ドライバの状態予測に向けた乗車前状態と運転行動の関係性

早田 有利^{1,a)} 田中 裕章¹ 入部 百合絵¹ 河中 治樹¹ 小栗 宏次¹

受付日 2017年4月11日, 採録日 2017年10月3日

概要:自動車運転時の事故要因はヒューマンエラーが大きな割合を占めるため、その防止対策の1つとしてドライバの状態を推定・予測する研究が行われている。従来の研究では、運転時に計測した情報を用いて状態を推定するものが多く提案されている。それに対し、我々は乗車前のドライバ状態に着目し、乗車前に計測した情報を組み合わせることで、従来よりも高精度に覚醒度低下状態を予測できる方法を提案した。しかし、眠気以外にも疲労や漫然など乗車前における様々な状態が、通常とは異なる運転行動を引き起こす可能性がある。本研究では約1カ月にわたる実験を通して眠気以外も含んだふだんとは異なるドライバの乗車前状態を判定し、各状態とその後の運転行動との関係性を明らかにした。その結果、乗車前がふだんとは異なる非通常な状態にあるとき、その後の運転において非通常な運転行動を引き起こす確率が約2.3倍増加することが明らかとなった。特に、乗車前の「反応力に関する特徴量」がその後の運転行動に大きく影響することが示唆された。

キーワード:ドライバモニタリング,乗車前,運転行動,状態推定,混合ガウスモデル (GMM)

Relationship Between Before and While Driving for the Prediction of the Driver's State

Yuto Hayata^{1,a)} Hiroaki Tanaka¹ Yurie Iribe¹ Haruki Kawanaka¹ Koji Oguri¹

Received: April 11, 2017, Accepted: October 3, 2017

Abstract: Since driver's human-error is one of the main reasons of accidents, researches of estimating and predicting driver's condition are conducted. Previous studies proposed methods of predicting driver's condition by using data obtained while driving. On the other hand, we focus on data which could be obtained before riding the car. By combining the data before and while driving, we propose a method to highly predict the condition of low arousal state. Not only drowsiness but other states (e.g. tiredness, distraction) have possibility of lowering arousal state. In this study we conducted experiments for 1 month obtaining data before driving and while driving. We revealed the relationship of each state before driving and the act during drive. As a result, we found out that unusual driving occurs for more than 2.3 times when drivers are in odd condition before driving. Specifically, data of "reaction speed" highly related with the rear condition of driver while driving.

Keywords: driver monitoring, before driving, driver behavior, state estimation, gaussian mixture model (GMM)

1. はじめに

交通事故は世界的な問題として考えられており, 低減が

¹ 愛知県立大学大学院情報科学研究科 Graduate School of Information Science and Technology, Aichi Prefectural University, Nagakute, Aichi 480–1198, Japan 望まれている [1]. 米国運輸省道路交通安全局(NHTSA)が行った交通事故発生要因に関する調査によると交通事故原因のうち、環境的要因が 5.4%、車輌的要因が 0.5%、人的要因(ヒューマンエラー)が 99.2%を占めることが報告されている(各要因が複合的に絡み合うため 100%を超える)[2]. このように、ドライバ自身によるヒューマンエラーが交通事故の大きな割合を占めることから、ヒューマ

a) yuto.hayata516@gmail.com

ンエラーを防止する技術が求められている。その対策の1つとして、自動車を運転する主体であるドライバの状態を観測するドライバモニタリングに関する研究がなされている [3], [4], [5], [6], [7], [8], [9], [10], [11], [12], [13]. 従来の研究では自動車運転時に計測したステアリング操舵量 [3], [4] やアクセル・ブレーキペダル [5] などの車輌操作情報,瞼開閉度 [6], [7] や瞳孔径 [8], 心電図 [9], [10],眼電図 [11],脳波 [12],皮膚温度 [13] などの生体信号から特徴量を抽出し,ドライバ状態をリアルタイムに推定(現在におけるドライバの状態を推定)している.

一方, NHTSA の報告 [2] によると, 不眠や過労など乗 車前の状態の違いが起因して起こった交通事故は交通事故 全体の半数以上を占めると推定されている. そのため, 近 年では運転中の状態推定ではなく, ドライバの状態変化の 予兆をとらえる状態予測に関する研究が行われている. た とえば西山ら [14], [15] は, 自動車運転時の路面の凹凸によ り必然的に生じる前庭動眼反射(VOR)と瞳孔ゆらぎに着 目し、眠気予兆検出法を提案した。また、Sandbergら[16] は、自動車運転には睡眠が大きく影響していると考え、サー カディアンリズム,起床時刻,就寝時刻に基づいて,ド ライバの状態を予測する数学的モデル SWP (sleep/wake predictor) を提案した. それに対して我々は, Dinges [17] や Fernandez-Mendoza ら [18] による研究のように睡眠に 関する情報だけでなく、乗車前のドライバの認知機能や情 報処理機能、自律神経活動もその後のドライバ状態を予測 するうえで重要な指標になりうると考え, 実験的なモデル を提案した. それにより, 乗車前に計測した情報を組み合 わせることで従来よりも高精度に運転中のドライバの覚醒 度低下状態を予測できることを示し, 乗車前情報の有効性 を示唆した[19]. このように、乗車前のドライバの眠気・ 覚醒度とその後の運転におけるドライバの眠気・覚醒度と の関係性については統計的[2]・実験的[16]に証明されて いる. また、乗車前に計測した情報から特徴量を抽出する ことで、その後の運転におけるドライバの眠気・覚醒度の 低下を高精度に予測できることが示されている[19].しか し、これらの研究の多くはドライバの眠気に関連するもの であるが、そのほかにもドライバに影響を及ぼす状態とし て疲労や漫然などがあり、これらは同時に発生している可 能性が高い. すなわち, 乗車前の眠気以外にも様々な要因 が運転に影響を及ぼし、通常と異なる運転行動を引き起こ していると考えられる. 今後, 乗車前に計測した情報を用 いて運転中のドライバ状態推定, 状態予測の研究を進めて いくためには, 眠気以外も含んだ乗車前状態と運転中のド ライバの状態もしくは運転行動との関係性を示す必要性が ある.

また、近年では、google glass や Apple watch、リストバンド型活動量計など日々の Life log を計測することができるウェアラブル端末が実用化されている。現在、自動車

とスマートフォンが連携しているが、今後はこれらのウェアラブル端末も自動車とつながる時代が訪れると考えられる。これらのウェアラブル端末により計測された Life logを日々の健康管理だけでなく、自動車運転時のサポートに応用することができれば、さらなる交通事故の低減につながると考えられる。本研究では、これらのことをふまえ、乗車前のドライバ状態とその後の運転行動との関係性に焦点を当てた実験を通して、ドライバの状態推定、状態予測の可能性について模索する。

2. 本研究における仮説

一般的にドライバの運転行動は、認知・判断・操作の3 行動から成り立つことが知られており、これらの行動の遅 れや誤りにより交通事故のリスクが高まることが報告され ている [20]. また、新エネルギー・産業技術総合開発機構 (NEDO) の「人間行動適合型生活環境創出システム技術 | (通称:人間行動プロジェクト) [21] では,「一般のドライ バが状況に応じて、いつも通り運転しているのであれば事 故につながるリスクが高まる状態になりにくいが、"ウッ カリ"して、いつもから逸脱した運転になるとリスクが高 まる状態になりやすい」という新たな考えを提案し、一時 停止・交差点での運転行動を対象に運転操作が通常と異な るかを検出し、その程度をドライバにリアルタイムで呈示 する車載型の運転支援システムのプロトタイプを開発し た [22]. ここでいう「いつも通りの運転」とは、一般的に 多くの人がとるであろう頻出する運転行動を指し,「いつ もから逸脱した運転」とは、頻出する運転行動とは異なる 稀な運転行動を指す. たとえば, 一時停止地点の減速行動 を考えた場合、図1に示す青線のような緩やかな減速が一 時停止地点における頻出する運転行動 (通常な運転行動) であると考えられる. それに対して, 図1に示す赤線のよ うな急減速や,早い段階から減速を始めるような運転行動 は稀な運転行動(非通常な運転行動)であると考えられる.

以上のことから,我々は乗車前のドライバ状態とその後 の運転行動との間の関係性を明らかにするための仮説とし て,「運転時における非通常な運転行動は,乗車前の非通 常なドライバ状態が起因しているのではないか」という仮 説を立てた.この仮説を明らかにすることで乗車前のドラ イバ状態とその後の運転行動との間に関係性があることを 示す.

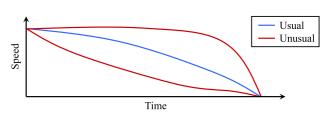


図1 一時停止地点における運転行動例

Fig. 1 Example of driving behavior near the traffic 'stop sign'.

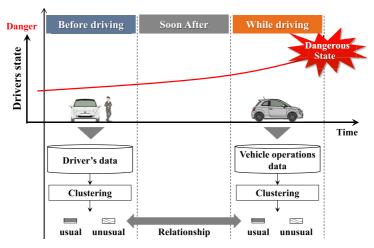


図 2 通常・非通常を分類する流れの概要図

Fig. 2 Schematic diagram of the flow to discriminate between usual and unusual.

3. 分析方法

3.1 概要

乗車前のドライバ状態およびその後の運転行動が通常 か、非通常かラベル付けすることができれば、乗車前のド ライバ状態とその後の運転行動との関係性について分析す ることができる.しかし、どの乗車前のドライバ状態およ び運転行動が通常または非通常であるかという判断は長期 的に観察しないと特定は難しい. そのため, 本研究では長 期間にわたりデータを計測し、それらのデータをもとに通 常・非通常を分類するためのクラスタリングを行う. 図 2 に乗車前および運転行動から通常・非通常を分類するまで の流れの概要を示す. 概要としては、まずはじめに、乗車 前の状態を表す情報として生体信号および主観評価を計測 し,運転中には車両操作情報をそれぞれ計測する.次に, 計測データから抽出した特徴量を入力とする教師なし学習 (混合ガウスモデル)により、データの分布に基づいて乗車 前のドライバ状態と運転行動のクラスタリングを行う. そ して、各クラスタに基づき乗車前のドライバ状態と運転行 動を通常・非通常であるかに分類することで、乗車前と運 転行動との間の関係性を明らかにする.

3.2 車輌操作情報からの特徴量抽出

車輌操作情報の計測には図3に示すドライビングシミュレータを用いた。ドライビングシミュレータは同一の運転シーンに対して再現性があり、発生した事象に対するドライバの反応や操作の分析が容易であるという利点を有するため用いた[23],[24],[25]。本研究で用いるドライビングシミュレータは、実車(トヨタ自動車「シエンタ」)の運転席周りを抽出して作成しており、ハンドルやシート、ペダルなどは実車同様のものを使用している。走行コースの作成には、Forum8社のUC/win-Roadを使用した。2章で述べた人間行動プロジェクトでの解析対象地点に基づい



図 3 ドライビングシミュレータ **Fig. 3** Driving simulator.

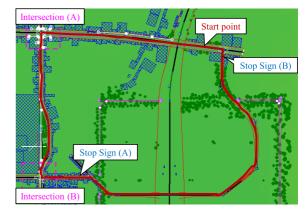


図 4 走行コースの概形

Fig. 4 Overview of driving course.

て、一時停止と交差点を含む市街地および郊外を模擬した 周回コースを作成した.作成した走行コースの概形を図 $\mathbf{4}$ に示し、走行コースの様子を図 $\mathbf{5}$ に示す.走行コースは、 1 周あたり約 $3,670\,\mathrm{m}$ であり、約 $5\,\mathrm{G}$ で 1 周することができる.

計測した車輌操作情報から運転行動を抽出するための 解析地点として本研究では,人間行動プロジェクトの解



(a) スタート地点 (a) Start point.

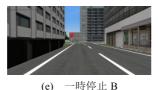




(b) 交差点 A (b) Intersection A.

(c) 交差点 B (c) Intersection B.





- (d) 一時停止 A (d) Traffic 'stop sign' A.
- (e) Traffic 'stop sign' B.

図 5 走行コースにおける各地点の様子

Fig. 5 Images of each point in driving course.

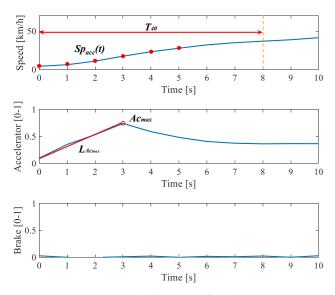


図 6 加速地点における各特徴量

 ${\bf Fig.~6} \quad {\bf Feature~extraction~from~vehicle~operations~data~at~the} \\ \quad {\bf acceleration~points}.$

析対象地点である一時停止,交差点での加速・減速行動を対象とした [22]. 一時停止地点や交差点を対象とした分析や,運転行動モデルを作成した先行研究に基づき,走行することにより得られた車輌速度,アクセル踏量,ブレーキ踏量から各解析対象地点における特徴量の抽出を行った [26], [27], [28], [29]. その結果の一例を図 6 と図 7 に示す.図 6 はある加速地点における車輌操作情報から抽出した特徴量の変移を表している.加速度地点で抽出した全特徴量を表 1 に示す.また,図 7 にある減速地点における車輌操作情報から抽出した特徴量の変移を示す.減速地点で抽出したすべての特徴量を表 2 に示す.なお,図 6 お

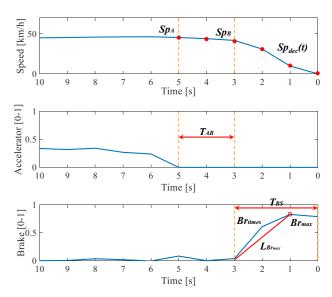


図 7 減速地点における各特徴量

Fig. 7 Feature extraction from vehicle operations data at the deceleration points.

表 1 加速地点における特徴量の一覧

Table 1 List of feature indexes at the acceleration point.

特徴量	説明
$Sp_{acc}(t)$	加速開始 t 秒後の車輌速度($t=0,1,,5$)
Ac_{\max}	アクセル踏量の最大値
$L_{ m ACmax}$	加速開始時とアクセル踏量最大値の変化量
T_{40}	加速開始してから車輌速度が 40km/h に至るまでの時間

表 2 減速地点における特徴量の一覧

 ${\bf Table~2} \quad {\bf List~of~feature~indexes~at~the~deceleration~point}.$

説明
停車 t 秒前の車輌速度 $(t=0,1,,5)$
ブレーキを踏み始めた時の車輌速度
アクセルを放した時の車輌速度
ブレーキを踏み始めてから停車するまでに要 する時間
アクセルを放してから停車するまでに要する 時間
停車までにブレーキを踏んだ回数
ブレーキ踏量の最大値

よび図7の縦軸は上から車輌速度,アクセル踏量,ブレーキ踏量を,横軸は時間を表している.

3.3 乗車前情報からの特徴量抽出

乗車前のドライバの状態を定量的に評価するために,乗

車前に計測する情報について述べる.

今回の実験では、ドライバの通常・非通常状態を適切に とらえるために、ドライバをある特定の状態に固定あるい は変化させてデータを計測するわけではなく、日常生活の 中で変化するドライバの状態を統計的に観測することとし た. そのため、ドライバに負担がかからず、短時間で簡便 に行えることが望まれる. また、日々の生活の中で変化す る人間の状態を的確にとらえることのできる情報を収集す る必要がある. これらの点を考慮し、乗車前に計測する情 報を選定した. 次項以降では、本研究で乗車前に計測した 情報について述べる.

3.3.1 主観評価

主観評価の取得には、前日の睡眠内省や自覚的な睡眠の質を評価することができる OSA 睡眠調査票 MA版 [30]、疲労の自覚症状を調べることができる自覚症しらべ [31]、精神的な負担を評価することができる RAS (Roken Arousal Scale) [32]、いまある不安 (状態不安)を評価することができる STAI (State-Trait Anxiety Inventory) [33]、体調の自覚症状を調べることができる VAS (Visual Analog Scale) [34]の5つの検査用紙を用いた。各検査用紙は被験者に安静着座状態で記入してもらうことで取得した。各検査用紙の評価方法に基づいて各因子を得点化し、特徴量として用いた。

3.3.2 体温

体温の計測には、テルモ社製の電子体温計 C230 を用いた. 被験者には、安静着座状態を保ってもらい、電子体温計を左脇に挟むことで計測を行った. 体温は、約20秒の予測検温方式を採用し、1回の計測値を特徴量として用いた.

3.3.3 α -アミラーゼ活性

 α -アミラーゼ活性の計測には、NIPRO 社製の酵素分解装置唾液アミラーゼモニター(旧 COCORO METER)を用いた [35]. 被験者には、安静着座状態を保ってもらい、計測チップの唾液採取紙が付いた部分を舌下に約 30 秒間入れることで、 α -アミラーゼ活性を 1 回計測し、特徴量として用いた.

3.3.4 血圧

血圧の計測には、エー・アンド・ディー社の自動血圧計 TM-2580 (Vital Note) を用いた。この血圧計は、オシロメトリック方式で収縮期血圧、拡張期血圧、脈拍数を計測することができる。被験者には、安静着座状態を保ってもらい、付属のアダルトカフを使用して計測を行った。計測は1分間隔で3回の計測を行い、各値の平均値および標準偏差を特徴量として用いた。

3.3.5 反応時間

反応時間の計測には、選択反応課題を用いた。本研究で用いた選択反応課題は、ブラックアウトされたモニタにランダム時間後、呈示されるターゲット(ランドルト環の左・下・右開放の3種類のうちのいずれか)に対して、適切なボタンを選択して押すという課題である。ターゲットに対

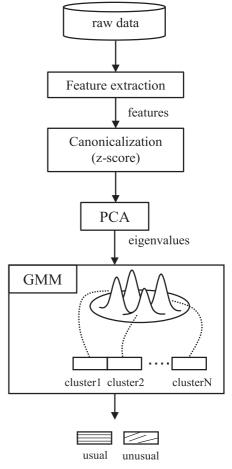


図 8 GMM によるクラスタリングの流れ **Fig. 8** Flow of clustering by GMM.

する反応には、キーボードの矢印キーを用い、ランドルト環の開放方向の矢印キーを押すように設定した。ターゲットが呈示されてから、所定のキーを押すまでの時間を反応時間と定義し、安静着座状態で25回計測を行った。25回計測して得られる反応時間の平均値、標準偏差、分散、中央値、最大値、最小値、範囲を特徴量として用いた。

3.3.6 フリッカー値

フリッカー値(CFF)の計測には、Flicker Health Management 社の FHM システム(Flicker Health Management System)[36] を iPad にインストールして行った。安静着 座状態で 5 回の計測を行い、出力されるフリッカー値を特 徴量として用いた。

3.4 通常・非通常の分類手法

図8に通常・非通常の分類手法を示す。まずは、ドライバから取得したデータから特徴量を抽出する。次に特徴量の次元数を減らすために主成分分析を行う。最後に主成分を混合ガウスモデル(GMM)によりクラスタリングし、クラスタの発生確率に基づき、通常・非通常に分類する。以降の項で各手法について記述を行う。

3.4.1 主成分分析による次元削減

教師なし学習によるクラスタリングを行う際に特徴量の 次元数が多い場合や、特徴量間に高い相関がある場合、適 切にクラスタリングができない可能性が高まる。そのた め、特徴量の次元数を事前に減らしておくことが必要であ ると考えられる。

特徴量の次元数を減らす方法には大きく特徴量選択と特徴量変換がある。正解となる教師がある場合には特徴量選択が有効であると考えられるが、本研究においては教師となるデータが存在しないため、主成分分析(Principal Component Analysis: PCA)による次元削減を行った。また、主成分分析を適用する特徴量については、特徴量ごとにデータの桁数が異なることが考えられる。そのため、各特徴量について平均 0、標準偏差 1 になるように z-score を用いて標準化を行った。

標準化された z-score を主成分分析に適用し、特徴量の次元削減を行った。主成分の採用基準には、カイザー基準(the Kaiser criterion) [37] やスクリープロット基準(the Scree test) [38] などがあるが、スクリープロット基準は過大推定、過小推定が起こることからカイザー基準を用いることが一般的であるとされている [39]。そこで、本研究では主成分の採用基準にカイザー基準を採用し、乗車前情報、各周の解析対象地点ごとそれぞれに対し主成分分析を行った。

3.4.2 混合ガウスモデルによるクラスタリング

主成分分析により採用した主成分を用いて混合ガウスモデル(Gaussian Mixture Model: GMM)によるクラスタリングを行った。GMM は多変量正規密度の混合として、観測した変数の確率密度関数を表すことによってクラスタリングする方法であり、事後確率による曖昧性を持たせた非線形なクラスタリングを行うことができる。

教師なし学習を行う際には、事前にクラスタリングしたいクラスタ数kを設定しておく必要があるが、最適なクラスタ数kは不明である。そこで、本研究ではクラスタ数kを2から順に増加させていき、各クラスタ数kの値でベイズ情報量基準(BIC)を算出(式(1))し[40]、クラスタリングの適合度合いを評価して最適なクラスタ数kの値を求めた。なお、式(1)における $N\log L$ は負の対数尤度、nは観測数、mは推定するパラメータ数を表す。

$$BIC = -2N\log L + m\log n \tag{1}$$

また、教師なし学習は初期値の与え方によってクラスタリングの結果が異なる場合がある。初期値の与え方による局所的最適解を採用しないために、300回の最尤推定により選ばれた結果を採用することとした。

3.4.3 通常・非通常状態の定義

GMM を用いることでクラスタリングをすることはできるが、クラスタリングされたどのクラスタが通常 (usual)

であり、どのクラスタが非通常 (unusual) であるか分からない。そのため、通常・非通常の定義を明確にする必要がある。データの判断・分類を行う統計的な基準として、パレートの法則や標準偏差などが用いられることが多い。そこで、本研究では通常・非通常な状態を分類するためにパレートの法則を適用し、クラスタの発生確率の高いものから加算して総計 80%に達するまでのクラスタを通常、その他のクラスタを非通常と定義した。

4. 実験

4.1 実験条件

乗車前および乗車時のデータを計測するために、ドライビングシミュレータを用いた実験を愛知県立大学で行った。被験者は、21~25歳の健常成人6名(男性1名、女性5名)であり、各被験者は週5日間の計測を4週間、計20日間のデータ計測を行った。時間による日内変化による影響を除外するために、データの計測開始時刻は被験者ごとに固有の時間を設け、毎日ほぼ同一時刻にデータの計測を行った。その際、日常生活における中で変化する被験者の状態をとらえるために、実験直前の過度な運動や飲食は控えてもらうように指示した。

実験プロトコルとしては、大学に到着後すぐに OSA 睡眠調査票 MA 版を実施し、ドライビングシミュレータ走行前に主観評価(自覚症しらべ、RAS、STAI、VAS)、体温、 α -アミラーゼ、血圧、反応時間、フリッカー値の順に計測を行い、その後ドライビングシミュレータ走行を行った.

ドライビングシミュレータ走行には、図4に示した走行コースを使用した.被験者には、第1車線を50km/hを目安として走行し、必要に応じて加減速を行い、車線変更を行わず、できる限り車線中央を走行するように指示した。ドライビングシミュレータ走行は、1日あたり3周とし、時間換算にすると約15分間の走行であった。また、外的刺激による被験者への影響を排除するために、走行車輌は自車輌のみとし、歩行者や信号の変化などがない状態で計測を行った

4.2 実験結果

4.2.1 GMM によるクラスタリングの結果

乗車前情報および各周の解析対象地点ごとに主成分分析を行い、抽出した主成分を用いて GMM によるクラスタリングを行った。結果の一例として、図 9 に一時停止 Bの減速に関わるデータをクラスタリングし、7つのクラスタに属するデータ群を平均化したグラフを示す。ここで、減速に関するデータとは車輌速度、アクセル踏量、ブレーキ踏量を指している。図 9 の縦軸は上から車輌速度、アクセル踏量、ブレーキ踏量を表しており、横軸は一時停止地点までの時間を表している。また、各クラスタの発生確率を表 3 に示す。

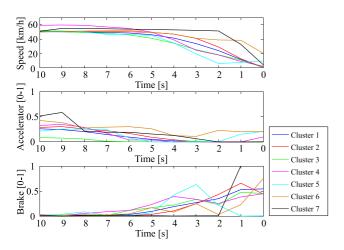


図 9 一時停止 B 減速における各クラスタの平均

Fig. 9 Average of each cluster near the traffic 'stop sign' B; deceleration.

表 3 一時停止 B 減速における各クラスタの発生確率

Table 3 Probability of each cluster near the traffic 'stop sign' B; deceleration.

Cluster	発生確率	累積確率
1	77.50%	77.50%
2	11.11%	88.61%
3	5.28%	93.89%
4	3.33%	97.22%
5	1.11%	98,33%
6	1.11%	99.44%
7	0.56%	100.00%

図 9, 表 3 において、クラスタの発生確率が 77.50%と最 も大きな値を示すクラスタ1の運転行動を例にドライバの 行動を示す.まず、図9の2番目のアクセルと3番目のブ レーキの図を眺めると、アクセルを放し、約6秒前からブ レーキを少しずつ踏み込むことによって、図9の1番目の 図である車輌速度は一時停止地点10秒前から一時停止す るまで緩やかに減速しており、一時停止地点における適切 な運転行動がとれていることが確認された.一方,クラス タ5,6,7などのクラスタの発生確率が低く非通常と分類 されたクラスタの運転行動に着目すると、クラスタ5では アクセルを通常よりも早く放し, ブレーキを早くから踏む ことで目標とする一時停止地点よりも前で減速しているこ とが明らかとなった. クラスタ 6,7では通常よりも遅く アクセルを放し, ブレーキを踏み始めるのが遅れることで 目標とする一時停止地点で適切に停止することができてい ないことが確認された. このようにクラスタの発生確率が 低いクラスタでは、その地点における適切な運転行動をと ることができていないことが考えられる.このことから, 本研究の提案手法により適切に通常・非通常を分類するこ

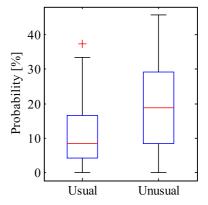


図 10 乗車前の状態とその後の運転行動との関係

Fig. 10 Relationship between driver's state before driving and driver behavior while driving.

表 4 非通常運転行動発生確率の中央値

Table 4 Median of the probability of unusual driver behavior.

乗車前状態	非通常運転行動 発生確率	p 値	
通常(usual)	8.3%	0.001	
非通常(unusual)	18.8%	0.001	

とができる可能性が示唆された.

4.2.2 乗車前とその後の運転行動との関係

乗車前における通常・非通常とその後の運転における通常・非通常との関係性を明らかにするために、箱ひげ図による分析を行った。箱ひげ図を図 10 に示す。図 10 の横軸は乗車前の通常・非通常を表し、乗車前の状態それぞれに対し、その後の運転における非通常な運転行動をとる確率(非通常運転行動発生確率)を縦軸に示している。表 4 に非通常運転行動発生確率の中央値を示す。

図 10 より, 乗車前に通常と分類されたとき, 非通常運転行動発生確率の中央値が 8.3%なのに対して, 乗車前に非通常と分類されたとき, 非通常運転行動発生確率の中央値は 18.8%であることが確認された. このことから, 乗車前が非通常な状態にあるとき乗車前が通常なときと比較して, その後の運転で非通常な運転行動をとる確率が約 2.3 倍に増加することが明らかとなった. また, 乗車前の通常・非通常の間に有意差があるかを t 検定により分析した結果, p 値 0.001 の有意差があることが示された. 以上のことから, 乗車前のドライバ状態とその後の運転行動との間に関係性があることが示唆された.

4.2.3 乗車前主成分とその後の運転行動との関係

前の 4.2.2 項より,乗車前のドライバ状態がその後の運転行動の間に関係性があることを確認できたが,乗車前のどのような特徴がその後の運転行動に影響を及ぼしているのかについては明らかでない。運転行動に関わる乗車前の特徴が明らかになれば,運転前のドライバへの注意喚起や運転回避につながり、ヒューマンエラー防止に役立つと期

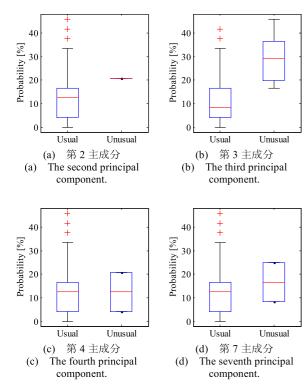


図 11 乗車前の各主成分とその後の運転行動との関係

Fig. 11 Relationship between each principal component and subsequent driver behavior.

待される. そこで, 乗車前情報から主成分分析により抽出された主成分ごとに, GMM により通常・非通常を分類し, その後の運転における通常・非通常との間の関係性について分析を行った. 図 11 に乗車前の各主成分とその後の運転における非通常運転行動発生確率との関係性を示した箱ひげ図を示す. 図 11 の縦軸は非通常運転行動発生確率を表し、横軸は乗車前の主成分ごとの通常・非通常を表す.また,表 5 は乗車前の各主成分の通常・非通常の各々に対する非通常運転行動発生確率の結果を表したものである.なお,第1・第5・第6主成分については,本研究での提案手法を用いて通常・非通常の分類を行った際にすべて通常に分類され,その後の運転行動との関係を分析することができなかったため省略している.

図 11 における第 3 主成分の結果について着目してみると、非通常運転行動は乗車前が通常なとき 8.3%、非通常なとき 29.2%の確率で生じていることが分かる。また、乗車前の通常・非通常の間に対し、t 検定を行った結果、p 値 0.0001 の有意差であった。一方、第 2・第 4・第 7 主成分の結果に関しては、乗車前が非通常であるとき、通常のときと比較して非通常運転行動発生確率は増加傾向にあるものの、いずれにおいても t 検定による有意差は確認できなかった。以上の結果から第 3 主成分がその後の非通常運転行動に大きく影響していると考えられる。

この第3主成分がどのような意味を持つ主成分であるか 把握するために抽出した主成分の因子負荷量に基づいて

表 5 主成分に基づく乗車前の各状態と非通常運転行動発生確率

Table 5 Each driver's state before driving based on principal component and probability of unusual driver behavior.

			1
乗車前状態		非通常運転行動 発生確率	p値
第2主成分	通常 (usual)	12.5%	0.4194
	非通常 (unusual)	20.8%	0.4194
第 2 全世八	通常 (usual)	8.3%	0.0001
第3主成分	非通常 (unusual)	29.2%	0.0001
第 4 	通常 (usual)	12.5%	0.9806
第4主成分	非通常 (unusual)	12.5%	0.9800
第7主成分	通常 (usual)	12.5%	0.5749
	非通常 (unusual)	16.7%	0.3749

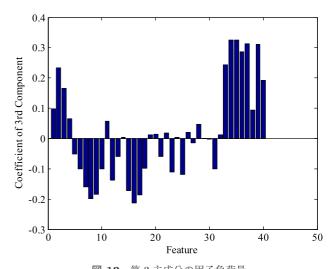


図 12 第3主成分の因子負荷量

Fig. 12 Factor loading of 3rd principal component.

解釈を行った.図 12 に第3主成分の因子負荷量を示す.図 12 の縦軸は第3主成分の因子負荷量を表し、横軸は乗車前の各特徴量を表している.図 12 においてプラス側に振れている主要な特徴量は反応時間の平均値、標準偏差、最大値、範囲であり、マイナス側に振れている主要な特徴量は自覚症しらべのねむけ感、不安定感、不快感やRASの注意集中困難、意欲減退であった。これらのことから第3主成分は乗車前の総合的な「反応力に関する特徴量」で

表 6 乗車前特徴量から抽出された主成分の解釈

Table 6 Interpretation of the principal component extracted features from before driving.

主成分	主成分の解釈
第1主成分	体調の良さを現す特徴量
第2主成分	疲労度合いを表す特徴量
第3主成分	反応力に関する特徴量
第4主成分	前日の睡眠の質を表す特徴量
第5主成分	自律神経活動を表す特徴量
第6主成分	やる気・意欲を現す特徴量
第7主成分	精神的ストレスを表す特徴量

あると考えられる.また,同様に乗車前情報から抽出した 主成分を因子負荷量に基づいて解釈を行った結果を表 6 に 示す.

これらの結果から,第3主成分の意味する乗車前の「反応力に関する特徴量」が,その後の非通常運転行動に大きく影響することが示唆された.

以上より、ドライバの状態を睡眠のように特定の状態に限ることなく、様々な要因から生じる乗車前のドライバ状態に対しても、その後の運転行動との間に関係性があることが明らかとなった。これにより、従来のように自動車運転時に取得した情報のみ利用していた研究よりも高精度にドライバ状態を推定および予測できると考えられる。さらに、それらの精度向上は、運転中の眠気や漫然、疲労などの人的要因による事故低減に貢献できると考えられる[2].

5. おわりに

本研究では、乗車前のドライバ状態とその後のとの間に関係性があるか明らかにするために、人間行動プロジェクトの結果から「運転時における非通常な運転行動は、乗車前の非通常なドライバ状態が起因しているのではないか」という仮説を立てた。この仮説に基づき、長期間にわたり乗車前およびドライビングシミュレータ走行のデータを計測した。計測した情報から特徴量を抽出し、混合ガウスモデルにより乗車前のドライバ状態およびその後の運転行動についてクラスタリングを行い、通常・非通常の分類を行った。その結果、乗車前が通常なときと比較して、非通常な状態にあるときにその後の運転で非通常な運転行動を取る確率が約23倍に増加し、有意な差が生じることが明らかとなった。特に、乗車前の「反応力」に関わる特徴量が運転行動と強い関係性にあることが示唆された。

本研究により、ドライバの状態を睡眠のように特定の状態に限ることなく、様々な要因から生じる乗車前のドライバ状態に対しても、その後の運転行動との間に関係性があることが明らかとなった。この結果は、乗車前に計測した

情報がその後の運転におけるドライバの状態推定,状態予測に有効な指標になりうることを意味している.

今回の実験では、検査用紙を用いた主観評価、体温、α-アミラーゼ活性、血圧の生理的指標、反応時間やフリッカー値の反応指標を計測し、それらのデータから特徴量を抽出することで、乗車前のドライバ状態とその後の運転行動との関係性について明らかにした。しかし、乗車前にこれらのデータの計測を実施することは難しい。そのため、将来は今後普及すると考えられるウェアラブル端末によって、日々の活動量や心拍数、睡眠、食事、排泄などをはじめとした様々な Life log を計測し、これらの情報を代用して乗車前のドライバ状態を判断することが求められる。本研究においても、ウェアラブルセンサを用いた実験により、乗車前のドライバ状態とその後の運転行動との関係性について明らかにするとともに、乗車前のドライバ状態を考慮した状態推定・予測の実用化を目指す。

参考文献

- [1] World Health Organization (WHO): GLOBAL STATUS REPORT ON ROAD SAFETY (2009).
- [2] NHTSA (National Highway Traffic Safety Administration): National Motor Vehicle Crash Causation Survey Report to Congress (2008).
- [3] Otamani, S., Pebayle, T., Roge, J. and Muzet, A.: Effect of driving duration and partial sleep deprivation on subsequent alertness and performance of car drivers, *Physiol. Behav.*, Vol.84, No.5, pp.715–724 (2005).
- [4] Liu, C., Hosking, S. and Lenne, M.: Predicting driver drowsiness using vehicle measures: Recent insights and future challenges, J. Safety Res., Vol.40, No.4, pp.239– 245 (2009).
- [5] Malta, L., Miyajima, C., Kitaoka, N. and Takeda, K.: Analysis of real-world driver's frustration, *IEEE Trans. Intell. Transp. Syst.*, Vol.12, No.1, pp.109–118 (2011).
- [6] Li, Q., Zhu, Z. and Lan, P.: Real-time nonintrusive monitoring and prediction of driver fatigue, *IEEE Trans. Veh. Technol.*, Vol.53, No.4, pp.1052–1068 (2004).
- [7] Smith, P., Shah, M. and da Vitoria Lobo, N.: Determining driver visual attention with one camera, *IEEE Trans. Intell. Transp. Syst.*, Vol.4, No.4, pp.205–218 (2003).
- [8] Bergasa, L.M., Nuevo, J., Sotelo, M.A., Barea, R. and Lopez, M.E.: Real-time system for monitoring driver vigilance, *IEEE Trans. Intell. Transp. Syst.*, Vol.7, No.1, pp.64-77 (2006).
- [9] Takahashi, I., Takaishi, T. and Yokoyama, K.: Overcoming drowsiness by inducing Cardio-Respiratory phase synchronization, *IEEE Trans. Intell. Transp. Syst.*, Vol.15, No.3, pp.982–991 (2014).
- [10] 今井章博, 小栗宏次:居眠り運転時の特徴的な眠気推移傾 向を組み込んだ眠気レベル推定手法の提案,電子情報通 信学会論文誌 D, Vol.J96-D, No.4, pp.1012-1019 (2013).
- [11] Damousis, I. and Tzovaras, D.: Fuzzy fusion of eyelid activity indicators for hypovigilance-related accident prediction, *IEEE Trans. Intell. Transp. Syst.*, Vol.9, No.3, pp.491–500 (2008).
- [12] Lal, S.K. and Craig, A.: Development of an algorithm for an EEG-based driver fatigue countermeasure, *J. Safety Res.*, Vol.34, No.3, pp.321–328 (2003).

- [13] 水野統太,野村収作,野澤昭雄,浅野裕俊,井出英人:鼻部皮膚温度によるメンタルワークロードの継続の評価,電子情報通信学会論文誌 D, Vol.J93-D, No.4, pp.535-543 (2010).
- [14] 西山順平, 木下伸一, 平田 豊:前庭動眼反射による眠 気予兆検出, 生体医工学, Vol.48, No.1, pp.1-10 (2010).
- [15] 西山順平,谷田公二,楠見昌司,平田 豊:瞳孔ゆらぎを指標とした覚醒度状態評価,生体医工学,Vol.46, No.2,pp.212-217 (2008).
- [16] Sandberg, D., Akerstedt, T., Anund, A., Kecklund, G. and Wahde, M.: Detecting Driver Sleepiness Using Optimized Nonlinear Combinations of Sleepiness Indicators, *IEEE Trans. Intell. Transp. Syst.*, Vol.12, No.1, pp.97–108 (2011).
- [17] Dinges, D.F.: An overview of sleepiness and accidents, J. Sleep Res., Vol.14, pp.4–14 (1995).
- [18] Frenandez-Mendoza, J., Vgontzas, A.N., Liao, D., Shaffer, M.L., Vela-Bueno, A., Basta, M. and Bixler, E.O.: Insomnia with objective short sleep duration and incident hypertension, *Hypertension*, Vol.60, pp.929–935 (2012).
- [19] 早田有利,河中治樹,小栗宏次:運転開始前後の生体情報を用いたドライバ覚醒度低下状態の早期予測,電気学会論文誌 C, Vol.133, No.12, pp.2160-2066 (2013).
- [20] Cacciabue, P.C., Mauri, C. and Owen, D.: Development of a model and simulation of an aviation maintenance technician task performance, *Cogn. Technol. Work*, Vol.5, No.4, pp.229–247 (2003).
- [21] 赤松幹之:人間行動適合型生活環境創出システム,バイオメカニズム学会誌, Vol.25, No.2, pp.93-95 (2001).
- [22] 独立行政法人新エネルギー・産業技術総合開発機構,独立行政法人産業技術総合研究所,研究評価委員会:「人間行動適合型生活環境創出システム技術開発」事後評価報告書(2004).
- [23] 大口 敬,津田浩輝,桑原雅夫,田中伸治:ドライビングシミュレータの高速道路追従走行の再現性,生産研究, Vol.59, No.3, pp.222-225 (2007).
- [24] 練尾正美,知久良夫:ヒューマンファクタ解析のためのシミュレータ技術,計測と制御, Vol.45, No.8, pp.726-730 (2006).
- [25] 相間 仁, 鈴木桂輔, 若杉貴志, 平松金雄: ドライビン グシミュレータによるドライバ特性の把握と運転支援機 能の評価, 国際交通安全学会誌, Vol.26, No.2, pp.96-102 (2001)
- [26] 赤松幹之:運転行動データベースの構築とアクティブセーフティ技術への利用,自動車技術, Vol.57, No.12, pp.34-39 (2003).
- [27] 岸本圭史,小栗宏次:直前の一定期間の運転行動を考慮 した AR-HMM に基づく停止行動予測,電子情報通信学 会 A, Vol.J92-A, No.9, pp.624-632 (2009).
- [28] Pentland, A. and Liu, A.: Modeling and prediction of human behavior, *Neural Comput.*, Vol.11, No.1, pp.229– 242 (1999).
- [29] Kumagai, T. and Akamatsu, M.: Prediction of human driving behavior using dynamic bayesian networks, *IE-ICE Trans. Inf. & Syst.*, Vol.E89-D, No.2, pp.857–860 (2006).
- [30] 山本由華吏,田中秀樹,高瀬美紀,山崎勝男,阿住一雄, 白川修一郎:中高年・高齢者を対象としたOSA 睡眠感調 査票(MA版)の開発と標準化,脳と精神の医学,Vol.10, No.4, pp.401-409 (1999).
- [31] 酒井一博:日本産業衛生学会産業疲労研究会撰「自覚症しらべ」の改定作業 2002, 労働の科学, Vol.57, No.5, pp.295-298 (2002).
- [32] 高橋 誠, 北島洋樹, 本城由美子:精神的作業負担チェッ

- クリストの作成とそれによる眠気とリラックス状態の関係 構造の検討,労働科学, Vol.72, No.3, pp.89-100 (1996).
- [33] 清水秀美, 今栄国晴: STATE-TRAIT ANXIETY IN-VENTORY の日本語版(大学生用)の作成, 教育心理 学研究, Vol.29, No.4, pp.348-353 (1981).
- [34] Aitken, R.C.B.: Measurement of feeling using visual analogue scale, Proc. R. Soc. Med., Vol.62, No.10, pp.989–993 (1969).
- [35] 山口昌樹, 花輪尚子, 吉田 博: 唾液アミラーゼ式交 感神経モニタの基礎的性質, 生体医工学, Vol.45, No.2, pp.161-168 (2007).
- [36] Iwaki, S. and Harada, N.: Mental fatigue measurement based on the changes in flicker perception threshold using consumer mobile devices, Adv. Biomed. Eng., Vol.2, pp.137–142 (2014).
- [37] Kaiser, H.F.: The application of electronic computers to factor analysis, *Educ. Psychol. Meas.*, Vol.20, No.1, pp.141–151 (1960).
- [38] Cattell, R.B.: The Scree Test for the number of factors, Multivar. Behav. Res., Vol.1, No.2, pp.245–276 (1966).
- [39] Fabrigar, L.R., Wegner, D.T., MacCallum, R.C. and Strahan, E.J.: Evaluating the use of exploratory factor analysis in psychological research, *Psychol. Methods*, Vol.4, No.3, pp.272–299 (1999).
- [40] Schwarz, G.: Estimating the dimension of a model, Ann. Stat., Vol.6, No.2, pp.461–464 (1978).



早田 有利

2015 年愛知県立大学大学院情報科学研究科博士前期課程修了. 同年東海旅客鉄道株式会社入社. 2017 年より愛知県立大学大学院情報科学研究科博士後期課程に在学中. 生体信号処理,ITS に関する研究に従事. 2013 年電

気関係学会東海支部連合大会奨励賞受賞,2014年 IEEE 名 古屋支部国際会議研究発表賞,電子情報通信学会学生研究 奨励賞受賞,2015年自動車技術会大学院研究奨励賞受賞. 日本鉄道電気技術協会会員.



田中 裕幸

1977 年静岡大学工学部電子工学科卒業. 同年日本電装入社. 車両コックピットシステム, 自動運転 HMI の研究に従事. 2017 年愛知県立大学大学院情報科学研究科博士課程修了. 博士(情報科学).



入部 百合絵 (正会員)

2001年名古屋大学大学院人間情報学研究科修士課程修了.2004年同大学院人間情報科学研究科博士課程満期退学.博士(学術).2004年豊橋技術科学大学マルチメディアセンター助手,2007年同大学情報メディア基盤セン

ター助教,現在,愛知県立大学情報科学部准教授.音声情報処理,ユーザインタフェースに関する研究に従事.電子情報通信学会,日本音響学会,人工知能学会各会員.



河中 治樹 (正会員)

2005年名古屋工業大学大学院工学研究科博士後期課程修了.同年中部大学先進計測研究センター非常勤研究嘱託.同年愛知県立大学大学院情報科学研究科助手.同大学院助教および講師を経て,現在同大学院准教授.博士

(工学). コンピュータビジョンとパターン認識の研究に従事. 電子情報通信学会, 画像電子学会, 日本生体医工学会, IEEE 等各会員.



小栗 宏次

1990年名古屋工業大学大学院博士課程修了.同年名古屋工業大学助手.1994年愛知県立大学助教授.1998年同大学情報科学部教授.1999年9月より平12年7月までドイツ連邦ミュンヘン大学計測科学研究所客員教授.2002

年愛知県立大学大学院教授,2009年同大学情報科学共同研究所所長(兼任),2011年東京大学生産技術研究所リサーチフェロー(兼任),2015年名古屋大学未来社会創造機構客員教授(兼任),現在に至る.生体信号処理,知的情報処理に関する研究に従事.工学博士.1996年日本エム・イー学会研究奨励賞受賞,1999年永井科学技術財団学術賞受賞、IEEE,日本生体医工学会,電子情報通信学会各会員.