

車載カメラ映像における周辺車両および道路空間の特徴を用いた 堆雪による道路の狭窄状況の分類に関する研究

A Study on a Method for Classifying Road Narrowing Condition Based on Features of
Vehicles and Road Environments Using In-vehicle Camera Videos

北海道大学 工学部 ○学生員 木下洋輝 (Hiroki Kinoshita)
北海道大学大学院工学院 学生員 八木雅大 (Masahiro Yagi)
北海道大学大学院工学研究院 正員 高橋 翔 (Sho Takahashi)
北海道大学大学院工学研究院 正員 萩原 亨 (Toru Hagiwara)

1. はじめに

北海道のような積雪寒冷地では、円滑な道路交通を確保するため冬期に除排雪作業が行われている。除雪作業は降雪の都度、除雪出動基準に従って実施されているが、その際に路肩に堆雪が発生する。路肩の堆雪による有効車道幅員の減少の影響で都市機能や、道路交通サービスの低下、深刻な交通事故の誘発、交通渋滞が引き起こされる。現在、除雪出動基準は、道路管理者による目視点検を基準に行われており、札幌では道路ネットワークが密になることで、点検すべき道路が多くなり、多大な時間と人員を必要としている。一方で、北海道の年間除雪費は増加傾向にあるのに対して、除排雪従事者は高齢化の影響により年々減少している背景がある¹⁾。したがって、積雪寒冷地における道路管理の除雪作業は今後さらなる効率化が必要となっている。

道路管理の効率化を実現するために、効率的な道路情報収集に関する様々な研究が行われている²⁾。例として冬期道路の有効幅員の計測技術があり、レーザースキャナを用いて、定量的な計測が実現可能である。しかしながら、この手法では、レーザースキャナ等の特殊な器具を搭載した専用車両を必要とし、専用車が走行できる限定的な区間での計測を可能にするものであるため、高効率な道路有効幅員の収集を実現していない。

また、道路状況の収集の高効率化が取り組まれている中、車載カメラを用いた情報収集は道路管理のコスト低減に貢献することが、期待されている。加えて、近年事故の記録や煽り運転の抑制等で車載カメラが普及している。車載カメラでの情報収集は専用車両を必要としない容易な手段となりつつある。したがって、車載カメラ映像を用いた情報収集は、効率的な道路情報の収集方法に発展することが期待できる。

本研究では、車載カメラを用いた道路有効幅員（以降、狭窄状況）の推定の手法を提案する。車載カメラ映像を用いた狭窄状況の分類は、特殊な専用車両を用意する必要がなく、一般に路上を走行している車両が将来に道路状況の把握に貢献可能となることが期待できる。

文献³⁾では道路が撮像された画像を階層的に3クラス分類することで道路の狭窄状況を Level1, The others に推定することの有効性が示されている。また車載映像を基に Level2, Level3 を分類することの有効性が示されて

いる。文献³⁾では道路空間の特徴に基づいて狭窄状況を階層的に推定することの有効性が示されている。しかしながら、浅い層で誤った分類を行った場合、それ以降の階層で正しく分類する機構については検討されていない。加えて、道路空間の特徴に焦点を当てているため、車両や歩行者などの道路構造物や道路付属物などの特徴算出の対象以外の物体が映像に撮像される場合、分類精度が低下する可能性がある。

本研究では、車載カメラを用いた道路有効幅員の推定の手法を提案する。具体的には、道路空間の特徴量および、映像に写る他車両から得られる特徴を考慮して狭窄状況の分類を行うことで、分類精度の向上を試みる。また PCA⁷⁾による次元削減をおこなうことで精度の向上を目指す。

以降本稿では、2で車載カメラ映像を用いた狭窄状況の分類方法について説明する。3では、実際に、2で説明した提案手法による実験を行い、その有効性を確認する。

2. 狭窄状況の分類

本章では、狭窄状況の分類について説明する。提案手法の概要を図-1に示す。提案手法では、車載映像から得られる特徴量に基づいた狭窄状況の分類手法の説明を行う。ここで、表1のような狭窄状況に応じた道路の有効幅員を Level1, Level2, Level3 の3つのクラスで定義する。これらのクラスは、札幌市の除雪の出動基準に基づいて定義している。本稿では、各段階の特徴量抽出方法について説明した後、特徴量に次元削減を行う過程を説明する。最後に、得られた特徴量から狭窄状況を分類する識別方法について説明する。

2.1 特徴ベクトルの算出

本節では、入力映像からの狭窄状況の分類に用いる特徴量について説明する。2.1.1, 2.1.2 では道路空間に着目した特徴量について説明し、2.1.3 では他車両に着目した特徴量について説明する。2.1.4 では、各映像に対しての特徴ベクトルの算出方法について説明する。

表-1 クラスの定義

	クラスの定義
Level1	道路有効幅員が4車線
Level2	道路有効幅員が3車線. 直進車両が右折車を回避できる
Level3	道路有効幅員が2車線. 直進車両が右折車を回避できない

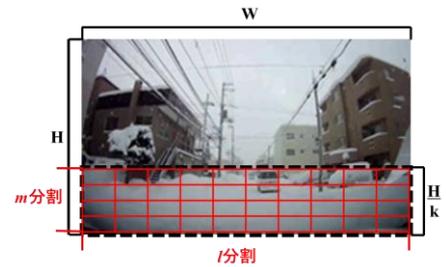


図-2 パッチの分け方

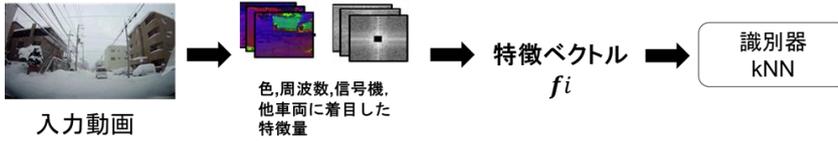


図-1 提案手法の概要

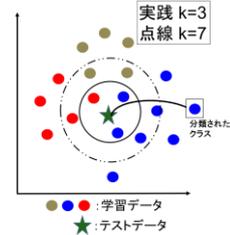


図-3 kNN のイメージ図

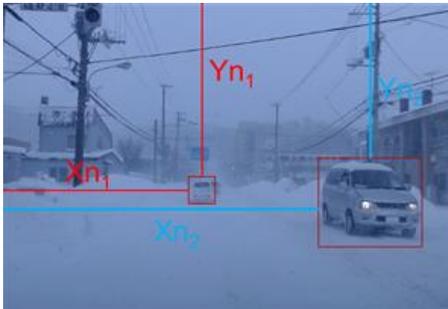


図-4 YOLOv3 を用いた他車両の位置推定

2.1.1 道路空間⁴⁾に着目した特徴量

まず、色とパワースペクトルに着目した特徴量抽出について説明する。提案手法では、ピクセル数が $W \times H$ の映像が入力された場合、図-2 のように縦方向に k 分割し、路面に注目した領域 $W \times H/k$ を抽出する。抽出した領域をさらに縦方向に l 、横方向に m 分割し、 $l \times m$ 個のパッチを得る。各々のパッチに対して、パワースペクトル、色に着目した特徴量で構成される特徴ベクトル f_i^{first} を算出する。ここで、 $i(i=0,1,2,3,\dots,I:I)$ は入力映像の総数は各入力画像である。さらに、取得したパッチを HSV 空間に変換し、各パッチに対して色相と彩度のヒストグラムを算出し、特徴ベクトル f_i^{color} を抽出する。道路が狭窄するとき、路面上の積雪や路肩の堆雪によって路面が雪で覆われる。一方、狭窄が進んでいない路面では、堆雪は少なく、アスファルトが露出している場合もある。そのため映像の色に着目することは有効であると考えられる。

次に取得したパッチごとに画像のパワースペクトルに着目した特徴ベクトル f_i^{ps} を算出する。入力された画像にガボールフィルタを適用することにより、画像の輝度勾配を抽出し、映像のエッジを検出することができる。道路が狭窄すると、堆雪や積雪により、エッジが少なくなるためエッジの検出と狭窄状況には関連性があると考えられる。

特徴ベクトル f_i^{color} , f_i^{ps} と f_i^{first} の関係性は式(1)で示さ

れる

$$f_i^{first} = \{ f_i^{color}, f_i^{ps} \} \quad (1)$$

2.1.2 道路構造物に基づいた特徴量⁴⁾

道路の路肩に堆雪があり、道路が狭窄されていても道路構造物の位置に変化はないが、車両の走行位置は限定される。つまり、道路構造物と車両の位置関係を取得することで、道路の狭窄状況の分類が可能であると考えられる。そこで、提案手法では、信号機に着目した特徴量を抽出する。特徴量は映像内の信号機の座標が学習済深層モデルの YOLOv3⁴⁾ を用いて算出される。YOLOv3 による物体検出では、映像内に含まれる物体の種類と位置の算出が可能になっている。車載カメラ映像に YOLOv3 を適用することにより、信号機を検出することが可能となる。信号機の位置に着目した特徴量を算出することで、車両の走行位置の特性から道路の狭窄状況の推定が可能になる。各映像で得られる信号機に着目した特徴ベクトルを f_i^{car} とする。

2.1.3 他車両に基づいた特徴量

道路が狭窄されると、道路の有効幅員が減少することによって、自車両や周辺車両の走行可能位置は限定される。つまり、先行車両や対向車両と自車両の位置関係を把握することで、道路の狭窄状況の分類が可能になると考えられる。そこで、提案手法では、他車両に着目した特徴量を抽出する。他車両の特徴量は映像内で撮像される車両が、信号機と同様に YOLOv3 を用いて算出される。車載カメラ映像に YOLOv3 を適用することにより映像に撮像される他車両の座標を抽出し、車両の走行位置の特性から道路の狭窄状況の推定が可能になる。

入力される映像の各フレームから YOLOv3 を用いてラベル "car" に該当する物体の中心座標 X_n, Y_n ($n=1,2,\dots,N:N$ は各フレームにある他車両の総数) を図-4 に表されるように取得する。次に車両の X 座標から先行車両と対向車両に分類する。これを入力される映像に対

表-2 各手法における評価

評価指標	Level1			Level2			Level3			Accuracy
	Recall	Precision	F-measure	Recall	Precision	F-measure	Recall	Precision	F-measure	
PM	0.82	0.75	0.78	0.55	0.58	0.56	0.76	0.79	0.77	0.72
CM1	0.82	0.75	0.78	0.55	0.58	0.56	0.76	0.79	0.77	0.72
CM2	0.82	0.69	0.75	0.55	0.52	0.54	0.69	0.77	0.73	0.69
CM3	0.82	0.75	0.78	0.55	0.58	0.56	0.76	0.79	0.77	0.72

表-3 識別に用いる特徴量と次元削減法

	道路空間に注目した特徴量 ⁴⁾	他車両に注目した特徴量	PCA1	PCA2
PM	✓	✓	✓	
CM1	✓	✓		
CM2	✓			
CM3	✓	✓		✓

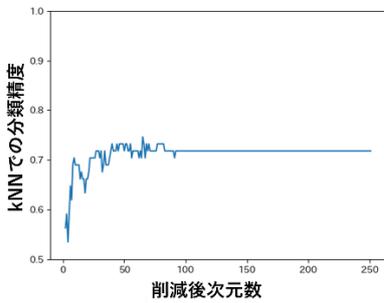


図-5 次元削減に対する分類精度の変化

して、行い他車両の座標 $X_{nm}, Y_{nm}(m=1,2,\dots,M:M$ は映像のフレーム数)を取得する。先行車両と対向車両の座標 X_{nm}, Y_{nm} から、座標の平均値および分散、隣接フレームにおける車両の座標の変化量を抽出し特徴ベクトル f_i^{car} を抽出する。特徴ベクトル f_i^{car} は他車両の自由度に応じて変化することが期待できる。つまり、狭窄している場合としていない場合で特徴ベクトルが変化すると考えられる。

2.1.4 映像の特徴ベクトル

得られた特徴ベクトル $f_i^{first}, f_i^{traffic}, f_i^{car}$ に対して、映像の特徴ベクトル f_i を以下の式(2)で算出する

$$f_i = \{ f_i^{first}, f_i^{traffic}, f_i^{car} \} \quad (2)$$

2.2 PCAによる次元削減

本節では上記した特徴ベクトルに対して、PCA⁸⁾ (Principle Component Analysis) による次元削減手法について説明する。本研究では、2.1.1, 2.1.2 で説明した特徴ベクトルには、次元数に大きな差が存在する。抽出した特徴量各々に対して次元削減を行うことにより、それぞれの特徴量の次元を揃えることで精度向上をはかる。加えて、次元削減は、計算量の削減が同時に期待できる。したがって提案手法では、抽出された特徴量に対してPCAを適用し、次元削減を行う。

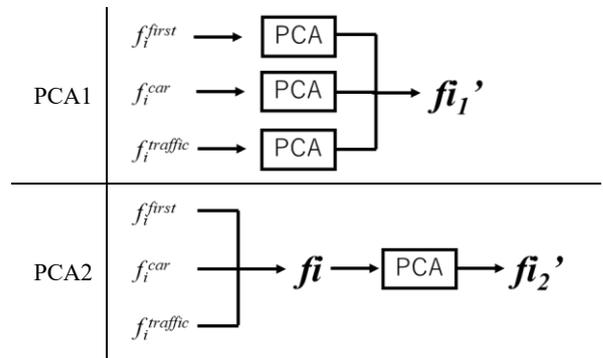


図-6 PCAによる次元削減

まず、各映像に対する特徴ベクトルを取得する。これに対して、PCAを行い、特徴ベクトルの次元を削減する。入力される特徴ベクトル f_i に対して、PCAによる次元削減を行った特徴ベクトルを f_i' とする。

表-2 に示す「PCA1」は抽出したすべての特徴ベクトルに対して一括で次元削減を行ったもの、「PCA2」は色に着目した特徴ベクトル、周波数に着目した特徴ベクトル、信号機に着目した特徴ベクトル、他車両に着目した特徴ベクトルそれぞれに対して次元削減を行った後、分類を行った結果である。PCAによる次元削減の過程を図-6に示す。

2.3 kNNによる狭窄状況の分類

本節では映像の分類するための識別器について説明する。識別器は抽出された特徴ベクトルを基に k 近傍法⁹⁾ (k Nearest neighbor) を適用することによって狭窄状況を分類する(以後、kNN)。kNN は教師あり学習アルゴリズムの一つである。入力されたテストデータのクラスラベルに対して、特徴空間におけるユークリッド距離が近い k 個の学習データのクラスラベルによって分類が行われる。kNN の適用イメージを図-3に示す。

特徴空間にて入力された特徴ベクトル f_i に対して学習データとの類似度を算出する。ここで、あらかじめ決定していた k に対して近傍の k 個の学習クラスを参照し、入力映像のクラスが算出される。これらを式(3)に示す。

$$Class = \arg \max_{c \in C} d_c \quad (3)$$

ここで、 c はクラスのラベルであり、 d_c は近傍 k 個のうち、クラスが c である映像の数を表す。

3. 実験

本章では提案手法の有効性を確認するための実験を行う。本実験では北海道札幌市西区西野の4車線道路を走行した車両に搭載された車載カメラ映像を用いる。本実験では level1, level2, level3 それぞれ 150 本、合計 450 本の映像からなるデータセットを用いる。入力映像の各フレームにおけるピクセル数は 640×480 であり、30fps の 3 秒間の映像である。各フレームの分割数は $l=20, m=3$ であり、合計 940 次元の特徴ベクトル f_i を各々の入力映像に対して取得する。また、学習済みモデル YOLOv3 は、物体検出や、領域分割へ向けたオープンデータの COCO⁹⁾ データセットを基に学習された物体検出を行う深層学習モデルを用いる。kNN の近傍数 k は 5 とする。

初めに、表-3 に示される CM1, CM2 を比較することにより、他車両の特徴量に注目することが分類精度を向上させるのに有効であるかを検証する。次に、PM と CM1 を比較することによって、特徴量選択による次元削減による分類精度の向上について検討する。最後に、CM1 と CM3 を比較することによって、次元削減による計算量の削減に対する、分類精度への影響を考察する。実験では式(4)~(7)を用いた定量評価を行う。 c はクラスのラベルである。

$$Recall = \frac{\text{クラス } c \text{ と推定した映像数}}{\text{クラス } c \text{ の映像数}}, \quad (4)$$

$$Precision = \frac{\text{クラス } c \text{ と正しく推定した映像数}}{\text{クラス } c \text{ と分類された映像数}}, \quad (5)$$

$$F\text{-measure} = \frac{2 \times Recall \times Precision}{Recall + Precision}, \quad (6)$$

$$Accuracy = \frac{\text{正しく識別された映像数}}{\text{識別器に入力した映像数}}, \quad (7)$$

表-2 より、CM1 と CM2 を比較すると、全体の Accuracy が 3%上昇している。また、Level2 においては Recall, Precision, F-measure に変化はなかったものの、Level1, Level3 においては、Recall, Precision, F-measure すべての指標で分類精度の向上が見られた。つまり、他車両の特徴量を追加することは、有効であると考えられる。次に次元削減を行った場合と行っていない場合を比較する。PM と CM1 を比較する。特徴量選択による次元削減により、精度向上を期待したが、分類精度に変化は見られなかった。しかし、次元削減による計算量の削減を行おうと、分類精度の低下がみられないということが分かった。CM1 と CM3 を比較する。PCA を用いた特徴量の

次元削減を行った際、情報量が減少しないため、狭窄状況の分類の精度を保持されることがわかる。図-5 は狭窄状況の分類において抽出した特徴量に対して、PCA を行った際の精度の変化である。約 100 次元から精度の変化は見られず、次元削減を行わずに分類した結果と同じ分類精度を示している。つまり、大幅な次元削減を行っても、分類精度に変化はないということが確認できる。次元削減による、特徴選択を行うことによって、狭窄状況の分類の精度を低下させることなく、計算量を大幅に削減することが可能となる。

4. まとめ

本稿では、車載カメラの映像から道路の狭窄状況を分類するための手法を提案した。また、実験から、他車両の特徴量を用いて狭窄状況の分類を行うことでの分類精度が 3%上昇し、提案手法が精度向上に有効であることが確認された。また、PCA をも用いた次元削減が計算量の削減に有効であるということが分かった。

ただし、現段階では、全体の正解率 70%となっており、約 3 割近くが誤った識別結果となっている。また Level2 に関しては、Recall, Precision, F-measure のすべてが 0.6 を下回っているため、さらなる精度向上が必要といえる。

排除雪作業の効率化という観点においては、道路の狭窄状況の推定のみならず、あらかじめ狭窄が発生しうる道路の予測を行うことが望ましいといえる。取得した映像に時系列の関係もふまえた分析を行うことで、除排雪計画におけるさらなる効率化が期待できる。

参考文献

- 1) 札幌市：札幌市冬のみちづくりプラン <https://www.city.sapporo.jp/kensetsu/yuki/huyumitiplan2018/huyumitiplan2018.tml>, 2018.c
- 2) 大上哲也, 住田則行, 三浦豪, 小宮山一重, 山崎貴志：冬期道路有効幅員計測システムの試作と計測実験について, JSSI & JSSE Join Conference, 2013.
- 3) Kozo Okumura, Sho Takahashi, Toru Hagiwara: An Estimation method of Road Narrowing Condition in In-vehicle Camera, IEEE global conference on consumer electronics, 2020
- 4) REDMON, Joseph, et al: You only look once: Unified, real-time object detection Proceedings of the IEEE conference on computer vision and pattern recognition, pp.779-788, 2016.
- 5) Lin, Tsung-Yi, et al: "Microsoft coco: Common objects in context." *European conference on computer vision*. Springer, Cham, 2014.
- 6) Cover, Thomas, and Peter Hart: Nearest neighbor pattern classification', IEEE transactions on information theory Vol.13.1, pp.21-27, 1967.
- 7) XIE, XIAOHUI: Principal component analysis, 2021.