

Time-Delay CNN とアクセル制御器による 自動車ステアリング・アクセル操作の End-to-End 学習

End-to-End Learning of Car Steering and Acceleration Control
Using Time-Delay CNN and Acceleration Controller

5116E022-0 本吉 俊之
MOTOYOSHI Toshiyuki

指導教員 尾形 哲也 教授
Prof. OGATA Tetsuya

昨今では自動運転技術の研究が盛んに行われているが、従来行われてきた手法では、高度なセンサーや高精度の 3D 地図データを用いる必要がある上、モデルの作りこみに手間がかかる。この問題を解決する方法として、Convolutional Neural Networks(CNN)の End-to-End 学習により、カメラ画像の入力から運転行動を直接生成するモデルが提案されている。本研究では、End-to-End 学習させた CNN とアクセル制御器を組み合わせたモデルを提案する。この際、Time-Delay Neural Network の手法を用いることで、CNN に時系列情報を考慮させる。このモデルを、自動車シミュレーターを用いた学習実験で評価した。CNN に考慮させる時間の幅を変えて走行性能を比較する実験により、時系列情報を考慮させることの効果が示された。また、アクセル制御器を介さないモデルとの比較により、アクセル制御器を用いる手法の有効性が確認された。この研究は、複数の運転者の運転データを学習させることで、ステアリングのみならずアクセル操作を行うことができるという点で、関連する先行研究に対して優位性がある。

キーワード：自動運転，ニューラルネットワーク，End-to-End 学習

Keywords：Self-Driving, Neural Network, End-to-End Learning

1. はじめに

昨今では自動運転技術の研究が活発に行われているが、従来の研究では、カメラや高度なセンサーの情報からの物体・車線認識、精緻な 3D 地図モデルとの組み合わせによる走行ルートの決定、運転操作、というように、運転を認知・判断・操作のプロセスに分割し、それぞれのプロセスについて独立した手法を取っているものが多い。このような従来の研究手法は、高度なセンサーや 3D 地図モデルが必要である、それぞれのプロセスの作りこみが困難である、といった課題が挙げられる。

この問題を解決する方法として、Neural Network の End-to-End 学習によって、運転者目線のカメラ映像のみから運転行動を直接生成するモデルが提案されている。

2. 関連研究

Bojarski ら[1]は、車の前方カメラから得られた画像を入力とし、ステアリング操作を出力するモデルを、Convolutional Neural Networks(CNN)の End-to-End 学習により実装した。このモデルに実車を運転させたところ、10 マイルのコースの走行時間の内の 98%を自動運転することに成功した。しかし、この研究はステアリング操作のみであり、アクセル・ブレーキ操作は行っていない。入力画像 1 枚であり、速度情報を考慮していないためだと考えられる。Codevilla ら[2]は、カメラ画像 1 枚と自車の速度情報および方向指示コマンドの入力か

ら車両のステアリングとアクセルの操作を出力するように、CNN を End-to-End 学習させた。その結果、シミュレーター内および実環境において、ステアリングだけでなくアクセル操作にも成功した。この研究では特定の運転者の運転のみを学習させているが、様々な状況での運転データを学習させる必要がある自動運転研究においては、複数の運転者のデータを収集し、学習させるのが自然だと考えられる。

3. CNN とアクセル制御器の複合モデル

本研究では、複数の運転者の運転を End-to-End 学習させた CNN と、目標速度と現在速度からアクセル操作値を導くアクセル制御器を組み合わせたモデルにより、ステアリング・アクセル操作を行う手法を提案する。この際、Time-Delay Neural Network [3]の手法により、CNN に時系列情報を持つ入力を与える。本研究では、これを Time-Delay CNN(TDCNN)と呼ぶ。

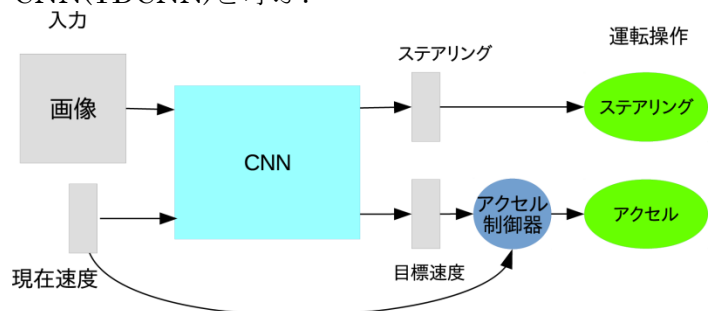


図1 CNN とアクセル制御器の複合モデル

本研究の TDCNN は、カメラ映像・現在速度 [km/h] を入力とし、ステアリング操作量 [rad] と目標速度 [km/h] を出力する。使用した TDCNN の構造を図 2 に示す。TDCNN の目標速度出力と現在の車速から、アクセル制御器によりアクセル操作量が決定される。今回は、アクセル制御器として以下のような ON-OFF 制御を用いた。アクセル操作は、 $[0.0, 1.0]$ の範囲で正規化されている。

$$\text{アクセル操作値} = \begin{cases} 1.0 & (\text{目標速度} > \text{現在速度}) \\ 0.0 & (\text{目標速度} \leq \text{現在速度}) \end{cases}$$

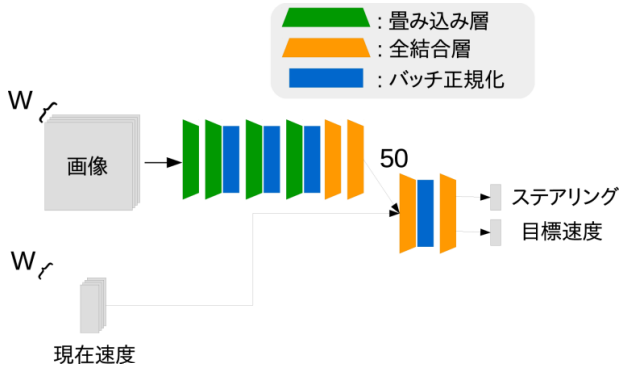


図2 TDCNN のネットワーク構造

4. 実験

上記の TDCNN に、複数の運転者による自動車シミュレーターの運転データを学習させた。このモデルにシミュレーター内車両を運転させることで、評価を行った。

4.1 時系列入力による性能評価実験

入力に時系列情報を持たせることの有用性を確認する実験を行った。TDCNN モデルの入力の時間幅を $W=1, 2, 4, 5, 6, 7, 10$ の7通りに変化させたものを学習させ、性能を比較した。各時間幅について、TDCNN の重みの初期化の seed 値を3通りに変えて学習を行った。

各時間幅の場合について、総走行距離の平均と分散を図3に示す。 $W=1$ の場合が最も走行性能が低いことがわかる。また、時間幅が長ければ良いということではなく、 $W=5$ の場合が最も良い結果となった。以上より、適切な時間幅を考慮することが自動運転研究において有効であると言える。




図3 時間幅の変化による結果の比較

4.2 アクセル制御器の評価実験

アクセル制御器によってアクセル操作を行うモデル(アクセル制御器モデル)の性能を確認する実験を行った。このアクセル制御器モデルと、アクセル制御器を介さずに TDCNN によってアクセル操作値を予測するモデル(アクセル予測モデル)との性能の比較を行った。

それぞれのモデルに50回ずつのシミュレーター走行を行わせた結果、アクセル制御器モデルはコースの走破に26回成功したのに対し、アクセル予測モデルでは一度も走破することができなかった。各モデルの総走行距離の平均と分散を図4に示す。以上の結果より、アクセル制御器モデルの性能が、アクセル予測モデルを大きく上回っていることがわかる。




図4 アクセル制御器モデルとアクセル予測モデルの比較

5. まとめ

TDCNN の End-to-End 学習とアクセル制御器の導入により、カメラ映像と速度の時系列情報からステアリング・アクセル操作を生成するモデルを獲得することに成功した。このモデルは時系列情報を考慮しているため、他車や歩行者等が入り混じる複雑な状況にも対応できると考えられる。また、運転操作の特徴が異なる複数の運転者の運転データを学習に使用することができるため、学習データ収集の面でも、先行研究に対して優位性がある。

今後は、未学習のコースやより複雑な状況への対応のため、さらなる走行性能の向上が必要になる。また、シミュレート環境で学習させたモデルを実環境でのモデル学習に応用する、転移学習についても検討していきたい。

参考文献

1. M. Bojarski et. al. "End to End Learning for Self-Driving Cars", 2016
2. F. Codevilla et. al. "End-to-end Driving via Conditional Imitation Learning", 2017
3. K. J. Lang et. al. "A Time-Delay Neural Network Architecture for Isolated Word Recognition", 1990