

マルチモーダル深層学習による洪水浸水域マッピングに関する研究

山梨大学 学生会員 荻島 準

山梨大学 正会員 宮本 崇

1. はじめに

水害を含む様々な災害対策への AI の活用が期待されており、災害事象の把握や将来状態の予測へと応用が検討されている。一方で、AI には計算過程や結果が必ずしも物理的に自然なものとならない問題があることが知られている。衛星画像を利用した浸水域マッピングを例にとると、一般的に標高が高い地域ほど被害を受ける可能性が減ることが物理的に自然な結果と考えられるが、衛星画像のみを分析する AI では標高データが考慮できず、上記のような物理的な直感も反映されないため、被害を受けにくいと思われる台地などでも被害があったと判断してしまうなど物理的に不自然な解釈がなされてしまう恐れがある。

そこで本稿では、推測結果の精度や物理的信頼性の向上した浸水域マッピング技術を開発することを目的として、災害前後の衛星リモートセンシング画像に加えて数値標高モデル (DEM) やその勾配値などのマルチモーダルなデータを入力に用いて洪水浸水域のマッピングを行う AI の開発を行った結果を報告する。

2. 手法

本研究では、「SAR 画像のみ」、「SAR 画像+DEM」、「SAR 画像+勾配値」の3つのケースの入力データを作成し、それぞれに対応した深層学習モデルを設計して浸水域を予測し、その精度を比較した。各入力データから浸水域のセグメンテーションを行う深層学習モデルには、ResNet をベースに入力データ次元を ch 方向に拡張したモデルを使用した。

また、モデルの学習にあたってはオープンデータセットの1種である Sen1floods11¹⁾を使用した。Sen1floods11 は、気象観測衛星 Sentinel-1 によって撮影された画像と、永久水と浸水域が分類されたラベルからなるデータセットである。本研究では、このデータセットに収録されている2種類の偏波(VH, VV)で撮影された SAR 画像(4837 枚)と浸水域の正解データを使用した(図1, 図5)。衛星画像として

SAR 画像を選択した理由として、光学画像と比べ白黒で表されるため視覚的な判別が難しいが、夜間や雲がかかっているにもかかわらず撮影可能でありリアルタイムの撮影に適しているなど、実災害時の運用に優れていることが挙げられる。

標高データには DEM を使用し(図2)、勾配値には DEM から数値勾配を算出した値を使用した(図3)。




図1. SAR 画像 (左: VV 偏波, 右: VH 偏波)




図2. DEM 例

図3. 勾配値例

図1から深層学習により浸水域を予測した結果が図4である。これを正解データと比較することで精度を評価した。




図4. 予測結果例

図5. 正解データ例

3. 結果

3.1 精度の比較

各入力データ形式に対応する予測結果の精度を

キーワード: 深層学習, マルチモーダル学習, 浸水域予測, リモートセンシング

連絡先: 山梨県甲府市武田 4-3-11 山梨大学 宮本 崇 tmiyamoto@yamanashi.ac.jp

IoU によって比較した結果を表 1 に示す.

表 1. 予測結果の精度

		epochs				
		50	70	100	150	200
IOU	ケース 1 (SAR画像)	0.3614	0.3868	0.3716	0.3803	0.3812
	ケース 2 (SAR画像+DEM)	0.3885	0.3875	0.3791	0.3964	0.3834
	ケース 3 (SAR画像+勾配値)	0.3726	0.3823	0.3827	0.3967	0.3828

表 1 より, ケース 1 (SAR 画像のみ) と比べ, 入力データに DEM や勾配値を追加したケース 2, 3 の場合に精度がわずかに向上していることが分かる.

3. 2 DEM による予測結果の影響

入力データに DEM を追加したことによる影響をより詳細に検討するため, ピクセル毎の偽陽性, 偽陰性を DEM の有無で比較した. 図 6 は, 偽陽性/偽陰性のピクセル数と, 画像パッチ毎の正規化標高の関係を示すヒストグラムである.




図 6 ケース 1, 2 の偽陽性数, 偽陰性数の比較

図 6 からは, DEM を追加したことにより標高が相対的に低い地点において偽陽性が増加かつ偽陰性が減少し, 反対に標高が相対的に高い地点では偽陰性が増加かつ偽陽性が減少していることが分かる. この結果は, DEM を追加することによって画像パッチ内で相対的な標高が低い地点では浸水域と予測しやすくなり, 逆に相対的な標高が高い地点では非浸水域と予測しやすくなったことを意味している. すなわち, 深層学習モデルは標高に応じた浸水域の予測を行っているが, このような標高による予測結果のバイアスは偽陰性と偽陽性のトレードオフを生じさせていることから, 大きな精度向上に繋がらなかったと考えられる.

3. 3 勾配値を追加したことによる影響

次に, 入力データに勾配値を追加したことによる影響を調査するため, 同様に勾配値の有無による偽陽性/偽陰性のピクセル数と, 画像パッチ毎の正規化

標高の関係を図 7 のように評価した.




図 7 ケース 1, 3 の偽陽性数, 偽陰性数の比較

図 7 からは, 勾配値を追加したことにより勾配が小さい地点において偽陽性が増加し勾配が大きい地点では偽陰性が増加していること, すなわち勾配が小さい地点では浸水域, 勾配が大きい地点では非浸水域と予測しやすくなっていることが分かる. したがって勾配値を追加したことにより勾配に応じた浸水域の予測を行うことができていたが, DEM の場合と同様に偽陰性と偽陽性のトレードオフが生じていることから大幅な精度向上には繋がらなかった.

4. 結論

SAR 画像を入力データとして深層学習を行い, 洪水浸水域マッピングを行った場合と比べ, DEM や勾配値を追加したことで地形情報を考慮した予測結果を出力することができることが確認できたが, 大幅な精度向上には繋がらなかった. 今後はより一層の精度や物理的特性の信頼性の向上を図るため, 入力データに SAR 画像, DEM, 勾配値を同時に加えた予測の実施や, 地形に伴う水の流れをより直接的に考慮したモデルの設計などを行いたいと考えている.

参考文献

1) Bonafilia, D., Tellman, B., Anderson, T. and Issenberg, E. : Sen1Floods11: A Georeferenced Dataset to Train and Test Deep Learning Flood Algorithms for Sentinel-1. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, pp. 210-211, 2020