

1. はじめに

自動運転には、多種多様なシーンに合わせた車体制御が必要となる。例えば、歩行者が道路脇を歩行している場合や渋滞の際には、ゆっくりとした走行が要求される。これらのシーンにおいて、走行速度を切り替える必要がある。従来の自動運転手法 [1][2] は、ステアリングやスロットルの制御を CNN を用いて実現しているが、このような走行速度の切り替えができない。本研究では、CNN を用いた自動運転制御において、走行速度を運転モードとして切り替えるために、安全度を導入する。これにより、走行速度の調整が可能な自動運転制御を実現する。

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、ステアリングを制御する手法を提案し、実車走行を実現した。CNN の学習には、教師データとして実際に人が走行した際のステアリング角度を用いている。村瀬ら [1] は、車載カメラ画像に加えて車体速度情報を入力することで、ステアリング及びスロットルの制御を実現した。

3. 提案手法

従来手法では、自動運転に対する運転モードの切り替えという概念が存在しない。そこで、本研究では、走行状況に合わせて運転モードを切り替えることが可能な CNN を提案する。運転モードを切り替えるための指標として安全度を定義する。安全度は、運転スキルの異なる複数のドライバの運転データから算出する。安全度を CNN の学習に用いることで運転モードの切り替えを行う。

3.1. 安全度の算出方法

安全度 S_i は、ドライバ i の運転の荒さとアクセル開度の関係から算出する。そのため、ドライバ i の運転データから速度の分散 V_i とアクセルの平均値 \bar{a}_i を算出し、乗算することでドライバ i の運転の荒さを示す安全度 P_i を求める。速度の分散は運転の荒さであり、アクセルの平均は走行速度の速さを示している。分散と平均値の両方が高い場合に P_i が高い値となり、荒い運転となる。同様に、 N 人分のドライバの運転データから安全度 P_i を算出し、すべてのドライバに対する安全度ベクトル $P = \{P_1, P_2, \dots, P_N\}$ を求める。ドライバ i の安全度 S_i は、式 (1) のように求める。ここで、安全度ベクトル P の最小値 P_{min} と最大値 P_{max} を用いることで、安全度を $[0, 1]$ に正規化する。

$$\text{安全度 } S_i = 1 - \left(\frac{P_i - P_{min}}{P_{max} - P_{min}} \right) \quad (1)$$

3.2. ネットワークの学習

学習システムを図 1 に示す。画像を CNN に入力し、ステアリング及びスロットルを出力する。加えて、車体速度及び安全度を全結合層 3 層目に入力する。CNN から出力されたステアリング及びスロットルと教師データのステアリング及びスロットルから誤差を算出し、逆伝播する。安全度を導入することで、ドライバによる走行の違いを学習でき、運転モードの切り替えを可能にする。




図 1: 学習システム

4. 評価実験

提案手法の有効性を示すためにシミュレータ環境にて評価実験を行う。

4.1. 実験環境

評価実験には、オープンソースシミュレータである CARLA を用いる。CARLA から車載カメラ画像、車体速度、ステアリング及びアクセル、ブレーキの数値等を取得する。学習には、11 人の運転データを使用し、1 人につき 20,000 フレームの合計 220,000 フレームを収集した。評価時は、特定のコースを学習した CNN に走行させる。評価指標には、次式のどれだけ人間の介入なしに自動運転できるかという自律性を用いる。

$$\text{autonomy}_c = \left(1 - \frac{(\text{interventions}_c \cdot 6 \text{seconds})}{\text{elapsed time}} \right) \cdot 100 \quad (2)$$

interventions は人間の介入回数で、 elapsed time は走行時間 [sec.] である。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 秒とし、人間の介入回数に 6 を乗算する。自律性は、ステアリング及びスロットルに対してそれぞれ算出する。すなわち、車線をはみ出した場合にステアリングに介入し、先行車に衝突しそうな場合や赤信号を無視しそうな場合にスロットルに介入する。6 分間の走行中における介入回数をカウントし、5 回の試行の平均を算出する。


4.2. 評価結果

従来法（安全度なし）及び提案手法による結果を表 1 に示す。従来法は、低い自律性となった。これは、1 つのシーンに対して複数ドライバの運転パリエーションが多くなり、学習が困難になっていることが原因である。一方、提案手法は、従来法と比べ精度が向上し、ステアリング及びスロットルの制御ができ、高い自律性能を持つことがわかる。また、安全度が 1.0 に近いほど自律性が高く、安全度が低いと運転が荒くなるため自律性が下がっている。

表 1: ステアリング及びスロットルの精度 [%]

	安全度	ステアリング	スロットル
従来法 [1]		22.2	89.7
提案手法	1.0	97.0	96.0
	0.5	95.5	92.7
	0.0	93.0	88.7

安全度 0.0 から 1.0 まで 0.1 ごとに直線の道路及びカーブを走行し、それぞれの全結合層 3 層目の特徴ベクトルを t-SNE により可視化した結果を図 2 に示す。直線及びカーブの走行共に安全度が高い場合と低い場合で分布が分かれている。そのため、安全度による連続的な制御が可能であるといえる。



(a) 直線走行時 (b) カーブ走行時

図 2: t-SNE の可視化結果

5. おわりに

本研究では、安全度による運転モードの切り替えを行う手法を提案した。今後は、様々な環境変化における走行シーンの自動運転制御を実現する。

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:1604.07316v1, 2016.