

歩行者脇通過時における歩行者属性に基づく運転行動の推定

新村 文郷¹⁾ 川西 康友¹⁾ 出口 大輔¹⁾ 平山 高嗣¹⁾ 井手 一郎¹⁾ 村瀬 洋¹⁾ 藤吉 弘亘²⁾

Estimation of Driver's Behavior based on Pedestrian's Attributes when Passing by a Pedestrian

Fumito Shinmura Yasutomo Kawanishi Daisuke Deguchi Takatsugu Hirayama Ichiro Ide Hiroshi Murase Hironobu Fujiyoshi

When passing by a pedestrian, a driver predicts the pedestrian's intention by observing his/her behavior and decides whether the vehicle can safely pass by or not. Estimation of the driver's decisions and behaviors would be helpful to assist safe driving. In this presentation, we propose a method to estimate driver's behavior when passing by a pedestrian based on his/her attributes. We consider that the process of a driver deciding his/her behaviors according to the pedestrian's state and behavior is similar to a conversation. Therefore, the proposed method makes use of the sequence to sequence model which is based on the recurrent neural networks and is usually used for a conversational model. We evaluate the performance of the proposed method using actual driving data collected by experienced drivers in control of the vehicle.

KEY WORDS: Safety, Pedestrian detection/protection, Driving support/driver support, Driver's behavior estimation (C1)

1. ま え が き

対歩行者事故を低減し、安全な運転を行うためには、自車の周囲に存在する歩行者について正しく把握し、衝突するかどうかを予測することが重要である。これまでも運転者が歩行者を見落としとして起こる事故を低減するために、車載カメラを用いた歩行者検出技術について広く研究が行われてきた^(1,2)。それらの技術の一部は既に衝突被害軽減のために実用化され利用されている。しかし、進路上の歩行者を感知して衝突に備えるだけでは、進路上へ侵入してくる歩行者に対して必ずしも有効ではない。特に自動車歩行者の近くを通過する際は、歩行者の横断や道路への急な飛び出しに備える必要がある。ゆえに、歩行者を認識するだけでなく、衝突の危険性をも推定する技術が強く望まれている。

一般的には、歩行者の行動を予測することで、衝突の危険があるかを推定する。しかし、歩行者は急に行動を変えることがあるため、正しく行動を予測することは難しい。そこで我々は運転者の行動に注目する。安全運転を心がけていれば、運転者は歩行者の行動を先読みして衝突の危険性を推定し、それに応じた運転行動を取ると考えられる。例えば、衝突の危険性がある歩行者の近くを通過する際は、いつでも停止できるようアクセルを離し、ブレーキを踏み準備をしつつ通過する。言い換えれば、そのような運転行動が取られた場合、その歩行者との衝突の危険性が高かったと推定できる。ゆえに、運転行動の推定を通して、衝突の危険性を評価できると考えられる。

本報告では、上述のような運転者が歩行者の行動を先読みした上で現れる運転行動の推定を目的とする。具体的には、

運転者が歩行者を見て、衝突の危険があるのでアクセルを離してブレーキを準備するか、あるいは衝突の危険はないのでアクセルを踏みかを推定する。本報告では特に、歩行者脇通過時に注目して運転行動を推定する。

先行研究として我々は、歩行者属性と運転行動の関係を分析した⁽³⁾。歩行者の行動予測には、歩行者の向きや動作といった歩行者属性を認識することが重要と考えられる。同様に、運転行動を推定する上でも歩行者属性が重要となると考え、7種類の歩行者属性について運転行動の推定において貢献するか否かを分析した。実際に熟練の運転者の走行データを用いて分析を行った結果、歩行者の体向きや自転車への気付きの有無といった歩行者属性が、運転行動の推定において重要であることを明らかにした。この結果を踏まえ、本報告では運転行動の推定に歩行者属性を利用する。

歩行者の状態や挙動に変化があった場合に運転行動が変化すると考えられる。例えば、歩行者の向きが変われば、それに応じて運転行動が変わると考えられる。運転者が歩行者の状態や挙動を観察し、それに応じてどのような運転をするか判断する。この一連の流れは人物の対話に近いと考えられる。近年、ディープラーニングを使用した対話モデルとして Sequence to Sequence (Seq2Seq) モデル⁽⁴⁾が提案され、入力された発話系列に応じて応答を生成する手法が報告されている。そこで、歩行者属性を入力される発話、運転行動をそれに対する応答と見なし、対話モデルを用いて運転行動を推定することで、運転行動推定精度の向上を図る。なお、本報告で取り扱うのは運転者と歩行者が1対1の場合のみとし、自動車が1人の歩行者の脇を通過する場面を想定する。

以上を踏まえ、本報告では対話モデルを利用し、歩行者属性に基づいて運転行動を推定する手法を提案する。

1) 名古屋大学(464-8601 愛知県名古屋千種区不老町)

2) 中部大学(487-8501 愛知県春日井市松本町 1200)

2. 関連研究

歩行者の行動を予測するためには、歩行者の状態や挙動を認識することが重要と考えられる。これまでに様々な歩行者属性を認識する研究が行われてきた。特に歩行者の体向きは進行方向を予測する上で重要な要素であることから、盛んに研究が行われてきた。Taoらは画像から複数の局所領域を切り出し、局所領域ごとにランダムフォレストを用いて向きを推定して統合することで、人物の体向きを推定する手法を提案している⁽⁵⁾。Flöhrらは顔と体の向きに相関があることを利用し、それらの共起性を利用することで推定精度を向上させる手法を提案している⁽⁶⁾。

また、歩行者の行動予測の一つとして、道路の横断を予測する研究が行われている。Kohlerらは、エッジに基づく特徴と機械学習手法を組み合わせ、歩行者の横断開始を早期に認識することで横断を予測する手法を提案している⁽⁷⁾。Fangらは、歩行者の姿勢情報を用いてSVMにより歩行者の横断意図を推定する手法を提案している⁽⁸⁾。

運転行動の推定を行う研究では、Shimosakaらは無信号交差点を含む直進路において、自車の位置や交差点の位置、法定速度を用いた逆強化学習を利用し、加速や減速、速度維持といった運転行動を推定する手法を提案している⁽⁹⁾。Misawarらは、個々人のドライビングスタイルを考慮した運転行動推定モデルを提案しており、10秒間の運転行動を用いて10秒後までの運転行動を高精度に推定した⁽¹⁰⁾。ただし、これらの研究では歩行者による影響は考慮されていない。歩行者による影響は交差点の位置や法定速度といった静的な要因やドライビングスタイルといった要因とは異なる影響を運転行動に対して与えるため、本報告の目的である歩行者脇通過時の運転行動の推定は難しい。

3. 提案手法

本節では、本提案手法が運転行動推定に用いる入力特徴量について説明し、次に提案する運転行動推定モデルの詳細と推定方法について説明する。

3.1. 入力特徴量

先に述べたように、歩行者属性が運転行動の決定において重要であることから、推定のための入力特徴量として利用する。本報告では、先行研究で分析した7種類の歩行者属性の中で最も重要であると判明した歩行者の体向きを利用する。

また、一般的に、自車から歩行者までの距離が十分に離れている間は、歩行者を認識しても注意を払って運転はしない。ある程度の距離まで歩行者に近付くと注意を払い始めることから、運転行動の推定に歩行者との距離は深く関係する。また、自車の速度に応じて減速量が変わることから、運転行動の推定に車速もまた関係すると考えられる。

以上を踏まえ、本手法において運転行動推定のための入力

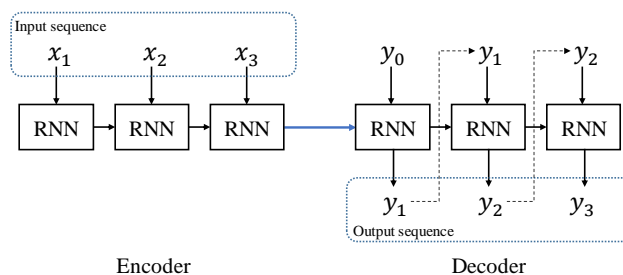


Fig.1 Outline of Seq2Seq model.

特徴量として利用するのは以下の3つである。

- 歩行者の体向き (8方向)
- 歩行者の相対位置 (進行方向の距離, 横方向の距離)
- 自車の速度

3.2. Seq2Seq モデル

本手法は、Seq2Seqモデル⁽⁴⁾を利用して運転行動を推定する。Seq2Seqモデルは、主に機械翻訳のモデルとして利用され、再帰型ニューラルネットワーク (Recurrent Neural Networks: RNN) を用いた Encoder 部と Decoder 部から構成されるモデルである。Seq2Seqモデルの概要を図1に示す。

Encoder部では入力系列の要素をRNNに入力し、RNNの隠れ層の出力を得る。得られた隠れ層の出力は次のRNNの入力として利用され、これを入力系列分だけ繰り返す。これにより得られる最終的なRNNの隠れ層の出力は、入力系列を表現する特徴ベクトルとなる。

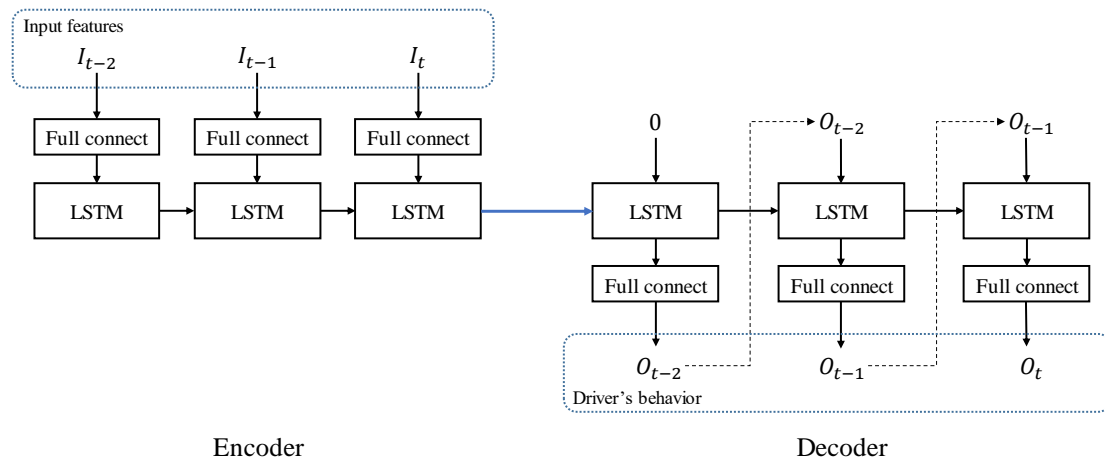
Decoder部では、Encoder部で得られた特徴ベクトルをRNNの初期値として、出力系列を推定する。最初のRNNには適当な初期値を入力し、推定結果とRNNの隠れ層の出力を得る。2回目以降のRNNには1つ前の推定結果をRNNに入力し、推定結果とRNNの隠れ層の出力を得る。これを出力系列分だけ繰り返す。学習時にEncoderを通した特徴ベクトルとDecoderを通した出力系列の関係をネットワークが学習するため、入力系列に応じて適切な出力系列を推定することが可能である。

3.3. 運転行動の推定モデル

上で説明したSeq2Seqモデルをもとに、運転行動推定に合わせてネットワークを構築した。提案手法の概要を図2に示す。本手法ではRNNの部分にLong Short-Term Memory (LSTM)を用いたモデルを利用する。また、入力特徴量の系列および出力される運転行動の系列は3フレームとした。

Encoder部では、まず入力特徴量を特徴ベクトルに変換するために、Full connect層を入力する。Full connect層の出力をLSTMに入力し、Seq2Seqモデルと同様にLSTMの隠れ層の出力を得ていき、最終的なLSTMの隠れ層の出力を得る。

Decoder部では、Seq2Seqモデルと同様にEncoder部で得られた特徴ベクトル (LSTMの隠れ層の最終出力) をLSTMの初期値とする。最初のLSTMには、初期状態を表す適当な値 (ここ



Encoder

Decoder

Fig.2 Outline of the proposed model for estimation of driver's behavior.

では 0) を入力し、推定結果と LSTM の隠れ層の出力を得る。LSTM から得られた推定結果は、各運転行動の確率に変換するために、Full connect 層に入力する。Full connect 層の出力をもとに最も確率の高い運転行動を求め、その時点の推定結果とする。2 回目以降の LSTM には、Seq2Seq モデルと同様に、1 つ前の推定結果を LSTM に入力し、推定結果と LSTM の隠れ層の出力を得て、推定結果は Full connect 層に入力することで各運転行動の確率を求め、推定結果を得る。これを繰り返して、運転行動の推定を行う。

4. 実験

4.1. データセット

実験には、実環境の様々な状況下で歩行者の脇を通過した運転データを集めたデータセットを使用した。運転データの収集には、様々なセンサ機器を搭載した実験車両を使用し、熟練運転者に運転を依頼して運転データを収集した。熟練運転者は、自動車学校にて教習員を務める運転者である。

データセットには画像、LiDAR 点群、CAN データが含まれており、CAN データに含まれるアクセルペダルの操作情報をもとに、運転行動が付与されている。運転行動は下記の 3 種類である。

- ① 通常状態：歩行者までの距離が遠く、歩行者を意識して運転が行われていない状態。
- ② 構え状態：歩行者に注意を向け、いつでも停止できるようブレーキ操作を準備している状態。
- ③ 安全見切り状態：歩行者の脇を通過しても安全と判断し、見切りをつけて加速している状態。

データセットのより詳細な情報および運転行動の定義については、先行研究の論文³⁾に記載されている。

また、使用するデータセットに対し、本手法の入力特徴量である歩行者の体向きと相対位置、自車の速度の情報を付与した。歩行者の体向きは画像から、歩行者の相対位置は LiDAR 点群から、自車の速度は CAN データから、それぞれ取得して

付与した。

データセットは 84 回の歩行者脇通過シーン（1 人の歩行者の脇を通過する場面のみ）を含み、合計 4,837 フレーム分の運転データの組から構成される。

4.2. 運転行動推定の実験

運転行動の推定では、データセットを 10 分割し、そのうち 9 個を学習に使用し、残りの 1 個をテストに使用して推定精度を評価した。すべてのデータが評価に用いられるよう、10 回テストを行い、10 回の平均精度を最終的な精度とした（10 分割交差検証）。推定精度の指標として、本手法を適用して得られた運転行動と正解の運転行動を比較し、その一致率（正解率）を精度とした。

本手法は 3 フレーム分の入力特徴量を用いて 3 フレーム分の運転行動が得られる。そのため推定では、シーン先頭の 3 フレームは、3 フレーム分の入力特徴量を用いて本手法を適用して得られた 3 フレーム分の運転行動を推定結果とする。4 フレーム目以降は、現在のフレームと直前の 2 フレームを足した 3 フレーム分の入力特徴量を用いて推定して、得られた 3 フレーム分の運転行動の 3 フレーム目を推定結果とする。

4.3. 実験結果

実験結果を表 1 に示す。比較のため、同データセットを使用し、SVM を用いて運転行動を推定した結果³⁾を示した。

表 1 から確認できるように、Seq2Seq モデルを用いた提案手法により運転行動の推定精度の向上が見られた。提案手法と比較手法の大きな違いとして、比較手法はフレームごとに運転行動を推定するため、時系列情報が考慮されていない。運転行動は、歩行者がある一定の距離まで近付いたときや、歩行者の状態や挙動に変化が生じたときに、行動が変わると考えられる。また、運転行動は頻繁に変化するものではなく、行動が変化する場合も前状態に依存する。そのため、時系列情報の利用は重要と考えられる。提案手法は、推定モデルの

Table. 1 Estimation results of the driver's behaviors.

手法	正解率
提案手法 (Seq2Seq モデル)	57.2 %
比較手法 (SVM) ⁽³⁾	55.9 %

Encoder 部と Decoder 部において、それぞれ入力特徴量と運転行動推定結果の時系列情報が考慮されるため、精度向上に貢献したと考えられる。

4.4. 課題

本提案モデルの学習では、学習データを繰り返し学習させることでモデルの学習を進める。しかし、学習の比較的早い段階から過学習の傾向が見られた。

道路環境のわずかな違い等により、運転者が運転行動を決定するタイミングにばらつきが生じる。これにより歩行者の位置や属性が非常に近い値であっても運転行動が異なる場合が発生する。これを正しく推定できるよう学習しようとするため、過学習を起こした原因になったと考えられる。

この問題を解決するためには、運転行動の決定のタイミングのばらつきを許容できるよう手法の改良が必要と考えられる。運転行動の決定には、運転者の個人差といった要因もあると考えられるため、個人差を考慮したモデル⁽¹⁰⁾の考え方を参考に解決を図ることができると考えられる。また、さらに多くの運転データを収集し、モデルの学習に用いることも有効と考えられる。

5. まとめ

本報告では、自動車が歩行者脇を通過する場面における運転行動を推定する手法を提案した。本手法は、歩行者の属性に応じて運転行動の決定が行われると仮定し、運転行動の推定のために歩行者属性を用いた。また、運転者が歩行者の属性に応じて運転行動を決定する一連の流れが、人物の対話に近いと捉え、対話モデルの枠組みを利用した運転行動推定手法を提案した。

今後の課題として、推定精度の向上に向けて有効な歩行者属性について検討するとともに、運転行動推定モデルの改良を行う計画である。また、より多くの運転データを用いて多様な環境下での実験を行いたい。また、複数の歩行者の近くを連続で通過する場面への応用に向けて、1対多の対話モデルの導入を検討したい。

謝辞

本研究の一部は国立研究開発法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーションプログラム (名古屋 COI : 人がつながる “移動” イノベーション拠点)」の支援及び、科学研究費補助金の援助によって行わ

れた。

参考文献

- (1) P. F. Felzenszwalb, R. B. Girshick, D. McAllester and D. Ramanan: Object Detection with Discriminatively Trained Part-Based Models, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.32, No.9, p.1627-1645 (2010)
- (2) S. Ren, K. He, R. Girshick and Jian Sun: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, Advances in Neural Information Processing Systems 28 (NIPS), p.91-99 (2015)
- (3) 新村文郷, 川西康友, 出口大輔, 井手一郎, 村瀬洋, 藤吉弘亙: 歩行者脇通過時における歩行者属性の運転行動の関係に関する分析, 自動車技術会 2017 年秋季大会学術講演会講演予稿集, p.480-485 (2017)
- (4) I. Sutskever, O. Vinyals and Q.V. Le: Sequence to Sequence Learning with Neural Networks, Advances in Neural Information Processing Systems 27 (NIPS), p.3104-3112 (2014)
- (5) J. Tao and R. Klette: Part-based RDF for Direction Classification of Pedestrians, and a Benchmark, In Proc. of Workshop on Intelligent Vehicles with Vision Technology in the 12th Asian Conference on Computer Vision, w11-p2 (2014)
- (6) F. Flohr, M. Dumitru-Guzu, J.F.P. Kooij and D.M. Gavrilu: Joint Probabilistic Pedestrian Head and Body Orientation Estimation, In Proc. of 2014 IEEE Intelligent Vehicles Symposium, p.617-622 (2014)
- (7) S. Kohler, M. Goldhammer, S. Bauer, K. Doll, U. Brunsmann and K. Dietmayer: Early Detection of the Pedestrian's Intention to Cross the Street, In Proc. of 15th IEEE Intelligent Transport System Conference (ITSC), p.1759-1764 (2012)
- (8) Z. Fang, D. Vázquez and A.M. López: On-Board Detection of Pedestrian Intentions, Journal of Sensors, 17(10), 2193-1-14 (2018)
- (9) M. Shimosaka, K. Nishi, J. Sato and H. Kataoka: Predicting Driving Behavior Using Inverse Reinforcement Learning with Multiple Reward Functions toward Environmental Diversity, In Proc. of 2015 IEEE Intelligent Vehicles Symposium, p.567-572 (2015)
- (10) H. Misawa, K. Takenaka, T. Sugihara, H. Liu, T. Taniguchi and T. Bando: Prediction of Driving Behavior Based on Sequence to Sequence Model with Parametric Bias, In Proc. of 20th IEEE International Conference on Intelligent Transportation Systems, p.1310-1315 (2017)