

Convolutional Neural Network による自動運転システムの学習と評価

Learning and Evaluation of Autonomous Driving System using CNN

1W120067-9 岩下 愛

IWAHISTA Megumi

指導教員 尾形 哲也 教授

Prof. OGATA Tetsuya

概要：近年、自動運転システムにおいて深層学習を用いることでカメラなどのセンサー情報からアクセル・ブレーキなどの操作情報を直接予測する End-to-End と呼ばれるアプローチが注目を集めている。

Convolutional Neural Network(CNN)は画像処理に特化した深層学習モデルの1つであり、これを運転席からの映像を処理させるために時系列を考慮した拡張モデル (Time-Delay CNN) が提案されていた。しかしこのモデルは人の運転データを学習することが示されていたものの、実際にモデルの予測した運転行動を使つての走行評価が行われていなかった。そこで本研究ではドライビングシミュレーターを用いて Time-Delay CNN の学習と走行能力評価を行なった。実験の結果、Time-Delay CNN が学習済みのコースを走行できることが示された。

キーワード：自動運転, End-to-End, Convolutional Neural Network

Keywords : Autonomous driving, End-to-End, Convolutional Neural Network

1. はじめに

従来の自動運転システム研究では作り込みモデルによる画像認識と制御システムによるもので、多様な運転状況への対応が課題となっていた。これに対して、深層学習を利用することで車のセンサー情報から直接運転行動を出力する End-to-End[1]と呼ばれるアプローチが近年注目を集めている。NVIDIA はシミュレーション環境下での End-to-End な自動運転システムを公開している[2]。このシステムでは Convolutional Neural Network(CNN)と呼ばれる神経回路モデルを用いて運転席に搭載されたカメラの画像からアクセル・ブレーキ・ハンドルの操作情報を予測生成させている[2]。しかしながら Deep Drive では各時刻におけるカメラ画像のみから運転行動生成を行っており、車の合流やすれ違いなどの過去の情報を利用しなければ次の行動を確定できない運転

状況への対応が難しい。

時系列を考慮した CNN による運転行動予測モデルとして、入力に決められた時間幅の過去の情報を入力とする Time-Delay CNN が提案されている ([3], 図 1)。しかし、このモデルは人の運転データを用いての学習が行われていることが示されているものの、実際にモデルの予測した運転行動を使つての走行評価が行われていなかった。

2. アプローチ

本研究ではシミュレーター環境下での人の運転データを用いて Time-Delay CNN を学習させ、実際に操作させることで運転行動予測の能力評価を行う。

3. 実験条件


シミュレーション環境として FORUM8 社による UC-win/Road を用いた。学習データとして 14 人、計分の運転データを収集したものをを用いて、Time-Delay CNN の

学習を行なった。学習データは入力として自動車の運転席に設置されたカメラの画像，速度[km/h]，そしてヨー角速度[rad/s]，出力としてハンドル[単位]，アクセル[単位]，そしてブレーキ[単位]を用いた。Time-Delay CNN は[3]で提案されているモデル (2D-CNN)，そして畳み込み層において時間方向の畳み込みを行える 3D Convolution と呼ばれる手法[4]を用いたモデル (3D-CNN) の2つを用いた。2D-CNN と 3D-CNN の違いは，CNN モデルに含まれた convolution 層における積和計算の違いである。その計算の違いは式(1)の通りである：

数式 1 2D-CNN と 3D-CNN の違い

$$2D: u_{ijm} = \sum_{n=0}^{N-1} \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} z_{i+p,j+q,n}^{(l-1)} h_{pqnm} + b_{ijm}$$

$$3D: u_{ijkm} = \sum_{n=0}^{N-1} \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} \sum_{r=0}^{T-1} z_{i+p,j+q,k+r,n}^{(l-1)} h_{pqrm} + b_{ijkm}$$



モデル図

図 1 Time-Delay CNN

これらのモデルを上記の運転データを用いて seed 値を変えたものを 2D と 3D でそれぞれ 5 つ，計 10 のネットワーク用いて学習させた後に，データ収集時と同じコース上で運転を行わせて評価を行なった。評価は 1) スタート地点からの走行距離， 2) 道路中央線と車の中心座標とのずれの2つを計測することで行なった。走行実験では3車線道路に外壁が設置してあり，車が衝突した時点でその試行は中止にした。

4. 実験結果

表 1 オープンテストの結果

ネットワーク	完走回数	ズレ平均
2D	20 / 25	0.497[m]
3D	5 / 25	0.579[m]

表 1 にあるように， 2 D-CNN， 3 D-CNN の両方でコースを概ね走破できることが分かった。道路中央線からのずれについては 2D-CNN が優れていることが分かった。

5. まとめ

本件研究ではシミュレーション環境下での Time-Delay CNN による時系列を考慮した End-to-End な自動運転システムの評価を行なった。実験の結果， 2 D-CNN， 3 D-CNN の両方でコースを概ね走破でき，また 2D-CNN が走るべきレーンレーンの中心に対してより沿って走れることが分かった。

6. 参考文献

- [1]M. Bojarski *et al.*, “End to End Learning for Self-Driving Cars,” *arXiv:1604*, pp. 1–9, 2016.
- [2]C. Chen, A. Seff, A. Kornhauser, and J. Xiao, “DeepDriving: Learning affordance for direct perception in autonomous driving,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2016, vol. 11 18-NaN-2015, pp. 2722–2730.
- [3]本吉俊之, Time-Delay CNN を用いた自動車の運転行動学習, 2016, 早稲田大学基幹理工学部表現工学科卒業論文
- [4]D. Tran, L. Bourdev, R. Fergus, L. Torresani, and M. Paluri, “Deep End2End Voxel2Voxel Prediction,” in *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2016, pp. 402–409.

