

畳み込みニューラルネットワークを活用したレーダ画像解析

国土交通省国土技術政策総合研究所 正会員 ○小沢 嘉奈子
 国土交通省国土技術政策総合研究所 正会員 川崎 将生
 国土交通省国土技術政策総合研究所 正会員 山地 秀幸

1. はじめに

深層学習 (Deep Learning) に関する研究は特に多くの関心が寄せられる分野である。中でも画像認識は、例えば河川管理の分野においても、これまでに蓄積された膨大なレーダ雨量計の画像から流域の降雨特性を把握したり、河川構造物の日常点検における膨大な写真等から劣化箇所を検知したりするなど、今後、様々な活用が期待される。本稿ではこうした画像認識に特化した畳み込みニューラルネットワークを用いたレーダ画像解析を行い、過去の降雨パターンと比較して類似降雨の検索を試行した。

2. 畳み込みニューラルネットワーク

音声認識や画像認識、自然言語処理などの分野において、近年注目を集めている手法が深層学習である。深層学習は多層ニューラルネットワークによる学習であり、中でも畳み込みニューラルネットワーク (Convolutional Neural Network, 以降 CNN) は画像を複数のカテゴリに分類することが可能で、画像認識の分野で非常に良い成果を出している。

CNN は一般的な順伝播型ニューラルネットワークと異なり、入力層、全結合層、出力層の他に畳み込み層 (convolutional layer)、プーリング層 (pooling layer) という特殊な層が内部に存在する。入力データが畳み込み層、プーリング層、全結

合層を経由して出力層で推測したクラスの確率が算出される仕組みである (図 1)。畳み込み層では入力データに対し特徴を検出しフィルタリングをかけ、プーリング層では畳み込み層でフィルタリングした特徴マップの領域毎の代表値を抽出する機能を持つ。これにより、入力した画像データの重要な情報は残しつつ、画像サイズは縮小される。

3. CNN を用いた類似降雨事例検索

(1) 概要

C バンドレーダ同時刻合成雨量データを用いて 5 降雨事例について、1 時間毎のレーダ画像を学習させた。全く同じデータを用いて動作確認を行った上で、同じ 5 降雨事例の C バンドレーダオンライン補正雨量データを用いて、1 時間毎のレーダ画像を学習した 5 降雨事例の、どれに類似するか検索した。

(2) データセットについて

荒川の二瀬ダム上流域 (流域面積約 170 km²) を対象に、表 1 に示す 5 降雨事例について検索精度を検証した。この 5 降雨事例について C バンドレーダ同時刻合成雨量データを、学習のためのトレーニングデータセットと学習状況を評価するためのバリデーションデータセットに同数ずつ振り分けた。

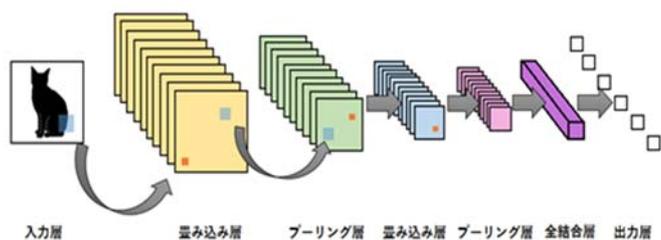


図 1 CNN のモデル構造例

表 1 データセットの概要

データセット	画像種別	クラス名	洪水期間	サンプル数
・トレーニングデータセット (偶数時刻)	C同時刻	2006年10月洪水	2006/10/5/0:00~2006/10/7/23:00	72
		2007年9月洪水	2007/9/5/0:00~2007/9/7/23:00	72
		2011年9月洪水①	2011/9/2/0:00~2011/9/5/23:00	96
		2011年9月洪水②	2011/9/19/0:00~2011/9/21/23:00	72
・バリデーションデータセット (奇数時刻)	C同時刻	2012年6月洪水	2012/6/19/0:00~2012/6/20/23:00	48
		テストデータセット	Cオンライン	2006年10月洪水
テストデータセット	Cオンライン	2007年9月洪水	2007/9/5/0:00~2007/9/7/23:00	72
		2011年9月洪水①	2011/9/2/0:00~2011/9/5/23:00	96
		2011年9月洪水②	2011/9/19/0:00~2011/9/21/23:00	72
		2012年6月洪水	2012/6/19/0:00~2012/6/20/23:00	48

キーワード 深層学習, ニューラルネットワーク, 画像認識

連絡先 〒305-0804 茨城県つくば市旭 1 番地 国土技術政策総合研究所 TEL : 029-864-2679

また、上記と同じ5降雨事例についてCバンドレーダオンライン補正雨量データをテストデータセットとした。

(3) 使用するソフトウェアについて

本検証では深層学習用のライブラリを使ったサンプルプログラム(9_Layer_CNN.py)¹⁾を使用した。このプログラムではKeras²⁾というライブラリを使用し、その背後で深層学習用のフレームワークであるCNTK³⁾が実行される。

(4) モデル構造の作成

畳み込み層が6層、全結合層が3層となっている9層のCNNを作成した。学習から推測までの一連の流れを図2に示す。また、モデル構造の詳細は表2のとおりである。学習の際、画像を正規化処理した上で画像の順番をシャッフルして前処理を行った。重みの更新に用いる学習係数や、それを調整するための学習係数の減衰率はサンプルプログラムのデフォルト値を使用し、使用機器のスペック等に合わせた学習回数やバッチサイズはデフォルト値から変更した。

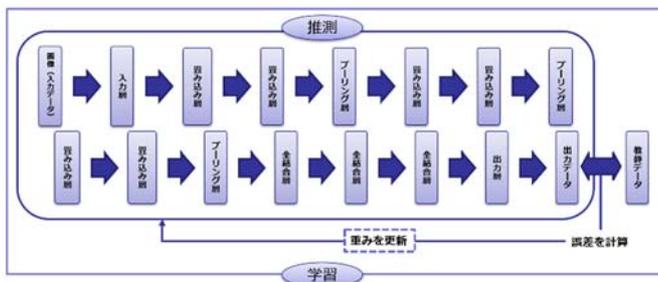


図2 学習から推測までの流れ

表2 9層CNNのモデル構造

	層数	説明	
入力層	3	224×224ピクセル	
隠れ層 (畳み込み層・プーリング層)	6	活性化関数Leaky ReLU	
全結合層	2	1024ユニット	ドロップアウト 50%
出力層 (全結合層)	1	活性化関数Softmax 5ユニット	
重みの更新	Optimizer SGD (確率的勾配降下法)		
学習回数	12epochs (回)		
バッチサイズ	5		

4. 検証結果

同じ画像データ同士による動作確認では、正解率

が100%となった。次に、テストデータとしてCバンドレーダオンライン補正雨量データを用いて類似降雨検索した結果を表3に示す。推測では、5降雨それぞれ確率が計算されており、確率が最も高い降雨事例を推測した降雨事例と判断する。いずれのケースも比較的高い正解率で降雨事例を推測できることがわかる。図4は、各降雨事例の1時間毎の判定結果を見やすくするためハイドログラフの形で示し、色分けしたものである。降り始めや降り終わりの正解率が低くなる傾向にあることが見てとれるが、教師データのサンプル数やモデル自体を改善することにより検索精度も向上すると考えられる。

表3 CNNを用いた類似降雨の検索結果

画像種別	クラス名	サンプル数	正解率 (%)
Cオンライン	2006年10月洪水	72	100.0
	2007年9月洪水	72	87.5
	2011年9月洪水①	96	96.9
	2011年9月洪水②	72	91.7
	2012年6月洪水	48	97.9

入力データ:2007年9月洪水

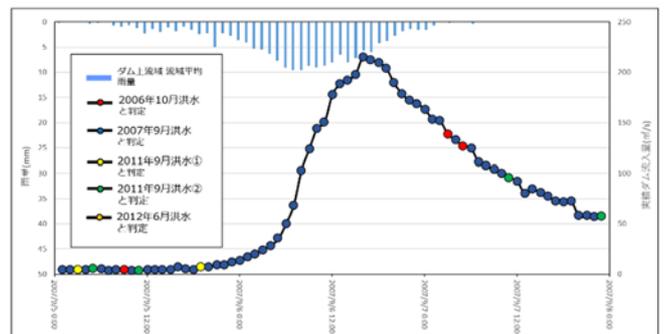


図4 類似降雨検索結果グラフ(2007年9月洪水)

5. おわりに

今回、CNNによる類似降雨事例検索を行い、レーダ画像の検索に対するCNNの有効性が見出された。今後はモデルに改良を加えるとともに使用する降雨事例数を増やし、学習した降雨事例とは異なる降雨事例のテストデータを用いた検証を行う。

参考文献

- 1) 藤田一弥, 高原歩: 実装 ディープラーニング, フォワードネットワーク監修, オーム社, 2016.12.
- 2) Keras: <http://keras.io/>
- 3) CNTK: <https://github.com/Microsoft/CNTK>