

テクニカルノート

自動車内情報システムインタフェース制御のための 運転過負荷状態の検出

北岡 教英^{†1} 高木 俊一^{†2} 中川 聖一^{†2}

カーナビなど複雑な情報機器が自動車内に導入され、その操作の複雑さが問題になっている。ユーザの認知的負荷を考慮せず、危険なタイミングで情報を提供したり要求したりすることにより、危険が増す。そこで、事故になる危険性が高いような状況では情報を提示しないなどの対処が考えらる。そのため、運転による認知的負荷の高い状態、すなわち過負荷状態の検出を試みた。アクセル踏圧力やブレーキ踏圧力、ハンドル操舵角などの運転行動信号から特徴を抽出し統計的な手法により認知的負荷の有無を推定した結果、検出率 0.8 を得た場合にアラーム率（全時間中の危険と判断された時間の率）0.129 という結果を得た。

Detection of Over-load Status for In-vehicle Information System Interface

NORIHIDE KITAOKA,^{†1} SHUN'ICHI TAKAGI^{†2}
and SEIICHI NAKAGAWA^{†2}

Complex information technologies such as car navigation systems are equipped in-vehicle environments, but the interfaces of the systems are still immature. Thus the operation of the systems may cause car accidents. To avoid such situations, the systems should take the drivers' cognitive loads into account. We propose a statistical method to detect over-load status of drivers from the driving behaviors such as gas pedal, brake pedal, and steering wheel operations. We obtained the detection rate of 0.8 with alarm rate of 0.129.

^{†1} 名古屋大学
Nagoya University

^{†2} 豊橋技術科学大学
Toyohashi University of Technology

1. はじめに

近年、カーナビゲーションシステムをはじめとする情報機器が自動車内にも多く導入されるようになり、その操作の複雑さが問題になっている。特に、情報提示機器はユーザがのぞまないタイミングでも文字や画像・映像などにより一方的に情報を提供しようとする可能性がある。そのような意味で、音声対話を中心とした音声インタフェースは、目や手を必要としないために有望なインタフェースと考えられている。しかし、自動車運転中の携帯電話の使用が禁止されていることから、音声対話インタフェースの使用も問題が発生する可能性がある。事実、他のインタフェースに比べ安全であると考えられるものの、運転への影響は指摘されている¹⁾⁻⁴⁾。

一般に、人間の認知的負荷には許容量があり、それを超えた負荷が与えられると行動に影響を及ぼしかねないと考えられ、これが事故の要因になるといえる。そのような問題の解決法としては、事故になる危険性が高いような状況では情報を提示しない、あるいは対話システムを起動しないようにすることが考えられる。そのような考え方のもとで、運転者が右左折や車線変更などなんらかの運転行動を起こすことを事前に予測することが考えられる^{5),6)}。しかし、状況だけでは実際に認知的負荷が多くかかっているかどうかの判断には十分ではない。

そこで本研究では、事故になる危険性が高いような状況、すなわち運転による認知的負荷の高い状態（以降この状態を過負荷状態と呼ぶ）の検出を目的とする。運転者には、周りの自動車や道路状況、あるいは自車のスピードなどの状況によって負荷が加わり、その状況は運転者の運転行動にある程度反映されると考えられる。そこで、アクセル踏圧力やブレーキ踏圧力、ハンドル操舵角などの運転行動から認知的負荷の度合いを推定することを考える。この推定ができれば、音声対話インタフェースをはじめとする種々のインタフェースの出力制御に応用可能である。

2. 運転状態とデータベース

2.1 運転過負荷状態

本研究では、運転中に認知的負荷を要する度合いが高い状態として、「走行車線中にある障害物（人・停車中の自動車など）を回避すること」や「カーブを曲がること」といった行動中を運転過負荷状態として扱う。

表 1 負荷状態ラベルデータの内訳
Table 1 Details of mental load labels.

状態	総時間	モデル学習	検出実験
全状態	6 時間 56 分	4 時間 48 分	2 時間 8 分
過負荷状態 L_1	22 分	12 分	10 分
過負荷状態 L_2	23 分	14 分	9 分
低負荷状態 L_{other}	6 時間 11 分	4 時間 22 分	1 時間 49 分

2.2 データベースとラベリング

本研究では、CIAIR 車内音声データベース⁷⁾を利用して運転過負荷状態の検出の実験を行う。このデータベース中のデータは自動車を運転している運転者が、3種類の対話（対音声対話システム，対 WoZ システム，対人間）を行っている中での車内動画（車内から車体前方向，運転者の顔，運転席と助手席），音声，運転信号（アクセル踏圧力，ブレーキ踏圧力，エンジン回転数，自動車速度，ハンドル操作角）を同期して収録したものである。また，これらの運転信号はすべて，サンプリング周波数 1 kHz，16 bit 量子化で収録されている。

これらのデータに対して，運転過負荷状態を示すラベルを付与するために，まず，収録された動画を見ながら，運転者でない第三者 1 名によって，ラベリング作業を行った。付与したラベルは，2.1 節で述べたような回避行動をとっている区間や，交差点にさしかかり周囲状況を注意深く見ているような区間などを対象としたラベル L_1 と，赤信号による停止行動区間を対象としたラベル L_2 の 2 種類を対象区間に付与した。それ以外の区間（負荷がかかっていない状態）を L_{other} とした。全 34 名分のデータに対してこの作業を行った。その内訳を表 1 に示す。

3. 運転状態のモデル化

3.1 ケプストラム分析

本研究では運転状態をモデル化するための特徴量として，一般的に音声などの時系列パターンの認識によく用いられ，スペクトル概形を表現できる，ケプストラムを特徴パラメータとして用いた⁸⁾。ケプストラム分析では，波形データを窓かけにより短時間フレームずつ取り出して離散フーリエ変換し，対数をとった後逆コサイン変換をして低次の係数を取り出すことにより，スペクトルの微細な変動を除去している。これにより，短時間のペダルの踏み込みなどの運転操作の特徴に適した粒度の情報がとらえられるという知見がある⁸⁾。

また，この短時間特徴のより長時間な動的特性をとらえるために，その一次回帰係数であ

る Δ ケプストラムを併用した。

3.2 混合正規分布

本研究では，運転状態をモデル化するために，特徴パラメータの分布を混合正規分布（GMM）で表す。

$$P(x|\lambda) = \sum_{m=1}^M w_{m\lambda} \cdot N(x; \mu_{m\lambda}, \Sigma_{m\lambda}) \quad (1)$$

ここで， x はある短時間フレームの特徴パラメータ， λ は L_1, L_2, L_3 (L_3 については後述)，およびそれ以外 L_{other} のいずれかであり， $\mu_{m\lambda}, \Sigma_{m\lambda}$ は状態 λ ，混合 m での平均値ベクトルと共分散行列である。学習は EM アルゴリズムにより行った。

4. 運転過負荷状態の検出

本研究において，対象とする過負荷状態を検出するため，2つの方法で運転状態モデルを作成した。

方法 1 L_1, L_2 ，および L_{other} という 3 種類のラベルに対応する運転状態に対して運転状態モデルを作成

方法 2 ラベル L_1 と L_2 を合わせたラベル L_3 を作成し，ラベル L_3 に対応する状態とそれ以外の状態という 2 種類の運転状態モデルを作成

方法 1 では，過負荷状態の中で頻度が高く，他の過負荷状態とは行動がやや異なる傾向にある L_2 は別にモデル化することで高精度化できると期待した。

GMM によるモデル化では，一般に尤度 $P(x|\lambda)$ を得ることができる。ここで， L_1, L_2 および L_{other} の 3 状態を考えた場合，運転状態はすべてこれらのいずれかに分類されるとすると，ベイズ則より事後確率 $P(\lambda|x)$ を得ることができる。方法 1，方法 2 それぞれの場合において，短時間フレームごとに過負荷状態の事後確率 $P(D|x)$ を算出する式を式 (2) および式 (3) に示す。

$$P(L_1 \cup L_2|x) = \frac{\sum_{k=1,2} P(L_k) \cdot P(x|L_k)}{\sum_{k=1,2,other} P(L_k) \cdot P(x|L_k)} \quad (2)$$

$$P(L_3|x) = \frac{P(L_3) \cdot P(x|L_3)}{\sum_{k=3,other} P(L_k) \cdot P(x|L_k)} \quad (3)$$

ここで， $P(L_k)$ は状態 L_k の事前確率であり，データベース中の頻度（表 1 のモデル学習データの時間比）により求めた。

この事後確率に閾値処理をすることで、過負荷状態の検出を行う。しかし短時間の特徴ではこの値は不安定となる。そこで、検出は T 秒間の確率値の平均を用いて、 T 秒ごと（実験では 1 秒ごと）に行うこととする。

5. 実験

過負荷状態確率による検出の実験を行った。実験条件を表 2 に示す。

出力された事後確率と、過負荷状態のラベルをプロットしたものを図 1 に示す。破線で示したのが過負荷ラベル区間であり、実線が過負荷である確率の推定値である。図から、過負荷区間で確率値が高めに推定されていることが分かる。

また、1 秒ごとに検出を行った場合の評価結果を図 2、図 3 に示す。ここでは過負荷区間

表 2 実験条件
Table 2 Experimental conditions.

フレーム長	128 msec
フレームシフト	100 msec
窓関数	ハミング窓
Δ ケプストラム窓長	16 フレーム
GMM 混合数	4
運転信号	アクセル踏圧力, ブレーキ踏圧力, エンジン回転数, 自動車速度, ハンドル操作角
特徴パラメータ	各運転信号につきケプストラム 3 次元, Δ ケプストラム 3 次元の計 30 次元




図 1 過負荷状態の事後確率の推定例(式(3)による)。実線の縦軸は確率値、横軸はフレーム数(1フレーム0.1秒)。破線は過負荷区間ラベル

Fig.1 An example of a posteriori probability estimation. (Estimation was done using Eqn. (3). X-axis and Y-axis mean time frame (1 frame = 0.1 sec.) and probability, respectively).

は L_1 と L_2 を合わせた区間とする。図 2 の横軸は各過負荷状態ラベルの区間の 10%以上のフレームを過負荷状態として検出できた場合に、その過負荷状態区間の検出ができたと考えたとき、全過負荷状態区間数のうち何%を検出できているかを示すものである。この数値を過負荷区間検出率と呼ぶこととする。また、縦軸はフレーム単位での検出の精度である。

図 2 を見ると、過負荷区間検出率が 0.8 のときにおける検出精度は式 (2) の場合には 0.287 であり、式 (3) の場合には 0.356 であった。

図 3 に過負荷区間検出率対アラーム率のグラフを示す。ここで、アラーム率とは全時間中の本検出手法によって過負荷状態だと判断された時間(正しい場合も誤りの場合も含む)の割合である。テストデータの過負荷区間率は 14.8%である。




図 2 過負荷区間検出率に対する検出精度

Fig.2 Detection performance (Detection accuracy of overload periods).




図 3 過負荷区間検出率に対する全過負荷判定区間(アラーム)率

Fig.3 Detection performance (Alarm rate).

図3では、過負荷区間検出率が0.8のときのアラーム率が式(2)の場合に0.180であり、式(3)の場合に0.129であった。また、図2、図3のどちらの評価においても、式(3)によって検出を行ったほうが良い結果が得られた。式(2)を用いる方が精度の高いモデル化ができて性能が良くなることを期待したが、今回の実験では逆の結果となった。この理由としては、学習データの不足が考えられる。これまでのところ、CIAIRデータの一部しかラベリングが行えていないが、これらすべてに同様のラベルを付けるなど、より多くのデータが学習に用いることができるようになれば良い性能が得られると考えられる。

6. 考 察

上記の結果(検出率0.8, 検出精度0.356, アラーム率0.129)を実際に車載機器操作に応用した場合を考える。過負荷と判断された場合には操作ができなくなるとすると、1時間のうち7.7分の間、操作不能の時間が生じる。しかし、検出されたうち実際に過負荷なのは2.8分程度であり、実際の過負荷区間の1/3程度の時間は操作を抑制できる。また、1分単位で見ると80%の検出率となるので、過負荷と判断されたらある程度の時間、操作不能にするなどすることで、かなりの過負荷時間帯における操作を抑制できると考えられる^{*1}。しかし、この評価基準だと1分という時間を要する点から、まだ十分とはいえないが、ある程度効果が得られ、また今後高精度化されればより効果的になる。

また、音声対話インタフェースを考えた場合には、操作を不能にする以外に、出力音声を理解が容易な内容にするなどの認知負荷軽減方法もあり、本手法が負荷の度合いを計測することができるならば、そのような方法への応用も考えられる。そのような観点からも、今後、本手法の出力に関してより詳細に分析する必要がある。

7. おわりに

本研究では、運転状態を混合正規分布でモデル化することにより、過負荷状態の検出を行った。実験の結果、本手法において、0.8という比較的高い検出率の場合において、アラーム率0.129という値を得た。

現在の処理方法は、たとえば T 秒ごとの平均化処理など単純な処理によることも多々あり、改良の余地はある。また、自動車のセンサは数多く開発されてきており、たとえば

*1 もちろん、過負荷でない区間での操作不能時間帯も増えることになる。しかし、図1を見ても想像できるように、過負荷区間では頻繁に、そうでない部分では時折過負荷と判定される傾向にあり、過負荷判定の頻度と操作抑制の調整によっては過負荷でない区間の操作可能率を大きく下げずに過負荷区間での操作を抑制できる可能性はある。

天候や車間距離など、運転信号とは別にも多くの情報が入手でき⁹⁾、これらも運転負荷に深く関与すると考えられる。このように、さらに多くのマルチモーダルな情報からのアプローチも検討する必要がある。

また、現在の方法は運転操作自体がなにかを考慮せずに、運転信号からのみ判断しているが、運転操作の識別、あるいは予測²⁾を組み合わせれば、より適切な制御が可能になると考えている。

参 考 文 献

- 1) 清水 司, 小島真一, 脇田敏裕, 本郷武明: 運転中における音声対話システムの評価: 情報処理学会研究報告, Vol.2000, No.64, pp.87-92 (2000).
- 2) 伊藤敏彦, 山田真也, 荒木健治: 音声認識率や状況の違いによる音声対話の言語的・音響的特徴の比較, 情報処理学会研究報告, Vol.2005, No.50, pp.101-106 (2005).
- 3) Consiglio, W., Driscoll, P., Witte, M. and Berg, W.P.: Effect of cellular telephone conversations and other potential interference on reaction time in a braking response, *Accident Analysis and Prevention*, Vol.35, No.4, pp.495-500 (2003).
- 4) Srinivasan, K. and Jovanis, P.: Effect of In-Vehicle Route Guidance Systems on Driver Workload and Choice of Vehicle Speed: Findings from a Driving Simulator Experiment, ITS-Davis UCD-ITS-RP-97-03 (1997).
- 5) Itoh, T., Yamada, S., Yamamoto, K. and Araki, K.: Prediction of driving actions using driving signals, *Biennial on DSP for In-Vehicle and Mobile Systems* (2007).
- 6) Schneider, J., Wilde, A. and Naab, K.: Probabilistic approach for modeling and identifying driving situations, *IEEE Intelligent Vehicles Symposium* (2008).
- 7) 河口信夫, 牛窪誠一, 松原茂樹, 岩 博之, 梶田将司, 武田一哉, 板倉文忠: 走行車室内音声対話収録システムの開発: 電子情報通信学会論文誌, Vol.J84-D-II, No.6, pp.909-917 (2001).
- 8) 小澤晃史, 西脇由博, 脇田敏裕, 宮島千代美, 伊藤克亘, 武田一哉: 運転操作信号のケプストラム分析に基づく運転者識別, 情報処理学会研究報告, Vol.scp60(3), pp.19-24 (2006).
- 9) Ozaki, A., Hara, S., Kusakawa, T., Miyajima, C., Nishino, T., Kitaoka, N., Itou, K. and Takeda, K.: In-car Speech Data Collection along with Various Multimodal Signals, *LREC2008*, p.6 (2008).

(平成20年7月8日受付)

(平成20年9月10日採録)



北岡 教英 (正会員)

平成 6 年京都大学大学院情報工学専攻修士課程修了。同年 (株)デンソー (旧・日本電装 (株)) 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)。主として音声対話, 音声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。



高木 俊一

平成 18 年豊橋技術科学大学工学部情報工学課程卒業。現在, 産業技術大学院大学修士課程在学。豊橋技術科学大学在学中は自動車運転信号処理に関する研究に従事。



中川 聖一 (フェロー)

昭和 51 年京都大学大学院工学研究科博士課程修了。同年京都大学工学部情報工学科助手。昭和 55 年豊橋技術科学大学情報工学系講師。昭和 58 年同助教授。平成 2 年同教授。昭和 60~61 年カーネギーメロン大学客員研究員。音声情報処理, 自然言語処理, 人工知能の研究に従事。工学博士。昭和 52 年および平成 12 年電子情報通信学会論文賞, 1988 年度 IETE 最優秀論文賞受賞。著書『確率モデルによる音声認識』(電子情報通信学会編), 『音声・聴覚と神経回路網モデル』(共著, オーム社), 『情報理論の基礎と応用』(近代科学社), 『パターン情報処理』(丸善) 等。本学会, 電子情報通信学会フェロー。