

29. 深層学習を用いた降水量の季節予報モデルにおけるモデルパラメーターによる感度分析

善光寺 慎悟^{1*}・松浦 拓哉¹・手計 太一²・榊原 一紀²

¹富山県立大学大学院 環境工学専攻 (〒939-0398 富山県射水市黒河 5180)

²富山県立大学大学院准教授 工学研究科 (〒939-0398 富山県射水市黒河 5180)

※E-mail: t957003@st.pu-toyama.ac.jp

本研究では、深層学習の 1 つである畳み込みニューラルネットワークを用いて全球表面温度からタイ国 の 2 ヶ月後の降水量の季節予報モデルを開発するためにモデルパラメータを変更し、それらの感動分析を行った。その結果、入力データである全球表面温度データには、圧縮のような特別な処理は必要ないことが分かった。また、複数月の全球表面温度を入力データとすることで、雨期・乾期ともに極値の再現性が向上した。パラメータ変更を行い予測精度が向上する場合は、乾期の精度が向上しやすい傾向にあった。また、パラメータ変更により予測精度が低下する場合は、雨期の精度が著しく低下した。したがって、深層学習を用いることで乾期の降水量を予測できることが示唆された。

Key Words: Precipitation, Global Surface Temperature, Seasonal forecast, Thailand, Deep Learning

1. はじめに

将来、降水量の強度はさらに大きくなり、その頻度も増加することが予測されている¹⁾。このような極端な降水現象は、洪水や氾濫洪水などの様々な 2 次災害を引き起こし、より甚大な被害をもたらす。しかし、これらの災害による被害は抑制することが可能である。その手法の 1 つとして、大規模貯水池の事前操作が例に挙げられる。これを行うことで、渇水や氾濫洪水による被害を抑えることが可能となる。貯水池の事前操作を行うためには、将来の予測降水量が必要となる。しかし、今現在、貯水池操作に利用できるほどの精度を有する、長期的な降水量予測はなされていない。

気象分野に限らず、統計的手法を用いた再現・予測を行うためには、大規模なデータセットが必要である。近年、気象分野の観測技術の向上に伴い、高品質かつ大規模データセットが整備されている²⁾。また、ひまわり 8 号など衛星画像データがリアルタイムで一般公開されている。

IT 技術の発展を背景に、機械学習の精度が飛躍的に向上している。その中でも、ニューラルネットワークを多層化したにすぎない深層学習の発展が著しい。深層学習の最大の特長は、そのモデル自身がパラメータ調整を行

う点にある。深層学習には、時系列データ処理に優れている回帰型ニューラルネットワーク(Recurrent Neural Network(RNN))や画像解析・処理に優れている畳み込みニューラルネットワーク(Convolutional Neural Network(CNN))など様々なアルゴリズムが存在する。CNN の精度が向上したことによって、衛星画像や全球データの用途幅がさらに拡張された。

気象分野や水資源管理においても、深層学習を利用した研究が多数なされている。森脇ら(2018)は Long Short-Term Memory(LSTM)を用いて、10 秒後の水平風速を予測した³⁾。一言ら(2016)は、深層学習を用いて、数時間後の河川水位を予測した⁴⁾。鈴木ら(2018)は CNN を用いた短期的な降水量予測を行っている⁵⁾。

これらの背景から、本研究では、深層学習を利用して全球表面温度データから、降水量の季節予報を行うための基礎的研究を行った。予測リードタイムは 2 ヶ月とした。本稿では、2 次元データ(全球表面温度)を入力データとし、1)入力データ(全球表面温度)の事前圧縮による影響、2~4)モデルパラメータによる影響、6)入力データの情報量増加による 6 つの Case における感度分析を行い、それらの精度評価を行った。

2. 研究手法

本研究では、深層学習のアルゴリズムの1つであり、2次元以上のデータ処理に優れているCNNを用いて、2ヶ月後の降水量予測の基礎的研究を行った。以下に、CNNの概要を示す。

CNNは、畳み込み層、プーリング層及び全結合層により構築されるネットワークである。以下に、それぞれの層の概要を示す。

畳み込み層では、特徴の検出器の役割を果たすフィルターを利用して演算処理が行われる。任意の配列(フィルター)を用いて、入力データの演算処理を行う。また、フィルター数を増加させることによって、より多くの特徴を考慮した計算を行うことが可能となる。本稿では、ゼロパディング処理を行い、空間解像度が小さくならないようにした。

プーリング層では、隣接する領域の代表値を抽出することで、データの前処理等により生じる微細な変化を打ち消す役割がある。本稿では、隣接する領域から最大値を抽出するマックスプーリング処理を用いた。

最後に、全結合層により計算処理が行われる。式-(1), (2)に、全結合層で行われる計算処理を示す。

$$y = F(u_i) \quad (1)$$

$$u^i = b + \sum_{i=1}^n w_i x_i \quad (2)$$

ここで、 w_i は重み係数、 b はバイアス、 u_i は層のニューロンの入力和、 $F(u_i)$ は活性化関数、 n は層のニューロン数、 y は i 層の出力値である。

全結合層による計算は、予測値の誤差が最も小さくなるように、重み係数を最適化することで行われる(勾配降下法)。学習時に用いた誤差評価関数はMSE(Mean Squared Error)である。

3. 各種データ

(1) 対象領域

図-1に対象領域であるタイ国チャオプラヤー川流域を示す。タイ国の降水現象の特長として、雨期(5月-10月)と乾期(11月-4月)が明瞭に分かれていることが挙げられる。そのため、氾濫や洪水が発生しやすい地域である。この流域には、Bhumibol reservoirとSirikit reservoirの2つの大規模貯水池が運用している。これら2つの大規模貯水池を効率的に運用することは、氾濫や洪水被害の抑制につながる。本稿では、これら2つの大規模貯水池より上流域(図-1白枠)を対象領域とした。

(2) 使用データ

使用したデータは、気象庁55年長期再解析(JRA-55)ブ

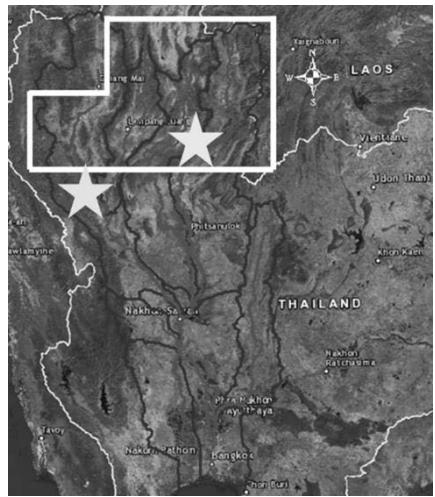


図-1 対象領域

表-1 環境構築に利用したライブラリ、モデル作成時に使用した手法、モデルパラメーター及びその値

	Case1	Case2	Case3	Case4	Case5
使用ライブラリ	Tensorflow, Keras				
バッチサイズ	5				
学習係数	Adam				
誤差評価関数	MSE(Mean Squared Error)				
フィルターサイズ	10×10				
1層目の全結合層の層数	4000				
入力データの圧縮倍率	1/5	2/5	3/5	4/5	5/5
畳み込み層の層数	1	2	3	4	5
プーリング層の層数	1	2	3	4	5
全結合層の層数	1	2	3	4	5
全結合層のニューロン数 (2層目)	2000	3000	4000	5000	6000
入力データの入力月 (ヶ月前)	2	2・3	2・3・4	△	△

プロジェクトにより提供されたものである²⁾⁶⁾。解析データは全球表面温度及び月平均日降水量である。解析期間は1958年1月から2017年12月の720ヶ月間である。学習期間を1958年1月から2010年12月(636ヶ月間)とし、2011年1月から2017年12月(84ヶ月間)を試験期間とした。全球表面温度及び月平均日降水量の空間解像度は、(1.25°, 1.25°)である。

月平均日降水量に関しては、対象領域(図-1白枠)内に存在する月平均日降水量の平均値を利用している。また、JRA55の月平均日降水量に、それぞれの月の日数を乗じ、月降水量値として用いた。

(3) 計算条件

表-1は環境構築に使用したライブラリ、モデル作成時に使用した手法、モデルパラメータ及びその値である。使用したライブラリはTensorflow⁷⁾及びKeras⁸⁾である。また、表中の太枠文字で示されている値は基準値である。

予測モデル作成において、epoch数の上限を100とし、その全epochの中から、検証期間の誤差が最も少ないモデルを採用した。Adam⁹のパラメータに関しては、論文で推奨されている値を使用した。

本稿では、入力データの圧縮率、畳み込み層の数、ブーリング層の数、全結合層の層数、2層目の全結合層のニューロン数、入力データの入力月の6つを変更させ、影響評価を行った。リードタイムは2ヶ月である。

4. 計算結果

CNNを用いてタイ国チャオプラヤー川の2ヶ月後の降水量予測を行った。3章(3)において記載した6つのモデルパラメータの影響を評価した。次に、それぞれのCaseにおける予測降水量とJRA55の降水量値から決定係数R²を算出し、評価を行った。

(1) 入力データの圧縮倍率

図-2は試験期間における、入力データを圧縮した場合の予測結果の時系列変化である。すべてのCaseを見ると、データの圧縮を行うほど予測精度の低下が確認できた。Case1, Case2, Case3を比較すると、入力データの空間解像度を3/5より粗くすると、予測精度が大幅に低下した。特に、雨期中における予測精度が著しく低下した。また、Case3, Case4, Case5を比較すると、入力データの圧縮を行ったCaseにおいて、雨期中のピーク降水量の予測値にばらつきが生じた。これらのことより、雨期中の降水量を予測するためには、より細かい空間解像度の表面温度データを使用する必要があると考えられる。

Case3, Case4, Case5を見ると、データの空間的圧縮を行うことによって、周期変動の位相にずれが生じる結果となった。圧縮操作を行うと、圧縮操作を行わない予測と比べて、乾期及び雨期のピーク値が1・2ヶ月程度遅く予測される傾向にある。

(2) 畳み込み層の層数

図-3は試験期間における、畳み込み層の層数を変化させた場合の予測結果の時系列変化である。畳み込み層の層数が増加するにつれて、予測精度が低下する傾向にあった。特に、乾期の予測精度が著しく低下した。しかし、すべてのCaseを比較すると、極値の再現性が高いのはCase1とCase4であった。Case4の予測結果に関しては、2013年及び2014年の雨期において、より詳細な降水量の変動に対応していることが確認できた。

これらのことより、畳み込み層の層数を増加させることは予測精度を向上させる可能性を秘めているが、予測自体が不安定になることが考えられる。

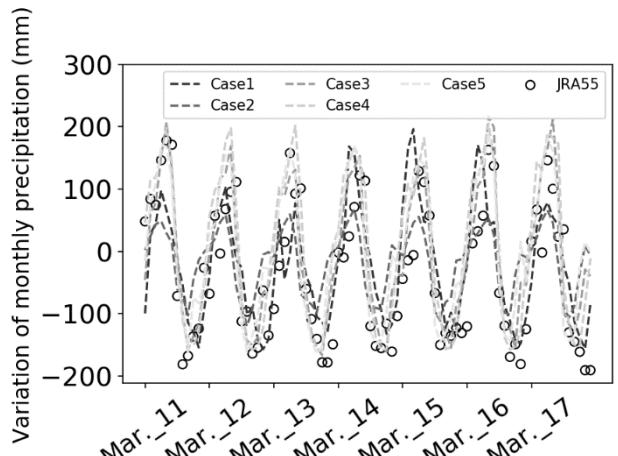


図-2 試験期間における、入力データを圧縮した場合の予測結果の時系列変化

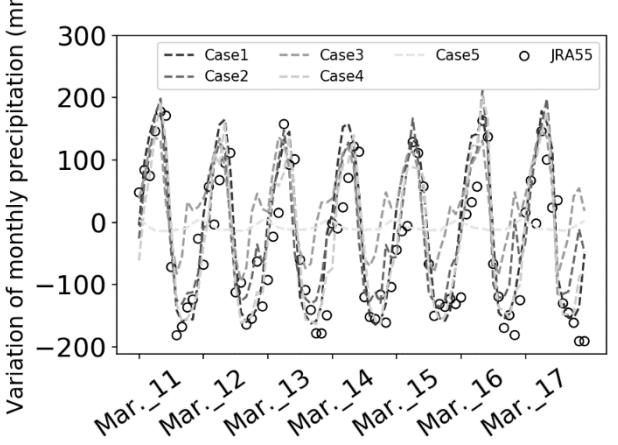


図-3 試験期間における、畳み込み層の層数を変化させた場合の予測結果の時系列変化

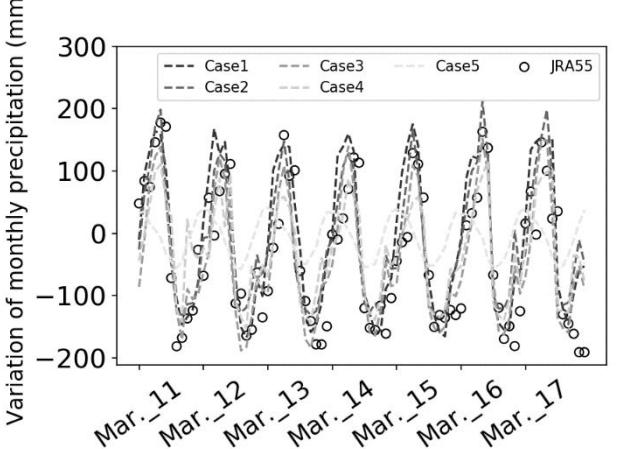


図-4 試験期間における、ブーリング層の層数を変化させた場合の予測結果の時系列変化

(3) ブーリング層の層数

図-4は試験期間における、ブーリング層の層数を変化させた場合の予測結果の時系列変化である。ブーリング層の層数を増加させると、予測精度は低下する傾向にあった。特に、ブーリング層が4層以上となった場合、

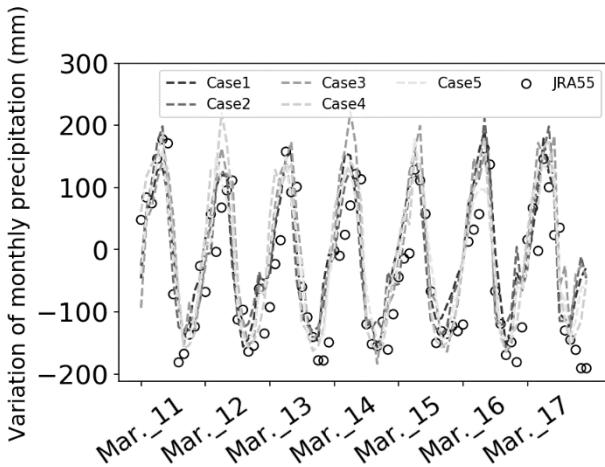


図-5 試験期間における、全結合層の層数を変化させた場合の予測結果の時系列変化

3層以下のCaseと比較して、予測降水量がとり得る上限及び下限が0に近づいていることが確認できる。この影響は、乾期よりも雨季の方が明瞭に表れた。また、乾期から雨期に移り変わる時期が数か月程度遅くなることが確認された。プーリング層の役割は、入力データの作成時や畳み込み層による処理によって生じるデータのズレを修正することにある。しかし、JRA55のようなデータ間の間隔が定まっているデータを用いる場合は、プーリング層の層数をあまり設けない方が精度が向上すると考えられる。

(4) 全結合層の層数

図-5は試験期間における、全結合層の層数を変化させた場合の予測結果の時系列変化である。全結合層の層数が増加するにつれて、予測降水量がとり得る下限が小さくなることが確認できる。これにより、乾期における予測精度の向上が見込める。しかし、全結合層の層数が3層以上となった場合、雨期中の降水量を過大評価する傾向にあった。

(5) 全結合層(2層目)のニューロン数

図-6は試験期間における、全結合層(2層目)のニューロン数を変更させた場合の予測結果の時系列変化である。Case1においては、2層目のニューロン数を小さくしすぎたために計算能力が低くなつたため、予測ができていないと考えられる。深層学習の利点の1つに、機械が特徴量の選択を行い、重みづけを行うことが挙げられる。Case3では、ニューロン数の数に変化がなかつたため、特徴量の圧縮や展開が行われず、深層学習の利点を最大限利用することができなかつた結果だと考えられる。Case2, Case4, Case5を比較すると、乾期においては、ニューロン数の数を増やしたCase4, Case5の方がより小さいこうす利用まで対応していることが確認できる。これらのことより、2層目のニューロン数を設定する際は、

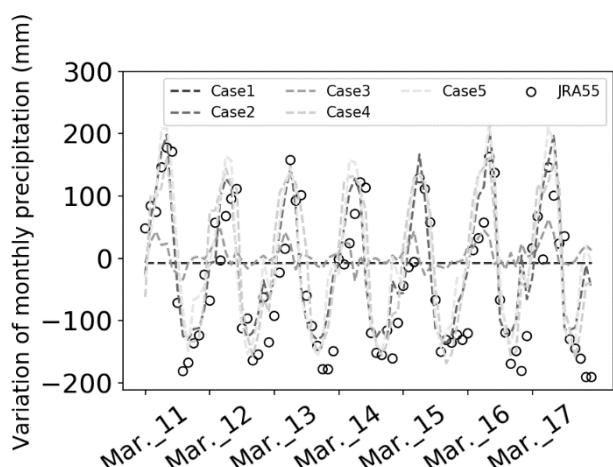


図-6 試験期間における、全結合層(2層目)のニューロン数を変更させた場合の予測結果の時系列変化

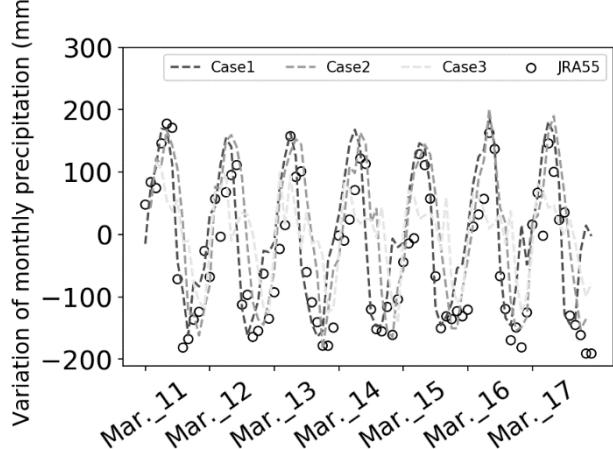


図-7 試験期間における、入力データに複数月の表面温度データを使用した結果の時系列変化

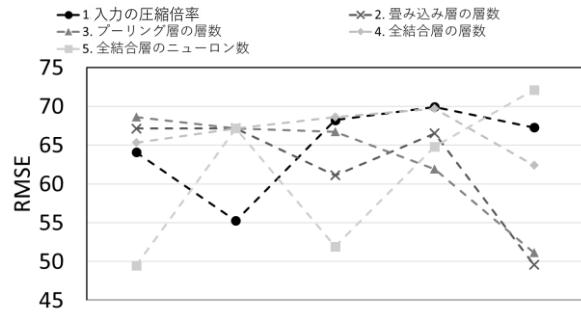


図-8 試験期間における、JRA55の降水量値と予測降水量値から算出した決定係数R₂の結果

層目のニューロン数より大きな値を設定することが望ましい。しかし、2層目のニューロン数を極端に大きな値とした場合、精度の良い学習が困難となると考えられる。

(6) 入力データの入力月

図-7は入力データに複数月の表面温度データを使用した結果の時系列変化である。より多くの月の表面温度データを入力データとして取り扱うことで、乾期のピーク時期をより再現することが可能であった。複数月のデ

ータを入力データとしたことで、入力情報に時間の概念が追加されたためと考えられる。ピーク時期を2・3ヶ月前の表面温度データを使用した場合、乾期における予測精度が最も向上した。この要因は2つ考えられる。1つは、ある月の表面温度はその4ヶ月後の降水量とは全く関係がない、もう1つは、モデル性能によるものである。ここでは、入力データが2ヶ月前の全球表面温度の条件で、パラメータを設定し、それを用いてモデル作成を行っている。そのため、4ヶ月前のデータから十分に特徴量の抽出ができなかつたのではないかと考えられる。

(7) 決定係数 R^2 による評価・まとめ

図-8はJRA55の降水量値と予測降水量値から算出した決定係数 R^2 の結果である。入力データの圧縮倍率は等倍に近いほうが高い精度を示す。また、プーリング層の層数が増加するにつれて、予測精度は低下した。これらのことより、入力データである全球表面温度には、圧縮操作を行う必要がないことが示唆された。

深層学習の精度は、複数の層を用いて計算を行うことによって、向上してきた。そのため、層数やニューロン数が大きい値をとるほど、高い計算能力を持つ予測モデルであるといえる。本稿により作成している降水量の予測モデルにおいては、全結合層を3層にした時点で、精度が向上しなくなった。

様々なモデルパラメータを変更することで、乾期の降水量の予測精度を向上させることができた。また、空間的圧縮及びプーリング層による圧縮操作が行われたCaseにおいては、乾期と比べて、雨期の予測にばらつきが生じた。したがって、深層学習を用いることによって、乾期中の降水量を定量的に予測できる可能性が示された。

入力データに複数の月のデータを入力することで、降水量の極値の再現性が高くなった。そのため、精度向上のため、この手法を用いることは有用な手段であるといえる。しかし、ニューロン数や全結合層数の増加など、モデルの計算能力の向上を必要とする。

5.まとめ

本稿では、深層学習を用いた降水量の季節予報モデルを作成するために、入力データの圧縮率、畳み込み層の数、プーリング層の数、全結合層の層数、2層目の全結合層のニューロン数、入力データを複数月入力するといった6つのCaseにおいて、予測モデルの感度分析を行い、それらの結果を評価した。

これらの予測モデルの性能を評価した結果、入力データの圧縮操作及びプーリング層により空間的圧縮がなさ

れたデータが予測計算に利用された場合は、その圧縮倍率に従って、予測精度が低下する傾向にあった。特に、雨期の降水量を予測する場合は、詳細な表面温度データが必要であることが示唆された。

モデルの計算能力を向上させる役割を果たす全結合層及びニューロン数を変化させたところ、全結合層の層数を増加させると予測精度が向上した。ニューロン数は前の層のニューロン数と異なる値で、近しい値を設定することで精度が向上した。

入力データに複数月の情報を与えることで、極値の月の再現性が向上した。これは、入力データに時間という概念が追加されたためと考えられる。したがって、この手法による精度向上は有効な手段であることが分かった。

すべてのCaseにおいて、予測精度が低下する場合、乾期よりも雨期の精度低下が著しかった。反対に、予測精度が向上する場合、雨期より乾季の予測精度がより向上した。したがって、深層学習を用いることで、乾期の降水量予測が行えることが示唆された。

謝辞：利用したデータセットは、文部科学省の委託事業により開発・運用されているデータ統合解析システム(DIAS)の下で、収集・提供されたものである。ここに感謝の意を示す。

参考文献

- 1) Intergovernmental Panel on Climate Change : Climate Change 2013 The physical science basis. Contribution of working group I to the fifth assessment re-port of the Intergovernmental Panel on Climate Change, pp.1-29, 2013.
- 2) データ統合・解析システム DIAS, <https://www.diasjp.net/>, (2019年7月19日閲覧).
- 3) 森脇亮, 今村実, 全邦釣, 藤森祥文 : 深層学習を用いた風速の短時間予測の試み, 土木学会論文集 B1(水工学), Vol.74, No.4, I_229-I_234, 2018.
- 4) 一言正之, 櫻庭雅明, 清雄一 : 深層学習を用いた河川水位予測手法の開発, 土木学会論文集 B1(水工学), Vol.72, No.4, I_187-I_192, 2016.
- 5) 鈴木紹晟, キムスンミン, 立川康人, 市川温, 萬和明:豪雨の発生予測に対する畳み込みニューラルネットワークの応用, 土木学会論文集 B1(水工学), Vol.74, No.5, I_295-I_300, 2018.
- 6) JRA55 : https://jra.kishou.go.jp/JRA-55/index_ja.html, (2019年5月7日閲覧).
- 7) Tensorflow : <https://www.tensorflow.org/?hl=ja>, (2019年7月19日閲覧).
- 8) Keras : <https://keras.io/ja/>, (2019年7月19日閲覧).
- 9) Diederik P. Kingma, Jimmy Lei Ba : Adam: A method for stochastic optimization, Published as a conference paper as ICLR, 2015.