

CNN・RNN 統合モデル 衛星・地上ライダーデータ 融合による流域平均雨量階級予測モデルの検討

原田 朋弥¹⁾・白水 元²⁾

¹⁾東海大学大学院工学研究科, ²⁾東海大学建築都市学部

1. はじめに

近年, 集中豪雨や線状降水帯が各地で発生し, 洪水や土砂災害などの深刻な被害が報告されている。これらの現象は温暖化の進行とともに頻度・強度を増しており, 今後さらなる被害の拡大が懸念されている。特に九州地方は地理的, 地形的条件から豪雨災害のリスクが高く, 実際に令和2年7月には, 九州中南部を流れる一級河川球磨川において, 時間雨量 30 mm 以上の降水が 8 時間以上継続し¹⁾, 大規模な氾濫被害が発生した。球磨川は河道勾配が大きく流速が速い日本三大急流の一つであり, 降雨時に水位が急上昇しやすいことから, 水害リスクが高い。このため, 球磨川流域における降水の発生や強度を即時に把握することは, 防災, 減災の観点から極めて重要である。そのような中で, 静止気象衛星「ひまわり 8 号・9 号」は, 可視から赤外に至る 16 波長帯の観測 (表 1) を, 2.5 分間隔で行うことが可能であり²⁾, 急激な気象変化を捉える有力な観測手段として活用が模索され, 観測データに深層学習を適用し, 降水推定を行う研究が進められている。藤本・手計 (2024)³⁾ はバンド 7-16 に加え地形データを用いた深層学習によりピーク時間前後の 1 時間積算降水量を推定し, Hirose ら (2019)⁴⁾ は 7-16 バンドの赤外データを用いて 1 時間積算降水量の推定を行っている。

しかし既存研究では, 流域平均雨量予測において, どのひまわりバンドが有効であるかについて, 定量的な比較に基づく検討は十分に行われていない。さらに衛星の水平分布情報に加えて, ラマンライダーのような鉛直方向の大気情報を統合した深層学習モデルの検討も行われていない。

そこで本研究では, 球磨川流域を対象として, 畳み込みニューラルネットワーク (CNN) を用いた流域平均雨量の予測を行い, 分類性能 (Accuracy, Precision, Recall, F1-Score) による評価を実施した。また, L1 正則化を適用し, 予測・分類に寄与するデータの検討を行った。さらに, ひまわりデータに CNN, ライダーデータに RNN を適用した統合モデル (CNN+RNN) を構築し, 衛星データのみを用いたモデルとの比較し, データ統合の有効性について検討した。

表 1 ひまわり 8 号・9 号ピーク観測高度⁵⁾

バンド	7	8	9	10	11
波長(μm)	3.83	6.24	6.94	7.35	8.59
観測対象(雲あり)	雲頂温度	雲頂温度	雲頂温度	雲頂温度	雲頂温度
観測対象(雲なし)	地表面温度 (純粋な赤外温度)	300-400hPa 水蒸気	400-500hPa 水蒸気	500-600hPa 水蒸気	地表面温度 (水蒸気影響)

バンド	12	13	14	15	16
波長(μm)	9.64	10.4	11.2	12.4	13.3
観測対象(雲あり)	雲頂温度	雲頂温度	雲頂温度	雲頂温度	雲頂温度
観測対象(雲なし)	対流圏下層温度 成層圏オゾン	地表面温度	地表面温度 (氷晶雲影響)	地表面温度 (水蒸気影響)	地表面温度 (CO ₂ 影響)

2. 研究方法

入力データには、気象衛星ひまわり 8・9 号の観測データと、下甕島に設置され下層の水蒸気観測に優れたラマンライダーの水蒸気混合比の観測データを用いた。ひまわりデータは赤外バンド（バンド 7-16）10 バンドを使用し、北緯 29-36 度・東経 126-133 度の範囲(図-1)に切り出し使用した。データの NaN は 0.0 に置換し、各ファイル内の値を最大値で除することで 0-1 の範囲に正規化した。データセットは、全データを学習データとテストデータが 4:1 となるようにランダムに分割した。本研究における降水量のクラス分けは、気象庁アメダス観測所の雨量計データに基づいて行った。対象地域は球磨川水系流域内に位置する 14 地点のアメダス観測所(図-2)であり、ティーセン分割により流域平均降水量を算出した。流域平均降水量に基づき、0 mm/h をクラス 1、0 mm/h 以上 10 mm/h 未満をクラス 2、10 mm/h 以上をクラス 3 として 3 階級に分類した。深層学習モデルの概要を図 2 に示す。ひまわりデータはバンド 7-16 をまとめて CNN に入力し(図-3 の①) ライダーデータは 1 時間平均の水蒸気混合比の鉛直構造を 24 時間分の時系列として RNN に入力した(図-3 の②)。CNN+RNN モデルでは、これら 2 種類の特徴量を統合して 3 階級分類を行い、1, 3, 6, 9, 12 時間前のデータを用いた流域平均雨量階級の予測を行った。また、L1 正則化を導入し、分類に寄与するバンドについても検討を行った。




図 1 データ範囲




図 2 アメダスとラマンライダーの位置

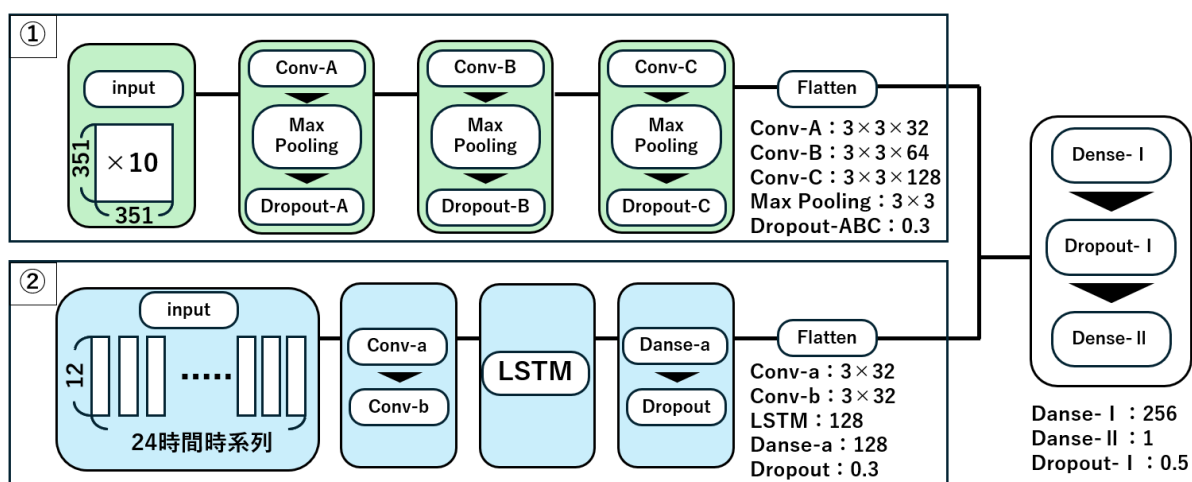


図 3 モデル構成図

3. 結果と考察

3.1 衛星バンド寄与率

ひまわり衛星の赤外バンドのみを入力とした CNN モデル (図 3 ①) を用い、予測時間ごとの流域平均雨量階級予測における各バンドの寄与率を検討した。データ期間は 2018-2024 年の 5 月-10 月に観測されたデータを使用した。学習データとテストデータは各クラスの件数が 1 対 1 対 1 となるようにランダムに抽出した。階級は、流域平均雨量が $R=0 \text{ mm/h}$ をクラス 1, $0\text{mm/h}<R<10\text{mm/h}$ をクラス 2, $R\geq 10\text{mm/h}$ をクラス 3 とした。学習データおよびテストデータの作成にあたっては、各クラスのデータ件数が同数となるように抽出し、学習データは各クラス 1,225 件ずつ、テストデータは各クラス 306 件ずつを使用した。これにより、学習・評価の双方においてクラス不均衡の影響を排除し、モデルが流域平均雨量階級を同程度に識別できる条件を整えた。

結果として予測ごとの Accuracy は、1 時間前 50.71%, 3 時間前 50.11%, 6 時間前 54.19%, 9 時間前 55.87%, 12 時間前 53.80% と大きな差は見られなかった。

しかしバンド 7 ($3.8\mu\text{m}$) の寄与率に注目してみると、1 時間前 4.79%, 3 時間前 7.00%, 6 時間前 20.21%, 9 時間前 12.57%, 12 時間前 11.82% となり、6 時間前に 20.21% と高い寄与率を示した (表 2)。バンド 7 は水蒸気や火山灰などといったエアロゾルに影響を受けにくい波長帯であり、純粋な輝度温度が観測されるとされている (表 1) ⁵⁾。そのため 6 時間前に観測される輝度温度の変化が流域平均雨量の階級を決定づける重要な手がかりとなっていると推測する。また、3 時間前、1 時間前では降水を発生させる雲がすでに形成されており、雲頂温度を観測するとされる (表 1) ⁵⁾ ため、他のバンドで保管されるため、バンド 7 の寄与率が低下したと考えられる。

さらに、水蒸気にピーク感度を有するバンド 8-10 (表 1) ⁵⁾ に着目すると、寄与の中心となる高度帯が時間とともに移動していることが示された (表 2)。1 時間前では、バンド 8 ($6.2\mu\text{m}$ 300-400hPa 水蒸気) の寄与が最も大きく、上層での湿潤化が降水直前の重要な指標となった。3 時間前では、バンド 9 ($6.9\mu\text{m}$ 400-500hPa 水蒸気) およびバンド 10 ($7.3\mu\text{m}$ 500-600hPa 水蒸気) が高い寄与を示し、下層から中層にかけての水蒸気輸送に注目している。6 時間前では、バンド 9 の寄与が最大となり、中層での水蒸気の集積が降水発生に向けた重要な要素となっていた。9 時間前になると、バンド 10 の寄与率が高くなり、下層での湿潤空気の供給に着目している。これらの時間ごとの水蒸気バンドの寄与の変化は、その物理的背景が未解明な部分が多い線状降水帯などの豪雨発生メカニズムの一つである「下層から上層へ向かう水蒸気移送」と一致しており、機械学習モデルが大気鉛直的な水蒸気分布の変化に着目して学習していることを示唆している。一方で 12 時間前という早い段階では、まだ雲の発達が顕著でなく、水蒸気鉛直分布に大きな偏りが形成されていないため、バンド 8-10 がほぼフラットな寄与を示したと考えられる。

表 2 バンド寄与率 (%)

バンド	7	8	9	10	11	12	13	14	15	16
1 時間	4.79	15.17	9.47	10.11	11.17	11.68	13.53	12.62	6.50	4.94
3 時間	7.00	14.46	15.98	0.00	12.86	7.71	11.40	13.62	11.38	5.58
6 時間	20.21	8.37	15.80	7.65	14.57	6.73	0.00	11.90	8.98	5.78
9 時間	12.57	7.92	11.04	14.89	11.97	6.13	13.34	9.74	8.76	3.65
12 時間	11.82	12.00	12.79	13.22	11.65	5.24	13.13	11.50	0.00	8.64

3.2 CNN+RNN

ひまわりデータとラマンライダーの観測データを統合した CNN+RNN モデル（図 3①②）を用いて、予測時間ごとの流域平均雨量階級予測における分類性能を検討した。対象期間は、ラマンライダーの観測が行われている 2024 年 5 月-10 月とし、学習データとテストデータは総サンプル数が限られているためランダムに 4 対 1 で選定した。階級は前節と同じに設定し、学習データはクラス 1 が 169 件、クラス 2 が 491 件、クラス 3 が 155 件とした。テストデータは同様にクラス 1 が 43 件、クラス 2 が 120 件、クラス 3 が 40 件とした。

結果として流域平均雨量 10 mm/h 以上階級の Accuracy が 3 時間前予測以外で向上した（表 3）。これより、ラマンライダーの高度方向の水蒸気情報を併用することで、特に流域平均雨量 10 mm/h 以上の高雨量階級において分類精度が向上し、降水の発生・発達に重要となる鉛直水蒸気構造が有効に寄与している可能性が示された。

表 3 域平均雨量 10mm/h 以上階級の Accuracy (%)

	1 時間前	3 時間前	6 時間前	9 時間前	12 時間前
CNN	42.50	42.50	47.50	45.00	40.00
CNN+RNN	50.00	42.50	50.00	52.50	47.50

4. まとめ

本研究では、ひまわり赤外バンドを用いた CNN モデルにより、6 時間前の輝度温度変化が流域平均雨量の判別に重要であること、また水蒸気バンド 8-10 の寄与が時間とともに上層から下層へ移動し、機械学習モデルが流域平均雨量予測に水蒸気移送を捉えていることが示された。さらに、衛星データにラマンライダーの鉛直水蒸気情報を統合することで高雨量階級の予測精度が向上し、その有効性を示した。

謝辞

本論文の研究は、国立研究開発法人海洋研究開発機構が運営する、データ統合・解析システムから取得したひまわりデータを用いた。また、降水量データについては、気象庁が提供するアメダスの観測データを用いた。さらに、本研究の遂行にあたり、東海大学のゴ・カキさん、宇井啓人さん、直木和弘さん、そして中島孝教授から多くの有益な助言と支援を受けた。ここに敬意を表す。

参考文献

- 1) 国土交通省：令和 2 年 7 月豪雨による被害状況等について（第 9 報），2020.
<https://www.mlit.go.jp/common/001354304.pdf>（2025/5/9 閲覧）
- 2) 気象庁：ひまわり衛星バンドの波長について，
https://www.data.jma.go.jp/mscweb/ja/himawari89/himawari8_band.html（2025/5/9 閲覧）
- 3) 藤本寛生，手計太一：静止気象衛星ひまわりを用いた深層学習による新たな衛星雨量 HiDREDv2 の提案，土木学会論文集，80 巻，16 号，2024.
- 4) Hirose H., Shige S., Yamamoto M.K., Higuchi A. : High Temporal Rainfall Estimations from Himawari-8 Multiband Observations Using the Random-Forest Machine-Learning Method , Journal of the Meteorological Society of Japan, 97(3), 689–710, 2019.
- 5) 気象庁気象衛星センター：気象衛星センター技術報告 特別号（2022 年 3 月），Meteorological Satellite Center Technical Note Special Issue (March 2022), 気象衛星センター，2022.
https://www.data.jma.go.jp/mscweb/technotes/msctechrep-sp_202203.pdf（2026/1/23 閲覧）