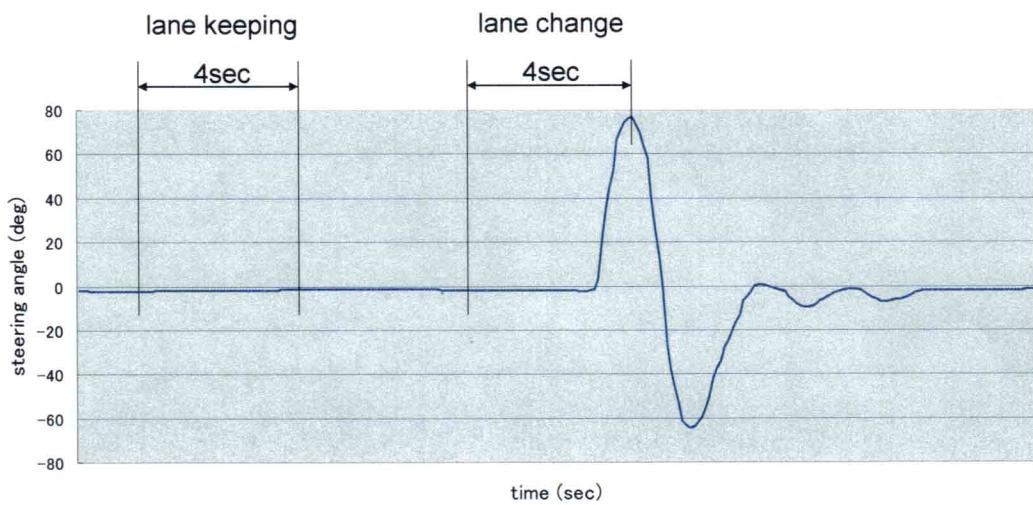


Fig.4 Extracted data

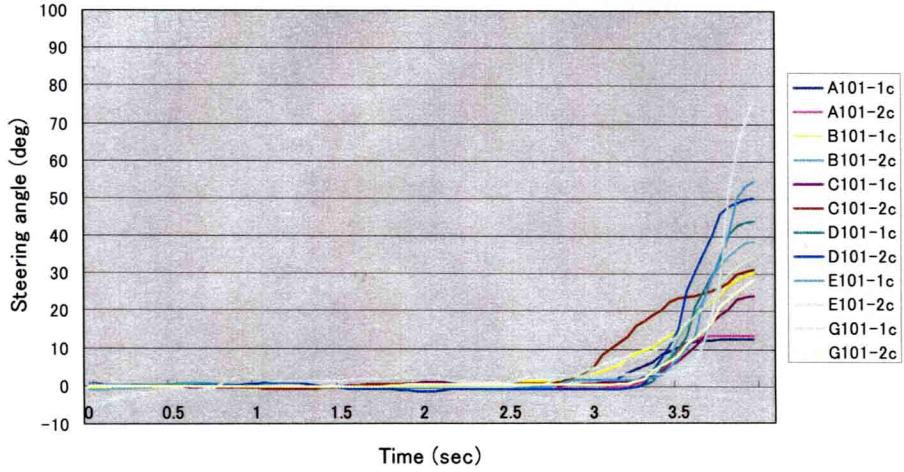


Fig.5 Normal right lane change data

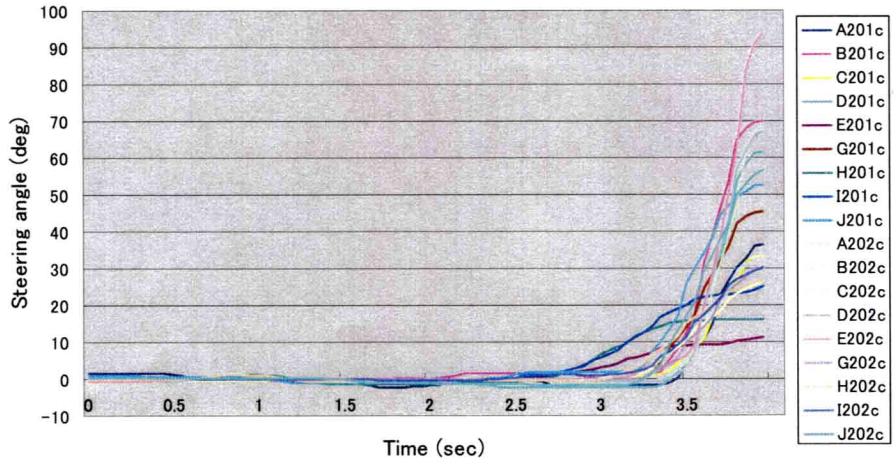


Fig.6 Emergency right lane change data

- (1) パラメータ学習：学習するパラメータの観測値データは、Leave-one-out Cross-validation 法に則り、推定評価対象となる被験者データを取り除いた操舵角度データとした。また、隠れ状態パラメータである操舵判断は、同様に被験者を除き操舵角度から計測者が操舵判断を推定し、操舵判断データとした。その際、操舵判断は、操舵開始時からとして、それまでは、車線維持判断とした。これらの操舵角度データと操舵判断データを用いて、隠れ状態の無い完全観測データとしてパラメータ学習を行った。学習は、学習が収束するまで、つまり、学習データに対する尤度が最大となるまで行った。
- (2) 従来の HMM によるモデル：評価の比較対象となる HMM によって推定する LKN , LCN , LCE は、次のサブモデルから構成されており、それぞれの関連は無い。

$$LKN = \{lkn\}, \quad LCN = \{lcn1, lcn2, lcn3\}, \quad LCE = \{lce1, lce2, lce3\}$$

サブモデルは、left-to-right 型の状態数 3 でガウシアン出力付きで、状態遷移回数 $T = 5$ 回 (0.25sec) とした。サブモデルの構造を図 7 に示す。サブモデルの学習は、図 8 に示すように状態遷移回数相当の時間毎にサブモデルを操舵角度に割り当てて行った。学習は、BNs モデルの学習条件と等しくするため、尤度が最大となるまで行った。学習および推定は、一般的な Baum Welch アルゴリズム⁽¹⁰⁾を使用した。HMM の計算処理には、同じく U.C.Berkeley で開発された Hidden Markov Model (HMM) Toolbox⁽¹¹⁾ を用いて行った。

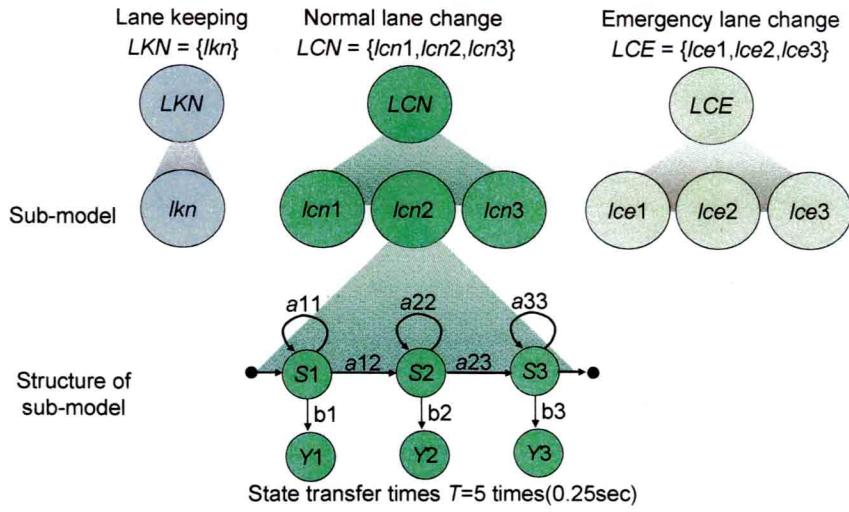


Fig.7 HMM sub-model structure

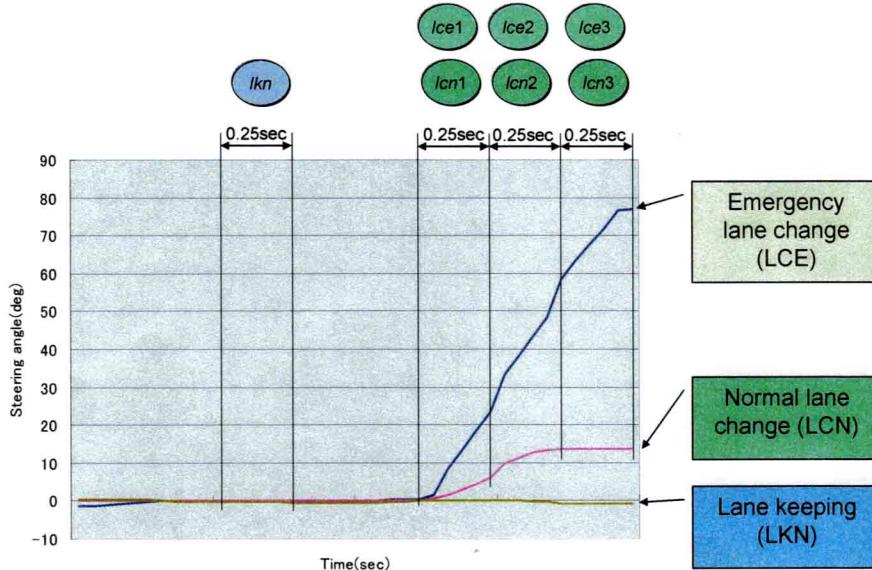
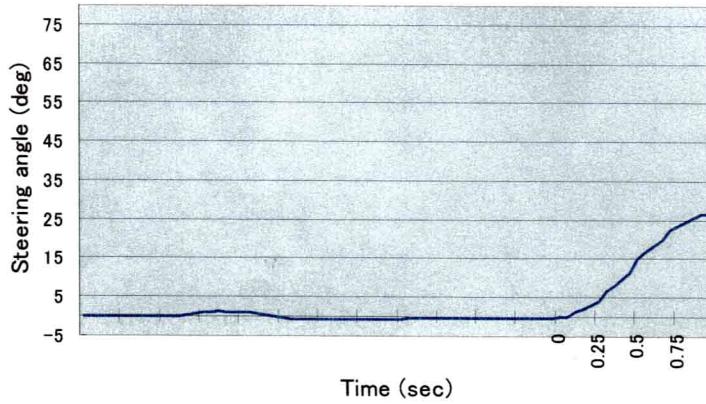


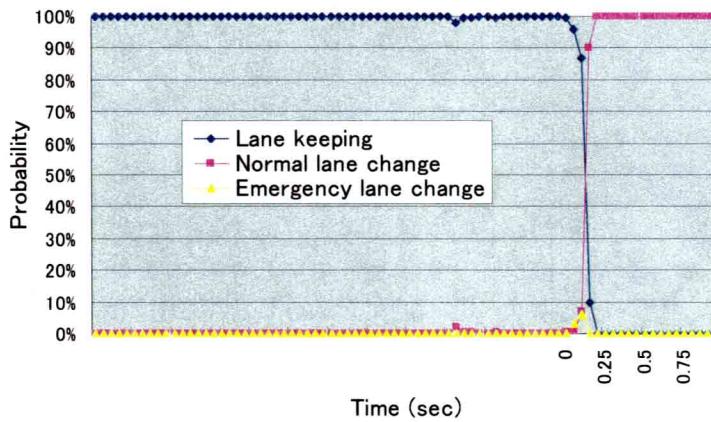
Fig.8 HMM sub-model allocation

3・4 車線変更推定結果と考察

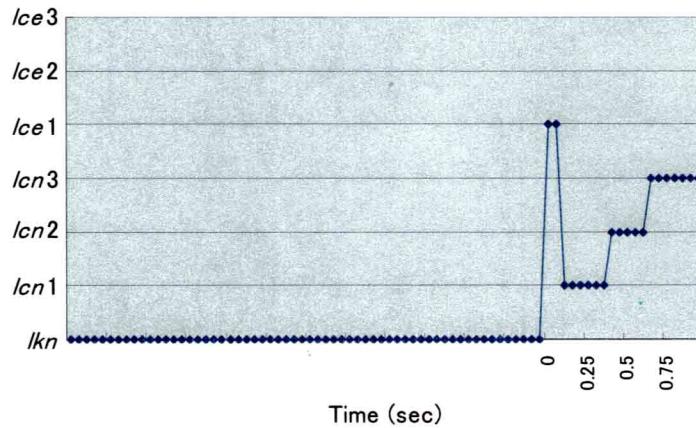
(1) 通常右車線変更推定結果の例：操舵角度データの時系列変化と推定結果を、BNs モデルでの推定確率変化と HMM モデルでの推定サブモデル変化とで比較し、図 9 に示す。図中の時間 0 は、操舵開始時点を意味する。BNs モデルを用いたほうでは、操舵開始から 0.15sec 時点で“通常車線変更”と 90% の確率で推定している。一方、HMM モデルを用いたほうでは、操舵開始から 0.10sec 時点で通常車線変更サブモデル $lcn1$ を、0.40sec で $lcn2$ を、0.65sec で $lcn3$ を推定している。また、通常車線変更の操舵開始直後の領域では、緊急車線変更サブモデル $lce1$ も誤推定されている。通常車線変更推定のこの例では、BNs モデルを用いたほうが安定して推定できていることがわかる。



(a) Original data



(b) BNs model inference result



(c) HMM model inference result

Fig.9 Inference results for normal lane change data

(2) 緊急右車線変更推定結果の例：操舵角度データの時系列変化と推定結果を、BNs モデルでの推定確率変化と HMM モデルでの推定サブモデル変化とで比較し、図 10 に示す。図中の時間 0 は、バン型乗用車の出現時間を意味する。BNs モデルを用いたほうでは、バン型乗用車出現から 0.50sec 時点で“緊急車線変更”と 90% の確率で推定している。一方、HMM モデルを用いたほうでは、バン型乗用車出現から 0.70sec 時点で緊急車線変更サブモデル $lce2$ を、0.90sec で $lce3$ を推定している。また、緊急車線

変更の操舵開始直後の領域では、通常車線変更サブモデル $lcn1, lcn2, lcn3$ も誤推定されている。緊急車線変更推定のこの例では、BNs モデルを用いたほうが明らかに安定して推定できていることがわかる。

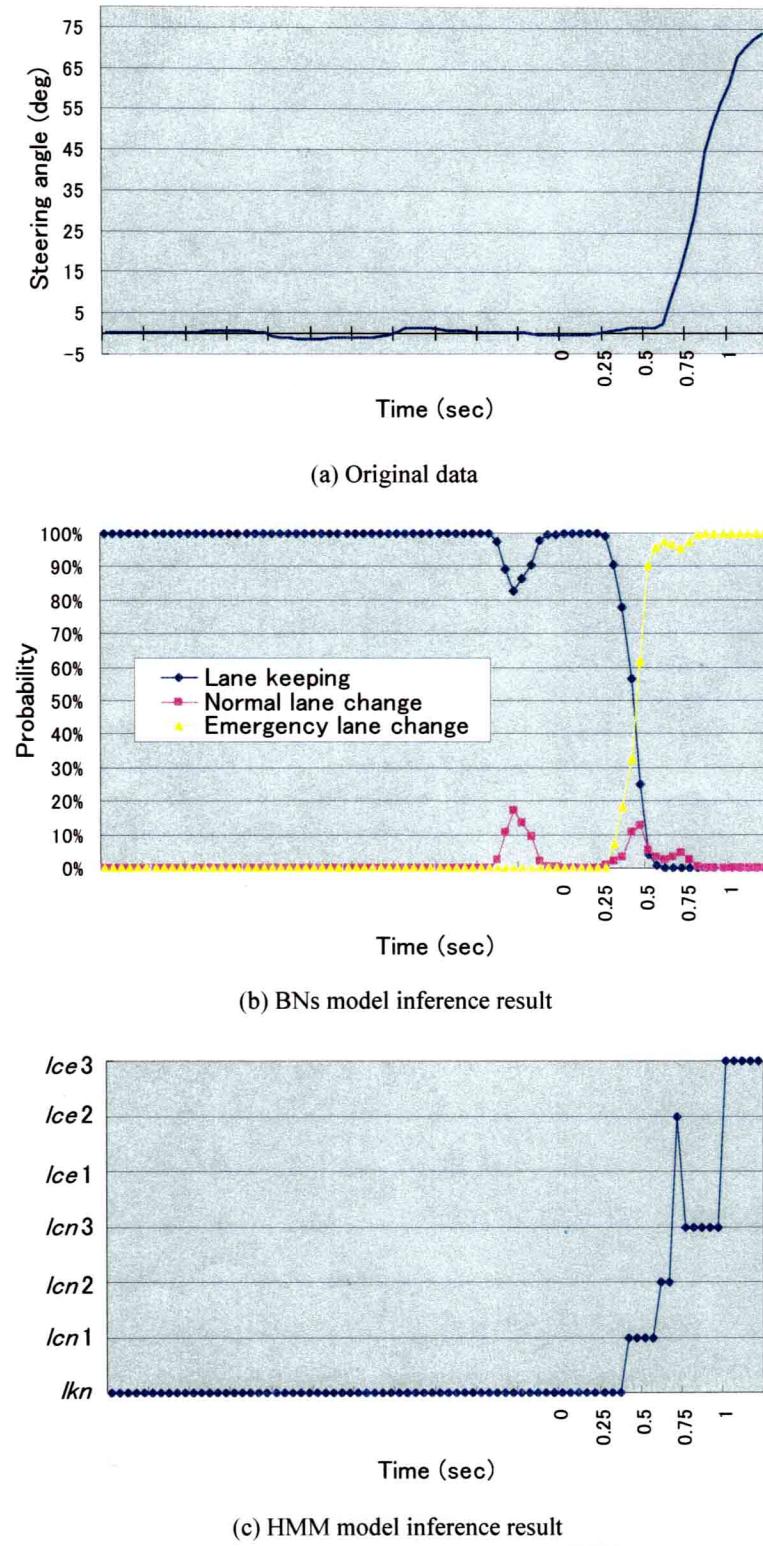


Fig.10 Inference results for emergency lane change data

(3) 推定率と考察: BNs モデルを用いたほうは、操舵角度第 1 ピークまでの間に被験者の操舵判断が 90% 以上の確率で正しく推定された場合を“正推定”とし、その間に、間違った操舵判断を 90% 以上の確率で

推定された場合を“誤推定が含まれる”とした。HMM モデルを用いたほうは、操舵角度第 1 ピークまでの間に被験者の操舵判断のサブモデル $lcn3$ または $lce3$ が正しく推定された場合を“正推定”とし、その間に、間違った操舵判断のサブモデル $lcn2 \sim 3$ または $lce2 \sim 3$ を誤って推定された場合を“誤推定が含まれる”とした。また、緊急右車線変更時のバン型乗用車の出現からの推定時間は、BNs モデルでは 90% 以上の確率で推定した時間とし、HMM モデルでは、 $lce1 \sim 3$ のいずれかのサブモデルが推定された時間とした。

次に、被験者データを評価するために被験者データと学習データとの特徴量の近さを求めた。特徴量の近さは、次式を用いて無次元化したノルム（ユークリッド距離）⁽¹²⁾として計算した。

$$|x_s, x_l| = \sqrt{\sum_{k=1}^n \frac{(x_{sk} - \mu_{lk})^2}{\sigma_{lk}^2}} \quad (3)$$

ただし、 k 番目の被験者データを x_{sk} 、 k 番目の学習データと平均値、分散値を x_{lk} 、 μ_{lk} 、 σ_{lk}^2 とする。また、データ数は、 $n = 80$ 個とする。緊急右車線変更時のノルムと推定時間の関係を図 11 に示す。この図を見ると、ノルムが小さい時、すなわち、被験者データと学習データの特徴量が近い時、BNs モデルは、推定時間約 0.5sec 付近で、安定して推定が行えることがわかる。

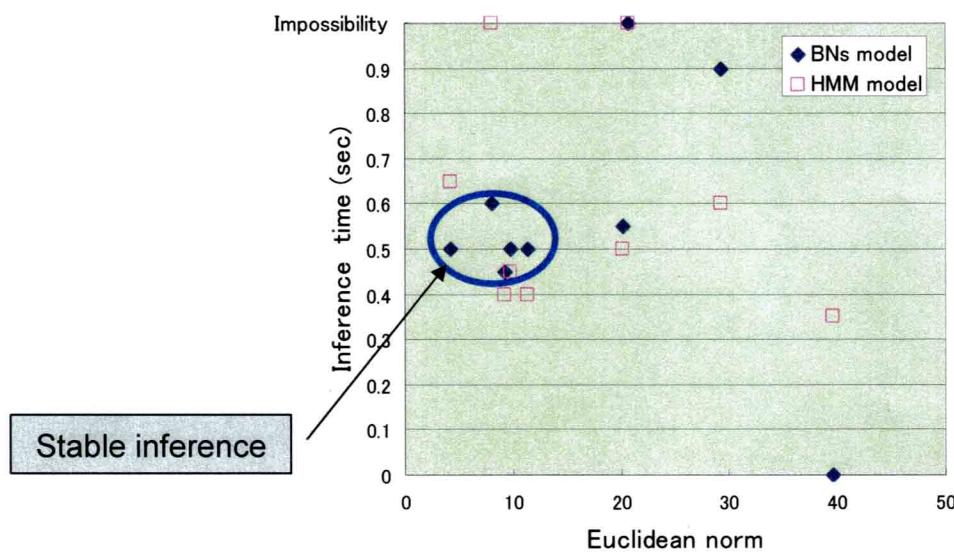


Fig.11 Inference time at emergency lane change

通常右車線変更時の BNs モデルと HMM モデルでの推定率の比較をノルム範囲別に、表 1 に示す。また、緊急右車線変更時の BNs モデルと HMM モデルでの推定率の比較をノルム範囲別に、表 2 に示す。表 1、2 の（）内の数値は、該当数と標本の被験者数である。

今回の実験では、BNs モデルと HMM モデルは共に尤度が最大となるまで学習が行われており、学習の程度は同じで推定結果は最適解である、と考えられる。つまり、表 1 と表 2 の結果から BNs モデルは、HMM モデルよりも推定率および誤推定が含まれる割合が、向上していることがわかる。特にノルム 10 未満の推定率は、通常右車線変更および緊急右車線変更ともほぼ 100% の推定率である。また、緊急右車線変更時のノルム 20 未満の誤推定が含まれる割合の改善度は、顕著である。これは、BNs が持つモデルパラメータの確率性と滑らかな特徴列の記述性により、運転行動の文脈依存性を表現できた結果と思われる。しかし、操舵角度の小さい通常右車線変更時の誤推定が含まれる割合の改善があまり見られず、操舵角度データだけで運転行動の文脈依存性を表現することは、不十分であることが

わかる。今回は、モデルの基本性能の比較を目的としたために入力の観測データは、操舵角度だけとしたが他の車両データを使い、運転行動をより高度な文脈依存性の表現としたモデルを構築する必要がある。

Table 1 Inference results for normal lane change data

Euclidean norm	under 10		under 20		all	
	BNs	HMM	BNs	HMM	BNs	HMM
correct inference rate	100% (4/4)	25% (1/4)	75% (6/8)	25% (2/8)	78% (7/9)	33% (3/9)
incorrect inference rate	50% (2/4)	50% (2/4)	63% (5/8)	63% (5/8)	56% (5/9)	67% (6/9)

Table 2 Inference results for emergency lane change data

Euclidean norm	under 10		under 20		all	
	BNs	HMM	BNs	HMM	BNs	HMM
correct inference rate	100% (4/4)	75% (3/4)	100% (5/5)	80% (4/5)	89% (8/9)	78% (7/9)
incorrect inference rate	0% (0/4)	75% (3/4)	0% (0/5)	60% (3/5)	33% (3/9)	67% (6/9)
average inference time	0.51se c	0.50se c	0.51se c	0.47se c	0.58se c	0.48se c

4. 結 語

車線変更時の運転行動を推定するドライバモデルを、運転行動階層モデルに基づくモデル構造の考え方則り、BNs の中でもスタティック型の条件付ガウシアンモデルを用いて構築した。このモデルの特性を従来の HMM モデルと比較し、ドライビングシミュレータを用いて解析を行い、次の知見を得た。

- (1) BNs の特徴を活かして、離散型ノードをシリーズに接続し、操舵判断が時系列に推移できるように表現したことにより、運転行動の文脈依存性を表現するドライバモデルを構築できる可能性を示した。特に緊急右車線変更時のノルム 10 未満では、推定率ほぼ 100%で、誤推定が含まれる確率は、0%であった。
- (2) 操舵角度の小さい通常右操舵では、本モデルを用いて推定率は向上したが、誤推定が含まれる確率は HMM モデルと同程度であった。誤推定率の低減のため、操舵角度以外の車両データを入力として、より高度な文脈依存性を表現したモデルについて今後検討する。
- (3) 運転行動階層モデルの Level1 から Level2 の一部である認知・判断までを本モデルを用いて表現できる可能性を示した。このことにより、本モデルが他の運転シーンにも適用できる可能性が高まった。

文 献

- (1) 天野也寸志, 菅原朋子, 名切末晴, 土居俊一: 運転行動予測による運転支援システムの構築, 日本機械学会論文集, C 編, Vol. 70, No.698 (2004), pp. 142-149.
- (2) Kumagai, T. et al., Prediction of Human Driving Behavior Using Dynamic Bayesian Networks, *IEICE Transactions Information and Systems (The Institute of Electronics, Information and Communication Engineers)*, Vol. E89-D, No. 2 (2006), pp. 857-860.
- (3) 久家伸友, 山村智弘, 下山修, LIU, A.: ドライビングシミュレータによる運転行動認識モデルの研究, 自動車技術会論文集, Vol. 31, No.3 (2000), pp. 95- 100.
- (4) Peräaho, M., et al., Driver Competence in a Hierarchical Perspective; Implications for Driver Education, *Traffic Research (University of Turku)*, (June, 2003), pp. 2- 11.
- (5) Russell, S., et al., Artificial Intelligence A Modern Approach Second Edition, (2003), P.492, Pearson Prentice Hall.
- (6) 中村篤, 次世代音声認識のための音響モデル-学習とダイナミクス表現-, 電子情報通信学会技術研究報告, Vol.104, No.470(SP2004 72-80) (2004), pp. 1- 6.
- (7) Richard, E. N., Learning Bayesian Networks, (2004), P.265, Pearson Prentice Hall.
- (8) Kevin, B. K., et al., Bayesian Artificial Intelligence, (2004), P.265, Pearson Prentice Hall.
- (9) Kevin Murphy's Bayes Net Toolbox (BNT), URL: <http://bnt.sourceforge.net/>
- (10) Russell, S., et al., Artificial Intelligence A Modern Approach, (1995), P.770, Pearson Prentice Hall.
- (11) Kevin Murphy's Hidden Markov Model (HMM) Toolbox, URL: <http://www.cs.ubc.ca/~murphyk/Software/HMM/hmm.html/>
- (12) 大川善邦, 波形の特徴抽出のための数学的処理, (2005), P.133, CQ 出版社