

ニューラルネットワークモデルを用いた走行車両の車線変更予測について

Prediction of Vehicle Lane Change Using Neural Network Models

Yang Heng¹⁾ 北 栄輔²⁾
Heng YANG and Eisuke KITA

¹⁾修 (情報学) 名古屋大学大学院情報学研究科 (〒 464-0814 愛知県名古屋市千種区不老町)

²⁾工博 名古屋大学大学院情報学研究科 (〒 464-0814 愛知県名古屋市千種区不老町, E-mail: kita@i.nagoya-u.ac.jp)

A vehicle lane change decision (LCD) model is discussed in this study. The LCD model, which is defined by neural network models, is trained using real vehicle data in NGSIM dataset. Comparison of the prediction accuracy of the models reveals that Bi-LSTM and Bi-GRU models are more accurate than LSTM and GRU models, respectively, and that the Bi-GRU model is the most accurate.

Key Words : Lane change decision, Prediction, Long Short Term Memory, Gated Recurrent Unit.

1. 緒論

交通渋滞は都市交通における重要な課題の1つであり、経済的および環境的に重大な影響を及ぼしている。交通渋滞を緩和するためには、潜在的な渋滞ポイントを事前に予測して車両に渋滞回避運転をさせる必要がある。当初、車両の挙動予測はルールベースのモデルとして定義され、事前定義されたルールと条件のセットによって予測していた[1]。その後、離散選択モデルを取り入れることで、車両挙動予測が大幅に進歩した。これらのモデルは効用理論を使用して意思決定プロセスをシミュレートし、車線変更動作の予測を可能にした[2]。近年では、サポートベクターマシン (SVM) やニューラルネットワーク (NN) などの機械学習アルゴリズムを使用して、動的な交通シナリオに基づいて車両の挙動を予測する方法が提案されている。

これに対して、本研究では、ニューラルネットワークを用いた車両の車線変更決定 (Lane Change Decision: LCD) モデルについて述べる。LCD モデルを長・短期記憶 (LSTM) モデルやゲート付き回帰型ユニット (GRU) モデル等の4つのニューラルネットワークモデルで定義し、NGSIM データセットの実車両の走行データを用いてモデルを学習する[3]。予測精度を比較し、モデルの有効性を検討する。

2. 提案手法

(1) データセット

Next Generation Simulation (NGSIM)[3] データセットには、0.1秒間隔で測定された走行車両の速度、加速度、位置などが含まれている、このデータセットには、オートバイ、乗用車、トラックなどのさまざまな種類の車両が含まれているが、本研究では自動車のデータを用いる。本研究では、車線変更操作の発生率が高い2つの高速道路セグメント I-80 と US-101 のデータに着目し、車線変更する車両 300 台と車線を維持する車両 300 台のサンプルを抽出して使用する。

(2) ニューラルネットワークモデル

a) 長・短期記憶 (Long Short-Term Memory, LSTM)

長・短期記憶 (LSTM) は、時系列データとシーケンスモデリングタスクを処理するために設計されたリカレントニューラルネットワーク (RNN) の一種である。LSTM は、シーケンスデータの長期依存関係を学習するように設計されている。交通シナリオにおいては、車両の現在の動作は、数分、数時間、場合によっては数日前のイベントの影響を受ける可能性がある。たとえば、重要なイベント (スポーツの試合やコンサートなど) が発生すると、数時間後にトラフィックが急増する可能性がある。LSTM はこのような問題の予測に適していると考えられる。

双方向 LSTM (Bidirectional LSTM, Bi-LSTM) では、順方向と逆方向の両方から時系列データを同時に処理する機能がある。これは、車線変更前の5秒間のデータについてモデルは各時点のフィーチャが周囲の情報にどのような影響を受けているか、また周囲の情報にどのような影響を与えていているかを理解できることを意味する。これにより、より複雑なパターンやインタラクションをキャプチャできる。

b) ゲート付き回帰型ユニット (Gated Recurrent Unit, GRU)

ゲート付き回帰型ユニット (GRU) モデルは、従来の RNN で発生する可能性のある勾配消失問題を解決することを目的とした RNN である。GRU は、一般的な RNN よりも効果的に長期的な依存関係を記憶するように設計されており、時系列分析、自然言語処理、音声認識などの逐次的なタスクで特に有効である。LSTM は長距離の依存関係をより適切に捕捉できるが、一部のタスクではオーバーフィットする可能性がある。GRU はより単純で、トレーニングが高速となる。データ量が小さい場合、特定のタスクでパフォーマンスが向上する可能性がある。

双方向 LSTM と同様に、双方向 GRU を定義して比

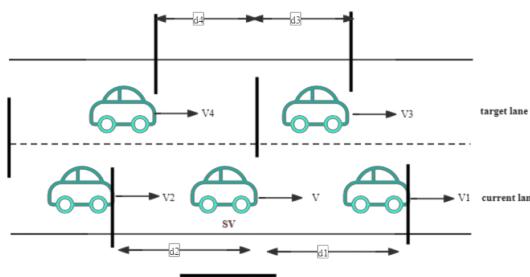


Fig1 Vehicle Driving Diagram

較する。

(3) 目的変数

本研究では、過去 5 秒間の車両軌跡データから、次の段階での車両の車線変更挙動を予測することである。したがって、目的変数は注目車両が車線変更する場合（状態 1）、車線変更しない場合（状態 0）である。したがって、目的変数は次のように定義される。

$$\text{Decision} = \begin{cases} 0, & \text{if lane-keeping} \\ 1, & \text{if lane-changing} \end{cases} \quad (1)$$

(4) 説明変数

注目車両と周辺車両の関係を図 1 に示す。説明変数ベクトルを次式で定義する。

$$\begin{aligned} Z = \{ & A_x, V_x, \Delta V_1(t_{LC} - t), \Delta V_2(t_{LC} - t), \\ & \Delta V_3(t_{LC} - t), \Delta V_4(t_{LC} - t), \Delta D_1(t_{LC} - t), \\ & \Delta D_2(t_{LC} - t), \Delta D_3(t_{LC} - t), \Delta D_4(t_{LC} - t) \} \end{aligned} \quad (2)$$

ここで、 A_x と V_x は注目車両の加速度と速度を表す。 ΔV_i と ΔD_i は、注目車両と車両 i の速度差及び車間距離差を示す。また、 t_{LC} は車線変更の実施点を示す。

(5) 損失関数

損失関数としてバイナリクロスエントロピー損失関数を用いる。予測された車線変更確率 y と真のラベル y_{true} に対して、損失関数は次式で与えられる。

$$\mathcal{L}(y, y_{\text{true}}) = -y_{\text{true}} \log(y) - (1 - y_{\text{true}}) \log(1 - y) \quad (3)$$

3. 実験結果

本実験では、ハイパーパラメータとして同じ数値を選択し、LSTM モデル、Bi-LSTM モデル、GRU モデル、Bi-GRU モデルの予測精度を比較する。ハイパーパラメータを表 1 に、精度比較の結果を表 2 に示す。

LSTM モデルと GRU モデルの両方の双方向バージョンである Bi-LSTM モデルと Bi-GRU モデルは、単方向モデルである LSTM モデルと GRU モデルと比較して優れたパフォーマンスを示している。まあ、GRU モデ

Table 1 The Training Parameters of LCD models

Hyperparameter	Value
Hidden Size	128
Layers	4
Epochs	15
Batch Size	1
Learning Rate	0.0001
Optimizer Type	Adam
Activation	tanh, sigmoid

Table 2 Performance comparison of different networks

Model	AUC	Precision	Recall	F1 Score
LSTM	0.933	0.9359	0.94	0.93
Bi-LSTM	0.94	0.9416	0.94	0.94
GRU	0.96	0.9631	0.97	0.96
Bi-GRU	0.98	0.9812	0.98	0.98

ルは一方向と双方で LSTM モデルよりも優れたパフォーマンスを示している。これは、その単純化された構造と効率的なゲートメカニズムに起因すると考えられる。ハイパーパラメータの調整、機能の選択、モデルの複雑さについてさらに調査すると、これらのモデルの予測能力がさらに向上する可能性がある。

4. 結論

本研究では、ニューラルネットワークモデルを用いて車両の車線変更を予測するモデルを定義した。予測モデルは、リカレントニューラルネットワークモデルである LSTM、Bi-LSTM、GRU、Bi-GRU で定義し、実際の車両の走行データを用いて予測モデルを学習した。実験結果より、LSTM モデルと GRU モデルよりも Bi-LSTM モデルと Bi-GRU モデルのほうが精度よく、Bi-GRU モデルがもっとも精度が高いことがわかった。

謝辞

本研究は JSPS 科研費 19K04140 の助成を受けたものです。

参考文献

- [1] Nicholas G Polson and Vadim O Sokolov. Deep learning for short-term traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 79:1–17, 2017.
- [2] K Ahmed, M Ben-Akiva, H Koutsopoulos, and R Mishalani. Models of freeway lane changing and gap acceptance behavior. *Transportation and traffic theory*, 13:501–515, 1996.
- [3] U.S. Department of Transportation Federal Highway Administration. Next generation simulation (ngsim) vehicle trajectories and supporting data. [Dataset]. Provided by ITS DataHub through Data.transportation.gov, 2016. Accessed 2024-01-22 from <http://doi.org/10.21949/1504477>.