

ディープラーニングによる 新しい降水予測手法の検討

STUDY OF NEW RAINFALL PREDICTION METHOD BASED ON DEEP LEARNING

金子 凌¹・仲吉 信人²

Ryo KANEKO and Makoto NAKAYOSHI

¹学生会員 工修 東京理科大学大学院理工学研究科土木工学専攻 (〒278-8510 千葉県野田市山崎2641 5号館三階)

²正会員 博士(工学) 東京理科大学理工学部土木工学科 (〒278-8510 千葉県野田市山崎2641 5号館三階)

Heavy rainfall has been causing many dreadful disasters, but its prediction is quite difficult in current weather forecast models. Today deep learning breakthrough in various field. We attempted to apply a deep learning algorithm, or stacked LSTMs, to rainfall prediction. Our LSTM weather prediction model was established with micro climate data in Kyusyu from 1990 to 2015 and validated for 2016-2018 rainfall events. The model was able to predict even weak rainfall but showed disadvantage for heavy rain fall events as well as rainfall onset prediction. We also suggested possible solutions for increasing reliability of LSTM rainfall models.

Key Words : precipitation, machine learning, deep learning, prediction, LSTM

1. 背景と目的

毎年のように発生する集中豪雨・局地的大雨は、人々の生活に甚大な被害をもたらす。特に中小河川とその流域では、急激な増水や氾濫によって、多くの人命、財産が失われる。例えば、平成29年7月九州北部豪雨や平成30年西日本豪雨などは記憶に新しい。

このような極端な豪雨イベントを気象シミュレーションで予測することは非常に難しく、データ同化などによるアプローチが盛んに行われているが未だ降水数時間前ですら予測が出来ないこともあるのが現状である。

一方、このような物理プロセスを扱うモデルとは異なる、ディープラーニング(DL)による予測が多分野で成果を上げている。従来の機械学習より、更に複雑な表現が可能で、医療、自動運転など、適用範囲は実に広い。土木、気象の分野でも徐々に注目を集めている。徳田ら¹⁾は機械学習が洪水イベントの予測に適用可能であることを示し、Matsuoka et al.²⁾は機械学習により台風の発生前の物理シグナル(台風のたまご)の予測を行うなど、従来の物理モデルに頼らない野心的な試みが行われ始めている。

そこで本研究では、シーケンシャルモデルを用いて、降水を予測するモデルを開発する。シーケンシャルモデルとは、各層が全結合でつながり、閉路を持っているグラフで構成されるDLモデルである。有向非巡回モデルなど複雑なDLモデルより計算負荷の低いモデルで検討することにより、降水予測分野におけるDLのベースラインを決定する。柔軟な表現力を持った有向非巡回モデルや、アンサンブルモデル作成に向け、シーケンシャルモデル単体での性能を評価することを目的とする。

精度良く降水予測が可能となると、豪雨時、河川の水位予測や氾濫予測をより早いうちに行うことができる。これは、水防活動や住民の避難に役立てられる。

2. 作成したモデル

(1) モデルの構成・学習アルゴリズム

モデルの構成を図-1(上)に示す。これまでも、機械学習を用い豪雨を予測するモデルは検討されてきているが³⁾、本モデルとそれらのモデルとの大きな違いは時系列データの学習に適したLSTM(Long short-term memory)⁴⁾

を用いることにある。気象現象は時々刻々と変化する。例えば我々は日常生活によって、発達した積乱雲による外出流を感じれば、豪雨に遭遇することを予想することができ、風も吹かない穏やかな日は、一日の天気が晴れるものだと考える。このように気象は時間変化と密接な関係があり、時系列データを扱うことに特化したモデルを作成することは有用だと考えられる。

本モデルはこのLSTMを連結させて用いる、Stacked LSTMsという手法を用いており、1層のLSTMよりも更に表現力を高めている。また、各LSTM層では、リカレントドロップアウト、ドロップアウトを20%ずつ行うことにより、モデルが過学習に陥ることを防いでいる。

さらに、LSTM層とLSTM層、LSTM層と出力層の間では、特徴量方向のBatch Normalization⁵⁾を行っている。これは、学習中に層間でバッチ単位の正規化を行うことにより、ネットワーク全体の安定化、学習の効率化を行うものである。

その他の各種設定を表-1に示す。オプティマイザーにはAdam⁶⁾を用いており、損失関数には二乗平均平方根誤差(Root Mean Square Error, RMSE)を用いた。エポック数は、過学習に陥らず、且つ学習が収束したと判断出来た100に設定した。またエポック数が70までは学習率を0.00010に設定しているが、それ以降は0.00005に落とし、安定した収束を狙った。入力バッチサイズは128で設定した。

(2) 学習データ

学習に用いたのは、九州の地域気象観測所が観測する気象値である。福岡・日田・佐世保・平戸・長崎・延岡・油津・都城・人吉・牛深・阿久根の11の地点(図-2)であり、時間解像度1時間のデータを学習させた。九州地方は、極端気象なども多く発生し(例えばH24年、H29年の九州北部豪雨)、年間雨量も多い。特徴量として扱うのは、各観測点の前一時間降水量・地上気圧・気温・相対湿度・風速(東西成分)・風速(南北成分)の6つである。これが各観測点分存在するので、計66の特徴量となる。なお、風速は、風速と風向(16方位)で提供されているが、それをベクトル分解し用いている。

学習データとして用いた期間は、1990年～2015年の26年分である。1時間値であるから、計227,904ステップのデータとなる。これを用い、2016年から2018年の3年間分の降水を予測する。

またこれらのデータは学習時の発散を防ぐため、以下の式により時系列方向に標準化されている。

$$x_{\text{zscore}}^i = \frac{x^i - \mu}{\sigma} \quad (1)$$

ここで、 x^i は各サンプル、 μ はサンプルの平均値、 σ はサンプルの標準偏差である。

(3) 学習内容と学習・予測手法




図-1 モデル構成(上)と学習データ(下)
BN: 特徴量方向のBatch Normalization

表-1 各種設定

項目	設定内容
エポック数	100
学習率	epoch $\leq$ 70 : 0.00010 70 < epoch : 0.00005
オプティマイザー	Adam ⁶⁾
バッチサイズ	128
損失関数	RMSE




図-2 観測地点

学習内容を図-1(下)に示す。今回作成したのは、1時間予測をするモデルである。具体的には、「66特徴量の、現在までの12時間分のデータ」を入力すると「現在から1時間後の66特徴量」を予測するというものである。

学習は上の予測手法を達成するため以下になる。図-1(下)中Observed Valueには1990年1月1日0時0分からの実際の観測データが1時間間隔で $X_1, X_2, \dots, X_{227904}$ とならんでいる。 X_i ベクトルは66の特徴量からなる。これらのデータを、先頭から連続して12時間分を抽出し(Sample1)、それをモデルに入力すると、予測値 y_{13} (Target1)が出力されるようにする。 y_{13} と実際の観測値 X_{13} の二乗平均平方根誤差(RMSE)が小さくなるように

表-2 降水タイプ分類(2016~2018)

分類項目 (略記)	サンプル数
寒冷前線性 (cf)	30
温暖前線性 (wf)	13
停滞前線性 (sf)	154
低気圧性 (lp)	53
台風性 (t)	59
層状性 (Ns)	44
未分類 (others)	120
計	473




図-3 日田での予測雨量と実況雨量の時系列図(CNTL)




図-4 油津での予測雨量と実況雨量の時系列図(CNTL)

学習をする。これをデータの先頭からデータの末尾まで全ての組み合わせで行い (Sample1, Sample2, ...), エポック数を重ねることにより学習を進める。

(4) 作成したケース

今回は気象因子の学習への影響も評価するため、各気象因子を削除し学習させた6ケースを作成した。入力因子以外のモデルの構成と設定は変化させていない。6要素をすべて入力するCNTL、相対湿度を削除したDropHumid、気圧を削除したDropPress、気温を削除したDropTemp、風速2成分を削除したDropWind、降水量のみを入力し降水量のみを予測するRainOnlyの6ケースで降水予測精度の比較を行う。

3. 学習結果

CNTLの学習曲線 (図略) は最終的に0.2598となった。これ以上の学習は、バリデーションテストを行った際に過学習となる傾向が確認されたため、100エポックで学習をストップさせている。予測変数が他より少なく学習




図-5 阿久根での予測雨量と実況雨量の時系列図(CNTL)




図-6 佐世保での予測雨量と実況雨量の時系列図(CNTL)

の早いRainOnlyのみ50エポックで止めているが、それ以外のケースは同様の設定で過学習せず、学習不足でもないことを確認済である。

4. 予測結果

(1) 予測に用いたデータと扱い

学習したモデルを用い、2016年~2018年の3年全ての期間に対して1時間予測を行う。また、降水イベントの抽出にはアメダス日雨量5 mm以上を、11地点のいずれかが観測した日を降水日とし抽出し、降水日ごとの降水タイプの分類も行う。天気図、衛星写真から判別が容易なものだけを分類した。例えば、九州地方を寒冷前線が通過した日など具体的な要因が分かるものは分類し、一日に寒冷前線と温暖前線が連続で通過した日など、降水の要因となるものが複数あり、または天気図から読み取れない場合は分類しない。更に、この時、衛星写真から九州地方に層状の雲がかかっている場合を層状性の降水日と分類した。分類したものは、寒冷前線性、温暖前線性、停滞前線性、低気圧性、台風性、層状性の6種類である。各分類のサンプル数は表-2のようになる。

(2) 予測値の全体的な傾向

抽出した降水日における、CNTLケース各地点での予測結果のRMSEは、福岡0.78 mm/h・日田1.16 mm/h・佐世保2.04 mm/h・平戸1.14 mm/h・長崎1.97 mm/h・延岡3.07 mm/h・油津2.21 mm/h・都城1.11 mm/h・人吉1.52

mm/h・牛深1.48 mm/h・阿久根2.73 mm/h となった。小雨の予測性能は高いが、集中豪雨など強雨での予測に難があることが多い。例として、九州地方の北東、南東、南西、北西に位置する4地点を取り上げる（図-3～6）。今回は紙面の都合上、この4点の平成29年の1月、3月、5月、7月、9月、11月の予測値、実測値を示すに留める。

九州地方の北東に位置し、平成29年九州北部豪雨で最大87.5 mm/hを観測した、大分県日田市での結果に着目する（図-3）。梅雨前線や秋雨前線による大雨は、精度良く予測出来ている箇所もある。しかし、豪雨災害が発生した7月5日の雨量は大幅に過小評価されていることが分かる。また、台風による大雨では逆に、大きく過大評価してしまうことがあった。

九州地方南東に位置する、宮崎県油津での同期間での降水量予測を図-4に示す。梅雨前線による大雨や弱雨は良く予測出来ることもあった。台風18号は、1度目のピークを予測出来なかったが、2度目のピークを予測出来た。

九州地方南西に位置する、鹿児島県阿久根での予測を図-5に示す。ここでも、弱い降水に関する予測は精度良く出来ることもある。しかし、瞬間的なピークを伴う台風3号などの予測はうまく出来ていないことが分かる。

九州地方北西に位置する、佐世保でも（図-6）、同様の傾向が得られている。

(2) 1時間予測のスレットスコア

スレットスコア(TS)という指標を用いる。同時刻における実況値、予測値ともに、降水ありを適中FOとする。実況が降水ありだが予測が無しのものをXO、予測は降水ありだが実況は無しのものをFXとする。このときTSは、FO、XO、FXの標本数を用い、以下の式で表される。

$$TS = \frac{FO}{FO+FX+XO} \quad (2)$$

本研究では、降水ありの閾値を1.0 mm/hに設定し、弱い降水を含めて、TSを比較した。また、本モデルのTS以外に、気象庁メソスケールモデル(MSM)から3時間ごとに与えられる予測値（1時間後、2時間後、3時間後）のTSも求め比較を行った。

地点ごとのTSは図-7のようになる。今回作成したモデルのどのケースもTSは大きく変わらない。また、MSMと比較すると、そのスコアはどの地点でも僅かながら高く、1時間後の降水の存在をMSMより良く捉えられていることがわかった。

(3) 立ち上がり捕捉率

降水予測をするとき、その降り始めを正確に予測することは重要である。そこで、降水の開始時予測精度に注目し判定（降水開始を予測出来るか否か）を行う。実況値において、前6時間が無降水であったときに降る雨(1.0 mm/h以上)を降り始めとして考える。これを予測すると




図-7 地域別TS




図-8 降水タイプ別立ち上がり捕捉率

き、予測値が1.0 mm/h以上であり、かつ予測値の1時間前の雨量が1.0 mm/h未満の場合、予測が出来たものとする。これを全期間で行い、予測が出来た割合を立ち上がり捕捉率(以下単に捕捉率)とする。

a) 降水タイプ別捕捉率

降水タイプ別の捕捉率を、図-8に示した。これは地域ごとの事象を降水タイプごとに全て合算し算出している。棒グラフの色は、それぞれの計算ケースを示す。前線性の降水は相対的に精度良く予測することが可能であるが、台風や層状性の降水は精度が良くないことが分かる。また、本モデルの降水タイプ別捕捉率はMSMよりも低い降水タイプが存在し、とりわけ寒冷前線性、層状性の降水に関して低かった。

b) 地域別捕捉率

11地点での捕捉率を、図-9に示した。降水タイプは考慮せず、降水を捕捉した事象を全て地域ごとに合算している。棒グラフの色分けは、それぞれの計算ケースを示す。全体的に、熊本県人吉、鹿児島県阿久根で他より精度が高いことが分かる。逆に長崎県平戸や宮崎県都城では精度が相対的に良くないことが分かる。九州の西や北東では精度が良いが、北西や南東では精度が良くない傾向があると考えられる。

降水イベント全体で見たとき、立ち上がりをうまく捕捉できていたのはMSMであった。




図-9 地域別立ち上がり捕捉率




図-10 CNTLにおける各地点、各降水の立ち上がり捕捉率比較




図-11 実況値のサンプル数

c) 計算ケース別TS, 捕捉率

図-7, 図-8, 図-9より, 計算ケースによるTSや捕捉率の差異は大きくはない. RainOnlyのケースにおいても, 降水予測の精度は大きく変わらないことから, 降水量が予測の精度を決めており, 他のパラメータは補助的な役割しか果たしていないと言える. 多地点の同時学習により移動性降水では, 風上側の地点が降水シグナルを捉え(雨量の立ち上がりや外出流, 湿度上昇), 風下の地点はそのシグナルを活かすことで予測精度の向上に繋がると予測していたが, そうはならなかった. これは, 学習に用いたデータは降水シグナルが活かされるには時空間的に荒すぎたためと考えられる.

5. 考察

(1) 地域ごとの各降水タイプによる捕捉率




図-12 MSMの立ち上がり捕捉率比較




図-13 右: 2016年12月14日, 左: 2017年9月4日の天気図
出典: 気象庁ホームページ
(<http://www.data.jma.go.jp/fcd/yoho/hibiten/index.html>)
「日々の天気図」

図-10に, 地域ごとの各降水タイプによる捕捉率をヒートマップで示した. 縦軸は各観測地点, 横軸は各降水タイプを示す. ヒートマップは捕捉率を示している. また, 図-11にはこの確率を算出するために抽出した, 実況値のサンプル数(確率を導くときの母数)を示している. また, 図-12にはMSMでの同様の結果を示している. 本モデルはMSMより捕捉率が良い箇所も存在するが, MSMは全降水タイプ, 全地点においてまんべんなく捕捉率が高いことが見て取れる. 以下, 特徴的なケースを取り上げて考察する.

(2) 層状性(Ns)の降水における捕捉率

図-10を見るとどのケース, どの地点においても, 層状性の降水は捕捉率が低いことが分かる. 降水量の低いタイプのため, 一見精度が良く見積もられて然るべきかと考えられるが, 最も良くても人吉の18.75 %であり, 0 %のところも4地点存在する. 気象庁の天気図を見ると, 層状性の雨の時には, 特に決まった気圧配置ではなく, 様々な気圧配置をとっている(図-13). また, 発生する期間も様々である. そのため, 降水範囲やその変化なども様々であり, レーダー雨量で見ると九州の西方から降水域が広がっていったり, 北方から広がっていったり, その降り方は様々であった(図略). このため, 学習時に一定の法則, 規則を見いだせず, 層状性の雨の予測を困難なものにしたと考えられる.

(3) 台風性(t)の降水の捕捉率

4章では, 層状性の雨に次いで, 台風性の降水の捕捉率も良くないことがわかった. これを図-10で地点ごとに見ると, どの地点でも一度も捕捉しなかったことはな

いが、全体的に捕捉率が低く評価されていることが分かる。台風は、進路によって降水量が異なり、またその風速や気圧なども異なる。そのため、捕捉率が低くなったものと考えられる。

(4) 温暖前線性(wf)の降水の捕捉率

4章では温暖前線性の降水の捕捉率は、他の計算ケースよりも高いことがわかった。図-10において各地点で比較してみると、温暖前線性の降水は牛深、人吉、長崎の3点で30%を超える捕捉率を出しており、他のケース、他の地点での捕捉率よりも高いことが分かる。ところが、福岡、日田、延岡、油津、都城では捕捉率は0%である。これは、温暖前線性の降水として抽出し評価したサンプル数が他の降水タイプと比べて非常に少ないことが原因として考えられる(図-11)。このため、1サンプルあたりの重みが大きくなり、一度捕捉するかどうかで、その全体での捕捉率は大幅に変化してしまった。更にサンプル数を増やし、検討することが必要と考えられる。

(5) 寒冷前線性(cf)の降水の捕捉率

上と同様に、各地点での捕捉率を評価した。人吉や油津などでの捕捉率は、MSMでの捕捉率よりも高かった。学習がうまくいくと従来の気象モデルよりも捕捉率が高くなる可能性が示唆された。

(6) 本モデルが予測可能である事象

TS(4章2節)と、捕捉率(4章3節)から降り始めと降水中での予測精度の差異が、非常に大きいことが分かる。

また、降り始めてからの降水量の予測は地域や降水タイプにより精度に違いがあることが分かった。

これらの結果には学習データの内容が影響している可能性がある。図-14に示すのは、降水量のヒストグラムである。紙面の都合上精度が良かった人吉と、精度が悪かった油津を例に挙げる。両者とも弱い降水(1 mm/h以上5 mm/h以下)に関しては多くの学習サンプルがあり学習が進んだと考えられるが、5 mm/hを超えたところからはサンプル数が極端に少ないことが分かる。このため強い降水の学習が満足に出来ず、予測に支障が出たと考えられる。また、油津の方が5 mm/hの降水量が多いことがわかる。一見、降水量が多い場合の学習の助けになると考えられるが、このような現象は短時間で発生するもので、決して十分なサンプル数とは言えないため、ノイズとして弱い雨の学習の妨げになったとも考えることが出来る。そのため、油津では弱い雨の予測も精度が悪かった可能性もある。

6. まとめと今後の展望

本研究では、Stacked LSTMsを用いたシンプルなシーケンシャルモデルを用い、降水予測モデルを作成した。




図-14 学習データの降水量別ステップ数

その結果、以下のようなことがわかった。

- ・ 降水の継続を予測することに関して精度が良いこともあった。
- ・ 層状性の雨は弱い雨であるが予測が難しい。
- ・ 強い雨や特定の地域では予測精度が落ちる。

本モデルは、全ての降水タイプを同時に使用し、また晴天日も使用し学習データを作成し学習をさせた。今後、学習を行うときには、降水日のみの抽出を行い、更に降水タイプ別の分類を行い、それぞれを学習させる。それぞれの降水に特化したモデルを作成することで精度向上に繋がると考えられる。また、5 mm/h以上の降水は、サンプル数が急激に少なくなるため、データの水増しが前処理として必要である可能性もある。例えば、既存の学習サンプルにガウスノイズを加えたものを新しく学習させるなどである。

参考文献

- 1) 徳田大輔, Eunho KOO, 金炯俊: 深層学習を用いた河川水位予測モデルにおけるネットワーク構造と入力データ量の依存性, 土木学会論文集B1(水工学), 第74巻, 第5号, pp. I_169-I_174, 2018.
- 2) Matsuoka, D., Nakano, M., Sugiyama, D. and Uchida, S.: Deep learning approach for detecting tropical cyclones and their precursors in the simulation by a cloud-resolving global nonhydrostatic atmospheric model, *Progress in Earth and Planetary Science*, Vol. 5, No. 1, pp. 80, 2018.
- 3) 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), 第74巻, 第5号, pp. I_295-I_300, 2018.
- 4) Hochreiter, S. and Schmidhuber, J.: Long Short-term Memory, *Neural computation*, Vol. 9, No. 8, pp. 1735-1780, 1997.
- 5) Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, arXiv e-prints, 2015.
- 6) Kingma, D. P. and Ba, J. L.: ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION, *3rd International Conference on Learning Representations*, pp. 1-15, 2015.

(2019. 4. 2受付)