

深層学習を用いた冬期道路の路面領域判別に関する基礎的検討

A Fundamental study for drivable surface discrimination from photograph using deep learning

齊田光¹, 徳永ロベルト¹, 佐藤昌哉¹

¹Akira Saida, ¹Roberto Tokunaga and ¹Masaya Sato

¹国立研究開発法人 土木研究所 寒地土木研究所

¹Civil Engineering Research Institute for Cold Region, Public Works Research Institute

1. はじめに

近年の深層学習に関する技術の進歩は著しく、深層学習を用いた画像認識手法は道路交通分野でも活用が期待されている。例えば、深層学習を用いた画像認識は自動運転を実現するための要素技術として用いられており、車載カメラ画像を用いた車両や歩行者等の検出手法¹⁾などが提案されている。また、冬期道路管理分野では深層学習を用いてCCTVカメラ等の画像から路面雪氷状態(乾燥、積雪、圧雪など)を判別する手法が提案されている²⁾。

これらの技術を実用化する上で、CCTVカメラや車載カメラ等で得られた画像中の被写体が何であるかを画像の部位ごとに判別することは非常に重要である。例えば、画像中から路面領域を判別することができれば、自動運転車両の制御を行う際に車両が通行可能かどうかを車載カメラ画像から判断することや、路面雪氷状態の判別対象とすべき領域をCCTVカメラ画像等から自動で抽出することなどが可能となる。画像中の被写体が何であるかを画素毎に分類する手法は画像セグメンテーションと呼ばれており、近年では深層学習モデルを用いて画像セグメンテーションを高精度に行う手法が提案されている。例えば、Badrinarayananらは自動運転車両での使用を想定した深層学習による画像セグメンテーション手法を構築し、車載カメラ画像から車両や路面領域を判別する手法³⁾を提案している。また、このような交通空間の画像セグメンテーション手法の開発に用いるための学習用データセット⁴⁾は公開されており、同様の手法は多くの研究機関等で開発が進められている。

これらの深層学習を用いた画像セグメンテーションによる路面領域等の判別手法は、そのほとんどが非積雪時の道路空間を対象としてモデルの学習や精度検証が行われている。一方で、冬期の積雪寒冷地における道路では吹雪による視界不良や積雪・堆雪が発生する。このような条件下では車載カメラ等で撮影した画像の被写体が不鮮明になる、積雪により路面と路肩堆雪や天空との判別が難しくなるな

どの現象により路面領域の判別精度が低下するおそれがある。Panら⁵⁾は深層学習を用いた画像セグメンテーションを用いて、冬期道路空間を撮影した画像を画素毎に20のカテゴリ(車道、建築物、車両、堆雪など)に判別する手法を提案しているが、積雪や視界不良の有無と路面領域等の判別精度の関係は依然不明な点が多い。

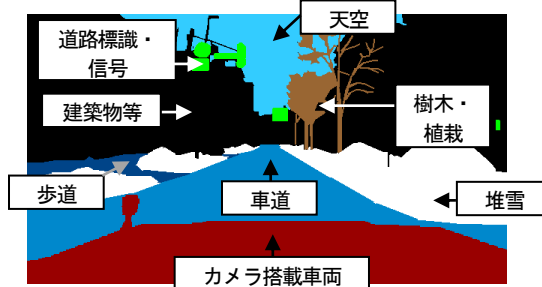
そこで本研究では、積雪時や吹雪による視界不良発生時等の画像データを用いて深層学習用データセットおよび画像セグメンテーションモデルを作成し、路面領域等の判別精度を非積雪時、積雪時および視界不良時のそれぞれについて検証したのでその結果を報告する。

2. 路面領域等判別モデルと学習用データセットの概要

本研究では、画像セグメンテーション手法として



(a) 車載カメラ画像



(b) 車載カメラ画像を基に作成したアノテーション画像

図-1 路面領域等判別モデルの学習用データセットとして使用した車載カメラ画像およびアノテーション画像の例

表-1 路面領域等判別モデルにより推定された被写体カテゴリー毎画素数と実際の被写体カテゴリー毎画素数の混同行列

		推定された被写体カテゴリー											再現率	適合率	IoU
		天空	建築物等	樹木・植栽	車道	路面標示	歩道	車両	歩行者	堆雪	道路標識・信号	カメラ搭載車両			
実際の被写体カテゴリー	天空	464748	5608	2517	22278	0	667	152	0	554	2	143	0.936	0.962	0.902
	建築物等	9264	180919	13918	18548	3	605	3802	0	4783	5	2984	0.770	0.816	0.656
	樹木・植栽	1895	7107	153514	2844	6	171	351	0	616	0	3700	0.902	0.864	0.790
	車道	2035	6965	3563	232542	175	1615	1108	0	8074	0	7775	0.881	0.624	0.576
	路面標示	0	1468	26	4902	799	50	37	0	31	0	318	0.105	0.808	0.102
	歩道	1193	4921	1333	7771	1	5263	141	0	5943	0	350	0.196	0.526	0.166
	車両	458	9993	575	1598	1	26	7317	0	1274	0	610	0.335	0.508	0.253
	歩行者	0	732	15	59	0	11	135	0	17	0	0	0.000	-	0.000
	堆雪	3442	2206	1852	58805	0	1443	664	0	53662	0	2083	0.432	0.709	0.367
	道路標識・信号	123	526	66	100	0	0	162	0	4	1	29	0.001	0.125	0.001
カメラ搭載車両	139	1353	320	23025	4	149	525	0	776	0	353617	0.931	0.952	0.889	

SegNet-Basic³⁾を使用し、画像から路面等が映っている領域を判別する深層学習モデル（路面領域等判別モデル）の構築を試みた。路面領域等判別モデルの学習に用いるデータセットには、図-1に示すような640×360pxの車載カメラ画像および車載カメラ画像を基に作成したアノテーション画像（車載カメラ画像に映っている被写体が何であるかを示す画像）のペアを200組用いた。車載カメラ画像は、2018、2019年度の冬期（積雪時）および2020年度の夏期（非積雪時）に札幌市および苫小牧市で撮影した画像を用いた。また、アノテーション画像は車載カメラ画像を基に、目視で画素毎に被写体を11のカテゴリー（天空、建築物等、樹木・植栽、車道、路面標示、歩道、車両、歩行者、堆雪、道路標識・信号および車載カメラ搭載車両）に分類し、各カテゴリーに対応した色で車載カメラ画像を塗り分けることで作成した。さらに、これらの車載カメラ画像およびアノテーション画像を左右反転した画像を生成し、学習用データセットの数を増加させた。その後、以上の方法で作成した学習用データセットの80%をモデルの訓練用として、20%をモデルの検証用としてそれぞれSegNet-Basicに入力し、640×360pxの画像中の被写体を11のカテゴリーに判別する路面領域等判別モデルを生成した。なお、モデルの学習および検証はPython 3.7.7およびKeras 2.3.1を用いて行い、学習回数は50回、学習率は 1.0×10^{-5} とした。

3. 路面領域等判別モデルの精度検証方法

本研究では、2.で生成した路面領域等判別モデルを用いて検定用データセットを対象に画像セグメンテーションを実行し、路面領域等判別モデルにより推定した判別結果と目視による実際の判別結果を比較することで路面領域等判別モデルの判別精度を検証した。検定用データセットの画像には、2018、2019年度の冬期および2020年度の夏期

に札幌市および苫小牧市で撮影した車載カメラ画像のうち、学習用データセットで用いたものとは別の地点および日時に撮影した画像を30枚（非積雪時、積雪時および視界不良時の画像を各10枚）用いた。また、検定用データセット中の被写体カテゴリーを画素毎に示す画像は、学習用データセットのアノテーション画像と同様の方法で作成した。

4. 路面領域等判別モデルの精度検証結果および考察

表-1は検定用データセットの全画像を対象として路面領域等判別モデルによる推定を行った時の、路面領域等判別モデルで推定された被写体カテゴリー毎の画素数と目視により判別した実際の被写体カテゴリー毎の画素数の混同行列を示す。また、同表には被写体カテゴリー毎のIoU（Intersection over Union、実際の被写体カテゴリーがAである領域と推定されたカテゴリーがAである領域がどの程度一致しているかを示す指標）、再現率（実際の被写体カテゴリーがAである画素について、推定したカテゴリーがAである比率）および適合率（被写体カテゴリーの推定結果がAである画素について、実際のカテゴリーがAである比率）を併せて示す。

カテゴリー毎のIoUは、車道カテゴリーで0.576、歩道カテゴリーで0.166となり、路面領域等判別モデルを用いると車道領域を概ね良好な精度で判別できることが確認された。一方で、路面領域等判別モデルにより歩道と推定された領域は実際の歩道領域とほとんど一致せず、少なくとも本研究で用いた路面領域等判別モデルでは冬期道路の歩道領域を判別することは困難であると考えられる。

各カテゴリーの再現率に着目すると、車道カテゴリーの再現率は0.881、歩道カテゴリーの再現率は0.196であった。この結果から、路面領域等判別モデルを用いると車道領域は概ね取りこぼすことなく判別が可能であるものの、歩道

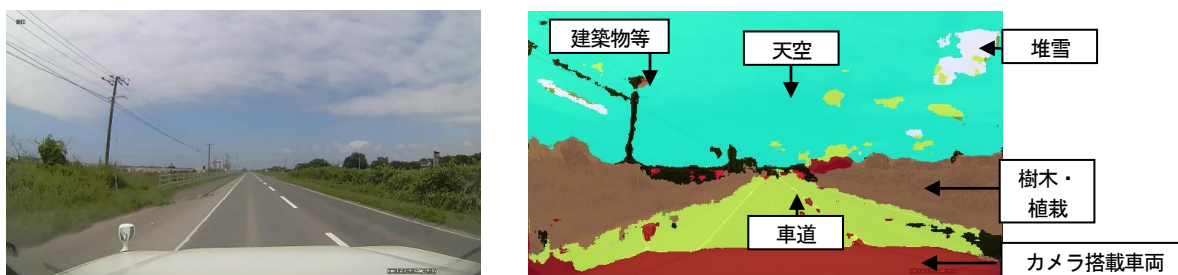


図-2 非積雪時における車載カメラ画像（左）および画像セグメンテーション結果（右）の例

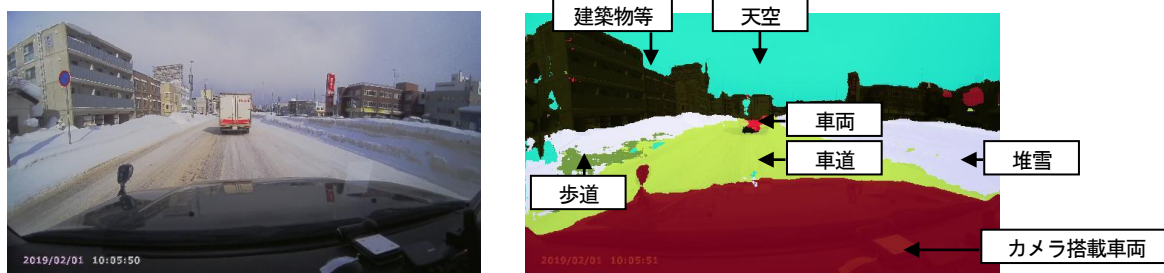


図-3 積雪時における車載カメラ画像（左）および画像セグメンテーション結果（右）の例




図-4 視界不良発生時における車載カメラ画像（左）および画像セグメンテーション結果（右）の例

領域は大部分が判別できず見逃してしまうことが明らかとなった。また、天空や樹木・植栽、カメラ搭載車両カテゴリの再現率は 0.8 以上であり、路面領域等判別モデルによりこれらのカテゴリに属する被写体の判別が精度良く行えることが確認された。他方、路面標示や歩行者、道路標識・信号カテゴリの再現率は 0.2 以下であった。

各カテゴリの適合率に着目すると、車道カテゴリの適合率は 0.624、歩道カテゴリの適合率は 0.526 であった。この結果から、路面領域等判別モデルにより車道と判別された領域は実際の画像でも概ね車道領域であること、路面領域等判別モデルにより歩道と判別された領域は約半数が歩道以外を映した領域であり誤判別が生じていることが明らかとなった。また、天空や建築物等、樹木・植栽、路面標示、カメラ搭載車両カテゴリの適合率は 0.8 以上であり、路面領域等判別モデルによる推定でこれらのカテゴリに判別された被写体は実際に推定結果と同じカテゴリに属している可能性が高いことが示された。一方で、道路標識・信号カテゴリの適合率は 0.2 以下と低く、路面領域等判別モデルによる推定結果がこれらのカテゴリである場合、実際の被写体は別カテゴリに属するもので

ある可能性が高い傾向にあった。以上の結果より、本研究で提案する手法で生成した路面領域等判別モデルは画像中の天空、建築物、樹木・植栽や車道が映っている領域を良好な精度で判別可能であること、および車両や歩行者、路面標示、信号・道路標識が映っている領域を判別することは困難であることが明らかとなった。

図-2 から図-4 は非積雪時、積雪時および吹雪による視界不良発生時の車載カメラ画像と路面領域等判別モデルによる車載カメラ画像の推定結果の例をそれぞれ示す。非積雪時の車載カメラ画像で車道が映っている領域は路面領域等判別モデルによる推定結果でも概ね車道であると判別された。路面領域等判別モデルを用いて図-2 に示すような非積雪時の車載カメラ画像 10 枚を対象として推定を行った場合の車道カテゴリの IoU は 0.748、再現率は 0.859 および適合率は 0.853 であることから、路面領域等判別モデルは非積雪時において車道領域を良好な精度で検出できることがうかがえる。一方で、車載カメラ画像中の歩道領域は大部分が車道または樹木・植栽であると誤って判別され、歩道カテゴリの IoU は 0.177、再現率は 0.246 および適合率は 0.386 となった。この理由としては、図-2 の車載




図-5 路面領域等判別モデルの学習に用いたデータセット数と推定のIoU, 再現率および適合率の関係

カメラ画像のように撮影地点から遠方に歩道が位置しているなどの理由により、隣接して存在する車道との境界が不明瞭であったためと考えられる。

路面領域等判別モデルを用いた車道領域の判別は積雪時においても良好な精度で行うことができ、路面領域等判別モデルによって図-3に示すような積雪時の車載カメラ画像10枚を対象として推定を行った場合の車道カテゴリのIoUは0.673, 再現率は0.821および適合率は0.789であった。図-3の推定結果からは、色相や彩度、明度が類似している車道領域と路肩・中央分離帯等の堆雪領域を概ね正確に判別できていることが見て取れる。他方、図-3の車載カメラ画像には堆雪等に遮られて歩道は映っていないが、画像セグメンテーション結果では画像左側に歩道領域と誤判別された領域が出現するなどの現象が見られた。

図-4に示すような吹雪による視界不良が発生している条件下では車道領域の一部が堆雪に誤判別される、天空領域の一部が車道領域に誤判別されるなどの現象が見られ、視界不良時の車載カメラ画像10枚を対象として推定を行った場合の車道カテゴリの再現率は0.954と高い値を示したものの、IoUは0.437, 適合率は0.446までそれぞれ低下した。吹雪による視界不良発生時の判別精度が低下する理由は、飛雪による画像のコントラスト低下により物体の表面形状に関する情報が失われることで、色相や彩度、明度が類似している天空、車道および堆雪の区別が困難になったためであると推察される。

以上のように、本研究で提案する手法で生成した路面領域等判別モデルは、非積雪時だけでなく視界不良が発生していない積雪時においても概ね良好な精度で車道領域を検出できる可能性があることが明らかとなった。

図-5は路面領域等判別モデルの学習に用いたデータセット数と、路面領域等判別モデルを用いて検定用データセットを対象に画像セグメンテーションを行った時の車道および歩道カテゴリのIoU, 再現率および適合率の関係を示す。車道および歩道カテゴリのIoU, 再現率・適合

率はいずれも学習用データセット数が増加するに従い上昇し、学習用データセット数が多くなるにつれて適合率および再現率の上昇が緩やかになる傾向が見られた。また、本検証では歩道カテゴリのIoU, 適合率および再現率は車道カテゴリのIoU, 適合率および再現率と比較して低くなる一方で、学習用データセット数を200以上とした場合にもIoU, 適合率および再現率が上昇し続ける傾向にあった。本研究で用いた学習用データセットでは、画像のうち歩道が映っている画素数が少なく、路面領域等判別モデルの学習が充分に行われなかった可能性がある。このため、これらのカテゴリに属する被写体の判別をより正確に行うためには、より多くの学習用データセットを用いて路面領域等判別モデルの学習を行う、またはIoUや適合率、再現率が低いカテゴリに属する被写体が大きく映っている画像を学習用データセットに用いて路面領域等判別モデルの学習を行うことが必要であると推察される。

5. おわりに

本研究では、冬期の積雪時や視界不良発生時などの条件下において、深層学習を用いた画像セグメンテーション手法により車載カメラ画像等から路面等が映っている領域を判別可能であるか検証を行った。その結果、積雪時の道路空間を撮影した画像等を基に生成した深層学習モデル(路面領域等判別モデル)は、非積雪時のみならず積雪時にも精度良く車道領域を判別できる可能性があることが明らかとなった。一方で、視界不良発生時には車道領域の判別精度が低下する、学習用データセット数の不足により歩道領域の判別精度に改善の余地があるなどの課題が確認できた。今後は路面領域等判別モデルの学習用データセット数を増やすことで歩道領域等の検出精度改善を試みる。

参考文献

- 1) 例えば, Michael Trembl et al.: Speeding up Semantic Segmentation for Autonomous Driving, proceedings of 29th Conference on Neural Information Processing Systems (NIPS 2016), 2016.
- 2) 吉永創, 川畑貴義, 山口隆志, 竹内茜, 大鹿美希: 雪氷作業の高度化と効率化に向けた技術開発と情報提供について, ふゆトピア研究発表会論文集, Vol.32, pp.121-124, 2020.
- 3) Vijay Badrinarayanan et al.: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, arXiv preprint arXiv:1511.00561, 2016.
- 4) Cityscapes Dataset, <https://www.cityscapes-dataset.com/> (2020/10/16 確認)
- 5) Zhaoyu Pan, Takanori Emaru, Ankit Ravankar, Yukinori Kobayashi: Applying Semantic Segmentation to Autonomous Cars in the Snowy Environment, arXiv preprint arXiv: 2007.12869, 2020.