

降雨レベル分類を前処理とした降雨強度の回帰モデル構築

Construction of a Regression Model for Rainfall Intensity with Preprocessing of Rainfall Level Classification

矢野 耕太郎[†]
Kotaro Yano[†]遠藤 聡志[‡]
Satoshi Endo[‡]佐藤 俊輔[§]
Shunsuke Sato[§]

1 はじめに

沖縄県の降水捕捉率は全国平均よりも低いことが知られている。株式会社ウェザーニューズは、ウェザーリポートというシステムを活用し、高い降水捕捉率を達成している。ウェザーリポートは、ウェザーニューズのアプリケーションユーザーが撮影した空の画像に天気情報を付与し、リポートするシステムである。末光 [1] らは車載カメラ画像に畳み込みニューラルネットワーク (CNN) を適応し、天気情報を付与して自動的にリポートを投稿するシステムを提案した。この研究では画像を晴れ曇、小雨、中雨、大雨の 4 つのクラスについて分類し、現在の天気をリポートするように設計されている。そこで、現在の画像から数分から数十分後の降雨強度を予測することで、ウェザーリポートの「今後の予想」を追加することが可能となり、より情報量の多いリポートをすることが可能となる。未来の天気を推定するためには、降雨に至るまでの時系列画像のデータセットが必要になる。

本研究は、雲の変化を捉えやすい定点カメラと Youtube の動画を用いて、降雨と降雨に至るまでの雲画像データセットを構築する。さらに、撮影画像から数分から数十分後の天気を予測するために、撮影画像と現在の降雨強度を予測モデルに入力する必要がある。したがって、雲画像から現在の降雨強度を推定する分類モデルと回帰モデルを組み合わせたモデルの作成を行う。Byun[2] らの先行研究では雲画像と対応する地上雨量を用いてデータセットを構築し、降水量を CNN の回帰にて求め、平均二乗誤差 (MSE) の平均が 3.0453 であった。さらに、Korea Meteorological Administration の基準を参考にし、3mm/h を境界値として分け、誤差 1mm 以内の精度を示している。研究では 3mm/h 以下の降水量における精度の平均は 77.12% であり、3mm/h 以上の降水量では 22.86% であったと報告されている。この結果から、降雨強度が強くなるほど推定が難しくなることが示唆されている。したがって、本研究では強い雨での予測精度を向上させるために、回帰モデルの前に降雨強度レベル分類モデルを挟むことで精度向上を目指す。さらに、降雨強度レベル分類における適切な分類数の検証も行った。

2 提案手法

研究の最終目標は図 1 に示すように、CNN とリカレントニューラルネットワーク (RNN) を組み合わせた CRNN モデルを用いて、数分から数十分後の降雨強度を予測することである。その目標を達成するためには、CRNN モデルに現在の雲画像と降雨強度を入力することが必要となる。したがって、本研究では降雨強度を数値として回帰モデルで推定するモデルの構築を行う。Byun らの先行研究では、まず降雨の有無を分類し、その後雨と分類された画像に対して一つの回帰モデルを適応して降水量を求めていた。本研究では、先行研究での課題である強い雨における予測精度の向上を目指す。具体的には、2 値分類後に降雨強度レベル分類モデルを挟み、分類クラスに応じた個別の回帰モデルで降雨強度を推定する (以降、提案モデル)。つまり、降雨強度レベルを 5 分類する場合、各クラスに一つの回帰モデルを作成し、合計で 5 つの回帰モデルを作成することになる。降雨強度レベル分類を挟むことで、回帰モデルが間違いやすい降雨強度を分類によって区別することが可能となる。これにより、苦手な降雨強度のデータだけで回帰モデルを学習することが可能になり、苦手な降雨強度における予測精度の向上が期待できる。また、降雨強度レベルの適切な分類数についても複数の分類数を検証し、最も良い分類数や分類数の傾向について調査を行う。

3 データセットの構築

本研究の最終目標は、CRNN モデルによる撮影された雲画像から何分後に雨が降るのかを予測することである。そのため、学習用データとして数分毎に撮影された時系列画像と、画像に対応するレーダ雨量計のデータが必要である。そのため、雲画像にレーダ雨量計の観測結果を正解ラベルとした雲画像データセットを構築した。また、本研究で用いたデータは 2023 年 12 月から 2024 年 5 月までのデータを用いている。

3.1 画像の取得

画像は沖縄県中頭郡西原町に設置した固定カメラおよび、Youtube にて沖縄県のライブ配信を行っている動画から取得した。Youtube では宮古島市伊良部島 [3] と国頭郡本部町 [4] で撮影されている動画を用いており、画像のおよそ半分が空を撮影しているものを選択した。設置したカメラにて北西方向の空を 7 時から 18 時の間を 1 分毎に撮影し、Youtube からは 5 分毎にスクリーンショットにて取得した。なお、Youtube からの画像は配信元より許可を得て取得している。

[†] 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

[‡] 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

[§] 株式会社ウェザーニューズ, Weathernews Inc.

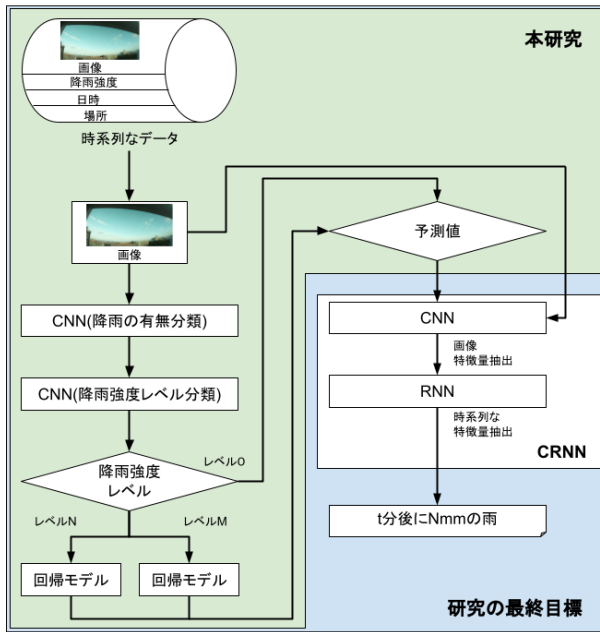


図 1 本研究と最終目標のイメージ

3.2 レーダ雨量計データの取得

レーダ雨量計のデータは京都大学が気象庁のデータをもとに公開している全国合成レーダー GPV(以降、合成レーダー)と、ウェザーニュースが提供している雨雲レーダーを用いた。合成レーダーは 10 分毎と 5 分毎 (2024 年 3 月以降) に降雨強度を取得できる。一方で、雨雲レーダーは 5 分毎に 0~1mm とした降雨強度レベルとして取得できる。さらに、雨雲レーダーの取得は画像を撮影している地域をスクリーンショットにて画像として保存している。雨雲レーダーは降雨強度レベルを赤色や黄色といった色で区別している。そこで、雨雲レーダーの画像からカメラに写っているおおよその地域内のピクセルの色を求め、降雨強度レベルに変換した。降雨強度レベルは最大のレベルと最頻のレベルを保存した。

3.3 データの紐付けとデータ除外

はじめに、合成レーダーの時刻をもとに雨雲レーダーとの紐付けを行ったが、完全に同じ時刻のデータでは無いため最大 2 分 30 秒の差がある。ここで、合成レーダーよりも雨雲レーダーのほうがより精度の高いレーダーも用いているため、雨雲レーダーの降雨強度レベルを真の値とする。合成レーダーの降雨強度をレベルに変換し、そのレベルが雨雲レーダーの最頻値から最大値の間の降雨強度レベルではない場合は、その時刻のレーダ雨量計のデータを除外する。次に画像とレーダ雨量計のデータの紐付けであるが、固定カメラはレーダ雨量計の時刻の画像と紐付け、Youtube の画像は誤差を最大 2 分 30 秒としてレーダ雨量計に最も近い時刻の画像を紐付けている。これらの手順によって、雲画像に合成レーダーの値をラベルとしたデータセットを構築した。

3.4 実験で使用したデータ

実験で用いるデータは、雲画像に降雨強度レベルと降雨強度をラベルとしたデータから構築されている。データの枚数は雨のデータ 695 枚と晴れ曇のデータ 687 枚からデータを構成している。また、雨のデータのうち 3mm/h 未満のデータは 527 枚であり、およそ 75% が弱い雨のデータである。図 2 は実験に使用した画像の一部を載せている。



図 2 実験で使用する画像

4 実験概要

先行研究のアプローチと提案モデルの予測精度の比較および、提案モデルにおける最適な降雨強度レベルの分類数の検証を行う。予測精度の比較として、平均絶対値誤差 (MAE) の値をもとに判断する。先行研究の MSE から今回の MAE へは、誤差がどれほどわかりやすく解釈するために変更した。また、誤差が 1mm/h 以内であるデータの割合を用い、モデルが正しく推定できた割合の調査も行う。先行研究のアプローチと提案モデルの双方で、降雨の有無を判定する 2 値分類モデルを使用する。先行研究のアプローチでは、2 値分類後に雨と分類された画像に対して、一つの回帰モデルによって降雨強度を推定する。一方で提案モデルでは、2 値分類後に雨の強さに分ける降雨強度レベル分類を行い、それぞれの分類クラスに独立した個別の回帰モデルを作成して降雨強度を推定する。したがって、2 値分類モデルと降雨強度レベル分類モデル、先行研究アプローチの回帰モデル、提案モデルの回帰モデルを作成する。

4.1 モデル

本実験では、前説でまとめたモデルを作成するにあたって EfficientNetV2B0 を用いる。これは先行研究とは異なるモデルを用いており、あくまで先行研究のアプローチと提案モデルの手法の比較を行う。2 値分類と先行研究アプローチの回帰モデルはデータを 2 倍に拡張して学習させた。また、降雨強度レベル分類はアンダーサンプリングを行い、各クラスが 100 枚になるよう拡張した。さらに、提案モデルの回帰では、分類で最も多い枚数のクラス枚数までオーバーサンプリングを行った。次に、全ての分類モデルと回帰モデルにおいて最適化関数である Adam, Adagrad, Adamax, バッチサイズとして 10, 16, 32, 64 にてハイパーパラメータ最適化を行った。

降雨強度レベル	1	2	3	4	5	6	7	8	9	10	11	12	13
3値分類の降雨強度幅 (mm/h)	0.1~5	5~10	10~										
4値分類の降雨強度幅 (mm/h)	0.1~1	1~5	5~10	10~									
5値分類の降雨強度幅 (mm/h)	0.1~1	1~2	2~4	4~8	8~								
6値分類の降雨強度幅 (mm/h)	0.1~1	1~2	2~4	4~6	6~10	10~							
7値分類の降雨強度幅 (mm/h)	0.1~0.5	0.5~1	1~2	2~3	3~5	5~10	10~						
13値分類の降雨強度幅 (mm/h)	0.1~0.25	0.25~0.5	0.5~0.75	0.75~1	1~1.5	1.5~2	2~2.5	2.5~3	3~4	4~5	5~6	6~10	10~

表1 提案モデルにおける多値分類の降雨強度レベルと降雨強度の関係

その結果、最も良いパラメータによってそれぞれの分類モデルと回帰モデルを構築した。また、実験は5分割交差検証によって行い、過学習の抑制として Train Loss を monitor とした Early Stopping を導入した。

4.2 多値分類の降雨強度のレベルへの変換について

提案モデルの降雨強度レベル分類における分類数と降雨強度との関係を表1に示す。分類数は3,4,5,6,7,13分類を行い、およそ0.1~10mm/hの範囲を分類しており、10~mm/h以上はデータ数が少ないため纏めて一つのクラスにしている。また、分類数である3,4,5,6,7,13はNational Wether Suevice, 気象庁, ウェザーニューズ, Yahoo, jaxa, National Oceanic and Atmospheric Administration の雨雲レーダーなどの降雨強度レベルの分け方を参考にし、データ数を考慮して再定義している。ここで、レベル1からレベル13までが雨の強さを区別しているが、晴れ曇りはレベル0として扱う。

5 結果と考察

5.1 提案モデルと先行研究アプローチの MAE の比較と考察

はじめに、先行研究のアプローチと提案モデルにおける MAE について表2に示す。top@1 と top@3 は回帰モデルにおける学習する範囲を表している。回帰モデルは分類クラスごとに作成しているが、top@1 はその分類されたクラスのみデータを学習させた回帰モデルであり、top@3 はそのクラスのみではなく前後のクラスまで学習させた回帰モデルである。例として、5値分類の level3 の回帰モデルでは、top@1 は level3 のデータのみで学習させたモデルであり、top@3 は level3 だけでなく level2 と level4 のデータも含めて学習させたモデルである。また、3値分類+回帰にて top@3 を行っていないのは、3値分類では全範囲を学習してしまうモデルが存在してしまうからである。

5.1.1 top@1 における考察

表2より top@1 における MAE の値は先行研究のアプローチが 1.726 と降雨強度レベル分類を挟んだ提案モデルのどれよりも精度が高いものとなった。提案モデルの精度が先行研究のアプローチよりも低い理由として、弱い雨における降雨強度レベルの分類精度が低く、弱い雨のデータが多いことが原因だと考えられる。図3に示しているのは2値分類+4値分類の混同行列である。図3からわかるように、レベル3やレベル4といった強い雨の分類精度は他の雨のレベルと比較しても高い精度であることがわかる。反対に、レベル1やレベル2といった弱い雨の場合は分類精度がとて

	MAE	
	top@1	top@3
3値分類 + 回帰	6.110	
4値分類 + 回帰	3.918	2.058
5値分類 + 回帰	3.084	2.368
6値分類 + 回帰	3.171	2.710
7値分類 + 回帰	2.755	2.549
13値分類 + 回帰	2.472	2.540
先行研究のアプローチ	1.726	

表2 提案モデルと先行研究のアプローチにおける MAE




図3 2値分類と4値分類を合わせた混同行列

も悪く、強い雨へと誤分類していることが見て取れる。降雨強度レベル分類後の回帰モデルはおおよそ学習した降雨強度の範囲の中で降雨強度を推定するため、誤差が大きくなってしまふ。よって、弱い雨を強い雨と誤分類することで、弱い雨において降雨強度の予測値の誤差が大きくなり、先行研究のアプローチよりも降雨強度の予測精度が悪くなってしまったと考えられる。また、弱い雨を誤分類し強い雨の分類精度が良い傾向は4値分類のみではなく、分類モデル全てで同様の傾向が見られた。

また、提案モデルにおいて最適な降雨強度レベルの分類数は13値分類で、分類数が多いほど MAE が小さくなる傾向がある。しかしながら、分類精度が向上しない限りは提案モデルでは MAE の値を小さくすることは難しい。

5.1.2 top@3 における考察

表2より top@3 の MAE の値は4値分類 + 回帰が 2.058 と top@1 を含めても提案モデルの中で最も低いものとなっ

た。しかしながら、先行研究のアプローチよりも誤差が大きい結果となった。top@1 よりも top@3 のほうが誤差が小さくなったのは、top@3 では学習範囲を広げることで弱い雨の誤分類による精度の悪化を多少補えるようになったからだと考えられる。しかし、top@3 でも降雨強度の予測精度に大きな影響を与える弱い雨を強い雨と大きく誤分類する画像まではカバー出来ないため、先行研究のアプローチよりも小さな誤差にならなかったと考えられる。また、分類数が少ないほど top@1 と比較して top@3 の MAE が小さくなっており、13 値分類+回帰では反対に MAE が大きくなってしまっている。これは、分類数が少ないと図 3 からわかるように弱い雨でも top@3 の範囲に誤分類した画像が入るため、その分の精度が改善されて誤差が小さくなっていると考えられる。ここで、図 4 は 2 値分類+13 値分類の混合行列を示している。分類数が多いと図 4 のように弱い雨において top@3 の学習範囲に誤分類した画像がほとんど入らないために精度の改善が行われない。だが、強い雨では学習範囲が広がることでモデルの精度は top@1 よりも落ちるため、誤差が大きくなる。結果として分類数が多いと top@3 では誤差が大きくなってしまおうと考える。




図 4 2 値分類と 13 値分類を合わせた混同行列

5.2 誤差 1mm/h 以内のデータ割合の結果と考察

誤差が 1mm/h 以内のデータの割合を表 3 に示す。表 3 からわかるように、3mm/h 未満の誤差は先行研究のアプローチが 75.5% と最も高いことがわかる。しかし、3mm/h 以上の誤差では top@1 の学習範囲である 6 値分類+回帰のモデルが 30.3% と最も良いことがわかる。よって、弱い雨では先行研究のアプローチのほうが正しく推定出来る割合が高いが、強い雨となると提案モデルである降雨強度レベル分類を行ったほうが正しく推定できる割合が高い。また提案モデルにおいて、3mm/h 未満の正しく推定できた割合は top@1 の学習範囲よりも top@3 の学習範囲に変更したほうが割合が高くなっているのに対して、3mm/h 以上では top@3 の学習範囲にすることで 3 値分類+回帰以外は割合が低くなっている。この結果より、弱い雨の場合は降雨強度レベル分類を行わずに、広い範囲を学習させた回帰モデルによる推定が良

	top@1 の学習		top@3 の学習	
	未満	以上	未満	以上
3mm/h に対して				
3 値分類 + 回帰	36.0%	19.0%		
4 値分類 + 回帰	40.5%	16.6%	67.1%	20.2%
5 値分類 + 回帰	53.8%	26.2%	62.1%	16.6%
6 値分類 + 回帰	42.2%	30.3%	50.2%	29.2%
7 値分類 + 回帰	55.4%	23.8%	62.7%	18.5%
13 値分類 + 回帰	56.6%	26.2%	57.5%	23.8%
3mm/h に対して				
先行研究のアプローチ	75.5%	15.4%		

表 3 誤差が 1mm/h 以内であるデータの割合

いものに対して、強い雨の場合は降雨強度レベル分類を行って top@1 のみを学習させた回帰モデルを用いたほうが予測精度が向上すると考えられる。

6 まとめと今後の展望

本研究では雲画像に降雨強度を付与したデータセットを構築した。また、構築したデータを用いて雲画像の降雨強度を回帰にて求めた。提案モデルとして降雨の有無の分類後に降雨強度レベル分類を行い、レベルごとの回帰モデルを作成し、先行研究のアプローチと精度の比較を行った。実験結果から、MAE は先行研究のアプローチが精度が良く、提案モデルは弱い雨の分類精度が低いことがネックとなって精度が良くないことがわかった。また、誤差が 1mm/h 以内のデータの割合から弱い雨の場合は降雨強度レベル分類をせずに回帰モデルを用いたほうが良く、強い雨では分類を行ってそのレベルのみを学習させたほうが良いことがわかった。今後の展望として、強い雨と弱い雨を分けてから異なるアプローチで降雨強度を推定することで、予測精度の向上を目指す。

謝辞

本研究は JSPS 科研費 23K11234 の助成を受けたものである。

参考文献

- [1] K. Suemitsu, et al., "Selection of Dash Cam Images for Weather Forecasting Based on The Sky Occupancy," 2022 Joint 12th International Conference on Soft Computing and Intelligent Systems and 23rd International Symposium on Advanced Intelligent Systems (SCIS&ISIS), Ise, Japan, 2022, pp. 1-8, doi: 10.1109/SCISISIS55246.2022.10002033.
- [2] J. Byun, et al., "Deep Learning-Based Rainfall Prediction Using Cloud Image Analysis," in IEEE Transactions on Geoscience and Remote Sensing, vol. 61, pp. 1-11, 2023, Art no. 4701411, doi: 10.1109/TGRS.2023.3263872.
- [3] Youtube, KuROKO-宮古島映像-, https://www.youtube.com/live/4v5e4eKIT_E?si=jkyHDa-MiYcg6.6p,2024/06
- [4] Youtube, Motobu Terrace, <https://www.youtube.com/live/Tlc3uegvdrQ?si=xMDiI40iMQKkalO0,2024/06>