

H-027

速度規制標識の検出に対する機械学習に用いる特徴量の検討

A study on the image features available for machine learning to detect the speed limit signs

岡 兼治†
Kenji Oka宮田繁春‡
Shigeharu Miyata

1. はじめに

日常生活において、自動車は欠かせないものとなっている。一方で、交通事故への対策などの課題がある。交通事故の件数は、ピーク時に比べると減少しているが、今でも多く発生している。交通事故の発生時刻は昼(日の出から日没)が約 73%を占めており、その原因のひとつとして速度の出し過ぎが挙げられる。速度の出し過ぎは、危険の発見が遅れたり、自動車の制御が難しくなったりするなど交通事故の大きな原因の一つとなっている。速度が速いほど、ブレーキを踏んでから止まるまでの時間が多くかかるため交通事故の衝撃が大きくなり、重大交通事故に繋がることが多い。このような状況から、自動車の自動運転や様々な運転支援に注目が集まっている。その際、道路標識を自動で認識することが試みられている。

本研究では、以上のことを踏まえ、昼の時間帯の速度規制標識を自動検出する方法について検討した。標識の検出・認識における先行研究例としては、SIFT 特徴量^[1]、テンプレートマッチング^[2]、ニューラルネットワーク^[3]など様々な手法が提案されている。近年、機械学習による検出や認識が採用されており、それに利用する特徴量も様々である。本報告では、速度規制標識の検出において機械学習法を用いた場合、代表的な Haar-like 特徴量、HOG 特徴量、LBP 特徴量を学習に利用した検出結果を比較して、速度規制標識の検出にどの特徴量を導入するのが適当であるかについて検討を行う。比較項目として、検出率、正検出率、誤検出率、誤検出している物体の分析、学習時間、学習の際の正解画像の数、不正解画像の数、正解画像に使う画像の解像度を採用する。

2. 標識検出

標識検出では、認識したい道路標識の画像(正解画像)と道路標識以外の画像(不正解画像)を多数用意し、その特徴量を機械学習させ、作成した識別器を用いて標識検出を行う。画像の特徴量として、Haar-like 特徴量、HOG 特徴量、LBP 特徴量を用いた。

2.1 検出手法

まず、標識が写った画像(正解画像)を 200 枚用意し、学習をする際に必要となる画像の特徴量ファイルを作成し、それに基づいて機械学習を行い、Adaboost 識別器を作成する。図 1 と図 2 は正解画像と不正解画像の一例である。



Fig.1 The images which include the speed limit signs.




Fig.2 The images which do not include the speed limit signs.

標識の検出は Adaboost 識別器を用いて行った。図 3 は検出結果の一例で、速度規制標識のみ検出している(正検出)結果と速度規制標識以外も検出している(誤検出)結果の一例である。




Fig.3 Examples of positive detection cases and mistaken-detection cases.

2.2 検出率の向上

3 つの特徴量において、不正解画像を 1000 枚で正解画像の枚数を 50 枚, 100 枚, 150 枚, 200 枚と増やしていった場合の検出率を表 1 に示す。

$$\text{検出率} = (\text{速度規制標識を検出した枚数} / \text{全枚数}) \times 100[\%]$$

Table.1 A detection rate each number of positive image for three features.

Number of positive image	Detection rate [%]		
	Haar-like	HOG	LBP
50	68.1	85.3	34.0
100	94.8	92.7	79.6
150	96.3	93.7	93.7
200	97.4	95.7	93.7

表 1 より 3 つの特徴量において、正解画像の枚数を増やすことで検出率が向上していることが分かる。検出率が向上

† 近畿大学大学院システム工学研究科, Graduate School of System Engineering, Kinki University

‡ 近畿大学工学部, Kinki University

したのは正解画像の枚数を増やすことにより様々なパターンを学習することができたからであると考えられる。

2.3 誤検出率の軽減

誤検出率を軽減させるために、不正解画像を100枚から7000枚まで変えてみた。不正解画像の枚数の違いによる誤検出率を表2に示す。

$$\text{誤検出率} = (\text{速度規制標識以外も検出した枚数} / \text{速度規制標識を検出した枚数}) \times 100[\%]$$

Table.2 A mistaken-detection rate each number of negative image for three features.

Number of negative image	Mistaken-detection rate [%]		
	Haar-like	HOG	LBP
100	100.0	11.8	100.0
500	38.9	4.3	40.2
1000	16.1	4.3	0
3000	10.7	6.0	0
5000	5.3	4.3	4.3
7000	15.2		

表2より Haar-like 特徴量においては5000枚までは誤検出率を軽減がすることができたが、7000枚になると誤検出率が上がっている。過学習もしくは学習がうまくできていないと考えられる。HOG 特徴量においては不正解画像を増やした時、500枚より増やしても誤検出率の軽減が見られなかった。LBP 特徴量においては1000枚、3000枚で誤検出率が0[%]であったが、5000枚で誤検出率がわずかに上がっている。この場合、過学習もしくは学習がうまくできていないと考えられる。不正解画像の枚数を増やすことで誤検出率を軽減することができた。しかし、特徴量によって必要な不正解画像の枚数が異なること、不正解画像の枚数を増やしていった時に誤検出率が上がってしまう可能性があることを確認した。

2.4 正解画像に使う画像の解像度

学習時間の短縮のために正解画像の解像度を低くするとどうなるのかの検討を行った。解像度を低くしていった場合、検出率が下がり誤検出率が上がった。したがって、解像度を低くするとデメリットのほうが多いことが分かる。

2.5 Haar-like, HOG, LBP 特徴量ごとの検出結果比較

3つの特徴量においてどのようなものを誤検出しているのかの検討を行った。Haar-like 特徴量を用いた場合の誤検出例としては、タイヤ、駐車禁止の標識、追い越し禁止の標識、看板の一部(丸に近い数字など)、丸まっている電線、道路の一部、車のボディ、木などがある。Haar-like 特徴量は輝度の差をとっているため、速度規制標識とは明らかに違うように見える道路の一部、車のボディ、木などの検出が見られる。HOG 特徴量を用いた場合の誤検出例としては、タイヤ、駐車禁止の標識、追い越し禁止の標識、看板の一部(丸に近い数字など)などがある。HOG 特徴量はエッジに着目しているため、速度規制標識に似た円形のものを誤検出している。しかし、

エッジに着目しているため Haar-like 特徴量を用いた場合に誤検出している道路の一部、車のボディ、木などの検出はなかった。LBP 特徴量においては追い越し禁止標識を誤検出している場合があった。Haar-like 特徴量は顔のような立体的で輝度に差がある場合には良いが、速度規制標識のような平面の場合には向いていないことが分かる。HOG 特徴量は人物のように輪郭が複雑な場合には特徴をうまく捉えることができるが、速度規制標識のように輪郭が複雑でない場合には、画像の中に速度規制標識としての特徴量と似た特徴量が多く存在しやすいため標識のみうまく捉えることができていない。以上のことから特徴量ごとに誤検出しているものの種類に差が生まれたと考えられる。

表2において各特徴量に対する誤検出率が最初に最小になった時、特徴量ごとの検出率、誤検出率、学習時間に対する比較を表3に示す。

Table.3 Three items, a detection rate, a mistaken detection rate, and a learning time, are compared for three features when the mistaken-detection rate shown in Table.2 achieved a minimum for the first time.

Features	Detection rate [%]	Mistaken-detection rate [%]	Learning time [hours]
Haar-like	98.4	5.3	192
HOG	96.3	4.3	16
LBP	93.7	0	6

表3より学習時間が短くて検出精度が良いのは HOG 特徴量と LBP 特徴量であることが分かる。しかし、誤検出した種類の数は HOG 特徴量の方が多い。従って、速度規制標識の特徴量をベストな状態で捉えることができていないのは、LBP 特徴量であり、3つの特徴量の中では LBP 特徴量を利用した機械学習がより適していると考えられる。

3. まとめと今後の課題

本研究は速度規制標識の検出法として機械学習法を用い、特徴量には Haar-like 特徴量、HOG 特徴量、LBP 特徴量を用いた。それぞれの検出結果を比較し、速度規制標識の検出にどの特徴量を導入するのが適当であるかについて検討を行った。その際、正解画像の枚数、不正解画像の枚数、正解画像に使う画像の解像度の検討も行った。それぞれの検出結果を比較した結果、学習に用いる正解画像の枚数と不正解画像の枚数を増やす場合の学習時間が長くなることを考え、LBP 特徴量を導入することが現時点では最良である。今後の課題としては、検出率や誤検出率の更なる改善と標識検出後の数字認識までを行っていく予定である。

参考文献

- [1] 高木雅成, 藤吉弘亘, “SHIFT 特徴量を用いた交通道路標識認識”, 電気学会誌 C, Vol. 129, pp. 824-831, (2009).
- [2] 清水聡一, 金森飛匡, 味岡義明, 難波知康, 新井正敏, 天野英晴, 今野大輔, “レーベンシュタイン距離を用いたテンプレートマッチングアルゴリズムの FPGA 実装”, 電子情報通信学会技術研究報告, pp. 7-12, (2007).
- [3] 朝倉俊行, 青柳裕治, “ニューラルネットワークを用いた速度規制標識の画像認識”, 日本機械学会論文集, pp. 206-212, (1995).