

Deep Learning を用いたドライバーの注視対象物の評価

池田 光汰[†] 猿田 和樹[‡] 寺田 裕樹[‡] 張 興国[‡] 陳 国躍[‡]

秋田県立大学大学院 システム科学技術研究科[†] 秋田県立大学 システム科学技術学部[‡]

1. はじめに

交通事故の発生要因のうち半数以上が前方不注意などドライバーの認知ミスである[1]。したがって、交通事故の予防のために、運転者の認知能力向上を目的とした運転者教育システムの研究が行われている。

須藤らはドライバーに車載カメラ映像を提示し、歩行者を発見した領域をタッチすることで認知時間を計測する運転者教育システムを開発した[2]。実験により、歩行者に対する認知時間の短縮効果が確認されている。また、岡らは映像を提示した際の注視行動の違いに着目し、注視行動レベル判定手法を提案、その有効性を検証した[3]。しかし、岡らの研究では注視行動を分析対象としており、ドライバーが何を注視しているのかについては明らかにしていない。

ドライバーが、何をどの程度注視するのか把握することができれば、何を見て何を見逃したかなど、注視対象物と注視の度合いを訓練後にフィードバックした教育ができる。これにより認知ミスの予防など、効果的な訓練が実施可能であると考えられる。本研究では一般道走行時のドライバーの注視対象物を画像認識により判定し、運転時に何を注視するのか評価する。

2. 注視対象物の認識処理概要

本研究では、一般道走行時の映像とドライバーの視線データを用いて、注視対象物を認識する。注視対象物の認識を行う大まかな流れを以下に示す。

- ①視線計測器を装着し一般道を運転
- ②運転時の映像および視線データを取得
- ③Deep Learning を用いて映像内に写る物体を認識
- ④視線座標と認識した物体の位置から注視対象物を判定

注視対象物の認識例を図1に示す。

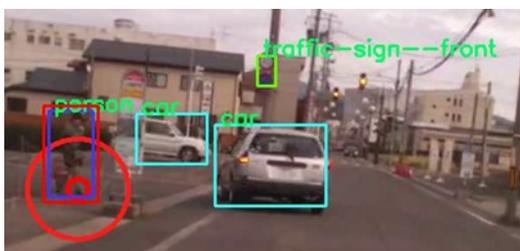


図1 注視対象物の認識例

Evaluation of Driver's Gaze Target using Deep Learning

[†]Kota Ikeda

Graduate School of Systems Science and Technology, Akita Prefectural University

[‡]Kazuki Saruta, Yuki Terata, Xingguo Zhang, Guoyue Chen

Faculty of Systems Science and Technology, Akita Prefectural University

映像内に写る物体の認識には Faster R-CNN[4]を用いる。Faster R-CNN は物体候補領域の抽出からクラス分類にかけて End-to-End で学習を行うことで既存の CNN ベースの手法を上回る検出精度を示している。

Faster R-CNN による物体検出の手順は以下のようなになる。初めに畳み込み層により入力画像から特徴マップを抽出。次に抽出した特徴マップから RPN(Region Proposal Network)により物体候補領域を抽出。最後に抽出した物体候補領域毎に特徴マップの情報を用いてクラス分類を行う。

また本研究ではグラス型視線計測器を用いて運転時の映像および視線座標を記録する。視線計測器の仕様を表1に示す。

表1 グラス型視線計測器の仕様

使用機器	Tobii Pro Glasses 2
映像サイズ	1,920×1,080pixel
フレームレート	25fps
撮影可能視野角	水平 82° 垂直 52°
視線座標サンプリングレート	50Hz

3. ドライバーの注視対象物の評価実験

ドライバーの注視対象物の評価実験について示す。評価実験では、運転映像と視線データから注視対象物を認識し、ドライバー間・道路環境別に比較する。実験には、被験者5名(A~E:運転経験3年以下)が一般道の4区間(狭い道・広い道等)を走行した際の運転映像および視線データを用いる。ただし運転時の注視条件を以下のように定義する。

- ・視線の停留領域
あるフレームでの視線座標を中心とした半径 50pixel の円内に、3フレーム以上連続で視線座標が停留した場合に、半径 50pixel の円を停留領域とする。
- ・物体の注視条件
上記で定義した停留領域内に Faster R-CNN で認識した物体が 3 フレーム以上連続で停留した場合、注視対象物とする。
また実験での走行区間概要を表2に示す。

表2 走行区間概要

	道路環境	交通量
区間1	片側1車線(直線)	少
区間2	中央線の無い細道(カーブ:多)	多
区間3	中央線の無い細道(直線)	中
区間4	片側2車線(直線)	中

4. 結果

ドライバー間の注視対象物の比較結果を表 3 に示す. 表 3 では運転映像内で注視対象物として認識した物体の内訳を示している. 例えば, 表 3(a)・区間 1 の被験者 E は 6 台の自動車に注視していることを示している. また表 3 の色付き欄は, 注視対象物として誤認識したことを示している. 色付き欄内の括弧内の数字は誤認識した物体数を示している. 区間 1・被験者 E の看板を例に説明すると, 実際には看板を注視していないが, 1 枚を注視対象物として誤認識したことを示している.

表 3 の認識結果から, いずれの被験者においても自動車を最も注視していることが確認できる. 一方で, いずれの被験者も信号機に対しては, ほとんど注視していなかったことが確認できる.

また信号機を注視している回数が少ない理由として, 前述したように先行車両に注意を向けている傾向があり, 先行車両に追従する形で, 発進・停止を行うことができると考えられる. そのため信号機に対して注視する回数が少ないのではないかと考えられる. さらに先行車両が存在しない場合では, ドライバーは周辺視野で信号機の色を確認することも可能であると考えられる.

区間別に注視対象物を比較すると, 区間 2・3 のように細い道路では, 対向車両や路肩の駐停車両とすれ違う際に, 周辺車両を多く注視していることが確認できた. さらに区間 4・片側 2 車線の広い道路では, 車線変更時に周辺車両を多く注視していることが確認できた. これらのことから認知負荷が高まる場面では, 周辺車両への注意が高まる傾向にあると考えられる.

次に被験者 C が区間 3 を運転していた際の注視対象物数と注視回数を表 4 に示す. 被験者 C は 4 台の自動車を 54 回注視し, 5 人の人を 11 回注視している. このことから自動車に対してより注意を向けていることが確認できる. この傾向は全被験者で確認されている. よって先行車両や対向車両・侵入車両など移動している物体により多く注意を向ける傾向があることがわかる.

5. まとめ

本研究では Deep Learning を用いてドライバーの注視対象物を認識する仕組みを構築し, 運転時の注視対象物をドライバー間・道路環境別に比較した. ドライバーは移動している物体へ注意が高まる傾向にあり, 認知負荷が高まる際には周辺車両へも注意が高まる傾向にあると考えられる.

また本研究では運転歴の短い若年者を被験者として, 注視対象物の比較を行った. そこで今後は運転歴の長いドライバーや高齢者に対しても同様の実験を行い, 注視対象物の比較を行う予定である.

表 3 ドライバー間の注視対象物の比較

(a) 区間 1 の注視対象物

	被験者 A	被験者 B	被験者 C	被験者 D	被験者 E
自動車	4	4	9	5	6
人	0	1	1	1	1
信号機	1	0	0	0	0
標識	1	0	1	1	1
看板	0	0	1	0	0(1)
二輪車	0	1	0	0	0

(b) 区間 2 の注視対象物

	被験者 A	被験者 B	被験者 C	被験者 D	被験者 E
自動車	13	19	18	18	19
人	1	2	0(1)	0(1)	0
信号機	0	0	0	0	0
標識	1	1	1	1(1)	0
看板	0	2	1	0	3
二輪車	0	1	0	0(1)	0

(c) 区間 3 の注視対象物

	被験者 A	被験者 B	被験者 C	被験者 D	被験者 E
自動車	9	7	4	6	7
人	1	1	5	0(1)	1
信号機	0	0	0	0	0
標識	1	0	2	0	0(1)
看板	2	2	1	1	2
二輪車	0	0	0	1	0

(d) 区間 4 の注視対象物

	被験者 A	被験者 B	被験者 C	被験者 D	被験者 E
自動車	1	7	5	1	6
人	0	2	1	0	0
信号機	0	0	0	0	0
標識	0	0(1)	1(1)	0	0(2)
看板	0	0	2	0	2
二輪車	0	0	0	0	0

表 4 注視対象物数と注視回数の比較例

	注視対象物数	注視回数
自動車	4	54
人	5	11
信号機	0	0
標識	2	2
看板	1	2
二輪車	0	0

謝辞

本研究は JSPS 科研費 15K01081 の助成を受けたものである.

参考文献

[1] 交通事故弁護士ナビ: “交通事故の要因”, (<https://jico-pro.com/columns/116/>)
 [2] 須藤ほか: “タブレット PC を用いた運転者教育システムの開発と評価”, 第 13 回情報科学技術フォーラム講演論文集第 3 冊分, pp. 49-54 (2014)
 [3] 岡ほか: “運転者教育のための注視行動レベル判定手法”, 2017 年電子情報通信学会総合大会講演論文集, H-2-29, p. 247 (2017)
 [4] S. Ren, K. He, R. Girshick, J. Sun: “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, Advances in Neural Information Processing System (NIPS), pp. 1-9 (2015)