

## 深層学習モデル LSTM を用いた降水予測モデルの検討

東京理科大学理工学研究科土木工学専攻 学生会員 ○ 金子 凌  
東京理科大学理工学部土木工学科 正会員 仲吉 信人

### 1. 背景と目的

降水量を定量的に予測することは、治水や利水において重要である。これまでも、数値気象モデルを始め様々なアプローチが行われ成果を挙げている。一方、深層学習があらゆる分野で成果を挙げ始め世間の着目を集めており、土木や気象の分野でも物理に頼らないモデルを導入する野心的な取り組み<sup>1)2)</sup>が行われ始めている。そこで本研究では、モデルに、九州の AMeDAS の 114 地点のデータを学習させ、深層学習による降水予測の可能性や問題点を明らかにすることを目的とする。

### 2. 学習データとデータセットの作成

九州地方で、観測が現在も続いており、かつ欠測の少ない 114 地点の AMeDAS の、1 時間解像度データを利用する（詳細は紙面の都合上割愛する）。1990 年～2015 年までを学習データ（内、後ろから 20%のデータをバリデーションに使用）、2016 年～2019 年 7 月 8 日までを学習やパラメータの調整に使用せず、性能評価のみに用いる、テストデータに設定した。学習に使用したデータは水平風速成分（u, v）、気温、比湿、気圧、降水量である。これらのデータは、系列ごとに標準化され与えられる。作成するモデルは、それぞれの観測点での前 12 時間の気象要素の変化を入力すると、各地点での 1 時間後の降水量を予測するというモデルである。このようなデータセットをタイムステップごとに作成した。

### 3. 作成したモデル

Google LLC が作成している、Keras (ver. 2.1.2) を使用しモデルを構築した。今回作成したモデルは、図-1 に示す LSTM 層を多層に重ねたモデルである。また、諸設定を表-1 に示した。LSTM は時系列データの学習に特化しているリカレントニューラルネットワークの一種であり、過去からのデータを記憶、必要に応じ忘却することにより、将来の予測を行う。以降、このモデルを単に LSTM モデルと呼ぶ。

### 4. 計算結果

バリデーションにより（図略）、エポック数が 50 程度で損失関数の減少が頭打ちとなったことから、以降の議論では、50 エポック時のパラメータを利用する。

紙面の都合上、降水予測ができた一つの事例を図-2 に示す。これより、概ね予測できている事例もあることが分かる。

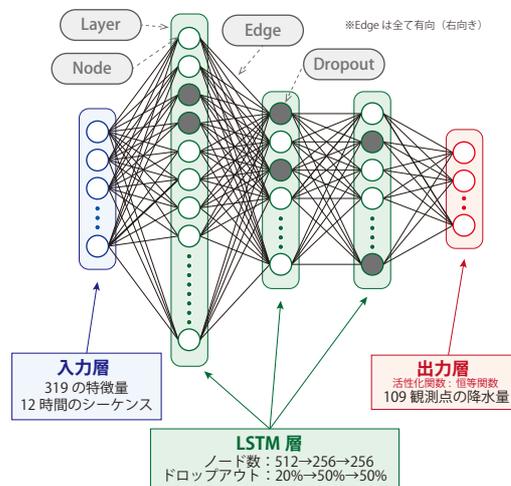


図-1 モデルの構築

表-1 モデルの設定

項目	設定値
学習法	ミニバッチ
バッチサイズ	128
損失関数	平均二乗誤差(MSE)
オプティマイザー	Adam ( $\beta_1=0.9$ , $\beta_2=0.999$ )
活性化関数	tanh
再帰計算時の活性化関数	Hard sigmoid
初期化手法	Xavier initialization
再帰計算部分の初期化手法	Orthogonal initialization
バイアスの初期化手法	全てを 0 で初期化
学習率	0.001 (一定)
エポック数	50
計算精度	倍精度

キーワード 機械学習, 深層学習, 降水予測, LSTM, ディープラーニング, AMeDAS

連絡先 〒278-8510 千葉県野田市山崎 2641 東京理科大学 5 号館 3 階水理研究室 TEL 04-7122-9620

全地点、全テスト期間でのスレットスコア（閾値 1 mm/h）と立ち上がり捕捉率を図-3 に示す。立ち上がり捕捉率とは、降水の始まりを捉えられているか評価する独自の手法である。観測値で無降雨が 6 時間続いた後に、現在降水が閾値（今回は 0.5 mm/h）以上で降りはじめたときを降り始めとする。予測値で、現在から 1 時間前の降水量が閾値未満で、現在を予測した降水量が閾値以上となれば、降水の始まりを予測できたと定義する。

LSTM モデルとの比較に用いたのは、気象庁の Meso-Scale Model（以降 MSM）である。MSM では毎日、0 時、3 時、6 時、9 時、12 時、15 時、18 時、21 時に、1 時間後予測、2 時間後予測、3 時間後予測が計算される。そのため、全てが 1 時間前の予測値ではないが、それも含めて現状の予測モデルの性能とみなし、MSM の 2 時間後・3 時間後予測も本モデルの 1 時間後予測と比較する。

LSTM モデルは、MSM よりもスレットスコアが高かった。1 時間後の予測であるなら物理過程を考慮しない LSTM モデルの性能が良いと考えられる。

LSTM モデルの立ち上がり捕捉率は、MSM よりも高い点も存在するが、低い点も存在する。低い点には、北、西、南の海沿いという傾向があることがわかった。

## 8. 考察

予測したエリアでは、降水が、偏西風の影響によって南西側から東側に向かう移流パターン、停滞前線のように北側から南へ、南側から北へ移流するパターンが多く見られる。そのため、LSTM モデルはそれらの移流パターンに最適化され学習されたことが考えられる。風上側の降水を捉えることにより、風下側の降水を予測した。北、西、南の海沿いでは、それより風上側の観測点がないため、立ち上がり捕捉率が低かったと考えられる。逆に、それより風下側の観測点では、海沿いの観測点の降水を感知することで、予測精度が高くなったものと考えられる。

## 9. 今後の課題

本モデルは、降水量が高いものに関しては、予測が難しかった。豪雨の事例を学習するにはそれらのデータが少なすぎるのが原因である。また、局所的な現象を予測するには、AMeDAS のみでは空間解像度が足りない可能性がある。そのため、豪雨の事例を重点的に学習させることや、衛星データを学習させることにより、モデルをより高精度化する必要があると考えられる。

## 参考文献

- (1) 板谷知明, 芳村圭: 深層学習を用いた水文気象場のダウンスケーリング手法の開発, 土木学会論文集 B1 (水工学), 第 74 巻, pp.151-156, 2018.
- (2) 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), 第 72 巻, 第 4 号, pp.I\_187-I\_192, 2016.

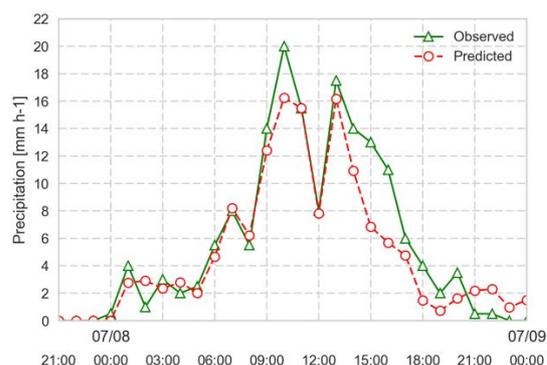


図-2 2016年7月8日-えびのアメダス

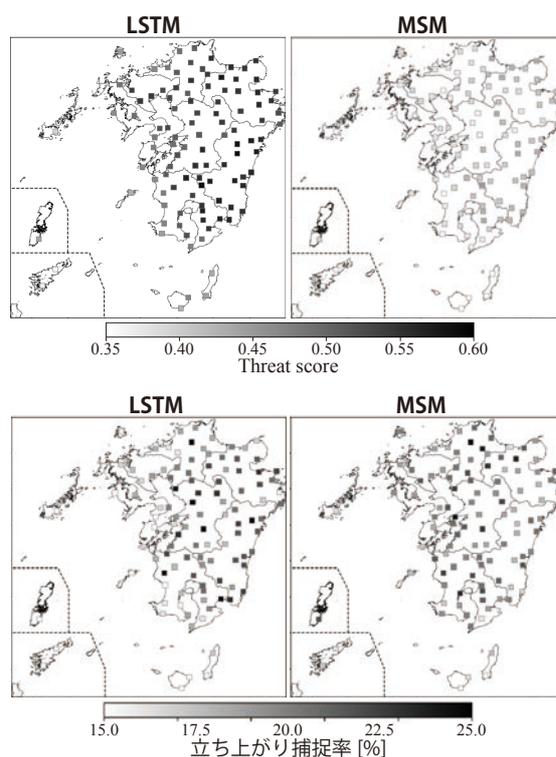


図-3 LSTM モデルと MSM の比較

(上: Threat score, 下: 立ち上がり捕捉率)