

## Convolutional LSTM を用いた降雨量データの欠損補間

篠田拓樹<sup>†</sup>稲毛惇人<sup>††</sup>飯棲俊介<sup>†</sup>大枝真一<sup>†</sup>木更津工業高等専門学校 情報工学科<sup>†</sup>木更津工業高等専門学校 制御・情報システム工学専攻<sup>††</sup>

## 1. はじめに

近年、豪雨による人や建物、農作物等の被害が深刻化している。このような現状を受けて、降雨量データを用いて豪雨を事前に予測することにより、被害を抑えようとする研究が行われている。研究に使われるデータとして、XRAIN と呼ばれる X バンドマルチパラメータレーダを用いた観測システムによって計測されているものがある。このシステムは、高分解能かつ多頻度の雨量観測が可能である。しかし、このデータは降雨量や雲の厚み等の気象条件によって計測が困難になり、欠損してしまう部分がある。そのため、時系列を扱うことの出来るニューラルネットワークである LSTM を用いることによって欠損の補間を行う研究が行われている [1]。しかし、その研究においては 1 次元によるデータ補間のため空間情報が失われてしまっている。

そこで、本研究では LSTM を拡張した Convolutional LSTM を用いることによって欠損した箇所を正確に補間することを目的とする。

## 2. XRAIN

XRAIN は eXtended RAdar Information Network(高性能レーダ雨量計ネットワーク)の略であり、高性能気象レーダを用いた雨量観測システムである。以前は、観測用のレーダに X バンド MP レーダのみが使用されていた。しかし、現在は従来の雨量観測に使われていた C バンドレーダがマルチパラメータ化され X バンド MP レーダと併用されている。X バンドレーダは、波

長が短く、高分解能な観測が可能である。また、MP(マルチパラメータ)レーダは垂直・水平の偏波を送受信することで従来のデータよりも多くの項目を測定することが可能であり、雨滴の扁平度等の情報から雨量を推定する。これらのレーダによって高精度・高分解能(250m メッシュ)・高頻度(1分毎)な観測を行うことが可能であり、観測データの補正を行わなくてよいためリアルタイムの情報配信が可能である [2]。

## 3. Long Short-Term Memory

時系列データを扱うニューラルネットワークとして RNN(Recurrent Neural Network)がある。その RNN の改良手法が LSTM(Long Short-Term Memory)である。

RNN には、長期の依存関係を学習することが困難であるという問題があった。これは、勾配消失問題と呼ばれる。この問題は、時間を遡るごとに勾配が消失してしまうことによって引き起こされていた。RNN の構造とその問題を解析し、長期の依存関係を学習可能にしたモデルが LSTM である。

LSTM では、勾配消失問題への対策として中間層のニューロンを特殊な構造に変更した。この構造の中心となる考え方は、CEC(Constant Error Carousel)と呼ばれるものである。CEC は、再帰構造として保持される状態の扱い方を式 (1) のように表したものである。

$$\begin{aligned} s_{c_j}(0) &= 0, \\ s_{c_j}(t) &= s_{c_j}(t-1) + y^{inj}(t)g(net_{c_j}(t)) \quad (1) \end{aligned}$$

また、LSTM には入力・出力ゲートと呼ばれる構造がある。これらのゲートは、入力・出力重み衝突を回避する目的で導入されたものである。それぞ

Interpolation missing data of rainfall data with Convolutional LSTM

<sup>†</sup>Hiroki SHINODA, National Institute of Technology, Kisarazu College

<sup>††</sup>Atsuto INAGE, National Institute of Technology, Kisarazu College

<sup>†</sup>Shunsuke IIZUMI, National Institute of Technology, Kisarazu College

<sup>†</sup>Shinichi OEDA, National Institute of Technology, Kisarazu College

れのゲートを式 (2), (3) に示す [3].

$$\begin{aligned} i_t &= \text{sigmoid}(W_{in}x_t + U_{in}y_{t-1} + b_{in}) \\ u_t &= \text{tanh}(W_u x_t + U_u y_{t-1} + b_u) \\ c_t &= i_t \odot u_t + c_{t-1} \end{aligned} \quad (2)$$

$$\begin{aligned} o_t &= \text{sigmoid}(W_{out}x_t + U_{out}y_{t-1} + b_{out}) \\ y_t &= o_t \odot \tanh(c_t) \end{aligned} \quad (3)$$

#### 4. Convolutional LSTM

Convolutional LSTM は, LSTM の入力データを画像データにおいても扱えるように拡張したモデルである. Convolutional LSTM のモデルを図 1 と式 (4)~(8) に示す. このモデルでは, LSTM の重みと各入力との掛け算部分を畳み込み演算に変更し, 重みをフィルターとして扱うことで画像データの学習を可能にしている [4].

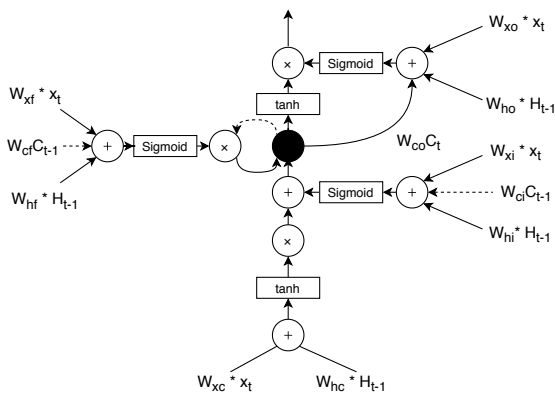


図 1 Convolutional LSTM 層

$$i_t = \sigma(W_{xi} * X_t + w_{ht} * H_{t-1} + W_{ci} * C_{t-1} + b_i) \quad (4)$$

$$f_t = \sigma(W_{xf} * X_t + w_{hf} * H_{t-1} + W_{cf} * C_{t-1} + b_f) \quad (5)$$

$$\begin{aligned} C_t &= f_t * C_{t-1} \\ &+ i_t \tanh(W_x c * x_t + W_{hc} * H_{t-1} + b_c) \end{aligned} \quad (6)$$

$$o_t = \sigma(W_{xo} * X_t + w_{ho} * H_{t-1} + W_{co} * C_t + b_o) \quad (7)$$

$$H_t = o_t \tanh(C_t) \quad (8)$$

#### 5. 提案手法

補間をする際に用いるデータは欠損箇所の前後が観測されているデータである. これにより予測は時間の順方向に行うのに対して, 補間は時間の順方向と逆方向の両方向から行うことが可能である.

そのため, 本研究では Convolutional LSTM を用いて欠損箇所を時間軸の順方向から補間する前向き補間と時間軸の逆方向から補間する後ろ向き補間, 前向きと後ろ向き補間の平均をとる双方向補間を提案する.

#### 6. 実験方法

入力が時系列の画像データであり出力が補間結果画像となる Convolutional LSTM 層を持つモデルを構築し, 実際の XRAIN データを用いて学習を行う.

検証に使うデータは, 実際の XRAIN データの一部箇所を人為的に欠損させることで作成する.

作成した欠損を含む XRAIN データの欠損箇所に対して, 学習したモデルを用いて欠損補間を行う. 欠損補間の方法としては, 提案手法である前向き補間と後ろ向き補間, 双方向補間の3つで行う.

結果は, RMSE を用いて誤差を測ることによって比較を行う.

$$\text{RMSE} = \sqrt{\frac{1}{N} \frac{1}{M} \sum_{i=1}^N \sum_{j=1}^M (y_{ij}^* - \hat{y}_{ij})^2} \quad (9)$$

#### 参考文献

- [1] 篠田拓樹, 稲毛惇人, 大枝真一, LSTM を用いた降雨量データの欠損補間, 2019 年電子情報通信学会ソサイエティ大会, A-19. 安全・安心な生活と ICT, A19-15, 2019.
- [2] 国土交通省, "https://www.mlit.go.jp/common/001136403.pdf".
- [3] Hochreiter Sepp, and Jürgen Schmidhuber, Long short-term memory, Neural computation, 9.8, pp.1735-1780, 1997.
- [4] Xingjian, S.H.I., et al, Convolutional LSTM network: A machine learning approach for precipitation now-casting, Advances in neural information processing systems, 2015.