

## 1. はじめに

CNNによる一貫学習を用いた自動運転制御では、車載カメラ画像を入力とし、スロットル・ステアリング値を出力することで、自動運転を実現している [1]。一貫学習ベースの自動運転制御は、様々なシーンにおけるありとあらゆるケースの運転データを収集して学習することが重要である。しかし、このデータセットの作成には膨大な時間を要する。本研究では、目的の異なる自動運転モデルを複数設計し、選択機構によりシーンに適した自動運転モデルの選択を行う手法を提案する。

## 2. CNNを用いた自動運転制御

Bojarskiら [2] は、車載カメラ画像をCNNに入力し、ステアリングの制御を実現している。これらの学習には、人間による運転時のステアリングを教師データとして用いる。村瀬ら [1] は車載カメラ画像と車体速度をCNNに入力し、スロットルおよびステアリングの制御を実現している。しかし、データを大量に集めて学習しても、データの偏りにより対応できないシーンが存在する。

## 3. 提案手法

一貫学習ベースの自動運転制御では、様々なシーンを全て網羅するように学習する必要があるが、全てを網羅したモデルの学習は困難である。そこで、シーンごとに一貫学習による自動運転モデルを学習し、シーンに合わせて適切なモデルを用いる手法を提案する。目的の異なる自動運転モデルとして、車線追従モデルと衝突回避モデルを用意する。図1で示すように、選択機構によりシーンに合わせて適切なモデルを選択する。

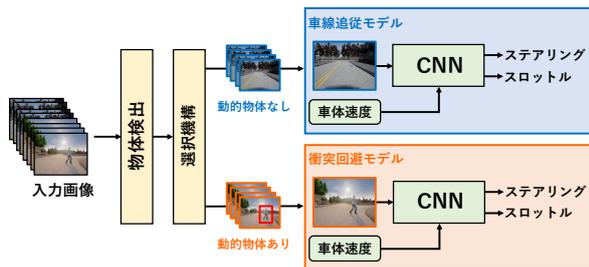


図1：提案手法の構成

### 3.1. データセットの作成

まず、動的物体が存在する環境と存在しない環境で運転データを収集する。走行環境は、自動運転用のオープンソースシミュレータであるCARLAを使用する。マップにはTown01を使用し、天候は晴れとする。

### 3.2. 車線追従モデル

車線追従モデルでは、動的物体が存在しないデータセットのみを学習データとし、車線追従を目的として学習する。ネットワークには、車載カメラ画像を畳み込み層、車体速度を中間層に入力し、スロットルおよびステアリングを出力する。実験に用いる運転データ数は、172,440フレームである。

### 3.3. 衝突回避モデル

衝突回避モデルでは、動的物体が存在するデータセットのみを学習データとする。このモデルでは、動的物体との衝突回避を目的とし、動的物体が車載映像上に存在する場面のみを用いて学習を行う。ネットワーク構造は車線追従モデルと同様である。実験に用いる運転データ数は、18,920フレームである。

### 3.4. 選択機構

選択機構では、物体検出された動的物体のバウンディングボックスの大きさにより、モデルを選択する。バウンディングボックスの大きさが閾値より低い場合は、選択機構で動的物体なしと判断し、車線追従モデルを選択する。同様

に、閾値以上の場合は動的物体ありと判断し、衝突回避モデルを選択する。

## 4. 評価実験

提案手法の有効性を示すために、自動運転シミュレータによる評価実験を行う。

### 4.1. 実験概要

選択機構ありの提案手法（車線追従モデルと衝突回避モデル）と選択機構なし（全データで学習したモデル）との比較を行う。CARLAのTown01上に動的物体である車を20台、歩行者を100人ランダムに出現させる。環境において学習モデルを実行し、衝突しそうな場合に人間が介入し、正しい操作を行う。評価指標には、式(1)の人間の介入なしで自動運転がどれだけできるかという自律性を用いる。

$$autonomy = \left(1 - \frac{interventions \cdot 6seconds}{elapsed\ time}\right) \cdot 100 \quad (1)$$

*interventions* は人間の介入回数で、*elapsed time* は走行時間 [sec.] である。自律性は、スロットルおよびステアリングに対してそれぞれ算出し、人間の介入後から自動運転制御に戻るのに必要な時間を6秒とする。試行回数は20回行い、1回の走行時間は6分とする。

### 4.2. 実験結果

図2に、選択機構なしおよび提案手法による実験結果を示す。また比較として、各モデルの評価結果を示す。図2の棒グラフは、*autonomy* の平均で、エラーバーは *autonomy* の標準偏差である。提案手法は、選択機構なしや他の各モデルと比べてスロットルの精度が最も高い。選択機構なしの場合、動的物体が存在しない状態でもブレーキを踏んでしまう場面が多い。一方、提案手法では車線追従モデルと衝突回避モデルを切り替えることにより、スムーズな走行が可能になった。車線追従モデルの場合、動的物体が存在しない環境で学習したため、歩行者や車の飛び出しに対応できず衝突してしまう。一方、提案手法では衝突回避モデルにより、歩行者や車の飛び出しに対応して停止することができる。衝突回避モデルの場合、衝突回避の場面を多く学習したモデルのため、車線追従ができず停止するため、スロットルの精度が最も低い。一方、提案手法のステアリングの精度が選択機構なしと比較し、約5%低い。これは、複数のモデルを選択する提案手法より、選択機構なしの方が学習データ数が多いためであると考えられる。

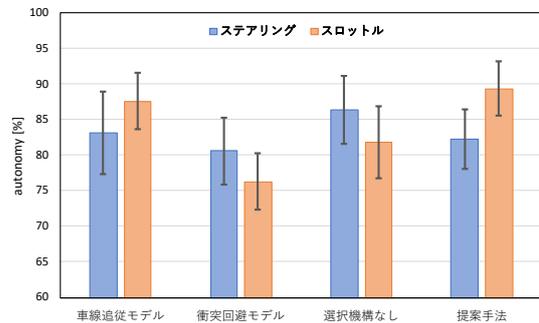


図2： *autonomy* の平均と標準偏差

## 5. おわりに

本研究では、状況に応じてモデルの切り替えを行う自動運転制御の手法を提案し、動的物体が存在する環境での制御を実現した。今後は、モデルを追加することで機能を拡充し、より状況に応じた自動運転制御を目指す。

## 参考文献

- [1] 村瀬卓也 等., “自己状態を付与したCNNによる自動運転制御の高精度化”, PRMU研究会, 2017.
- [2] M. Bojarski, et al., “End to End Learning for Self-Driving Cars”, arXiv:1604.07316, 2016.