

# 車載カメラを用いた道路空間の画像解析に基づく堆雪による狭窄状況の識別に関する研究

木下 洋輝<sup>1</sup>・八木 雅大<sup>2</sup>・高橋 翔<sup>3</sup>・萩原 亨<sup>4</sup>

<sup>1</sup> 学生会員 北海道大学 工学部 (〒060-8628 北海道札幌市北区北 13 条西 8 丁目)

E-mail: hiorkiusa@eis.hokudai.ac.jp (Corresponding Author)

<sup>2</sup> 学生会員 北海道大学大学院 工学院 (〒060-8628 北海道札幌市北区北 13 条西 8 丁目)

E-mail: masahiro@eis.hokudai.ac.jp

<sup>3</sup> 正会員 北海道大学大学院 工学研究院 (〒060-8628 北海道札幌市北区北 13 条西 8 丁目)

E-mail: stakashi@eng.hokudai.ac.jp

<sup>4</sup> フェロー会員 北海道大学大学院 工学研究院 (〒060-8628 北海道札幌市北区北 13 条西 8 丁目)

E-mail: hagiwara@eng.hokudai.ac.jp

積雪寒冷地において路肩に堆積した雪は、交通渋滞や、交通事故を引き起こす一因となり、都市交通の機能を維持する上では重大な問題となっている。冬期の道路有効幅員の確保のために、路肩に生じた堆雪の排雪や除雪が行われているが、道路情報の収集には、多大な時間と人員を必要とする。本研究では、冬期の道路有効幅員（以後、狭窄状況）を車載カメラから撮像された映像より識別する手法を提案する。車載カメラから道路の狭窄状況の推定を可能とすることにより、一般車両からでも道路情報の収集が技術的に可能となり、多大な人員や時間を必要としない環境が構築可能となることが期待できる。

**Key Words:** road narrowing by snow accumulation, in-vehicle camera, image analysis, classification

## 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道路幅員の減少が影響し、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、交通渋滞を引き起こされる。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ため、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。しかし、除排雪従事者は高齢化の影響により年々減少している<sup>1)</sup>。したがって、積雪寒冷地における道路管理の除排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<sup>2)</sup>。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、定量的な計測が可能となっている。しかしながら、この手法では、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にはいたっていない。

また、このような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できる。加えて、近年事故の記録や煽り運転の抑制のために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。

そこで本研究では、車載カメラを用いて道路有効幅員（以降、狭窄状況）を識別する手法を提案する。車載カメラ映像を用いた狭窄状況の識別は、特殊な専用車両を用意する必要がなく、路上を走行している一般車両が将

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-3 パッチの分け方

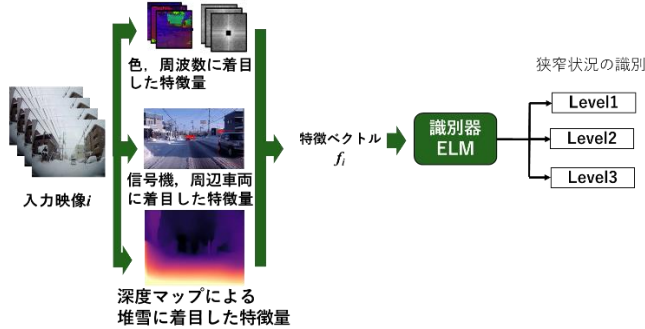


図-1 提案手法の概要



図-4 Yolov3 による周辺車両の座標の取得

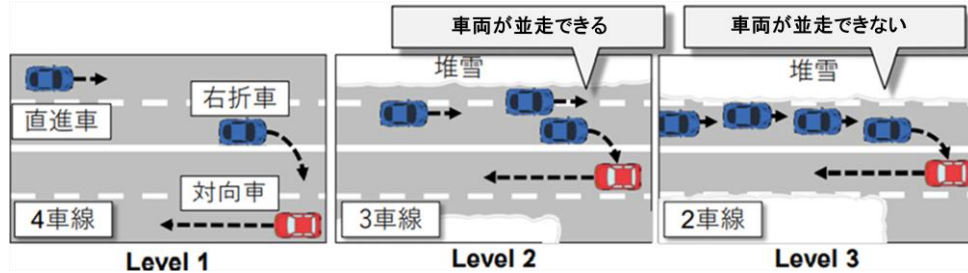


図-2 狭窄状況の定義

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。

著者らは文献<sup>3)</sup>で道路が撮像された映像を基に表-1に定義した3クラスに道路の狭窄状況を識別する手法の有効性を示した。しかし、文献<sup>3)</sup>では分類精度が全体で7割となっており、更なる精度向上が課題となっている。

そこで本稿では、路肩の堆雪が道路の狭窄にともなうて高くなることに注目し、深度マップ<sup>7)</sup>によって得られる特徴量を用いて道路有効幅員を高精度に車載カメラ映像から識別する手法を提案する。

また、文献<sup>3)</sup>ではkNNを用いた識別器を構築し、分類を行っている。kNNは、高い汎用性があるが、特徴空間における特徴ベクトルのユークリッド距離の類似度に基づいて分類を行っているため、教師データの増減で分類結果に相違が生じる可能性がある。このため、本稿では、識別器に深層学習の1つであるExtreme Learning Machine(ELM)を用いた狭窄状況の識別を行う。

以降本稿では、2で車載カメラ映像を用いた狭窄状況の識別方法について説明する。3では、実際に、2で提案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. 狭窄状況の識別

本章では、狭窄状況の識別について説明する。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識別を行う。次に、

抽出した特徴量をもとに、映像に対する特徴ベクトルを算出し、ELMを用いて構築した識別器を用いて、狭窄状況を3段階に識別する。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。また、道路の狭窄状況のイメージ図を図-2に示す。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、2.1で各段階の特徴量抽出方法について説明した後、2.2で抽出した特徴量をもとに識別器を構築する過程を説明する。最後に、提案手法の有効性を確認するための実験を行う。

### 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識別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<sup>3)</sup>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では堆雪に着目した特徴量について説明を行う。2.1.5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。

#### 2.1.1 道路空間に着目した特徴量

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-3のように縦方向にk分割

し、路面に注目した領域を画像の下部  $W \times \frac{h}{k}$  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  $f_i^{\text{first}}$  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  $f_i^{\text{color}}$  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  $f_i^{\text{ps}}$  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。

### 2.1.2 道路構造物に基づいた特徴量

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、道路の狭窄状況の識別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 YOLOv3<sup>5)</sup> 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  $f_i^{\text{traffic}}$  とする。

また、道路空間に基づいた特徴量、道路構造物に基づいた特徴量の具体的な算出方法は、参考文献<sup>4)</sup>に示されている。

### 2.1.3 周辺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、道路の狭窄状況の識別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して、行い他車両の座標  $X_n^m, Y_n^m$  ( $m=1,2,\dots,M:M$  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  $X_n^m, Y_n^m$  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  $f_i^{\text{car}}$  を抽出する。特徴ベクトル  $f_i^{\text{car}}$  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 堆雪に着目した特徴量

路肩の堆雪が増大するにつれて、道路は狭窄する傾向にある。よって、堆雪の大きさから、道路の狭窄状況を推定することが可能であると考えられる。堆雪に着目した特徴量を算出するために、単眼深度推定を用いる。単眼深度推定は Depth CNN, Pose CNN の二つの畳み込みニューラルネットワークを用いた映像に撮像される物体の三次元空間の奥行きを推定することが可能である。単眼深度推定の詳細は文献<sup>7)</sup>を参照されたい。単眼深度推定により算出されるデプスマップを用いて、堆雪の大きさを推定する。提案手法では、デプスマップを用いて、堆雪に着目した特徴量を考える。デプスマップを用いた堆雪に着目した特徴量から、特徴ベクトル  $f_i^{\text{depth}}$  を抽出する。

入力された映像に対して各フレームに対するデプスマップを算出する。入力された映像に対して、得られたデプスマップの例を図-6に示す得られたデプスマップでは入力される映像における奥行きを色によって表現される。故に図における算出された、デプスマップにグレースケール化処理を行うことによって、映像内の近辺の物体は淡色で表現され、遠方の物体は濃色で表現される。

次に得られたグレースケール画像に対して、2 値化を行う。2 値化を行う上で、入力される画像の各画素に対する閾値  $t$  を以下のように求める。閾値  $t$  を境にクラス 0、クラス 1 に分別する。入力される映像に対して、全体の画素数  $P_{\text{all}}$ 、クラス 0 に含まれる画素数  $P_0$ 、クラス 1 に含まれる画素数を  $P_1$  とすると、全体におけるクラス 0 の割合は  $R_0$ 、クラス 1 の割合  $R_1$  は式(1)で求める。

$$R_0 = \frac{P_0}{P_{\text{all}}}, R_1 = \frac{P_1}{P_{\text{all}}} \quad (1)$$

全ての画素の輝度の平均を  $M_{\text{all}}$ 、クラス 0 内の平均を  $M_0$ 、クラス 1 内の平均を  $M_1$  とした時、クラス間分散  $S_b^2$  は式(2)のように定義される。

$$S_b^2 = R_0 \times R_1 \times (M_0 - M_1)^2 \quad (2)$$

またクラス 0 内の分散を  $S_0^2$ 、クラス 1 の分散を  $S_1^2$  とすると、各クラスの分散を総合的に評価したクラス内分散  $S_{in}^2$  は式(3)のように定義され、閾値は式(2)が最大となるように定める。





図-5 ELM のイメージ図




(a)入力画像



(b)算出されたデプスマップ

図-6 デプスマップの算出



(a)算出されたデプスマップ



(b)グレースケール化




(c)2 値化された画像


図-7 2 値化の例



(a)Level1



(b)Level2



(c)Level3

図-8 2 値化の例

$$S_{in}^2 = R_0 \times S_0^2 + R_1 \times S_1^2 \quad (3)$$

得られたデプスマップをもとに算出した閾値  $t$  を用いて 2 値化した画像例を図-7 に示す。

図の画像の白黒の境界線に注目すると、道路が狭窄するにつれて、境界線は直線から曲線に変化する傾向がある。よって、2 値化した画像から境界線の非線形性を特徴ベクトル  $f_i^{depth}$  として算出する。狭窄レベルに応じた 2 値化処理の例を図-8 に示す。

### 2.1.5 映像の特徴ベクトル

得られた特徴ベクトル  $f_i^{color}, f_i^{fps}, f_i^{traffic}, f_i^{car}, f_i^{depth}$  に対して、道路空間に着目した特徴ベクトル  $f_i^{road}$  を式(4)で、映像の特徴ベクトル  $f_i$  を以下の式(5)で算出する。

$$f_i^{road} = \{ f_i^{color}, f_i^{fps}, f_i^{traffic} \} \quad (4)$$

$$f_i = \{ f_i^{road}, f_i^{car}, f_i^{depth} \} \quad (5)$$

## 2.2 ELM による狭窄状況の識別

本節では、狭窄状況の識別を行うための識別手法について説明する。文献<sup>3)</sup>では、kNN<sup>8)</sup>を用いて、狭窄状況の分類を行った。kNN はアルゴリズムがブラックボックス化しないシンプルなため、幅広い分類モデルにおいて、汎用的に適応することが可能であるという利点がある一方、ノンパラメトリックな手法である。また、データの量が少ないという観点においては本研究では kNN を用いて狭窄状況の分類を行うことは必ずしも有用であるとは断言できない。また kNN は訓練されたモデルは汎化された方程式を有しておらず、 $k$  の値によって分類されるクラスが変動するため、最適傍数  $k$  が重要なパラメータとなる。加えて  $k$  の値は小さすぎると過学習に弱く、局所最適に陥り、逆に大きすぎると、モデルの精度の低下に繋がる可能性もあるため、正確な識別結果を得られないというデメリットも存在する。故に、本研究では、識別器 ELM<sup>9)</sup>を用いて狭窄状況の識別を行う。

表-2 各手法において用いる特徴ベクトル

	$f_i^{road}$	$f_i^{car}$	$f_i^{depth}$
PM	✓	✓	✓
CM1	✓	✓	
CM2	✓		✓

表-3 各手法における評価 (実験 1)

	Level1			Level2			Level3			Accuracy
	Recall	Precision	F-値	Recall	Precision	F-値	Recall	Precision	F-値	
PM	<b>0.96</b>	0.87	0.92	0.63	<b>0.96</b>	<b>0.76</b>	<b>0.98</b>	0.66	<b>0.79</b>	<b>0.82</b>
CM1	0.91	0.86	0.89	0.61	0.86	0.71	0.91	0.70	<b>0.79</b>	0.79
CM2	0.90	<b>0.96</b>	<b>0.93</b>	<b>0.73</b>	0.63	0.68	0.76	<b>0.81</b>	<b>0.79</b>	0.80

表-4 各手法における評価 (実験 2)

	Level1			Level2			Level3			Accuracy
	Recall	Precision	F-値	Recall	Precision	F-値	Recall	Precision	F-値	
ELM	<b>0.96</b>	<b>0.87</b>	<b>0.92</b>	<b>0.63</b>	<b>0.96</b>	<b>0.76</b>	<b>0.98</b>	0.66	<b>0.79</b>	<b>0.82</b>
CM1	0.82	0.75	0.78	0.55	0.58	0.56	0.76	<b>0.79</b>	0.77	0.72

ELM は 3 層のニューラルネットワークからなる。Single hidden layer feedforward neural networks (SLFNs) の一種であり、速い学習速度や少ない学習データによる普遍的な近似を可能としており、1 層の隠れ層を持ち、隠れ層の重みをランダムに生成する。ELM のイメージ図を図-5 に示す。

まず、学習データに特徴ベクトル  $f_i$ 、および狭窄レベルを  $z_i = [z_i^{level1}, z_i^{level2}, z_i^{level3}]^T$  (ただし、 $z_i$  の属する狭窄状況のレベルが 1 の場合、 $z_i^{level1} = 1$ 、 $z_i^{level2} = 0$ 、 $z_i^{level3} = 0$  となる。) とする。また、出力層への重み  $\beta$  を求める。具体的には、シグモイド関数  $G$  を用いて特徴変換を行うことで、次式によって  $d(f_i)$  を算出する。

$$d(f_i) = [G(u_1, v_1, f_i), \dots, G(u_K, v_K, f_i)]^T \quad (6)$$

ただし、 $u_k (k = 1, 2, \dots, K)$ 、および  $v_k (k = 1, 2, \dots, K)$  はシグモイド関数  $G$  のパラメータであり、 $K$  は隠れ層のノード数を表す。次に、次式により、最終層の重み  $\beta$  を求める。

$$\beta = (D^T D)^{-1} D^T Z \quad (7)$$

ただし、 $Z = [z_1, z_2, \dots, z_M]^T$ 、 $D = [d(f_1), d(f_2), \dots, d(f_M)]^T$ 、 $M$  は学習データの数である。最後に、テストデータにおいて、特徴ベクトル  $f$  を ELM に入力したとき、出力値は  $g = d(f)^T \beta$  であり、クラスラベルは  $g$  の内、最も大きな値を出力したノードに対応するクラスラベルとする。

### 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 2 つ行う。具体的には 3.1 では 2.1.3 で説明した、堆雪に着目した特徴量を追加することの有効性を確認する。3.2 では ELM で構築した識別器を用いた識別を行うことの有効性を確認する。

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。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  $640 \times 480$  であり、30fps の 3 秒間の映像である。各フレームの分割数は  $l=2, m=3$  であり、合計 1579 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 COCO<sup>10</sup> 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。また ELM のノード数は特徴ベクトルの次元数の 2 倍とする。

実験では式(8)-(11)を用いた定量評価を行う。 $c$  はクラスのラベルである。

$$\text{Recall} = \frac{\text{クラス } c \text{ と推定した映像数}}{\text{クラス } c \text{ の映像数}}, \quad (8)$$

$$\text{Precision} = \frac{\text{クラス } c \text{ と正しく推定した映像数}}{\text{クラス } c \text{ と分類された映像数}}, \quad (9)$$

$$F\text{-measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}, \quad (10)$$

$$\text{Accuracy} = \frac{\text{正しく識別された映像数}}{\text{識別器に入力した映像数}}. \quad (11)$$

#### 3.1 実験 1

本項では、堆雪に着目したデプスマップによる特徴量を追加することに対しての有効性を確認する。提案手法は特徴ベクトル  $f_i^{road}$ 、 $f_i^{depth}$ 、 $f_i^{car}$  を用いた識別に対して、比較手法 1 では  $f_i^{road}$ 、 $f_i^{car}$  のみを用いた実験を行う。比較手法 2 では、 $f_i^{road}$ 、 $f_i^{depth}$  のみを用いた実験を行う。これらを表-2 に示す。実験結果を表-3 に示す。

提案手法と比較手法を比較すると、提案手法の正解率が比較手法 1、比較手法 2 と比較して最も高い。また、Level2, Level3 においては提案手法の F-measure が比較手法と比較して、最も高く、Level1 に関しても 0.01 の差であった。つまり、提案手法は道路の狭窄状況を分類す

ることの精度向上に有効であるといえる。また、比較手法 2 に着目すると、Level1 の Precision, F-値や Level2 の recall, Level3 の Precision が提案手法、比較手法 1 と比べて最も高い値となっている。

### 3.2 実験 2

本項では、識別に用いる識別器を kNN から ELM に変更したことに対する有効性を確認する。実験結果を表-4 に示す。表より、ELM で狭窄状況の識別を行った場合、kNN で狭窄状況の分類を行った場合と比較して、Level3 の Precision を除いたすべての指標において、識別精度が高かった。また、正解率においては、10%の向上が見られた。つまり、狭窄状況の識別を行う上では、kNN よりも ELM が識別器としての優位性があるといえる。よって、ELM で道路の狭窄状況を識別することに対しての有効性が確認された。

### 4. まとめ

本稿では、デプスマップを用いた、堆雪に着目した新たな特徴ベクトルを追加した手法を提案した。また、ELM を用いた識別器を構築し、その有効性を確認した。またこれらは、狭窄状況を識別するうえで精度向上に有効であるということが確認された。

しかしながら、Level2 の Recall, Level3 の Precision は依然として、7 割を下回っている。つまり Level2 と Level3 は未だに精度向上に課題があると考えられる。

本研究では狭窄状況の識別を行う手法を提案したが、除排雪作業の効率化という観点においては、道路の狭窄状況の識別のみならず、あらかじめ狭窄が発生しうる道路の予測を行うことが可能であれば、さらに円滑な道路管理を実現できると考えられる。取得した映像に対して、時系列の関係をふまえた分析等を行うことが出来れば、除排雪計画におけるさらなる効率化が期待できる。また、得られた情報を地図等にマッピングすることが出来れば、交通渋滞や交通事故の削減、除排雪計画のみならず道路を利用するすべての人に対して有益な情報提供をすることも可能になると考えられる。

**謝辞：**本研究の一部は、JST さきがけ(JPMJPR21PD)、および JSPS 科研費 JP19H02254 の支援を受けたもので

ある。

### 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.
- 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) 木下洋輝, 八木雅大, 高橋翔, 萩原亨：車載カメラ映像における周辺車両および特徴空間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, 令和 3 年次土木学会北海道支部技術研究発表会, 2022
- 4) Kozo Okumura, Sho Takahashi, Toru Hagiwara: An Estimation method of Road Narrowing Condition in In-vehicle Camera, IEEE global conference on consumer electronics, 2020
- 5) 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.
- 6) Andreas Geiger, Philip Lenz, and Raquel Urtasun: Are We Ready for Autonomous Driving? The KITTI Vision Benchmark Suite. 2012 IEEE conference on Computer Vision and Pattern Recognition. IEEE, p.3354-3361, 2012.
- 7) Clément Godard, Oisín Mac Aodha, Michael Firman and Gabriel Brostow: Digging Into Self-Supervised Monocular Depth Estimation. CVPR, 2019
- 8) Cover, Thomas, and Peter Hart: 'Nearest neighbor pattern classification', IEEE transactions on information theory Vol.13.1, pp.21-27, 1967.
- 9) Huang, Guang-Bin, Qin-Yu Zhu, and Chee-Kheong Siew: Extreme learning machine: theory and applications. Neurocomputing pp.489-501,2006.
- 10) Lin, Tsung-Yi, et al: "Microsoft coco: Common objects in context."European conference on computer vision. Springer, Cham, 2014.

A STUDY ON A METHOD FOR CLASSIFYING ROAD NARROWING  
CONDITIONS BY SNOW ACCUMULATION BASED ON IMAGE  
ANALYSIS OF ROAD ENVIRONMENT IN IN-VEHICLE CAMERAS

Hiroki KINOSHITA, Masahiro YAGI, Sho TAKAHASHI and  
Toru HAGIWARA

In snowy and cold regions, piled snow on road shoulders may cause traffic congestion and even traffic accidents, and can be a serious problem in maintaining the functionality of urban transportation. In order to maintain the effective width of roads during the winter, piled snow on the road shoulders is removed and cleared, but getting road information requires great deal of time and manpower. In this paper, we propose a method for classifying the effective road width by road narrowing by piled snow on road shoulders, based on videos captured from an in-vehicle cameras. Estimating road narrowing conditions from in-vehicle cameras will enable ordinary vehicles to collect road information and create an environment that does not require a great deal time or manpower to gather road information.