

ドライバの非通常運転行動予測における乗車前状態の有効性

早田 有利

指導教員：小栗 宏次

1 はじめに

交通事故は依然として高い水準で推移しているため低減が望まれている。中でも人的要因による事故は、99.2%と多くの割合を占めている。そのため、ドライバの状態をリアルタイムに検知・推定する研究が為されている。しかし、リアルタイムな状態検知・推定では危険な状態に推移してから捉えることとなる。そのため、より早い段階で状態を予測することが望まれている[1]。こうした状態予測を実現するために、本研究では“乗車前”のドライバ状態に着目した。乗車前状態の考慮が状態予測に有効であることを明らかにするために、乗車前状態とその後運転との間に関係性があることを示す。そして、乗車前情報が状態予測における有効な指標になることを示す。

2 乗車前状態とその後運転との関係

乗車前状態とその後運転との間に関係性を明らかにするために、産業技術総合研究所の報告[2]に基づいて「いつもと異なる(非通常な)運転行動は乗車前の状態に起因しているのではないか」という仮説を立てた。この仮説を検証するために被験者毎に繰り返しデータを計測し、教師なし学習によるクラスタリングを行うことで通常・非通常のラベル付けを行った。

2.1 分析方法

運転行動をクラスタリングするために一時停止地点及び交差点における加速・減速行動から特徴量抽出を行い[2][3]、教師なし学習である混合ガウスモデル(GMM)を用いてクラスタリングを行った。クラスタリングは特徴次元が多い場合や特徴量間に強い相関がある場合、適切にクラスタリングできない可能性が高まる。そのため、事前にz-scoreによる標準化を行い、主成分分析(PCA)による特徴次元の削減を行った。クラスタリングの際のクラスタ数 k はベイズ情報量基準(BIC,式(1))により適合度を評価し、最適なクラスタ数 k を求め、最尤推定によるクラスタリングを行った(図1)。

$$BIC = -2N \log L + m \log n \quad (1)$$




図1 GMMによるクラスタリングの流れ

図2は、交差点での減速行動に対してGMMによるクラスタリングを行った様子を示す。図2における凡例は、各クラスタにおけるデータの占める割合を表しており、運転行動の発生確率を表している。発生確率の低い運転行動はその地点における適切な運転行動が取れておらず、通常とは異なる非通常な運転行動を取っていることが考えられる。そこで本研究では、累積運転行動発生確率78%(1 σ)に達するまでの運転行動を通常と定義し、それ以外を非通常と定義した。乗車前に対しても同様の処理を行い、これにより判断される通常・非通常から乗車前のドライバ状態とその後運転との間に関係性についてApriori modelと分散分析により検討した。




図2 交差点での減速行動をクラスタリングした様子(上から順に車輪速度, アクセル踏量, ブレーキ踏量)

2.2 データ計測

被験者6名に対して1ヶ月間のデータ計測を行った。乗車前には自覚症しらべなどの主観評価及び、血圧や反応時間などの生体信号を取得し、その後ドライビングシミュレータ(DS)による走行を行った(図3)。DS走行には交差点及び一時停止地点を含む市街地を模擬した周回コースを使用した(図4)。




図3 ドライビングシミュレータ構成



図4 走行コース

2.3 評価指標

Apriori modelにより抽出されたルールの評価には、ルールの希少さを表す指示度(式(2))と確かさを表す確信度(式(3))を用いて評価を行った。式中の M はデータ数、 X, Y はデータ内の項目、 σ は指示度数を表す。

$$Supp(X \Rightarrow Y) = \frac{\sigma(X \cup Y)}{M} \quad (2)$$

$$Conf(X \Rightarrow Y) = \frac{\sigma(X \cup Y)}{\sigma(X)} = \frac{Supp(X \Rightarrow Y)}{Supp(X)} \quad (3)$$

2.4 結果

Apriori modelより抽出されたルールを表1, 2に示す。各表より乗車前主観、生体に関するルールは確信度が約25%前後であることから有効なルールがないことがわかる。また、図5に乗車前状態毎の非通常な運転行動の回数を示す。各図の横軸は乗車前の通常・非通常、縦軸は非通常な運転行動の回数を表す。非通常な運転行動の回数について分散分析を行った結果、乗車前主観、生体共にp値0.05以下の有意差があることがわかった。

以上のことから、乗車前状態とその後運転行動との間に単純なルールが存在していないが、傾向的な関係性があることがわかった。乗車前状態の違いによりその後運転行動に影響を及ぼすことから、乗車前情報は状態予測における一指標になることが示唆された。

表 1 乗車前主観とその後の運転行動に関するルール

Rules($X \Rightarrow Y$)	Supp($X \Rightarrow Y$)	Conf($X \Rightarrow Y$)
乗車前主観 \Rightarrow 一時停止減速	4.44%	26.67%
乗車前主観 \Rightarrow 交差点減速	3.33%	20.00%
乗車前主観 \Rightarrow 一時停止加速	0.69%	4.17%
乗車前主観 \Rightarrow 交差点加速	0.00%	—

表 2 乗車前生体とその後の運転行動に関するルール

Rules($X \Rightarrow Y$)	Supp($X \Rightarrow Y$)	Conf($X \Rightarrow Y$)
乗車前生体 \Rightarrow 交差点減速	4.72%	25.76%
乗車前生体 \Rightarrow 一時停止減速	2.50%	13.64%
乗車前生体 \Rightarrow 一時停止加速	1.39%	7.58%
乗車前生体 \Rightarrow 交差点加速	0.00%	—




図 5 乗車前状態毎の非通常の運転行動の回数

3 覚醒度低下状態の早期予測

乗車前情報が状態予測における一指標になることがわかったが、実際に有効であるかはわからない。そのため、覚醒度低下状態の早期予測を行うことで乗車前情報の有効性を検証した。

3.1 覚醒度の定義

覚醒度は北島らが提案する眠気表情評定法を用いた。交通事故は眠気レベル 3.2 でリスクが高まると報告されているため眠気レベル 3 を覚醒度低下状態と定義し、走行開始から眠気レベル 3 に到達するまでの時間を危険眠気レベル到達時間と定義した。

3.2 予測方法

乗車前及び乗車時に計測した情報から特徴量抽出を行い、抽出した特徴量を用いて重回帰分析による危険眠気レベル到達時間の予測を行った(式(4))。

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ij} + \epsilon \quad (4)$$

重回帰分析を行う上で問題となる多重共線性を考慮するため Stepwise 法による特徴量選択と分散拡大要因 (VIF) を考慮した。VIF は式(5)に基づいて v を算出し、 v が 3 以上となったとき目的変数との相関係数 r が低い特徴量を除外した(図6)。

$$v = \frac{1}{1 - r_{x_i x_j}^2} \quad (5)$$




図 6 危険眠気レベル到達時間の予測方法

3.3 データ計測

被験者 5 名に対して乗車前及び DS 走行時のデータ計測を行った。乗車前の状態の違いを模擬するために、普段の睡眠時間 (6, 7 時間睡眠) と普段より短い睡眠時間 (2, 3 時間睡眠) の 2 状態でデータ計測を行った。計測は各被験者に対して 6 回 (2 状態 \times 3 回) 実施した。計測は乗車前に血圧、計算時間、反応時間の計測を行い、その後、DS による走行を行った。DS 走行時には、心電図、視覚情報、車輛操作情報、顔動画の計測を行った。

3.4 予測結果

乗車直後、乗車前及び乗車直後に計測した情報から危険眠気レベル到達時間を予測した結果を図 7 に示す。各図の横軸は真値となる危険眠気レベル到達時間、縦軸は重回帰分析による予測値を表している。予測精度に関して相関係数 R と誤差標準偏差 SDE を用いて評価を行った結果、乗車直後に計測された情報のみを用いて予測を行うよりも、乗車前に計測した情報を踏まえて予測することでより高精度な予測を実現できることがわかった。このことから、乗車前情報が予測に有効な指標であることを示唆し、その有効性を検証することができた。




図 7 危険眠気レベル到達時間の予測結果

表 3 予測精度の比較

Data set	R	SDE
乗車直後	0.80	279.0
乗車前及び乗車直後	0.85	244.1

4 おわりに

本研究では、状態予測において乗車前情報が有効な指標になるか検討し、その有効性について検証した。その結果、乗車前とその後の運転との間に関係性があることを明らかにし、乗車前情報が状態予測における一指標になることを示唆した。また、乗車前情報が状態予測に有効であることを示すために覚醒度低下状態の早期予測を行った。その結果、乗車前情報を用いることでより高精度に予測できることを示唆した。以上のことから、これまで考慮されてこなかった乗車前情報が状態予測に有効な指標になることを示唆し、その有効性を示すことができた。

参考文献

- [1] D. Sandberg *et al.*, "Detecting Driver Sleepiness Using Optimized Nonlinear Combinations of Sleepiness Indicators," *IEEE Trans. ITS*, 2011.
- [2] 産業技術総合研究所, "人間行動適合型生活環境送出システム技術", 2005.
- [3] T. Kumagai *et al.*, "Prediction of Human Driving Behavior Using Dynamic Bayesian Networks," *IEICE Trans. D*, 2006.