

# 天気情報収集のための車載カメラ画像を活用した降雨強度と雲の種類 の推定 Estimating Rainfall Intensity and Cloud Types Using Dashcam Images for Monitoring Current Weather Conditions

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

天気予報には気象現況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、天気アプリ「ウェザーニューズ」のユーザーから空画像と天気情報を取得するウェザーリポートに取り組んでいる。ウェザーリポートを活用することで、令和 4 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天気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。提案システムは撮影、現況天気 の予測、投稿の 3 つの処理を想定している。

従来のウェザーリポートは、空画像と曇り具合や降雨強度といった天気情報もユーザーから取得している。気象予報士は観測レーダーに映らない積乱雲のような雷雨の前兆となる雲をリポートで検出している。それにより、WNI はゲリラ豪雨の発生兆候を掴み、予測を可能にした。そのため、提案システムにおいても、撮影画像から、降雨強度と雲の種類 の天気情報を予測し、付与することを目指す。以上を踏まえ、本稿では、車載カメラ画像から降雨強度と雲の種類 の分類に取り組む。画像分類は、画像の内容をラベルで識別するが、分類に関係ない不要な情報は、特徴量の重要度を低下させ、分類器の判断力を弱める。そこで、分類精度の向上を目的とした、Semantic Segmentation を用いたマスク処理による特徴量選択を行う。Semantic Segmentation は空領域と路面領域の予測に用いる。雲の種類 の分類は予測された空領域以外にマスク処理を行い、空と雲の特徴量のみで学習させる。降雨強度の分類は、予測された路面領域以外にマスク処理を行い、路面の特徴量のみで学習させ、有効性を検証する。

## 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、天気アプリ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、予報する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。天気は曇り具合や降雨強度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。WNI はウェザーリポートから細かい地点の天気情報を取得できるが、ユーザーの投稿には限界があるため、他のデータ源の検討が必要である。



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

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<sup>\*2</sup>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。

WNI はウェザーリ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リ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 6 つの処理で構成されている。

#### step1) 自動撮影

車載カメラは動画画像だけでなく撮影位置と撮影時間も取得できる。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) 降雨強度の分類

従来のウェザーリポートの場合、ユーザーは表 1 の一列目の 5 つの擬音をもとに降雨強度を直感で選択する。WNI はこれら 5 つの指標から、現況の降雨強度を把握している。ユーザーは視覚情報だけでなく、聴覚情報である雨音も手がかりにして、細かい降雨強度の選択を行っている。しかし、提案システムでは、車載カメラ画像の視覚情報のみで分類するため、従来の細かい分類は困難と考えた。そこで、提案システムでは、WNI の指標であるポツポツとパラパラを「小雨」、サーを「中雨」、ザーザー、ゴォーを「大雨」とし、降雨強度を 5 段階から 3 段階に減らす。さらに、晴れ曇りを追加した 4 段階評価での分類を行い、降雨強度を付与する。表 1 の二列目に提案システムにおける降雨強度の区分指標を示す。

#### step3) 空画像の選抜

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/s/topics/202212/230215/>

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



図2 自動投稿までの流れ

WNI	提案システム	降雨量	目安
-	晴れ曇り	0mm	雨なし
ポツポツ	小雨	1mm 未満	傘無しでも OK
パラパラ		1~2mm	傘が必要
サー	中雨	2~4mm	並みの雨
ザーザー	大雨	4~10mm	大きい傘が必要 外出うんざり
ゴォー		10mm 以上	土砂降り 外出は苦痛

表1 WNI と提案システムにおける降雨強度の指標比較

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。トンネル内のような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、現況天気判断は困難である。そのため、著者ら [1] は Semantic Segmentation を用いた空占有率の予測を行い、空占有率が 20%以上あれば空画像として適切であることを示した。

#### step4) 雲の種類分類

雲は気象状況を理解するための手がかりとなっている。乱層雲や積乱雲は雨の兆しであり、特に積乱雲はゲリラ豪雨の原因となることが多い。そこで、空画像から雲の種類を分類し、ゲリラ豪雨の発生地点を早期に把握することを目的とする。提案システムは、「積乱雲」「乱層雲」「その他」の3種類の雲の種類に空画像を分類し、雲の種類情報を付与する。

#### step5) 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, Step4 で予測した降雨強度と雲の種類をもとに簡易的なウェザーレポートを作成する。

#### step6) 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。

提案システムは以上の6つの処理を行うことで、走行中の幅広い時間と距離に応じた現況の空画像と気象情報の自動取得ができる。著者ら [1] は、これまでに step3 の空画像の選抜を Semantic Segmentation を用いて行った。そのため、本稿では、step2 と step4 の降雨強度と雲の種類分類モデルの学習と精度評価を行う。

## 3 実験概要

本実験では降雨強度と雲の種類分類モデルの学習及び精度評価を行い、有用性を検証することを目標とする。

## 3.1 データセット

### 3.1.1 降雨強度の分類におけるデータセット

データセットは自前の車載カメラで収集した画像を用いて作成した。自作データセットは表1の二列目のように降雨強度を4段階で区分し、手動でアノテーションを行った。アノテーション方法は、車載カメラ画像から取得した撮影位置と撮影時刻を基に、気象庁の公開している10分間ごとの降雨量<sup>\*3</sup>を参照し、表1の二列目に表示指標でラベル付を行なった。図3に各ラベルの画像例を示す。データセットは晴れ曇りが868枚、小雨が604枚、中雨が687枚、大雨が604枚の合計2763枚であり、9割を訓練データ、1割をテストデータとして使用する。



図3 沖縄の各降雨強度ラベルの画像例

### 3.1.2 雲の種類分類におけるデータセット

データセットは Jinglin ら [2] によって構築された雲画像データセット Cirrus Cumulus Stratus Nimbus (CCSN) を用いる。CCSN は世界気象機関が定義した、積乱雲や乱層雲などの10種類の雲と飛行機雲を合わせた11種類の雲画像で構成されており、合計2543枚のデータセットである。実験では、CCSN を用いて、積乱雲と乱層雲とその他(残りの9つのラベル)でデータセットを再構築した。図4に各ラベルの画像例を示す。データセットは積乱雲が239枚、乱層雲が273枚、その他が248枚の合計760枚であり、8割を訓練データ、2割をテストデータとして使用する。

\*3 <https://www.data.jma.go.jp/obd/stats/etrn/index.php>



図 4 雲形ラベルの画像例

### 3.2 モデル

本実験では, ImageNet による学習済みモデル EfficientNet を用いて, 各データセットを学習させる. EfficientNet は, CNN のモデルスケールが自動化されたモデルである. 従来の CNN は, ネットワークの深さ, 幅, 解像度のいずれか一方を拡大することで精度を向上させていたが, EfficientNet はこれらの要素をバランスよく拡大することで, 計算量とパラメータ数を削減しながら高い精度を達成した. EfficientNet は, ImageNet などの様々なデータセットで高い精度を達成しており, 画像認識の分野において汎用性の高い手法である. そのため, 本実験においても, 高い精度が期待できる.

なお, 最適化には Adam を使用し, 学習率は  $5 \times 10^{-4}$ , バッチサイズは 32, epoch 数は 30 で学習した.

### 3.3 マスク処理による特徴量選択

画像分類は, 画像の内容をラベルによって識別するタスクである. 画像分類の精度は, 画像から抽出される特徴量に大きく依存する. しかし, 画像には分類に関係ない背景などの不要な情報が含まれていることが多い. これらの情報は, 特徴量の重要度を低下させ, 分類器の判断力を弱める可能性がある. そこで, 画像の不要な箇所を隠し, 分類に重要な箇所のみを学習させることで, 特徴量の精度や表現力を向上できると考えた.

降雨強度の分類では, 図 3 から分かるように, 天気によって空や雲の色や路面の濡れに違いがある. そのため, 空と路面の特徴量が重要だと考えた. しかし, 曇りと雨の空は似ているため, 路面のみの特徴量を用いて学習させることが適切だと判断し, 路面以外の領域に対してマスク処理を行い学習させる. 雲の種類は雲の形や現れる高さをもとに十種類に定義されたことから, 雲の種類の分類では, 雲の形や高さが重要な特徴量になると思い, 空以外の領域に対してマスク処理を行い学習させる.

本実験では, 分類精度の向上を目的としたアプローチとして, 各データセットに対して, Semantic Segmentation を用いたマスク処理による特徴量選択を行う. 図 5 にマスク画像の作成手順を示す. まず, 元画像に対して, Semantic Segmentation を用いて特徴として必要な領域を予測し白にカラーマップ化する. 降雨強度データセットであれば路面, 雲形データセットであれば空の領域を予測した. また, 不必要な領域は全て黒にカラーマップ化した. 最後に, 画像処理ライブラリの OpenCV を用いて, 元画像と予測画像を合成してマスク画像を作成した. 実験では, 自動運転用データセット BDD100K[3] による学習済みモデル Deeplabv3+<sup>\*4</sup> を使用し, 予測を行った. モデルは BDD100K に対して空領域のみに対する IoU は 94.41%, 路面領域のみに対する IoU は 94.43% を達成したことから, 十分な精度で空と路面の領域を予測できると考えた.

\*4 [https://github.com/SysCV/bdd100k-models/tree/main/sem\\_seg](https://github.com/SysCV/bdd100k-models/tree/main/sem_seg)




図 5 マスク画像の作成手順 (上段: 降雨強度データセット, 下段: 雲形データセット)

## 4 結果と考察

### 4.1 降雨強度の分類結果と考察

表 2 に全体領域から特徴量を学習させた全体領域モデルとマスク処理を行い路面の特徴量のみで学習させた路面領域モデルのテストデータに対する F 値と Acc を示す. F 値から, どちらのモデルも晴れ曇りと大雨に対して高い精度で分類できるが, 小雨と中雨に対しては精度が下がる傾向になることがわかる. 小雨と中雨の精度が低い要因は, アノテーションの難しさである. アノテーションは, 撮影位置に近い観測レーダーの降雨記録に基づいている. しかし, 撮影位置と観測レーダーの位置が離れていると, 誤差が生じるため, アノテーションが正確でない可能性がある. 特に, 小雨と中雨は降雨量の差が小さいので, 判別が複雑である. 小雨と中雨の分類精度を向上させるには, データ収集時の撮影位置を調整し正確にアノテーションを行う必要がある.

また, 路面領域モデルの Acc は, 全体領域モデルより 0.11 低く, 路面の特徴量のみでは精度向上しないことがわかった. マスク処理による精度低下の要因を Grad-CAM[4] を用いて調べた. 図 6 に可視化結果を示す. 分類根拠と思われる箇所は暖色でヒートマップ化される. 図 6 上段の画像は, 車のテールランプあたりを注視している. また, 図 6 下段のマスク画像は路面に反射する車のライトを注視していることが確認できる. このことから, 降雨強度を分類する上で, 路面だけでなく, 車のライトも分類根拠となっているからと考える. 雨が降る場合, 雲の中の水分が結合し水滴が大きくなることで雨が降る. 水滴が大きいくほど, 雲は厚く, 低くなるため, 透過する太陽の光が減らす. そのため, 画像全体の明るさが低くなる. さらに, 降雨量が大きいくほど雲の水滴が大きくなり, 太陽の光をさらに減らす. つまり, 降雨量が大きくなるにつれて画像の明るさが暗くなり, 車のライトがより強調されるため, 重要な特徴量になった可能性がある.

このことから, 路面領域モデルは, 車のライトを特徴量として学習できなかったため, 精度が低下したと考察する. しかし, 路面は 90%以上の精度を達成したことから, 降雨強度を分類する上で重要な特徴量であることが示された.

モデル	F 値				Acc
	晴れ曇り	小雨	中雨	大雨	
全体領域モデル	1	0.86	0.85	1	<b>0.936</b>
路面領域モデル	1	0.82	0.86	0.98	0.925

表 2 全体領域モデルと路面領域モデルの精度比較

### 4.2 雲の種類分類結果と考察

表 3 に全体領域の特徴量で学習させた全体領域モデルとマスク処理で空の特徴量のみで学習させた空領域モデル

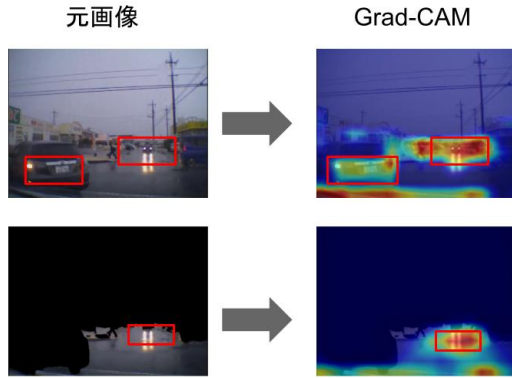


図6 Grad-CAMによる分類根拠の可視化の結果(上段:全体領域モデル,下段:路面領域モデル)

ルのテストデータに対するF値とAccを示す。F値から、積乱雲は高い精度で分類できたが、乱層雲とその他は精度が低いことがわかる。乱層雲は、その他に含まれる層積雲や層雲から変化するため、図7に示すように形や色が非常に似ている。そのため、乱層雲は積乱雲と比べて、分類が難しいと考える。

また、空領域モデルのAccは全体領域モデルと比較して、0.348高く、マスク処理による空の特徴量選択が効果があることがわかった。図8に全体領域モデルと空領域モデルの予測画像に対するGrad-CAMの可視化結果を示す。図8上段の可視化結果から、全体領域モデルは下に位置する白のヨットを注視している。下段の可視化画像はマスクされているため、雲のみを注視している。空領域モデルはマスク処理によって不要な情報を消去し、空と雲の特徴量のみで学習した。そのため、空領域モデルは全体領域モデルに比べて、雲の形状や色などの視覚的な特徴を分類の手がかりにする傾向になったと考察する。

モデル	F 値			Acc
	積乱雲	乱層雲	その他	
全体領域モデル	0.86	0.59	0.66	0.701
空領域モデル	0.86	0.68	0.67	<b>0.736</b>

表3 全体領域モデルと空領域モデルの精度比較



図7 乱層雲と層積雲と層雲の画像例

## 5 今後の展望

現況の空画像と天気情報の付与したウェザーレ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ーレポートの自動投稿システムを提案した。本研究では、天気情報の付与を目的に、車載カメラ画像から降雨強度の分類と雲の種類の分類を行った。また、各データセットにマスク処理による特徴量選択を行い学習させ、精度向上を目指した。降雨強度の分類では、路面の特徴量のみを学習させたが、車のライトも重要な分類根拠であったため、精度向上には至らなかった。し

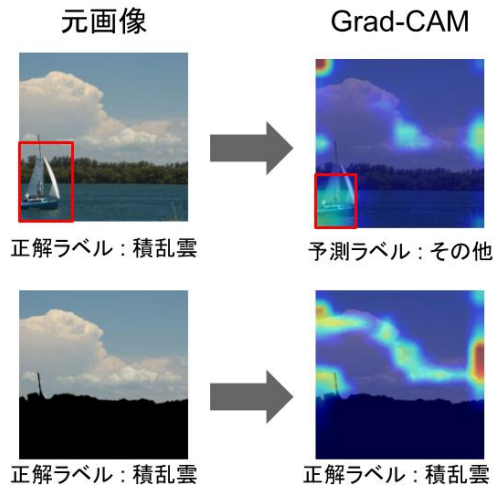


図8 Grad-CAMによる分類根拠の可視化の結果(上段:全体領域モデル,下段:空領域モデル)

かし、路面特徴量のみで、90%以上の精度を達成しているため、降雨強度における路面の重要性が示唆された。雲の種類分類では、雲と空の特徴量のみを学習させることで、建物などの重要でない箇所を注視した誤分類が減り、3.5%高い、73.6%の分類精度を達成した。しかし、データセットが少量のサイズであることや車載カメラの画角でないことから、提案システムを想定した汎用性の検証が必要である。今後の展望としては、車載カメラの画角に合わせたデータセットの作成や拡張を行い、実際の提案システムに近い環境での分類精度を評価を検討する。

### 謝辞

本研究はJSPS科研費23K11234の助成を受けたものです。

### 参考文献

- [1] Kodai Suemitsu, Satoshi Endo, and Shunsuke Sato. Selection of dash cam images for weather forecasting based on the sky occupancy. In *2022 Joint 12th International Conference on Soft Computing and Intelligent Systems and 23rd International Symposium on Advanced Intelligent Systems (SCIS&ISIS)*, pp. 1–8. IEEE, 2022.
- [2] Jinglin Zhang, Pu Liu, Feng Zhang, and Qianqian Song. Cloudnet: Ground-based cloud classification with deep convolutional neural network. *Geophysical Research Letters*, Vol. 45, No. 16, pp. 8665–8672, 2018.
- [3] Fisher Yu, Haofeng Chen, Xin Wang, Wenqi Xian, Yingying Chen, Fangchen Liu, Vashisht Madhavan, and Trevor Darrell. Bdd100k: A diverse driving dataset for heterogeneous multitask learning. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pp. 2636–2645, 2020.
- [4] Ramprasaath R Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, and Dhruv Batra. Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision*, pp. 618–626, 2017.