

Neural Attention Modelを用いた走行位置揺らぎからのドライバ眠気レベル推定

本井 みくに

指導教員：河中 治樹

1 はじめに

眠気推定の研究には生体信号を用いたものが多いが、実用化の観点からドライバーへのセンサ装着は現実的でない。そこで本研究では、生体信号を用いずにドライブレコーダ(ドラレコ)の情報のみから眠気を推定することを目指している。走行情報から眠気レベルを推定するものとして、金子ら [1] は速度や加速度情報に加え、車線内走行位置情報からのドライバーの眠気レベル推定を報告している。しかし、対環境ロバスト性やヒトによる反応の多様性などの観点から十分な精度が得られていない。

そこで本研究では、車線内走行位置ゆらぎに着目した眠気レベルの新たな推定方法を提案する。そして、実車走行実験により既存の手法との比較を行うことで眠気レベルの推定精度を評価した。

2 眠気レベルの推定手法

2.1 眠気の指標

ドライバーの眠気の基準として、北島ら [2] の提案する顔表情から眠気を分類する眠気表情評定値を用いる。

2.2 ドラレコで取得する情報と事前のデータスクリーニング

本研究の提案手法の概要を図1に示す。ドライバーが漫然状態のときには車両がふらつくと言われており、車両のふらつきとドライバーの眠気レベルとの間に関連性があると考えられる。したがって本研究ではまず、車両のふらつき量を取得するために、ドラレコの前方映像から白線を検知し、自車から左右白線までの距離を取得する。しかしながら、白線の途切れや、複数の白線の合流、白線以外の部分の誤検出などにより、これらの情報に急激な変化を伴うことがしばしばある。これによって眠気由来の特徴が埋もれてしまっている可能性があるため、それらの区間についてスクリーニングを行う。

2.3 走行位置揺らぎに基づく特徴量の抽出

眠気の特徴が表れる車両のふらつき情報を捉えるために、自車位置情報の統計的な変化を特徴量として抽出する。時刻 t_s から t_e までの白線までの距離の平均値を $m(t_s, t_e)$ 、標準偏差を $\sigma(t_s, t_e)$ とするとき、現在の車両のふらつき範囲を、 P_σ 、 N_σ として次式より求める。

$$P_\sigma(t_s, t_e) = m(t_s, t_e) + \sigma(t_s, t_e) \quad (1)$$

$$N_\sigma(t_s, t_e) = m(t_s, t_e) - \sigma(t_s, t_e) \quad (2)$$

しかしながら、車種やドライバーの個性の違いによって、走行位置情報が異なり、 P_σ 、 N_σ に影響を及ぼすことがわかっていく。そこで本研究では、走行開始数分のふらつきに対する変動量の特徴量とする。 t_w をスクリーニング済みのデータが W 秒たった時刻とすると、次式から P 、 N を特徴量として抽出する。ただし、定数 W は蓄積したドラレコデータから経験的に決定する。

$$P(t) = \begin{cases} P_\sigma(t - t_w + 1, t) - P_\sigma(1, t_w) & \text{if } t > t_w \\ 0 & \text{others} \end{cases} \quad (3)$$

$$N(t) = \begin{cases} N_\sigma(t - t_w + 1, t) - N_\sigma(1, t_w) & \text{if } t > t_w \\ 0 & \text{others} \end{cases} \quad (4)$$

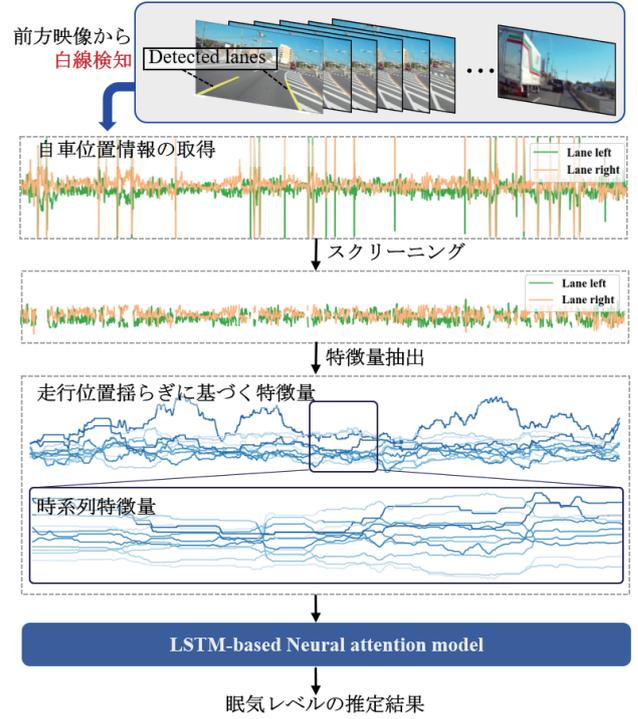


図1 提案手法の概要

P 、 N に加えて、 P 、 N のそれぞれの変化量 D や P 、 N の差 S 、 S の絶対値である B 、走行開始 t_w 秒間の走行位置からの差異について大きくずれた回数の特徴量 C を抽出する。以上に記した特徴量 P, N, D, S, B, C を、左右白線までの距離それぞれについて抽出すると、特徴量 $P_l, N_l, D_l, S_l, B_l, C_l$ および $P_r, N_r, D_r, S_r, B_r, C_r$ が得られる。これらの特徴量を、 $x = \{P_l, N_l, P_r, N_r, D_l, D_r, S_l, S_r, B_l, B_r, C_l, C_r\}$ とする。

2.4 時系列特徴量の抽出

本研究では、眠気の特徴が時系列変化にも表れるとの仮説から、走行位置揺らぎに基づく特徴量から時系列特徴量を抽出する。時刻 t のときの時系列特徴量を $x_t^{(1)} = \{x_{t-L_s+1}^{(1)}, \dots, x_t^{(1)}\}$ 、 $x_t^{(2)} = \{x_{t-L_s+1}^{(2)}, \dots, x_t^{(2)}\}$ 、 $x_t^{(n)} = \{x_{t-L_s+1}^{(n)}, \dots, x_t^{(n)}\}$ として抽出する。ただし、 L_s は時系列特徴量抽出時の窓枠である。定数 L_s は蓄積したドラレコデータから経験的に決定する。

2.5 推定に用いるモデル

本研究では、時系列変化を学習するために、Recurrent Neural Network の拡張である Long short-term memory (LSTM)[3] をベースとしたモデルを提案する。提案モデルを図2に示す。本研究で提案するニューラルネットワークは、時系列変化の局所的な特徴を捉える Convolution 層、情報の位置変動に対応するための Pooling 層、時系列情報に対して認識を行う LSTM 層、予測に寄与した特徴の寄与度を算出する Attention 層 $a^{(1)}, a^{(2)}, \dots, a^{(n)}$ からなる。これらを組み合わせることで

短期的にも長期的にも時系列変化を考慮した眠気推定が可能である。時系列特徴量 $\{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(n)}\}$ ごとにネットワークへ入力し、Convolution 層や LSTM 層によって特徴を抽出する。抽出された特徴を結合し、Dense 層で識別を行う。出力層の数は一つで損失関数に平均二乗誤差、最適化関数として RMS prop を用いる。モデルのパラメータとして、学習率を 0.01、ドロップアウト係数を 0.4 としている。

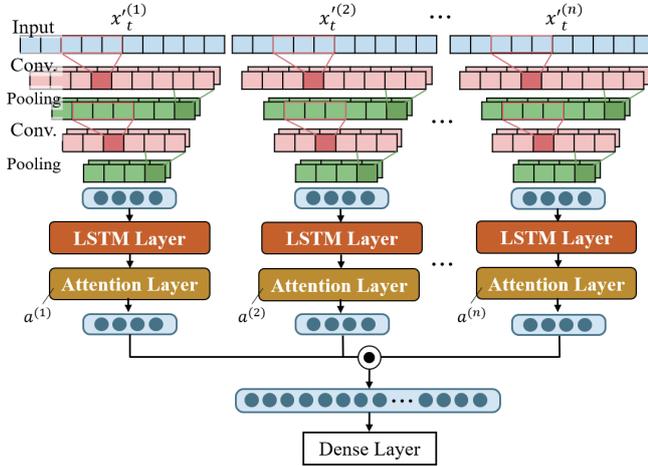


図2 提案モデル Neural Attention Model

3 実験

提案手法を評価するため、事業用ドライバの走行データに対する眠気レベル推定の性能評価実験を行った。

3.1 実験の方法と条件

データは事業用車両での高速道路走行によって取得した。被験者7名の23走行データを用いる。全23データの内、22データを学習に用い、残り1データを評価に用いる leave-one-out 交差検証を行なった。評価指標として、推定眠気レベルと正解眠気レベルとの平均絶対誤差 (MAE) を用いた。実験パラメータは、 $W = 1200$, $L_s = 900$ とした。

本実験では、提案手法の有効性を評価するために、二つの手法と比較を行った。

■比較手法: Kaneko 比較手法として金子ら [1] が提案した手法による眠気レベル推定を行った。この手法では、ドラレコから、速度や加速度に加えて、自転車における白線までの距離や横移動速度、白線と白線との消失点移動量などの特徴を取得し、重回帰分析によって眠気レベルを推定している。

■比較手法: FF-NN 時系列特徴量の抽出および Neural Attention Network モデルの有効性を評価するため、もう一つの比較手法として、feed-forward neural network(FF-NN) による眠気レベルの推定性能を評価する。本実験では、説明変数を $x = \{P_l, N_l, P_r, N_r, D_l, D_r, S_l, S_r, B_l, B_r, C_l, C_r\}$ 、目的変数を眠気レベルとした。モデルの隠れ層の数は3、隠れ層の素子数は128、活性化関数は ReLU 関数とした。最適化アルゴリズムとして、学習率を 0.01 とした RMS prop を用いた。

3.2 実験結果と考察

実験の結果を表1に示す。表では、MAE および眠気レベルごとの MAE を示している。表より、MAE について提案手法が最

も精度が高く、金子らが提案する従来手法や FF-NN よりも優れた性能を示した。

表1 眠気レベル推定結果の精度

Model	Total	Lv 1	Lv 2	Lv 3	Lv 4
Kaneko	0.686	0.86	0.23	0.97	1.79
FF-NN	0.611	0.97	0.12	0.82	1.4
Proposed	0.48	0.89	0.31	0.23	1.28

金子らの手法と比べて FF-NN では、眠気レベル 3, 4 の推定誤差が小さくなっており、特に眠気の高まりに対する追従性が上がったことがわかる。この理由として、特徴量抽出時に個人差による影響を考慮したことや、特徴量抽出時の窓枠として 10 秒ではなく、約 10 分間としたことが有意に働いたと考える。

また、提案手法が FF-NN よりも優れていた理由としては、FF-NN モデルは瞬間的な特徴のみに注目して推定しているのに対して、提案手法では特徴の時系列的な変化に注目していることが挙げられる。図3に、モデル内の Attention 層 $a^{(1)}, a^{(2)}, \dots, a^{(n)}$ の重みを示す。図3より、推定する瞬間に得られた特徴だけではなく時系列的な特徴に着目して推定を行っていることがわかり、時系列変化の特徴を推定することの有効性が示された。

しかしながら、表1より、依然、眠気レベル4に対する推定が困難である。これは、学習データに眠気レベル4のデータセットが極端に少ないためだと考えられるため、眠気レベルの高いデータの収集や不均衡データに対する考慮が必要である。

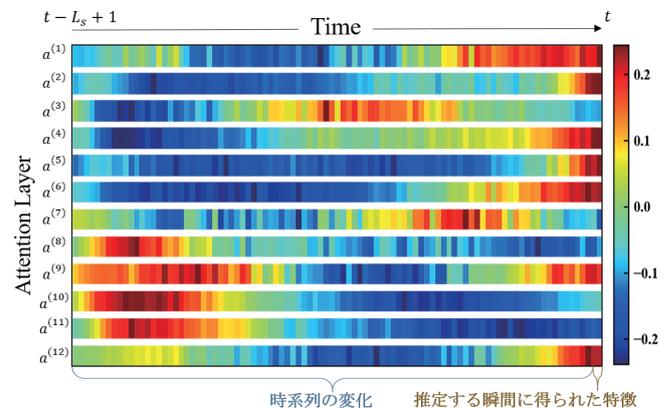


図3 各 Attention 層の重み

4 おわりに

本論文は、ドライバの走行位置揺らぎ情報を特徴量とした新たな眠気レベルの推定手法を提案した。事業用車両により取得したデータを用いた実験結果から、既存手法に比べて精度の向上を確認し、本提案手法の有効性が示された。今後の課題として、眠気レベルの高い状態のデータセットを収集することが挙げられる。

参考文献

- [1] K.Yuki *et al.*, ITSWC2016, 2016.
- [2] 北島他, JSME(C 編), 1997.
- [3] S.Hochreiter *et al.*, Neural computation, 1997.