

# フォーミュラ 1 におけるドライバー特定のための 車体ナンバー認識

後藤 知也<sup>†</sup> 中島 克人<sup>‡</sup>

東京電機大学<sup>‡</sup>

## 1 はじめに

フォーミュラ 1(以下 F1)をはじめとするモータースポーツ競技では、競技時間が約 2 時間程度と長い為、ハイライト映像には大きな需要がある[1]。そこで我々は、特定のチームやドライバー(選手)に注目した F1 放送映像等からのハイライト映像の制作支援システムを目指している。今回我々は、深層学習に基づく物体検出器による車両検出と、数字認識モデルでの車体ナンバー(図 1)認識を組み合わせた、選手特定のための手法を提案し、評価したので報告する。



図 1 ドライバーナンバーの例

## 2 関連研究

### 2.1 YOLOv5[2]

深層学習ベースの物体検出器の中で、精度と速度が現在最も優れるとされるものの 1 つに YOLOv5 がある。YOLOv5 には速度と精度のバランスの異なる x, l, m, s の 4 つのモデルがあるが今回はオフラインでのハイライト映像制作を目的としているため、最も精度のいい YOLOv5x を採用する。

### 2.2 The Street View House Numbers (SVHN) Dataset[3]

SVHN は、Google Street View の画像の中からハウスマンバーを集めた公開データセットである。このデータセットは、異なる色、形状、および欠陥(傷、欠け等)を持つ様々な数字を含み、Nakamura ら[4] が示した通り、今回の車体ナンバーのようなデフォルメされ、かつ、モーションブラーのある数字の認識モデル作成に有用であると考えられる。

## 3 提案手法

### 3.1 2 段階の車体ナンバー認識

選手ごとに予め割り当てられている車体ナン

Car Number Recognition for Driver Identification in Formula1

<sup>†</sup> Kazuya Goto · Tokyo Denki University

<sup>‡</sup> Katsuto Nkajima · Tokyo Denki University

バー認識を実現するためには、まず確実に車両検出を行う必要があるため、図 2 のような車両検出と車体ナンバー認識の 2 段階の手法によるシステムとした。

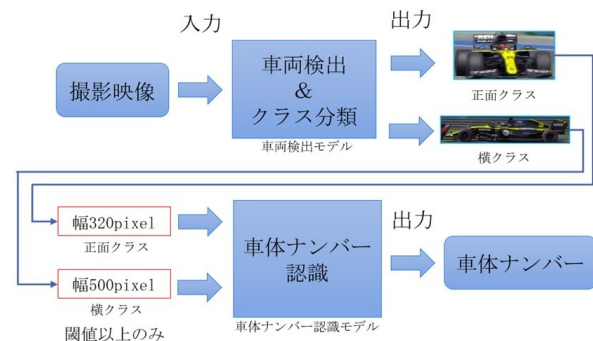


図 2 車体ナンバー認識の全体図

### 3.2 車両検出モデル

車体ナンバー認識のためには、車体の番号が表記されている正面や横を向いている車両を検出しなければならない。そのため車両検出のクラスを「正面」(図 3a)「横」(図 3b)「その他」に分けた 3 クラスの車両検出モデルを作成した。



(a)正面クラス

(b)横クラス

図 3 クラスの例

### 3.3 車体ナンバー認識モデル

F1 の車体ナンバーのデータセットは見当たらず作成には時間と手間がかかるため、本研究では公開データセットである SVHN の全データ約 63 万枚を用いて車体ナンバー認識モデルを作成した。前段の車両検出モデルは車両追跡にも使用する事から、検出車両の大きさは車体ナンバーの視認が困難な小さなものも含む。そのため、車体ナンバー認識モデルに入力する検出結果の車両画像のサイズに閾値を設けた。予備実験の結果、正面クラスでは横幅 320 ピクセル以上、横クラスでは横幅 500 ピクセル以上とした。

## 4 実験と結果

### 4.1 車両検出モデルの学習

独自に撮影映像[1]から切り出して作成した車両画像データセットで YOLOv5x の学習を行った。データセットはシーン画像 586 枚から正面クラス 612 枚, 横クラス 482 枚, その他クラス 692 枚からなる。F1 放送映像特有の照度の変化やモーションブラー対応するべく, 輝度を±30%の間でランダムに変動させ, 加えて最大3ピクセルのブラーを施した。更に左右での見え方に対応するため水平反転も施した。最終的に学習データは計 5,358 枚である。学習時のハイパーパラメータはデフォルトから表1に変更した。

表1 学習ハイパーパラメータ

入力サイズ(pixel)	640×640
エポック数	500
バッチサイズ	16
学習率	0.01

### 4.2 車両検出の精度

クラスごとの適合率と再現率に関して, 学習後の車両検出モデルをテストデータ 84 枚によって評価した。表2のように3つのクラスとも適合率と再現率が高く, 車体ナンバー認識を行う前段として十分な性能であった。

表2 車両検出における各クラスの精度(%)

クラス	適合率	再現率
正面	100.00	94.55
横	81.25	92.86
その他	98.46	95.52

### 4.3 車体ナンバー認識モデルの学習

認識モデルは全データ約 63 万枚を用いて YOLOv5x の追加学習で作成した。ハイパーパラメータはデフォルトから表1に変更した。

### 4.4 車体ナンバー認識の精度

正面クラスでは表3のA・B・Cの3項目, 横クラスではA・Bの2通りで評価を行った。評価用データとして, 作成した車両検出モデルから出力された異なるチーム, 異なる試合の車両画像 30 枚を用いた。条件Cの台形変換は正面クラスで認識すべき傾きのある数字データが SVHN には含まれないため, 車体ナンバーを正立させることによって認識精度向上を図るものである。

認識精度は, 正面クラスでは条件A・Bともに0%, Cでは93%であった。横クラスでは条件Aで0%, 条件Bで97%となった。図4に正面クラス条件Cにおける認識結果と横クラス条件Bにおける認識結果の例を示す。

表3 車体ナンバー認識の評価項目

条件	内容
A	車両検出から得た検出矩形そのまま
B	A+認識範囲の限定
C	B+台形変換

	正面クラス			横クラス		
入力						
真値	44	5	18	77	3	11
出力	44	5	19	77	3	11

図4 車両ナンバーの認識結果

## 5 考察

車両検出では, 各クラスでの車両検出の精度は良好であり, データ増強により他のレースでも同様の検出精度が期待できるであろう。車体ナンバー認識では, 検出範囲の限定に加え, 正面クラスでは台形変換の必要もあるものの, SVHN をデータセットとして用いた車体ナンバー認識モデルは有効であった。手間はかかるが, 学習データとして SVHN に車体ナンバーの画像を追加することにより, 更なる精度向上が見込めよう。

## 6 まとめ

今回はレース中のドライバー特定を目的とし, 車両検出と車体ナンバー認識の2段階の手法を提案し評価した。ただし, 条件Bの認識範囲は手動で限定をしたため, これの自動化が必要である。また, 車体ナンバー認識は小さく映る車両や正面でも真横でもない車両の映像からは車体ナンバー認識は不可能であるため, レース全体での選手特定は実現できない。従って, 車両の追跡や映像シーン切り替え時の高度な車両同定が必要である。そのためには, 色特徴量等によるチームの判別だけでなく, レースの進行に伴う順位変動なども考慮した手法を検討する必要がある。

## 参考文献・引用

- [1] “2020 Austrian Grand Prix : Race Highlights” by <https://www.youtube.com/watch?v=1Q470aUwi3E>”
- [2] “YOLOv5,” 2020. [Online]. Available : <https://github.com/ultralytics/yolov5>.
- [3] Y.Netzer, et al., “Reading digits in natural images with unsuper-vised feature learning,” In NIPS 2011.
- [4] T.Nakamura, et al., “Who Is Your Favourite Player? Specific Player Tracking in Soccer Broadcast,” In VISAPP 2020.