

ロードヒーティング制御に向けたセマンティックセグメンテーションによる路面画像の積雪状況認識

今原 智広^{1,a)} 横山 想一郎² 山下 倫央² 川村 秀憲²

概要：ロードヒーティングとは路面の雪を融かす設備で、企業から一般家庭まで幅広く利用される。しかし、現在の一般的な制御方法である積雪センサーでは低温の雨と雪を判別することができないため、必要以上に融雪のための熱源を稼働することが問題となっている。本研究ではセマンティックセグメンテーションを用いて、駐車場の路面を俯瞰する画像から路面の積雪割合を認識する機構を学習し、その精度を検証する。札幌市内の駐車場を30メートル程の高さから俯瞰する画像を用いて実験を行った結果から、ロードヒーティングの制御において問題のない判定精度が得られることが確認され、この手法がロードヒーティングの現場に応用可能であることが認められた。

Recognition of Snow Covering Condition in Road Surface Images by Semantic Segmentation for Control of Road Heating

1. はじめに

ロードヒーティングとは路面の融雪や、凍結の防止のために路面の温度を上げる設備のことである。近年普及が進み、ロードヒーティングは企業から一般家庭まで広く利用がされている。

現状のロードヒーティング設備で採用されている制御方法として降雪センサーを利用した制御がある。降雪センサーは、センサー上に落ちた雪が融けて水となったものを検知するものであり、これは降雪を低温の雨などと区別して検知することができない。そのため実際は設置場所に積雪が発生していない場合でも、ボイラーを稼働させてしまうケースがある。また、降雪センサーによる制御は路面の状況を確認することはできないため、降雪を検知した場合に、設定した一定時間のボイラー稼働を行うという方法を取っている。この設定時間は雪の融け残りを防ぐためにあらかじめ長めに設定されており、路面の雪が融けきっている場合でもボイラーは稼働しているというケースも発生

し、余分なコストを浪費してしまっている。

本研究ではDeepLabV3+[1]モデルのネットワークを用いて、積雪と非積雪の画像を学習する。路面画像に対してセマンティックセグメンテーションを行い積雪の有無を推定、それを元にボイラーの熱源稼働の有無を決定するといったシステムの可能性の検証を目的とする。画像の積雪の有無を正しく判定できれば、その情報をロードヒーティング機の制御に利用することで過剰な熱源の稼働や雪の溶け残りといった問題を軽減できる。

2. 関連研究

本章では画像処理に関する関連技術およびロードヒーティング制御の先行研究について説明する

2.1 セマンティックセグメンテーション

セマンティックセグメンテーションとは画像内のピクセルを分割し、それら全てに意味的ラベルの付与を行うタスクのことを指す。

セマンティックセグメンテーションは自動運転を始めとし、医療用画像への応用 [2] やトンネルや建築物の老朽化を効率よく点検するための手段 [3], [4] などさまざまな分野で利用されており、積雪関連では、路面画像から雪に覆わ

¹ 北海道大学 工学部

School of Engineering, Hokkaido University

² 北海道大学大学院情報科学研究院

Faculty of Information Science and Technology, Hokkaido University

a) imahara@ist.hokudai.ac.jp

れた路面と通常の路面をセマンティックセグメンテーションにより推定し [5], [6], 路面状況から運転の危険度を表す指標を計算しドライバーの事故防止に役立てる研究などがある。

本研究でセマンティックセグメンテーションを用いる理由を述べる。画像の積雪判定を回帰問題として捉えると、画像認識を用いて行う上で邪魔になる車や建築物、人などの障害物に対処するためには事前処理が必要である。この事前処理は障害物自体の移動や、カメラ角度の変化が起こる関係で無視できない作業量となってしまう。そのため障害物領域の推定もセマンティックセグメンテーションで試みることで、作業量を減らす。他にも1ピクセルごとに学習データがあると考えられるので、1枚の積雪割合を回帰問題として捉えるよりもデータ数を多く扱うことができる点。今後制御を高度化する際に、積雪が多くなりやすい領域や積雪が少なくなりやすい領域の情報を利用できる点が挙げられる。

2.2 深層学習を用いた路面の積雪認識によるロードヒーティング制御

画像から積雪の有無を深層学習を用いて推定し、ロードヒーティング制御に利用した研究を紹介する。横山ら [7] は CNN を用いて路面画像の認識を行い、その画像から積雪の有無を判定、ロードヒーティングのボイラー制御をするシステムを提案した。

この研究で提案されたシステムの簡単な概要は以下の通りである。

- (1) Raspberry Pi 及び LTE モデム 及び カメラを搭載した自作のロードヒーティングコントローラで設置場所の路面画像を撮影。
- (2) 撮影した路面画像から積雪割合を判定。
- (3) 判定結果から熱源稼働の有無をボイラーに送信。

カメラで撮影される画像は 1024×768 ピクセルで、そこから 64×64 の部分画像に分割され、それぞれに $[0,1]$ の範囲で積雪状態かどうかの確率を出力する。その部分画像の出力の平均値を、全体画像のうちの積雪割合とみなしている。判定結果である積雪割合とあらかじめ設定したしきい値を比較し、ボイラー稼働の判定を行っている。

札幌市内の 14 地点にロードヒーティングコントローラを設置し、そのうちの 6 地点のデータを用いて熱源の稼働時間の削減効率について検証。その結果 2 月下旬から 4 月下旬の札幌市内において、熱源の稼働時間を 45 % ほど削減できるという可能性を示している。

3. 実験準備

2.2 節で紹介した横山らの研究は、ロードヒーティング機制御のために路面画像を用いることの有用性を示している。よって本研究でも路面画像を利用した積雪判定をおこ



図 1 駐車場撮影画像の例

なう。

3.1 従来研究との差分

2.2 節で紹介した研究と本研究との差異について述べる。横山らの研究はロードヒーティングコントローラに搭載したカメラを利用して撮影を行った。その撮影範囲はおよそ 1m 四方であり、日当たりや熱源からの距離を考慮した位置にロードヒーティングコントローラを配置しなければ、ロードヒーティングによる加熱の効果を確認することは難しかった。

そこで本研究では、高所からの俯瞰画像を利用した積雪領域推定を行う。より広い範囲を撮影することによって設置箇所による判定のムラを防ぐ。撮影範囲を広くすることで生じる課題が 2 つ考えられる。

- (1) 積雪の有無の判定の邪魔をする物体が写り込む。
- (2) 夜の撮影画像を用いた際に、街灯やライトなど光源の当たり方次第で積雪の有無を確認できないことがある。

この課題に対し、ラベル付け段階で障害物というラベルを用意し、障害物と推定された領域を除く領域の積雪割合からボイラーを制御することを考える。

3.2 データセット作成

実験に利用するデータについて述べる。利用したデータは北海道大学情報科学研究棟 9 階から撮影した 1920×1080 ピクセルの画像である。撮影期間は 11/20 ~ 1/25 であり、その中から 850 枚を選択しセマンティックセグメンテーションの正解ラベルを付与した。図 1 は撮影画像の例である。

期間内の撮影画像には積雪が全く確認されない画像や、積雪のみで路面の露出が確認されない画像などが含まれており、期間内のすべてのデータからランダムに選ぶと、学習に必要な積雪領域と路面領域の両方を 1 枚の中に含む画像があまり選択されない可能性がある。そのため、積雪の有無、平日か休日、昼夜など撮影画像から見て取れる要素が均等になるように 850 枚のデータを作成した。さまざまな状況での撮影画像を学習データとして選択した。

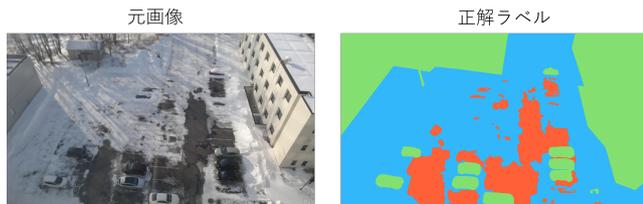


図 2 ラベル付け例

3.2.1 ラベル付け定義

学習用データのラベル付け定義について述べる．対象となる撮影画像に対し正解ラベルを付与し，学習用の正解であるマスクデータとする．

画像内の全ピクセルにラベルを付与するものとし，画像内のピクセルはすべていずれかのクラスに属するものとする．画像に付与する正解ラベルは下記の 3 種類である．

(1) 積雪

積雪が確認されたピクセルに付与するラベル．

(2) 非積雪

積雪が確認されていない路面の領域に付与するラベル．ロードヒーティングが導入されている路面を想定してアスファルトの路面にのみ付与する．草むらや砂利の路面には付与をしない．

(3) 障害物

上記の 2 クラスの判定の障害となるものに付与するラベル．

建物，車，ロードヒーティングが導入されていない路面である草むらなどが該当する．また撮影時間が夜の場合では，画像内にラベル付与をできない領域があった場合も障害物ラベルを付与する．

図 2 は元画像と実際にラベル付けを行った画像であり，青が積雪ラベル，橙が非積雪ラベル，緑が障害物ラベルとなっている．

このようなマスクデータを撮影画像の選択枚数分用意し，作成したマスクデータと対応する撮影画像のデータセットを用いて学習を行う．

3.3 ボイラー制御方法

ボイラー制御方法について述べる．式 (1) で定義される積雪割合を利用した制御を行うことを考える．ラベル付けをおこなったマスクデータを対象に，積雪割合について算出を行う．各画像の積雪割合を式 1 で定義する．

$$\text{積雪割合} = \frac{\text{積雪ラベルのピクセル数}}{(\text{積雪ラベル} + \text{非積雪ラベル}) \text{のピクセル数}} \quad (1)$$

算出結果の枚数分布が図 3 であり，横軸がその積雪割合の範囲で縦軸が枚数となっている．

本研究ではこの値を利用してボイラー稼働の有無を判断するという想定である．たとえばしきい値を 0.5 とした場合，対象画像の積雪割合が 0.5 以上の場合に積雪と判定しボイラー機を稼働状態，0.5 を下回った場合に非積雪と判

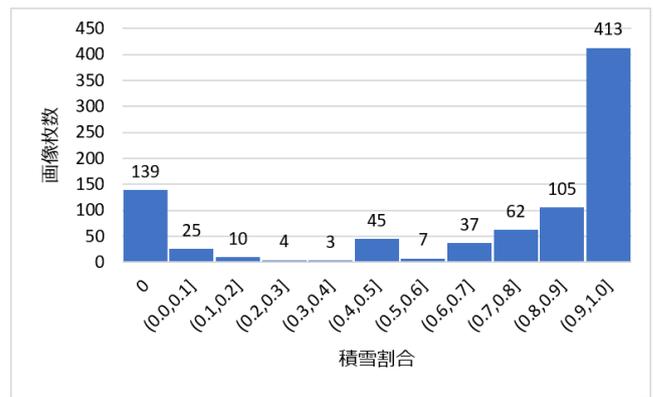


図 3 正解データにおける積雪割合の分布

定しボイラー機を非稼働状態とする．

4. 学習モデルの実行・評価

実験の流れについて述べる．

- (1) 用意した元画像とそのマスクデータを DeepLabV3+ ネットワークモデルで学習．
 - (2) 学習したモデルで撮影画像に対して領域推定を実行．
 - (3) 推定結果と正解のマスクデータを比較して評価．
- 評価としては各クラスが正しく領域推定されているかどうか，設定したしきい値に対応してボイラー機稼働の有無を判断できているかどうかを対象とする．

4.1 学習モデル

Semantic-Segmentation のタスクで高いスコアを残していた DeepLabV3+[1] を利用する．

DeepLabV3+ は Encoder-Decoder 構造のモデルであり，Encoder の特徴抽出の部分では Xception[8] のネットワーク構造が用いられている．さらにその後の Atrous Spatial Pyramid Pooling(ASPP) と呼ばれる，異なる大きさの受容野畳み込み層を並列に配置する構造により，画像の広い範囲から局所的な情報まで様々な情報を抽出することを可能にしている．Decoder 部分で Encoder からの特徴は 4 倍でアップサンプリングされ，同じ空間解像度をもつネットワークバックボーンの該当する特徴と結合される．これにより，オブジェクトの境界をくっきりと推論できる．PascalVOC2012[9] のデータセットでは高い精度を示した．

この DeepLabV3+ を tensorflow で実装されたモデルを用いて学習を行った．

4.1.1 学習設定

PascalVOC2012 のデータセット 20 クラス，10582 枚での事前学習済みモデルを用いて転移学習を行った．ネットワーク構造は Xception を利用する．ラベル付けを行った画像のうち訓練画像を 680 枚，テスト画像を 170 枚とした．学習パラメータは表 1 に示すものを用いた．

表 1 学習パラメータ

ステップ数	10000
ミニバッチサイズ	4
最適化	Momentum SGD
学習率	初期値:0.0001 次式で徐々に減少 $0,0001 * (1 - (step/10000))^{0.9}$

表 2 混同行列

		推定結果	
		正例	負例
正解 データ	正例	TP(True Positive)	FN(False Negative)
	負例	FP(False Positive)	TN(True Negative)

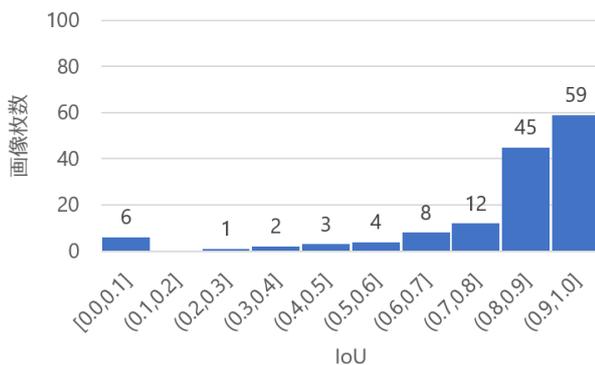


図 4 積雪ラベル画像の IoU 分布

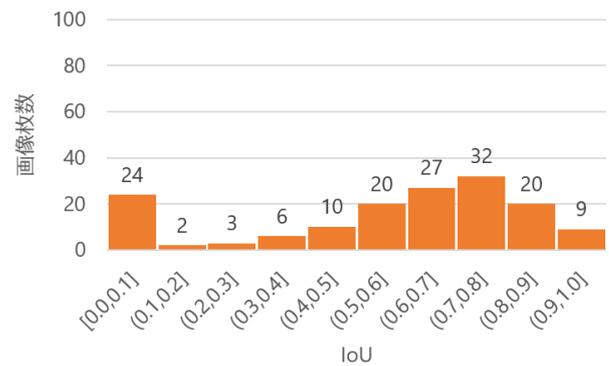


図 5 非積雪ラベル画像の IoU 分布

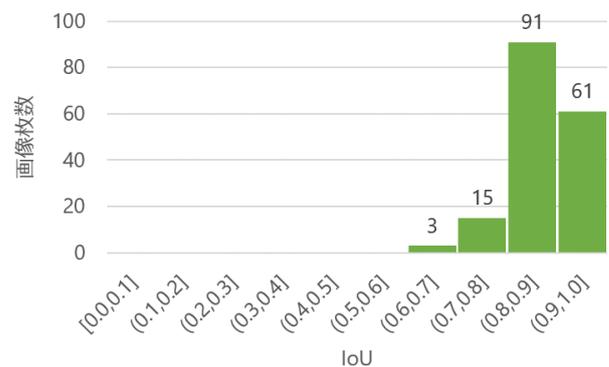


図 6 障害物ラベル画像の IoU 分布

4.2 認識システムの評価

4.2.1 Intersection over Union

Intersection over Union (以下 IoU) とは、物体検出の評価指標である。正解ラベルを付与した画像と推定結果の画像を比べた際に、正解領域と推定領域がどのくらい重なっていたかを表す。画像 1 枚 1 枚に対し、積雪、非積雪、障害物クラスの IoU を算出する。各クラスをそれぞれ正例とし、画像内の各画素に対して表 2 のような混同行列を作成する。

このとき IoU は下記式で与えられる。

$$IoU = \frac{TP}{TP + FP + FN} \quad (2)$$

4.2.2 実験結果

各クラスの IoU の枚数分布を図 4、図 5、図 6 に示す。

積雪と障害物のクラスでは比較的高い IoU の数値を出した画像が多かったが、非積雪のクラスは少し他のクラスと比べても劣る枚数分布となった。非積雪ラベルにおける IoU が低くなった画像の特徴としては、そもそも正解データの非積雪領域が小さい傾向があることが確認できた。非積雪ラベルの IoU が 0.11 と小さい画像の例を図 7 に示す。

4.3 ボイラー制御に関する評価

式 1 で示される積雪割合を正解データと推定結果のマスクデータについて算出し、その違いを比較する。正解

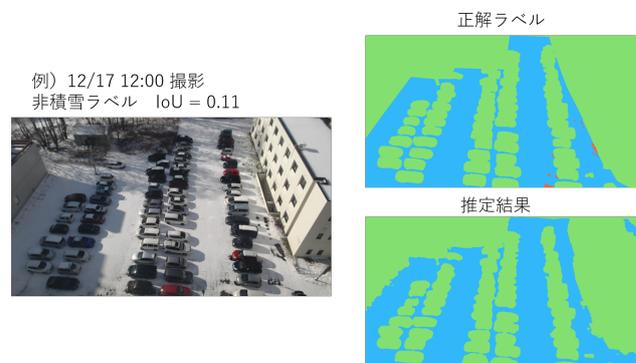


図 7 非積雪ラベルの画像の誤判定例

データの積雪割合は 4.3 章の図 3 に示した通りである。正解データと推定結果の積雪割合の混同行列を表 3 に示す。評価に用いたデータは少ないものの、大きな積雪割合の誤判定はない。したがって俯瞰画像を用いたボイラー制御は可能であるといえる。表 3 を見ると、積雪割合が 0 であるにもかかわらず積雪があると誤判定した画像があることがわかる。このような画像の例を図 8 に示す。図より、砂利を一部積雪と誤判定していることがわかる。推定値と正解の積雪割合の差は 0.004 とわずかであるものの、このような事象が発生することから少しでも積雪があることをボイラー稼働条件とするのは好ましくないと考えられる。

表 3 積雪割合の混同行列

	正解データ										
	0.0	(0.0,0.1]	(0.1,0.2]	(0.2,0.3]	(0.3,0.4]	(0.4,0.5]	(0.5,0.6]	(0.6,0.7]	(0.7,0.8]	(0.8,0.9]	(0.9,1.0]
0.0	30	0	0	0	0	0	0	0	0	0	0
(0.0, 0.1]	6	2	1	0	0	0	0	0	0	0	0
(0.1, 0.2]	0	2	0	0	0	0	0	0	0	0	0
(0.2, 0.3]	0	0	0	0	0	0	0	0	0	0	0
(0.3, 0.4]	0	0	0	0	0	0	1	0	0	0	0
(0.4, 0.5]	0	0	0	0	0	0	0	0	0	0	0
(0.5, 0.6]	0	0	0	0	0	4	1	0	0	0	0
(0.6, 0.7]	0	0	0	0	0	3	0	8	0	0	1
(0.7, 0.8]	0	0	0	0	0	1	0	1	9	3	3
(0.8, 0.9]	0	0	0	0	0	0	0	0	4	17	0
(0.9, 1.0]	0	0	0	0	0	0	0	0	1	2	70

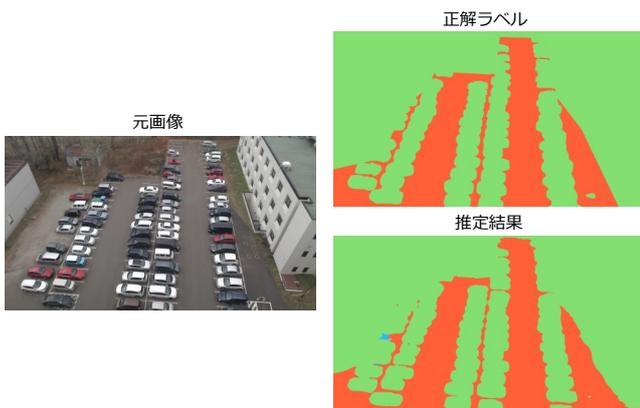


図 8 積雪割合が 0 の場合の誤判定画像

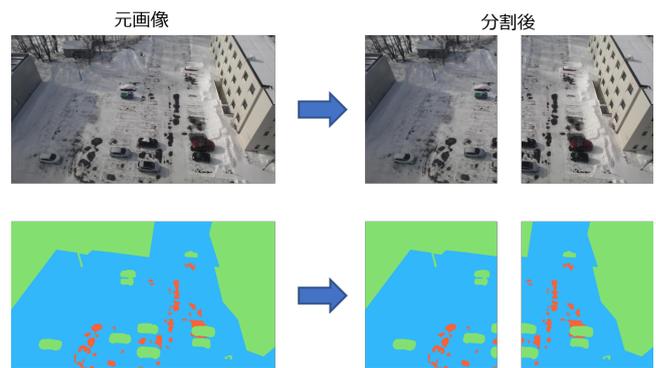


図 9 画像分割の方法

4.4 1 地点で学習したモデルの未知の地点への転用

これまでの実験では 1 地点から撮影された画像を用いて領域推定を学習し、同一地点の画像における推定精度を評価した。

そのため画像内の位置がほぼ固定される建物などの障害物の IoU は比較的高い値となった。ただこの積雪領域推定をボイラー制御に利用する上で、学習データが撮影された地点とは異なる地点にカメラを設置し、そのカメラで撮影された画像をもとにボイラーを制御する状況が考えられる。

このため、先の実験で用いた画像データを分割し汎化性能調査を行う。実験で利用した 1920 × 1080 ピクセルの撮影画像を横に分割し、図 9 に示すように 960 × 1080 ピクセルの画像を 2 枚用意した。正解マスクデータに対しても同様の操作を行う。分割した 2 枚の画像データを擬似的に別地点での撮影画像とみなすこととする。片方を訓練用データ、もう片方をテストデータとすることで、未知の地点における積雪領域推定について評価を行う。本実験ではラベル付けデータの 850 枚を用いて実施した。

4.4.1 左半分を訓練データ、右半分をテストデータとした場合

左半分を訓練データとし、右半分をテストデータとした場合の結果を述べる。画像ごとの各クラスの IoU 分布は図 10、図 11、図 12 のようになった。

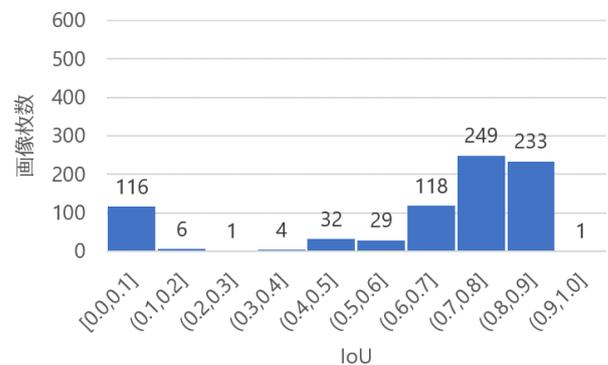


図 10 左半分の領域で訓練した際の積雪ラベル画像の IoU 分布

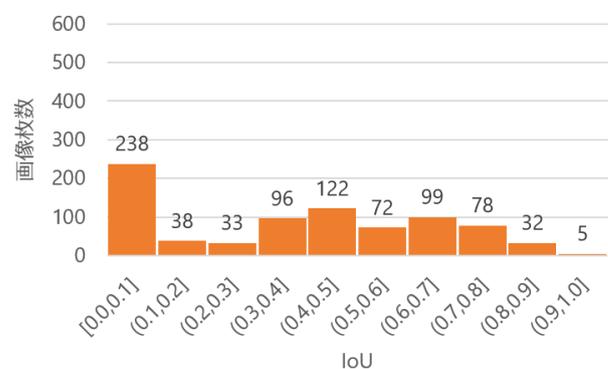


図 11 左半分の領域で訓練した際非積雪ラベル画像の IoU 分布

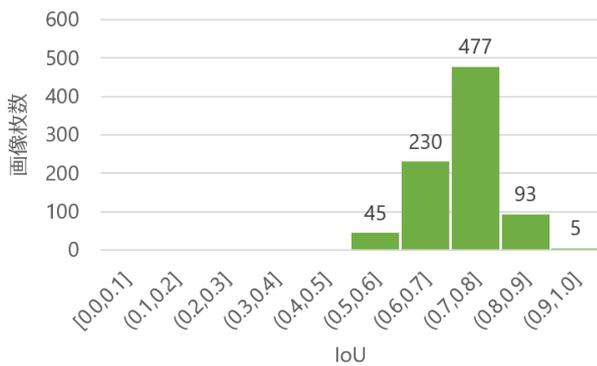


図 12 左半分の領域で訓練した際の障害物ラベル画像の IoU 分布

4.2 節で示した実験結果と比べると、全体的に各画像で IoU の値が下がっている。特に、積雪ラベルの IoU が 0 ~ 0.1 の範囲の画像が大きく増加している。こうした画像の例を図 13 に示す。

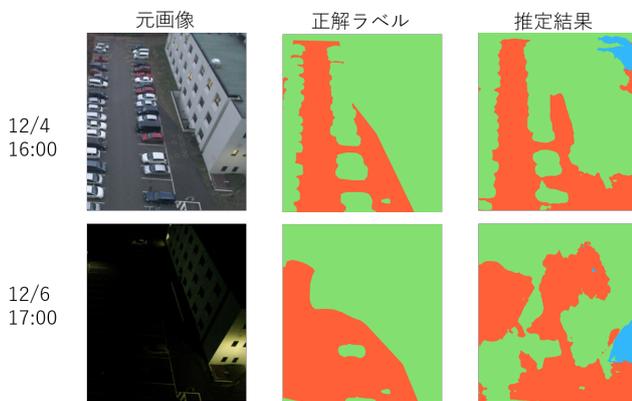


図 13 障害物を積雪領域として誤判定した事例

正解画像には積雪ラベルが付与された領域が存在しないものの、推定結果で建物の一部が積雪と誤判定された。そのためこの画像に対しては積雪ラベルの IoU が 0 となった。図 13 で見られるような障害物の一部を別ラベルとして判定する事例があるため、3 つの各ラベルで IoU が低くなるという結果になった。そのため未知の障害物に対する汎化性能は示されなかった。

4.3 節と同様に、正解データと推定結果の積雪割合の混同行列を表 4 に示す。4.2 節の実験と比較して誤判定枚数割合が増加しているが、極端な積雪割合の画像に対しては外れ値が少なくなっている。

4.4.2 左半分をテストデータ、右半分を訓練データとした場合

今度は右半分を訓練データとし、左半分をテストデータとして学習したモデルの推定結果を載せる。画像ごとの各クラスの IoU 分布は図 14、図 15、図 16 のようになった。

4.4.1 節の結果と比較すると、積雪ラベルと非積雪ラベルの IoU の画像枚数分布は似たような形になったが、障害物ラベルの IoU の画像枚数分布は精度が落ちる形となった。

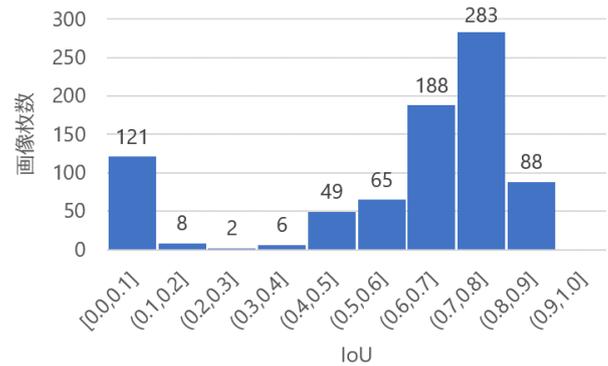


図 14 右半分の領域で訓練した際の積雪ラベル画像の IoU 分布

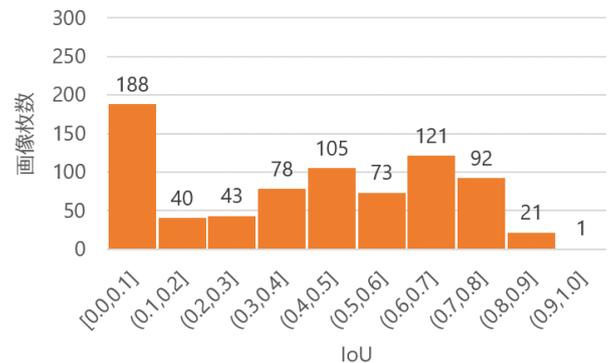


図 15 右半分の領域で訓練した際の非積雪ラベル画像の IoU 分布

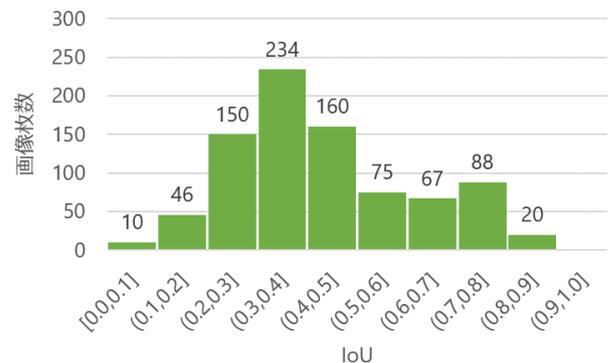


図 16 右半分の領域で訓練した際の障害物ラベル画像の IoU 分布

これは正解データで主に障害物ラベルを付与していた領域を正しく判定できていないからだと考えられ、建物のみが障害物ラベルのほとんどであった 4.4.1 節の実験よりも、様々なものを障害物ラベルとして意味付けしているためである。

4.3 節と同様に、正解データと推定結果の積雪割合の混同行列を表 5 に示す。4.2 節の実験と比較して誤判定枚数の割合が増加しているが、大きな外れ値はない結果となった。

5. 結論

セマンティックセグメンテーションにより、積雪、非積

表 4 左半分の領域で訓練した際の積雪割合の混同行列

		正解データ										
		0.0	(0.0,0.1]	(0.1,0.2]	(0.2,0.3]	(0.3,0.4]	(0.4,0.5]	(0.5,0.6]	(0.6,0.7]	(0.7,0.8]	(0.8,0.9]	(0.9,1.0]
推定結果	0.0	61	0	0	0	0	0	0	0	0	0	0
	(0.0, 0.1]	88	9	0	1	0	0	0	0	0	0	0
	(0.1, 0.2]	4	7	0	0	0	0	0	0	0	0	0
	(0.2, 0.3]	0	9	2	2	0	0	0	1	0	0	0
	(0.3, 0.4]	0	0	0	1	1	1	1	0	0	0	0
	(0.4, 0.5]	0	0	0	0	0	2	2	1	0	0	0
	(0.5, 0.6]	0	0	0	0	0	1	0	1	0	0	0
	(0.6, 0.7]	0	0	0	0	0	30	1	2	12	1	11
	(0.7, 0.8]	0	0	0	0	0	7	0	11	32	15	18
	(0.8, 0.9]	0	0	0	0	0	2	1	10	14	57	29
	(0.9, 1.0]	0	0	0	0	0	0	0	0	1	23	378

表 5 右半分の領域で訓練した際の積雪割合の混同行列

		正解データ										
		0.0	(0.0,0.1]	(0.1,0.2]	(0.2,0.3]	(0.3,0.4]	(0.4,0.5]	(0.5,0.6]	(0.6,0.7]	(0.7,0.8]	(0.8,0.9]	(0.9,1.0]
推定結果	0.0	40	0	0	0	0	0	0	0	0	0	0
	(0.0, 0.1]	90	2	8	0	6	0	0	0	0	0	0
	(0.1, 0.2]	7	0	6	1	0	0	0	0	0	0	0
	(0.2, 0.3]	2	2	5	0	0	0	3	1	1	0	0
	(0.3, 0.4]	0	2	1	2	1	5	2	0	0	0	0
	(0.4, 0.5]	0	0	0	0	3	19	4	0	0	0	0
	(0.5, 0.6]	0	0	0	0	2	16	3	2	2	1	28
	(0.6, 0.7]	0	0	0	0	0	6	0	26	6	12	12
	(0.7, 0.8]	0	0	0	0	0	0	1	10	17	7	7
	(0.8, 0.9]	0	0	0	0	0	0	0	0	27	40	24
	(0.9, 1.0]	0	0	0	0	0	0	0	0	0	24	364

雪，障害物の各領域の推定を行った．非積雪ラベルのIoUが低い結果となってしまっていたが，それが撮影画像内の非積雪領域が極端に小さい場合に限られ，今回想定したボイラー制御設定ではそこまで問題のない誤差であった．このことから，俯瞰画像からの積雪認識は十分可能であるといえる．その点はボイラー制御の評価の章でも確認されており，積雪割合に稼働判断に影響するほどの大きな誤差は見られなかった．また分割画像を用いた実験では，現状のデータセットでは1地点のみの学習で他地点に対する積雪認識をおこなうのは難しいことが明らかになった．画像内の固定の位置にある建物などの障害物を領域推定するためにはより多様な障害物を含んだデータセットの作成が必要である．

参考文献

[1] Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F. and Adam, H.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, *European Conference on Computer Vision (ECCV)*, pp. 801–818 (2018).

[2] 大竹義人，日朝祐太，高尾正樹，菅野伸彦，佐藤嘉伸：医用画像処理における深層学習の応用と展望，*医療機器学*，Vol. 88, No. 4, pp. 490–496 (オンライン)，DOI: 10.4286/jjmi.88.490 (2018).

[3] 中島道浩，安野貴人，永富大亮，野田一弘，青柳 聖，関口齊治：目視点検の損傷画像による鉄筋露出セグメンテーションの転移学習，*人工知能学会全国大会論文集* (2019).

[4] 川城研吾，安田 亨：セマンティックセグメンテーションを用いたトンネルの損傷抽出の取り組み，*情報処理学会第82回全国大会講演論文集*，pp. 233–234 (2020).

[5] Yasuno, T., Fujii, J., Sugawara, H. and Amakata, M.: Road Surface Translation Under Snow-covered and Semantic Segmentation for Snow Hazard Index, *CoRR*, (online), available from (<https://arxiv.org/abs/2101.05616>) (2021).

[6] Liang, C., Ge, J., Zhang, W., Gui, K., Cheikh, F. A. and Ye, L.: Winter Road Surface Status Recognition Using Deep Semantic Segmentation Network, *International Workshop on Atmospheric Icing of Structures(IWAIS)* (2019).

[7] 横山想一郎，山下倫央，川村秀憲，武田清賢：交通システム深層学習を用いた路面の積雪認識によるロードヒーティング制御，*画像ラボ*，Vol. 30, No. 6, pp. 27–33(オンライン)，入手先 (<https://ci.nii.ac.jp/naid/40021936404/>) (2019).

[8] Chollet, F.: Xception: Deep Learning with Depthwise Separable Convolutions, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1800–1807 (online), DOI: 10.1109/CVPR.2017.195 (2017).

[9] Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J. and Zisserman, A.: The PASCAL Visual Object Classes Challenge 2012 (VOC2012) Results, <http://www.pascal-network.org/challenges/VOC/voc2012/workshop/index.html>.