

# 空領域の占有率を基準とした天気判断可能な車載カメラ画像の選抜 Selection of Vehicle-mounted Camera Images for Weather Forecasting Based on The Occupancy of Sky Area

末光 航大<sup>1)</sup> 遠藤 聡志<sup>2)</sup> 佐藤 俊輔<sup>3)</sup>  
Kodai Suemitsu Satoshi Endo Shunsuke Sato

## 1 はじめに

天気予報には現況の空情報を多く取得することが必要である。気象会社ウェザーニューズ(以下 WNI)では、気象情報アプリ「ウェザーニュース」のユーザーから空画像と現況天気を取得するウェザーリポートに取り組んでいる。ウェザーリポートは天気の変化を読み取る重要な手がかりとなっている。実際に、令和3年度の降雨捕捉率の全国平均において、WNIは気象庁よりも約8%高い予報精度を達成した<sup>\*1</sup>。しかし、亜熱帯気候に属する沖縄は予報の難しいゲリラ豪雨が頻繁に発生するため、全国で最も降雨捕捉率が低い。解決策としてユーザー以外からも空情報を取得することが考えられる。そこで我々は通信型車載カメラと深層学習による画像認識を活用したウェザーリポートの自動投稿システムを提案する。近年、車載カメラはデータを記録するだけでなく、記録データを有効活用することで新たな価値を生み出している。自動車保険では通信型車載カメラとAI分析を活用し、事故の検知から事故状況の伝達を自動化することに成功した<sup>\*2</sup>。そこで、通信型車載カメラから空画像と現況天気の予測結果をWNIに自動投稿することで、ユーザー以外にもウェザーリポートを取得できると考えた。提案システムは撮影、現況天気の予測、投稿の3つの処理を自動で行う必要がある。従来のウェザーリポートでは予報の手がかりとなる空の色や雲の形を伝えるために、空を広く撮影することを意識している。しかし、提案システムによる自動撮影では、トンネルなどの空領域が少ないシーンも撮影する場合がある。空領域が少ない画像は天気判断が困難かつ予報への手がかりが少ないため、精度向上につながるリポートと考える。よって、前処理として空領域に応じた天気判断可能な画像の選抜が必要である。

提案システムでは画素単位で特定カテゴリの領域検出が可能な Semantic Segmentation を用いて、画像全体に対する空占有率の予測結果から天気判断可能な画像の選抜を目指す。車載カメラ画像で構成されたデータセット BDD100K(Berkeley Deep Drive)[1]は Clear や Rainy といった天気ラベルが定義されている。しかし、空が遮蔽された画像は天気判断が困難なため天気ラベルが未定義である。以上の点から、天気ラベルの定義は空からわかる視覚情報が重要であると仮定した。本稿では、天気の視認性をもとに BDD100K から2つのデータ群を作成し、各データ群に対して Semantic Segmentation による空領域の予測

と空占有率の算出を行う。また、各データ群の空占有率の比較結果から、天気判断可能な車載カメラ画像の閾値を検討する。

## 2 研究背景

### 2.1 ウェザーリポート

ウェザーリポートとは、ウェザーニュースのユーザーから空画像と現況天気を獲得する取り組みである。図1にウェザーリポートの例を示す。ウェザーリポートの投稿には2つの処理が必要である。まずは、天気を読み解く上で重要な情報である空を広く撮影する必要がある。次に、現況の天気と体感、五感予想を選択肢から選択する。天気は曇り具合や雨の強さなどを基準に選択する。体感は暑いや寒い、五感予想は回復しそうや下り坂になりそうなどの直感的な情報をもとに選択する。空画像だけでなく天気情報を付与することで、明細な天気の現況を伝えることが可能である。空画像と3つの天気情報をもとに図1のウェザーリポートが作成され、WNIに投稿される。

WNIはウェザーリポートから各地の空や雲の形、色、高さを知ることで、観測レーダーより細かい地点の天気情報を取得することが可能となった。予報において現況天気のデータ量は最も重要であるため、ウェザーリポートは重要な情報源となる観測インフラである。しかし、ユーザーは投稿できる地点と時間帯が限定されるため、ユーザー以外からのデータ取得も求められる。



図1 ウェザーリポートの例

### 2.2 自動投稿システムの提案

#### step1) 自動撮影

通信型車載カメラは映像を記録するだけでなく、記録映像をLTE通信経由でクラウドなどにアップロードすることができる。自動車保険会社では、衝撃を検知すると、AIが動画画像から事故状況を分析し、分析結果を保険会社に伝えるサービスがある。以上のように、通信型車載カメラとAIを組み合わせることで、記録映像は事故後の証拠映像だけでなく、新たな価値を生み出すことができる。

1) 琉球大学大学院理工学研究科知能情報プログラム, Graduate School of Engineering and Science, University of the Ryukyus

2) 琉球大学工学部工学科知能情報コース, Computer Science and Intelligent Systems, University of the Ryukyus

3) 株式会社ウェザーニューズ, Weathernews, Inc

\*1 [https://weathernews.jp/ip/info/evaluation/2021/wni-jma\\_202101-12.html](https://weathernews.jp/ip/info/evaluation/2021/wni-jma_202101-12.html)

\*2 <https://www.ms-ins.com/personal/car/gk/mimamoru-dr.html>

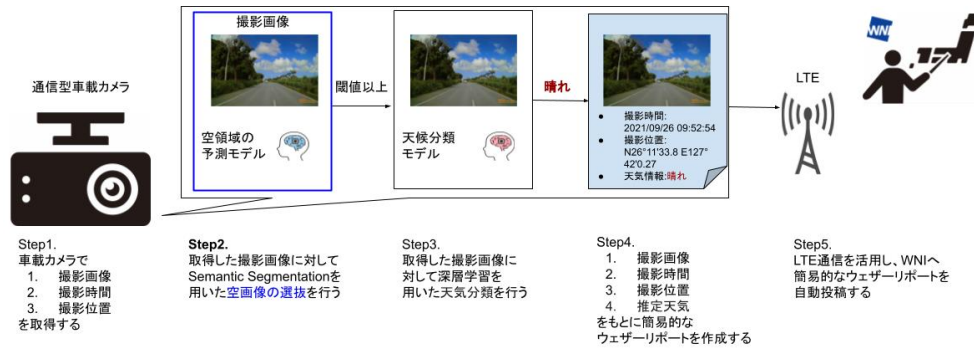


図 2 自動投稿までの流れ

WNI はウェザーレポートを取得することで予報精度を向上させた。そこで、我々は通信型車載カメラと深層学習による画像認識を活用したウェザーレポートの自動投稿システムを提案する。自動投稿までの流れを図 2 に示す。提案システムは 5 つの処理で構成されている。

#### step1) 自動撮影

車載カメラは動画だけでなく撮影位置と撮影時間も取得できる。提案システムの撮影時は撮影画像と撮影時間、撮影位置も自動取得する。

#### step2) 空画像の選抜

提案システムは自動撮影を想定しているため、常に空画像を撮影できる訳ではない。図 3 のような空が遮蔽された場面では空の様子を十分に捉えることができないため、現況天気の判断は困難である。そのため、空領域の大きさを指標とし、天気判断が可能な画像のみを選抜する必要がある。以上の課題を解決する手法として Semantic Segmentation によるアプローチの適用を次節で検討する。



図 3 空を捉えていない画像例

#### step3) 天気分類

ウェザーレポートは空画像だけでなく天気情報も付与することで明細な天気の現況を伝えることができる。そのため、提案システムでは選抜された空画像に対して画像分類を用いた天気分類を行い、天気情報を付与する。

#### step4) ウェザーレポートの作成

Step1 で取得した撮影画像、撮影時間、撮影位置と Step3 で予測した天気情報をもとに簡易的なウェザーレポートを作成する。

#### step5) ウェザーレポートの投稿

LTE 通信を通して簡易的なウェザーレポートを自動投稿する。

提案システムは走行中の幅広い時間と距離に応じた現況天気の自動取得が期待できる。

### 3 アプローチ

提案システム実現の第 1 段階として空画像の選抜を実装する。この処理のアプローチとして、Semantic Segmentation を用いた空領域の予測と空占有率を基準とした選抜を提案する。Semantic Segmentation とは、画像内の全画素に対して事前に設定したカテゴリを割り当てることで、設定カテゴリの領域を検出する手法であ

る。Olaf らは畳み込みによる特徴抽出とアップサンプリングによる特徴マップの拡大を行う Encoder-Decoder 形の U-Net[2] を提案した。Chen らはプリーングによる空間情報の損失を考慮した Atrous 畳み込み層を取り入れた DeepLabv3+[3] を提案した。これら手法は画素単位で特定領域の検出が可能であるため、車や道路領域の予測が必要とされる自動運転分野で活用されている。

本稿では画像全体に対する空占有率を求めるために、空領域の予測が必要である。そのため、画素単位で特定領域の予測が可能な Semantic Segmentation を用いて、空領域および空占有率を求める。

### 4 実験概要

本稿では天気判断が可能なデータ群と困難なデータ群を作成し、各データ群に対して空領域の予測と空占有率の算出を行った。また、各データ群の空占有率の比較結果から、天気判断可能な画像の選抜基準となる空占有率を検討した。

#### 4.1 データ群の作成方法

BDD100K[1] は UC Berkeley が公開している自動運転マルチタスクデータセットである。10 万枚以上の車載カメラ画像で構成されており、1 枚の画像に対して時間と天気に関する教師ラベルが付与されている。時間ラベルは Daytime, Dawn/Dusk, Night の 3 種類である。天気ラベルは Clear, Partly-Cloudy, Overcast, Rainy, Foggy, Snowy, Undefined の 7 種類である。以下のラベル条件をもとに、BDD100K から画像を選択し 2 つのデータ群を作成した。

天気判断が可能な画像のラベル条件

- 時間ラベルが Daytime であること
- 天気ラベルが Clear, Partly-Cloudy, Overcast, Rainy のいずれかであること

天気判断が困難な画像のラベル条件

- 時間ラベルが Daytime であること
- 天気ラベルが Undefined であること

各データ群は空の状態が鮮明にわかる時間ラベル Daytime のみを対象とした。図 4 中央と右の時間ラベル Dawn/Dusk, Night の画像は空を捉えているが輝度や明度の影響で天気判断が困難であることがわかる。よって、時間ラベル Daytime の画像のみを用いて検証する。次に天気ラベルをもとに各データ群の画像を選択した。提案システムの目的は沖縄の降雨捕捉率の向上であるため、沖縄の気候を考慮する必要がある。そこで、図 5 左側の天気ラベル Clear, Partly-Cloudy, Overcast, Rainy の画像のみを扱う。これらは空の様子から天気判断が可能であるため適



切な天気ラベルが付与されていると考えた。反対に、図 5 右側のような視覚情報のみでの天気判断が困難な画像は天気ラベル Undefined が付与されている。そこで、本稿では天気ラベル Clear, Partly-Cloudy, Overcast, Rainy の画像らを天気判断が可能な画像、天気ラベル Undefined の画像らを天気判断が困難な画像として選択し、二つのデータ群を作成した。また、天気ラベルが付与されたデータ群を WDD(Weather Define Data)、天気ラベルが undefined のデータ群を WUD(Weather Undefine Data) と表記する。各データ群の合計枚数は WDD が 11431 枚、WUD が 8023 枚である。



図 4 各時間ラベルの画像例



図 5 各天気ラベルの画像例

## 4.2 モデル

本稿では前説で説明した 2 つのデータ群に対して空領域の予測と空占有率の算出を行う。BDD100K には Semantic Segmentation タスクの教師データとして、1 万枚のアノテーションマップが含まれている。アノテーションマップには研究テーマである空だけでなく、空を遮蔽する恐れのある木や建物など 19 種類のカテゴリが設定されている。BDD100K ではこれら教師データによって学習と評価が行われた 15 種類の学習済みモデル<sup>\*3</sup>が公開されている。その中から、正解領域と予測領域の一致率を表す mIoU(mean Intersection over Union) が最も高い DeepLabv3+[3] を用いて実験を行った。学習済みモデル DeepLabv3+ は mIoU が 57%、空領域のみに対する IoU は 94.42% であることから、十分な精度で空領域を予測できると考えた。

以上を踏まえ、本稿では BDD100K による事前学習済みモデル DeepLabv3+ を用いて、WDD と WUD の空領域の予測と空占有率の算出を行う。そして、また、各データ群の空占有率の比較結果をもとに天気判断可能な画像の選抜基準となる空占有率を検討する。

## 5 結果と考察

### 5.1 空領域の予測結果と考察

学習済みモデルを用いた WDD と WUD の予測画像を図 6 に示す。図 6 の上段右側の WDD に対する予測画像から空領域を正確に予測できたことが分かる。空占有率は予測された空領域をもとに約 33.13% と算出された。図 6 の下段右側の WUD に対する予測画像から空を遮蔽し

ている木や建物を正確に予測できたことが分かる。木や建物を正しく予測できたため、約 1.65% の僅かな空占有率を算出できた。



図 6 予測画像の例 (上段:WDD, 下段:WUD)

図 7 は WUD を入力画像とした際に空占有率が正しく算出されなかった例である。図 7 左側の入力画像から、空は天井や壁の影響で全く映っていないことが分かる。しかし、図 7 右側の予測画像から、モデルは天井を空と誤って予測したことが分かる。空以外の領域を空領域と誤って予測したため、空占有率は 22.71% と不正確であった。予測ミスの要因として、モデルが天井などの設定カテゴリに含まれない物体を学習していないことが考えられる。図 8 に BDD100K の元画像とアノテーションマップ画像、予測画像を示す。BDD100K は 19 種類の物体をカテゴリとして設定しているが、画像中には設定カテゴリ外の物体も含まれている。例えば、図 8 元画像の赤丸で囲まれた高架橋は設定カテゴリ外である。アノテーションマップ画像から設定カテゴリ外の物体は黒色でアノテーションされていることが分かる。モデルは全画素に対して 19 種類の設定カテゴリの中から予測するため、黒色の設定カテゴリ外の画素は必ず誤って予測される。特に高架橋のような上部に位置する設定カテゴリ外の物体は、同じく上部に位置する空と予測する傾向がある可能性がある。



図 7 空領域と誤認識した予測画像

このように、学習済みモデルは空領域を正しく予測できるが、上部に位置する設定カテゴリ外の物体を空領域として誤認識し本来の空占有率よりも大きく算出する場面もある。しかし、このような場面は木や建物といった設定カテゴリが空を遮蔽する場面に比べて稀である。よって、学習済みモデル DeepLabv3+ はほとんど場面で正確な空占有率の算出ができるため十分な有効性があると考えられる。

### 5.2 各データ群の空占有率の比較

予測結果の考察から、モデルは正確に空領域を予測できることを確認した。そこで、WDD と WUD から空占有率を算出し、空占有率の比較から二つのデータ群の性質の違いを考察する。図 9 に WDD と WUD の空占有率の

\*3 [https://github.com/SysCV/bdd100k-models/tree/main/sem\\_seg](https://github.com/SysCV/bdd100k-models/tree/main/sem_seg)




図 8 設定カテゴリ外のアノテーション

比較結果を示す。縦軸の度数は枚数、横軸の 2%毎に区切った階級は空占有率を表している。橙の WUD は半数以上が空占有率 6%以下に分布し、空占有率が増えるにつれて枚数は急激に減少している。青の WDD も空占有率が増えるにつれて枚数が減少しているが、WUD と比べると緩やかな減少である。そのため、空占有率 20%以上に分布する大半のデータは WDD であった。空占有率の比較結果から、天気ラベルが定義された WDD と未定義な WUD は空占有率に大きな違いがあることが分かった。

以上の比較結果から、車載カメラにおける天気判断は空占有率が大きいほど可能であることが示唆された。そのため、提案システムにおいて空占有率を基準とした選抜は天気判断可能な画像を選抜するのに有効的と考える。また、空占有率 20%以上に分布する大半のデータが WDD であることに着目し、提案システムでは空占有率 20%以上であれば天気判断可能な画像として選抜する。




図 9 各データ群の空占有率の比較結果

## 6 提案システムの有効性の検証

次に、沖縄で撮影した車載カメラ映像を用いて提案システムおよび空画像の選抜の有効性を検証する。検証方法を図 10 に示す。

### step1) 映像の取得

映像はアメダスが設置されている南城市糸数から那覇市の沖縄気象台を通過し、沖縄市胡屋のアメダスに向けて約 36km を走行し撮影した。撮影日時は 2022 年 4 月 24 日、車載カメラは KENWOOD 社の DRV-MR740 を使用した。

### step2) フレーム画像の生成

気象機関では、数 km の格子状に区切ったメッシュごとの気象を観測している。雲の動きはメッシュが小さいほど正確に捉えることができる。WNI は一般的な 1km メッシュの 1/4 サイズである 250m メッシュで観測することで、1 時間間隔の予報を 5 分間隔に短縮できた。

提案システムにおいても 250m 間隔で自動撮影し、雲の細かい変化を捉えることを目指す。車の速度を時速 40km/h と仮定すると秒速は約 11m/s である。そのため、20 秒間隔でフレーム画像を生成することで、250m 間隔程度の車載カメラ映像を取得できると考えた。

### step3) 空画像の選抜

学習済みモデルを用いて、空占有率 20%以上の空画像を選抜する。選抜画像は視認性をもとに天気判断が可能であることを評価した。



図 10 沖縄の車載カメラ映像を使った検証方法

検証結果として、全フレーム画像 217 枚の内、選抜された 198 枚のフレーム画像は天気判断可能であることが確認できた。また、選抜画像の中には天気の変化を捉えた画像があった。図 11 に天候変化を捉えた選抜画像を示す。初めは黒い雲から雨が降っていたが、20 秒後のフレームから青空が徐々に見え始め、晴れたことが確認できる。このような急激な天気の変化を捉えることは時間解像度の細かい予報に役立てることができている。提案システムは 250m 毎の自動撮影を基本としているが、天候変化の状況に応じて撮影頻度を高くすることで更なる有効性が期待できる。



図 11 天候変化を捉えた選抜画像

## 7 今後の展望

本研究ではウェザリポートによる予報精度向上に着目し、通信型車載カメラと画像認識を用いたウェザリポートの自動投稿システムを提案した。提案システムの第一段階として天気判断可能な空画像を選抜する必要があるため、BDD100K による学習済みモデル DeepLabv3+ を用いた空領域の予測と選抜基準となる空占有率を調査した。実験結果から、ほとんどの場面で空領域を正確に予測し空占有率を算出できた。また、天気の視認性をもとに作成した WDD と WUD の空占有率の比較結果から、空占有率 20%以上であれば天気判断可能な画像を選抜できることが示唆された。今後の展望として、選抜した車載カメラ画像に対して天候状況を付与するために、空や雲の色、道路のテクスチャを考慮した天候分類モデルの作成に取り組む。

### 参考文献

- [1] Fisher Yu, Haofeng Chen, et al. " BDD100K: A Diverse Driving Dataset for Heterogeneous Multitask Learning ". IEEE Conference on Computer Vision and Pattern Recognition. 2020.
- [2] Olaf Ronneberger, Philipp Fischer, et al. " U-Net: Convolutional Networks for Biomedical Image Segmentation ". Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. 2015.
- [3] Chen, Liang-Chieh, et al. " Encoder-decoder with Atrous Separable Convolution for Semantic Image Segmentation. " Proceedings of the European Conference on Computer Vision. 2018.