

## 道路形状に独立したアルゴリズムによるドライブレコーダからの眠気レベル推定

金子 祐来

指導教員：河中 治樹

## 1 はじめに

これまでに生体信号を用いたドライバの眠気を検知する研究が様々行われてきている。例えば、大須賀ら [1] は顔表情による覚醒度の評定を正解値として心電図や視線などの生理的指標からドライバの状態推定を行った。ステアリング操舵角、胸部心電図、脳波、眼電、皮膚電位、呼吸測定している。また、宮下 [2] は 11 項目のアンケートにより取得した主観的な疲労感を正解値として、筋電図、心電図、脳波、発汗量からドライバの疲労感に関する研究を行った。

このように、生理情報からドライバを推定するのはドライバの危険状況を検知するのに有効であるが、実用化を考えると、運転しながら生体信号を取得することは運転者の負担や車両に特別な機材を搭載しなければならないなどの問題がある。また、顔表情を取得するための車載カメラの設置も運転者のプライバシーや撮影されることによるストレスを与えるなどの問題もある。

西郷ら [3] は、ドライバモデルを作成し、車線内変位におけるモデル誤差の分散を調べ、低い眠気レベルと高い眠気レベルとの間でその有意差があることを確認している。しかし、この研究は眠気レベル推定にまで至っていない。我々はこれまでに眠気の連続性 [4] を利用した過去の眠気の推定値を現在の眠気推定に用いた [5]。この時、横軸は走行開始からの距離、縦軸は眠気レベルを表し、異なる走行日の推定眠気レベルをプロットしてある図 1 はいずれの推定結果も同様な推定結果の変化をしている。この原因として、道路の曲率や道路勾配といった道路形状によるものが影響していると考えられる。このため、道路形状に依存しないための特徴量の補正について述べる。

## 2 眠気レベル推定の手法

## 2.1 ドライバの眠気レベル

北島ら [6] はドライバの眠気の基準として顔表情から眠気を分類する眠気表情評定を提案している。研究の概要を知らない熟練した複数人の評定者が文献 [6] に示した基準で走行開始から 10 秒ごとに評定を行う。本研究ではその値を眠気レベルとし、眠気の正解値として用いる。

## 2.2 重回帰分析による推定

まず、ドライブレコーダからは表 1 に示す 9 種のデータを取得する。これらのデータは 10 Hz で記録されるものとする。

FOE 揺らぎ  $f_F(t)$  とは時刻  $t$  の FOE の値  $F(t)$ 、過去 10 秒

表 1 眠気レベル推定に用いる特徴量

変数	特徴量名	単位
$v_x$	自車速度	km/h
$v_y$	横移動速度	m/sec
$a_x$	進行方向加速度	G
$a_y$	左右方向加速度	G
$f_F$	FOE 揺らぎ	pixel
$d_F$	FOE 基準点からのズレ	pixel
$p_c$	自車位置	m
$p_r$	右白線までの距離	m
$p_l$	左白線までの距離	m

の移動平均を用いて式 (1) のように求める。

$$f_F(t) = \overline{F(t)} - F(t) \quad (1)$$

FOE 基準点からのズレ  $d_F(t)$  は過去 10 秒間の移動平均  $\overline{F(t)}$  と FOE の基準点  $F_r$  を用いて式 (2) のように求める。

$$d_F(t) = \overline{F(t)} - F_r \quad (2)$$

自車位置  $p_c(t)$  は右白線  $p_r(t)$  および左白線までの距離  $p_l(t)$  を用いて式 (3) のように求める。

$$p_c(t) = \frac{|p_r(t) + p_l(t)|}{2} \quad (3)$$

表 1 に示す 9 種類のデータの時刻  $t$  における値を  $x(t)$  とし、10 秒間の標準偏差、最大値、最小値、平均値、中央値、最頻値および範囲の 7 種類の基本統計量を求める。更に、眠気が段階的に変化することを考慮して時刻  $t-T$  の推定値  $y_{t-T}$  を特徴量に追加する。次に、推定の非線形性に対応するために式 (4) のような線形カーネル  $B$  を用いる。

$$B = |A_i \times A_j| \quad (4)$$

ただし、 $A_i$  および  $A_j$  は 64 種の特徴量のいずれかをあらかず。線形カーネルを加えた  ${}_{64}C_2 + 64$  種の特徴量について多重共線性に対処するために説明変数との相関が 0.2 以上の特徴量のみを抽出する。さらに、主成分分析を施し、累積寄与率 0.90 以上となる特徴量に圧縮する。以上の前処理を行った特徴量を用いて式 (5) のように重回帰式を構築する。

$$y = \alpha_1 \times x_1 + \alpha_2 \times x_2 + \dots + \alpha_n \times x_n + \beta \quad (5)$$

ただし、 $x_i$  は特徴量 (説明変数)、 $y$  は目的変数、 $\alpha_i$  は  $i$  番目の係数、 $\beta$  は切片を示す。ただし、係数と切片を求めるためにステップワイズ特徴選択を用いる。

## 3 道路形状に独立した推定アルゴリズム

## 3.1 曲率によるデータの補正

ドライブレコーダから取得した GPS 情報の緯度、経度から 3point 法に従って現在の時刻と前後 10 秒の 3 点を用いて時刻  $t$  秒の曲率  $C(t)$  を求める。この  $C(t)$  と推定に用いる特徴量との相関係数をみると、表 1 に示す左右方向加速度、FOE 揺らぎ、




図 1 同経路の推定結果




図2 推定結果と曲率の相関係数 図3 推定結果と勾配の相関係数

FOE 基準点からのズレの3つの特徴量の相関が高いことが分かった。そこで、時刻  $t$  秒の曲率  $C(t)$  を用いて式 (6) のように特徴量の補正をする。

$$x'(t) = \frac{1}{2} \left( \frac{x(t)}{C(t) \times 10^{-3} + 1} \right) \quad (6)$$

ただし  $x(t)$  は、左右方向加速度、FOE 揺らぎ、FOE 基準点からのズレのいずれかをあらわす。これにより、道路曲率の影響を低減させることができる。

### 3.2 勾配によるデータの補正

ドライブレコーダから取得した進行方向加速度は傾斜の影響を受ける。そこで、運動方程式を利用すると式 (7) と示す。

$$a_x(t) = a_x'(t) + \sin \theta \quad (7)$$

式 (7) 中の  $g$  は重力加速度 ( $9.8 \text{ m/s}^2$ ) を示す。更に、式 (7) 中の方程式を用いて、勾配の影響を受けない進行方向加速度の値を式 (8) を用いてデータを補正する。

$$a_x'(t) = a_x(t) - \frac{L(t)}{100} \quad (8)$$

ただし、 $L(t)$  は時刻  $t$  秒の位置の勾配 (横 100 m に対する高さ) をあらわし、 $L(t) = 100 \sin \theta$  である。

## 4 実験による提案手法の効果検証

方法は、学習データは DS を用いて走行したデータを用いる。被験者数は 21 から 40 歳の 7 名で、各被験者が 1 から 3 回の走行をして計 15 回分のデータを取得した。被験者は運転席に座り、前方の 6 面ディスプレイに表示されるコース映像を見ながら走行した。計測時は部屋を暗くし、夜間の高速道路を模擬した 3 車線の全長約 25 km のコースを走行した。このコースは半径 1000 m の緩やかなカーブや直線を含む単調なものとなっている。被験者には第 2 車線をはみ出さないように 70 km/h 以上で走行するように指示を与え、最大 2 時間走行した。ただし、被験者が途中で入眠した場合はその時点で計測を終了した。

また、評価用のデータとしてドライブレコーダを用いて実環境下で記録した 3 種類の車種と 8 名からなる 55 データを用いる。解析区間は高速道路の区間で走行開始してから初めて 70 km/h を超えてから最後に 70 km/h を下回るところとした。特徴量の補正前後による推定結果と曲率および勾配の相関係数の結果を図 2 と図 3 に示す。図 2 より、特徴量の補正を行うことにより推定結果は曲率との相関係数が減少した。中央値は 0.30 から 0.15 にまで減少し、推定結果が道路形状 (曲率) の影響を低減した推定結果となった。同様に図 3 より、特徴量の補正を行うことにより推定結果は道路勾配との相関係数が減少した。中央値は 0.43 から 0.13 にまで減少し、推定結果が道路形状 (道路勾配) の影響が低減した結果となった。




図4 車種ごとの平均絶対誤差




図5 正解眠気レベルごとの推定誤差

推定値の平均絶対誤差を車種ごとにまとめた結果を図 4 に示す。青色は従来手法、赤色は特徴量の補正をした場合の結果を示す。全てのデータでの平均誤差は補正なしの時に 1.23 であり、補正後には 0.73 であった。特徴量の補正によりいずれの車種においても平均絶対誤差が減少した。これは補正によって道路形状による影響が抑制され誤差が小さくなったことを表している。

推定誤差を正解眠気レベルごとにまとめた結果を図 5 に示す。青色は従来手法、赤色は特徴量の補正をした場合の結果を示す。眠気レベル 1 と 2 は、特徴量を補正することにより推定誤差が減少したが、眠気レベル 3 と 4 については上昇してしまった。これは、提案手法が正解眠気レベルに関わらず推定眠気レベルが 2 周辺になったためであり、この原因については更なる分析が必要である。

## 5 まとめと今後の課題

本研究では常時記録型のドライブレコーダから取得したデータである走行情報と前方映像からの情報のみからドライバの眠気レベル推定を行った。推定式の構築には DS 環境下で取得したデータを用いた。実環境で記録したデータは道路形状に依存しているが、道路のカーブや傾斜を用いて特徴量を補正することで道路形状に依存しない推定を実現した。しかしながら、提案手法の結果は眠気レベルによっては推定が上手く追従できていないという問題が確認された。そのため、今後は更なる推定精度向上に向けた推定方法の改善方法を検討する。

## 参考文献

- [1] 大須賀ら, JSAE, No.74, pp.21-26, 2011
- [2] 宮下, JES, pp.106-107, 2012
- [3] 西郷ら, JSAE, Vol.42, No.3, pp.721-727, 2011
- [4] 今井ら, IEICE, D 編, Vol.J96-D, No.4, pp.1012-1019, 2013
- [5] Yuki et al., ITS WC2016, 2016
- [6] 北島ら, JSME(C 編), 63 巻 613 号, No.96-1780, pp.93-100, 1997