

畳み込み LSTM を使用した アルゴフロートの軌跡予測に関する基礎検討

東 芹奈^{1,a)} 木下 貴裕^{1,b)} 福井 健一² 細田 滋毅³ 小野 智司^{1,c)}

概要: 海洋観測を大域的かつ長期的に行うためアルゴフロートと呼ばれる自律移動フロートが稼働している。このフロートが他国の経済水域に入る場合は 9 か月前の申請が必要となるため、フロートの軌跡を予測することが重要となる。現在使用されている粒子シミュレーションモデルでは、フロートの移動に影響を与えるとされる渦の発生を考慮できず、正確な軌跡予測が困難となっている。このため、本研究では畳み込み LSTM を使用したフロートの移動を予測する手法を提案する。提案手法の特徴は、性質の異なるデータを扱える点、および、過去のフロートの動きから帰納的に予測を行う点である。

キーワード: 畳み込み LSTM, 海洋観測, 自律移動フロート, 軌跡予測, 機械学習, 回帰, 画像特徴抽出

A Preliminary Study on Trajectory Prediction of Argo Floats Using Convolutional LSTM

Abstract: An autonomous drifting buoy called Argo Float is operating to perform globally-covered and long-term ocean observation. It is important to predict the float trajectory because, if this float enters the economic sea zone of a certain country, it is necessary to require the permission 9 months in advance. The particle simulation model currently used cannot take into account the affection of vortices that may affect the movement of the float, making accurate trajectory prediction difficult. Therefore, this study proposes a float prediction method using a convolutional long short-term memory (LSTM), which is a recurrent neural network architecture whose linear operations are replaced with convolution operations. The proposed method can handle multi-modal data with different properties and can perform inductive prediction from past float movements.

Keywords: Convolutional long short-term memory, Ocean observation, Autonomous drifting buoy, Trajectory prediction, Machine learning, Regression, Image feature extraction

1. はじめに

気候変動には海洋の状態が深く関与しており、海洋内部の状態を理解することで気候変動の予測や仕組みの解明に

繋がる。これは、地球の表面積の約 7 割を占める海洋が大気の約 1,000 倍の熱量を含んでおり、大気の状態を大きく変化させることができるためである。海洋内の観測を行うため、船舶やブイ人工衛星などを用いた海洋観測が行われていたが、海洋内部の網羅的な観測が困難であった。地球上の海洋内部の様子を網羅的にかつ常時観測するため、2000 年にアルゴ計画が開始され、アルゴフロートと呼ばれる海洋観測ロボットを用いた海洋観測が行われている [1]。

アルゴフロートは 30 以上の国毎に運用されているが、フロートが他国の経済水域に入る恐れがある場合は 9 ヶ月前に申請を行う必要がある。しかし、現在のフロートの軌跡予測は粒子シミュレーションにより行われており、渦などの発生を考慮しておらず、経済水域に入る恐れのある国全

¹ 鹿児島大学
Kasoshima University, 1-21-40, Korimoto, Kagoshima 890-0065, Japan

² 大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University, 8-1, Mihogaoka, Ibaraki, Osaka 567-0047, Japan

³ 国立研究開発法人海洋研究開発機構
Japan Agency for Marine-Earth Science and Technology, 2-15, Natsushimacho, Yokosuka, Kanagawa, 237-0061, Japan

a) sc116059@ibe.kagoshima-u.ac.jp

b) sc115015@ibe.kagoshima-u.ac.jp

c) ono@ibe.kagoshima-u.ac.jp

てに対して申請を行っている。

このため、本研究では、より適切に申請を行えるよう、機械学習を使用した予測モデルを作成し、フロートの長期的な予測を行うことを目的とする。提案する手法は、畳み込み LSTM (convolutional Long Short Term Memory: ConvLSTM) を用いており、性質の異なる複数の系列データを利用して予測を行うことが可能である。本研究では、過去のフロートの軌跡データに加えて、海流データを画像化することで ConvLSTM に入力し、フロートの軌跡の予測を行う。

2. 関連研究

2.1 深層ニューラルネットワークを用いた気象現象等の予測

Petrou らは畳み込み LSTM (Convolutional Long Short-Term Memory: ConvLSTM) を使用して海水の軌跡予測に関する方式を提案した [2]。この方式は、過去に観測された海水画像の系列のみを与え、数日後の海水の動きを予測する。ConvLSTM を使用したエンコーダデコーダネットワークの教師なし学習を行うため、訓練データにラベル付けを行う必要がなく、end-to-end で訓練を行うことが可能である。実験結果より、従来手法より鮮明な予測画像を生成できることが示された。

Rüttgers らは敵対的学習ネットワーク (Generative Adversarial Network: GAN) [3] を使用した台風の軌跡予測の研究を行った [4,5]。この手法では、衛星写真に加えて、海面温度、海面圧力、速度場といった台風の移動に影響を与えると考えられる物理量を追加して学習を行うことで、予測精度の向上を実現した。

松岡らは、CNN (Convolutional neural network) を使用して発生前の熱帯低気圧の予兆を示す雲を精度よく検出する研究を行った [6]。実験結果より、NICAM (Nonhydrostatic ICosahedral Atmospheric Model) による気候実験データを用いた熱帯低気圧のタマゴの検出に限っては、高い検出性能が示されている。

また、林らは、ConvLSTM を拡張し、マルチモーダル学習を行うことで降水量の予測を行った [7]。この研究では、過去の降水量に加えて、降水量に影響を与えると考えられる雲の厚さ、地形、風向きといった複数のモダリティを入力として与えている。複数のモダリティを ConvLSTM に入力する際、モダリティ毎のチャンネルを用意して 1 枚の画像とすることでマルチモーダル学習を行うことが可能となり、精度の向上を実現している。

2.2 数値シミュレーションを使用したフロートの移動予測

数値シミュレーションを使用してアルゴフロートの移動先を予測する方式が提案されており [8] [9]、フロートを投入する際に実際に利用されている。本方式は、フロートに

見立てた粒子をモデルの流速場に任せ、粒子の移動経路を計算する。モデルの流速場には過去 18 年の海流の月平均データを使用し、季節変動を与えている。アルゴフロートは 10 日毎に海面に浮上し、11 時間海面に滞在するためこのシミュレーションでは、深度 2035m 地点に 9 日 12 時間、深度 5m 地点に 12 時間交互に滞在するとして計算を行っている。また、投入予定点 1 点に対し多数の粒子 (フロート) を配置して計算を行い、投入場所によるフロートの動きの違いを統計的に調べる。しかし、このシミュレーションで用いる流速データは 1 年分のデータを繰り返し用いるため、この年に特徴的な流速構造が含まれる場合、それを除外することは困難でありシミュレーション結果に反映されてしまう。また、黒潮や親潮等により生み出され、フロートの移動に影響を与えるとされる渦の再現が困難である。

3. 提案手法

3.1 基本アイデア

本研究では ConvLSTM を使用したアルゴフロートの軌跡予測手法を提案する。本研究の基本アイデアは、過去のフロートの軌跡に基づいて帰納的な予測を行う点、および、性質の異なる複数の種類のデータを利用するマルチモーダル学習を行う点にある。

過去の軌跡に基づく帰納的な予測: 数値シミュレーションに基づく従来のモデル [8] では、過去数年の海流から季節変動を学習し、最後の 1 年の海流を繰り返し使用して位置予測を行う。これに対して本研究では、過去のフロートの軌跡から学習を行うことにより、海流データのみからでは予測が困難なフロートの動きを考慮することが可能となる。

マルチモーダル学習: 本研究では、フロートの過去の軌跡と月平均の海流データ、特性の異なる 2 種類のデータを利用する。フロートデータは、10 日毎に海面に浮上した際の位置 (緯度、経度) と時刻からなる。海流データは、 0.5×0.5 度四方の範囲における、東西、南北それぞれの方向の月平均流速である。このように性質の異なるデータを同時に扱うため、提案手法では、それぞれのデータを画像化し、多チャンネルの 1 枚の画像として統一的に扱う。また、時間軸の解像度が揃うように線形補間で画像を追加する。

3.2 モデルの構成と処理手順

提案する方式で用いる ConvLSTM の構成を図 1 に示す。ConvLSTM は、LSTM の線形演算を畳み込み演算に置き換えた再帰型ニューラルネットワークである [10]。一般的な LSTM の処理を以下に示す。

$$i_t = \sigma(w_{xi}x_t + w_{hi}h_{t-1} + w_{ci} \circ c_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(w_{xf}x_t + w_{hf}h_{t-1} + w_{cf} \circ c_{t-1} + b_f) \quad (2)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(w_{xc}x_t + w_{hc}h_{t-1} + b_c) \quad (3)$$

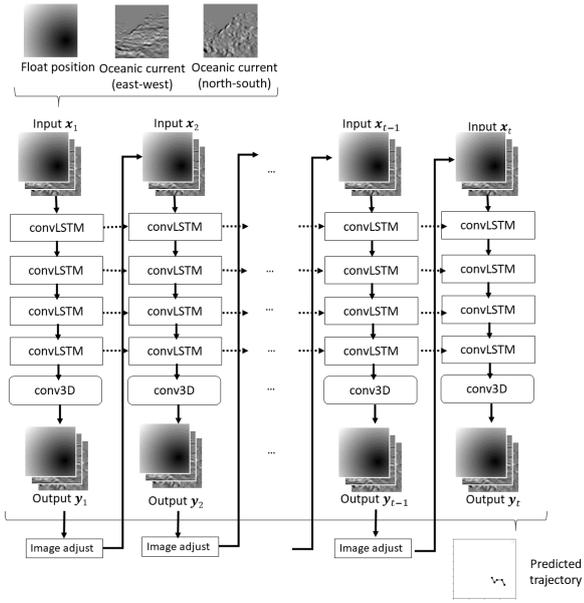


図 1 提案する方式で用いる ConvLSTM のネットワーク構成

$$\mathbf{o}_t = \sigma(\mathbf{w}_{x_o}\mathbf{x}_t + \mathbf{w}_{h_o}\mathbf{h}_{t-1} + \mathbf{w}_{c_o} \circ \mathbf{c}_t + \mathbf{b}_o) \quad (4)$$

$$\mathbf{h}_t = \mathbf{o}_t \circ \tanh(\mathbf{c}_t) \quad (5)$$

ここで、 \mathbf{i}_t は入力ゲートの活性化ベクトル、 \mathbf{f}_t は忘却ゲートの活性化ベクトル、 \mathbf{c}_t はセル状態のベクトル、 \mathbf{o}_t は出力ゲートの活性化ベクトル、 \mathbf{h}_t は隠れ状態のベクトルを表す。 \circ はアダマール積、 σ はシグモイド関数を表す。 \mathbf{c}_t と \mathbf{h}_t の初期値は 0 である。

ConvLSTM は、LSTM の線形演算を畳み込みに置き換えるため、以下のように表される [10].

$$\mathbf{i}_t = \sigma(\mathbf{w}_{x_i} * \mathbf{x}_t + \mathbf{w}_{h_i} * \mathbf{h}_{t-1} + \mathbf{w}_{c_i} \circ \mathbf{c}_{t-1} + \mathbf{b}_i) \quad (6)$$

$$\mathbf{f}_t = \sigma(\mathbf{w}_{x_f} * \mathbf{x}_t + \mathbf{w}_{h_f} * \mathbf{h}_{t-1} + \mathbf{w}_{c_f} \circ \mathbf{c}_{t-1} + \mathbf{b}_f) \quad (7)$$

$$\mathbf{c}_t = \mathbf{f}_t \circ \mathbf{c}_{t-1} + \mathbf{i}_t \circ \tanh(\mathbf{w}_{x_c} * \mathbf{x}_t + \mathbf{w}_{h_c} * \mathbf{h}_{t-1} + \mathbf{b}_c) \quad (8)$$

$$\mathbf{o}_t = \sigma(\mathbf{w}_{x_o} * \mathbf{x}_t + \mathbf{w}_{h_o} * \mathbf{h}_{t-1} + \mathbf{w}_{c_o} \circ \mathbf{c}_t + \mathbf{b}_o) \quad (9)$$

$$\mathbf{h}_t = \mathbf{o}_t \circ \tanh(\mathbf{c}_t) \quad (10)$$

ここで $*$ は畳み込み演算を表す記号である。

入力信号は、1 チャンネル目にフロートデータ、2 および 3 チャンネル目に東西および南北方向の海流データを含む画像データである。入力画像の生成については 3.3 節で後述する。また、フロートによる観測と浮上の頻度が 10 日に一度であるため、提案する方式における時間の単位は 10 日とする。1 ステップの推論により 10 日後のフロートの位置を予測することとなる。予測結果をネットワークに入力することで、20 日以降のフロートの位置を予測することも可能である。

なお、提案する方式では、フロートの位置を予測すると同時に、その時間に対応する海流の予測も同時に行う。これにより、フロートに影響を与える海流の動きを考慮した

学習を行えると期待できる。

3.3 対象データ

提案する方式では、フロートの位置情報を表す画像を、図 3.3 のようにグラデーションにより表現する。すなわち、フロートが観測された位置の画素の輝度値を 0 とし、これを中心とする正規分布に従って周辺の画素の輝度値を決定する。

一方、海流データは水平方向、垂直方向に分けて作図を行う。流速が $0[m/s]$ の場合に当該画素の輝度値を 128 (256 段階の場合) とし、水平方向の場合は右向きを 128~255、左向きを 0~128 の輝度値として表すことで画像化する。垂直方向も同様に、上向きを 128~255、下向きを 0~128 の輝度値とする。海流を画像化した例を図 3 および図 4 に示す。使用する海流データは月平均のデータであるため、線形補間を行い、10 日毎の海流画像を作成する。

フロートと海流の双方の作図を行った後に、予測を行う海域を決め、画像のトリミングおよび線形補間を行う。

ConvLSTM による出力の例を図 5(a) に示す。ConvLSTM によるフロートの位置の予測は、画像を出力する形で行われ、グラデーションにおける頂点 (輝度値がもっとも低い画素) がフロートの位置を表すこととなる。ConvLSTM が常に滑らかなグラデーションを出力するとは限らないため、出力画像の輝度値と凸関数とのフィッティングを行うことで、フロートの予測位置を求める。その結果をもとに、滑らかなグラデーション画像を生成する (図 5(b)).

3.4 学習方法

提案する方式において、ConvLSTM の訓練を行う際は、図 6 のように 1 時刻先の予測を行い、予測結果の画像と正解画像から損失関数を算出する。本研究では、フロートの誤差は正解位置と予測位置のピクセル間の距離で表すようにし、海流の誤差はピクセル毎の輝度値の差で表すことにしている。次の時刻の予測を行う際は、1 時刻前の出力画像ではなく、正解画像を入力として使用する。以上のように予測と誤差の算出を繰り返し、損失関数を算出する。本研究では、損失関数に MAE (Mean Absolute Error) を使用し、予測画像と正解画像のピクセル値の誤差を取り、絶対値の平均を loss 値とする。データサンプル 1 つの長さが 10 時刻分であるため、10 回の予測を行い、合計の誤差の平均をもとに損失関数を算出する。上記の処理をあらかじめ定められたバッチサイズと同数のサンプルに対して行った後に、モデルパラメータの更新を行う。訓練データサンプル全てに対して行う処理を 1 エポックとし、あらかじめ定められたエポック数の上限まで上記の処理を繰り返す。

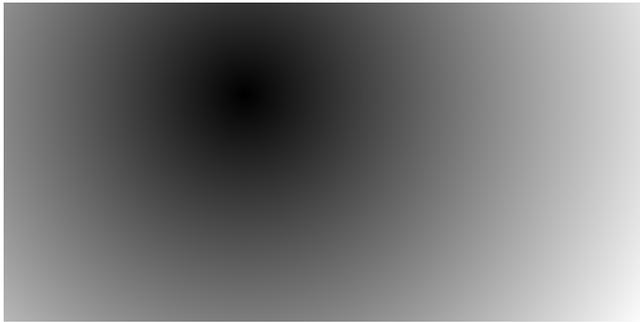


図 2 グラデーションで表現したフロートの位置情報

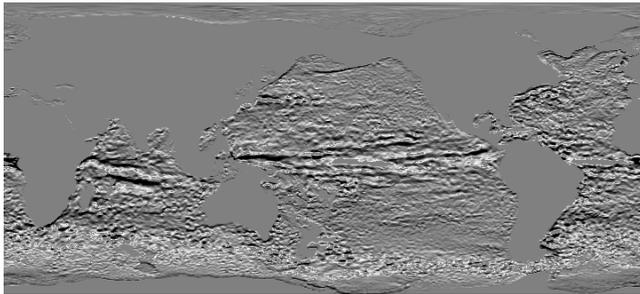


図 3 東西方向の海流

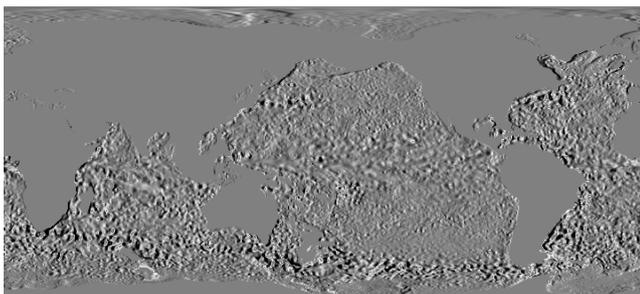
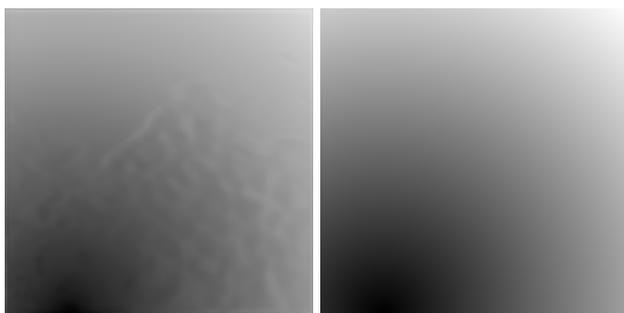


図 4 南北方向の海流



(a) 予測結果 (b) 補正処理後

図 5 ConvLSTM により予測されたフロートの位置の例

4. 評価実験

4.1 実験条件

提案手法の基本的な予測性能を検証するため、北太平洋域の比較的海流が穏やかな海域において、フロートの軌跡予測の精度を検証した。対象とした海域は北緯 30 度から

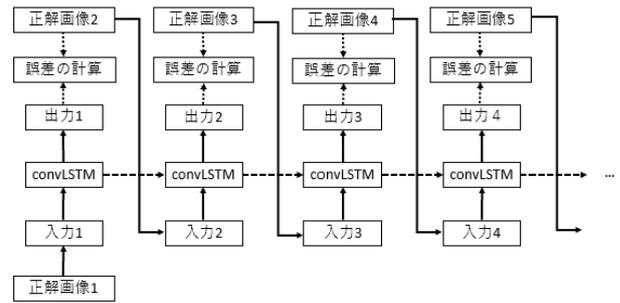


図 6 ConvLSTM の学習方法

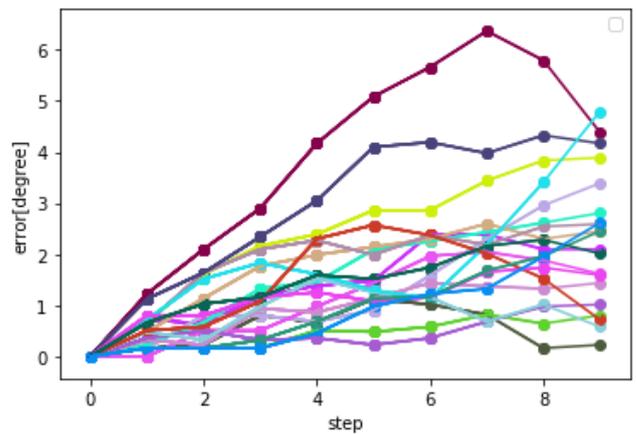


図 7 フロート位置の推定誤差

66 度，東経 144 度から 180 度の範囲とした。この海域において，2003 年 1 月 15 日から 2008 年 12 月 31 日までに観測されたフロートの位置情報を学習データとし，2009 年 1 月 1 日から 2011 年 12 月 31 日までに観測されたフロートの位置情報をテストデータとした。1 つの事例は 10 回のフロート計測位置およびその各時点における海流データから構成される。すなわち，フロートは 10 日に 1 回の頻度で計測を行うため，1 つの事例は約 3 ヶ月間のデータを含むこととなる。学習データは 879 事例，テストデータは 20 事例となった。画像の解像度は 224×224 画素とした。ConvLSTM の学習を行う際は，バッチサイズを 1，エポック数を 30，学習アルゴリズムを Adam，学習率を 0.001 とした。

4.2 実験結果

4.1 節のようにして学習を行った ConvLSTM を，テストデータに適用して検証を行った。本実験では最大 9 ステップ (90 日) 後のフロートの位置まで予測を試みた。

全テストデータにおけるフロート位置の推定誤差を図 7 に示す。図より，ステップが進むにつれて誤差が大きくなっていることがわかる。

テストデータにおいて良好な予測を行えた例について，フロート位置の軌跡を図 8，各時刻の出力と正解画像を図

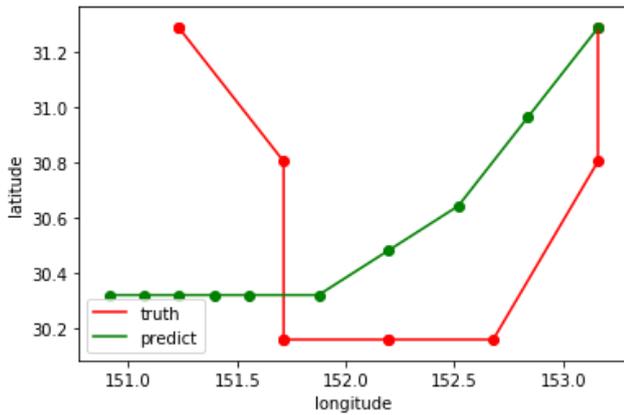


図 8 予測を適切に行えた例の軌跡

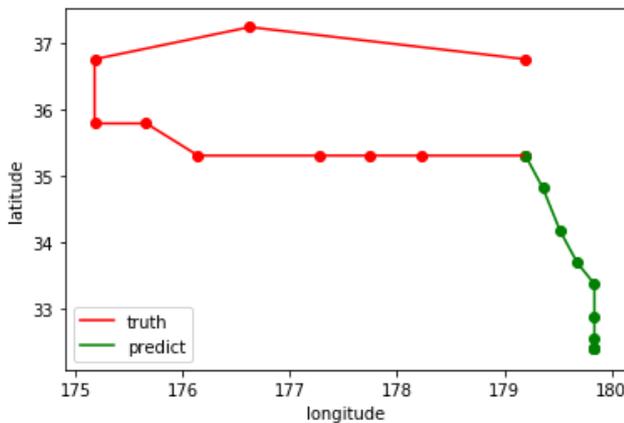


図 9 予測を行えなかった例の軌跡

10 に示す。図 10 のフロート位置の青点は予測されたフロートの位置を示しており、赤点は実際のフロートの位置を示す。図 10 より、予測開始から 5 ステップ後まで正解位置と近い場所に移動すると予測しており、予測位置と正解位置の距離の誤差が小さいことが分かる。

逆に、予測結果が不適切であった例について、フロート位置の軌跡を図 9、各時刻の出力と正解画像を図 11 に示す。図 9、図 11 より、正解位置とは逆向きに移動すると予測していることがわかる。また、いずれの場合も、予測が進むにつれて海流の画像全体のコントラストが低下しており、海流の予測が適切に行えていないことが分かる。

5. 結論と今後の課題

本研究では機械学習でアルゴフロートの軌跡予測を行うため、畳み込み LSTM を使用し、過去のフロートの軌跡および海流の変化の双方から学習を行い予測を行う手法を提案した。実験結果よりフロートの急な方向転換に対する予測が難しく、また、予測が進むにつれ誤差が大きくなっていくことが分かった。

今後、提案手法の精度向上のための学習方法の見直しと、数値シミュレーションによる予測手法との比較検討を行う予定である。

参考文献

- [1] 水野恵介. 高度海洋監視システム (argo 計画) 構想について. *Techno marine 日本造船学会誌*, Vol. 854, pp. 485–490, 2000.
- [2] Zisis I Petrou and Yingli Tian. Prediction of sea ice motion with convolutional long short-term memory networks. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 57, No. 9, pp. 6865–6876, 2019.
- [3] Mehdi Mirza Bing Xu David Warde-Farley Sherjil Ozair Aaron Courville Yoshua Bengio Ian J. Goodfellow, Jean Pouget-Abadie. Generative adversarial networks.
- [4] Mario Rüttgers, Sangseung Lee, and Donghyun You. Typhoon track prediction using satellite images in a generative adversarial network. *arXiv preprint arXiv:1808.05382*, 2018.
- [5] Mario Rüttgers, Sangseung Lee, and Donghyun You. Prediction of typhoon tracks using a generative adversarial network with observational and meteorological data. *arXiv preprint arXiv:1812.01943*, 2018.
- [6] Daisuke Matsuoka, Masuo Nakano, Daisuke Sugiyama, and Seiichi Uchida. 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, p. 80, 2018.
- [7] 林政行, 伊藤孝行. 深層学習を用いたマルチモーダル学習による降水量予測. 第 78 回全国大会講演論文集, No. 2016.1, pp. 369–370, 2016.
- [8] 岡英太郎. Argo フロートの投入シミュレーション. 海洋科学技術センター試験研究報告, No. 44, pp. 9–16, 2001.
- [9] Naoto Iwasaka, Tsugukazu Okumura, Eitarou Oka, and Kensuke TAKEUCHI. A simulation of argo float distribution in the south pacific. 海洋科学技術センター試験研究報告, No. 49, pp. 43–50, 2004.
- [10] SHI Xingjian, Zhouong Chen, Hao Wang, Dit-Yan Yeung, Wai-Kin Wong, and Wang-chun Woo. Convolutional lstm network: A machine learning approach for precipitation nowcasting. In *Advances in neural information processing systems*, pp. 802–810, 2015.

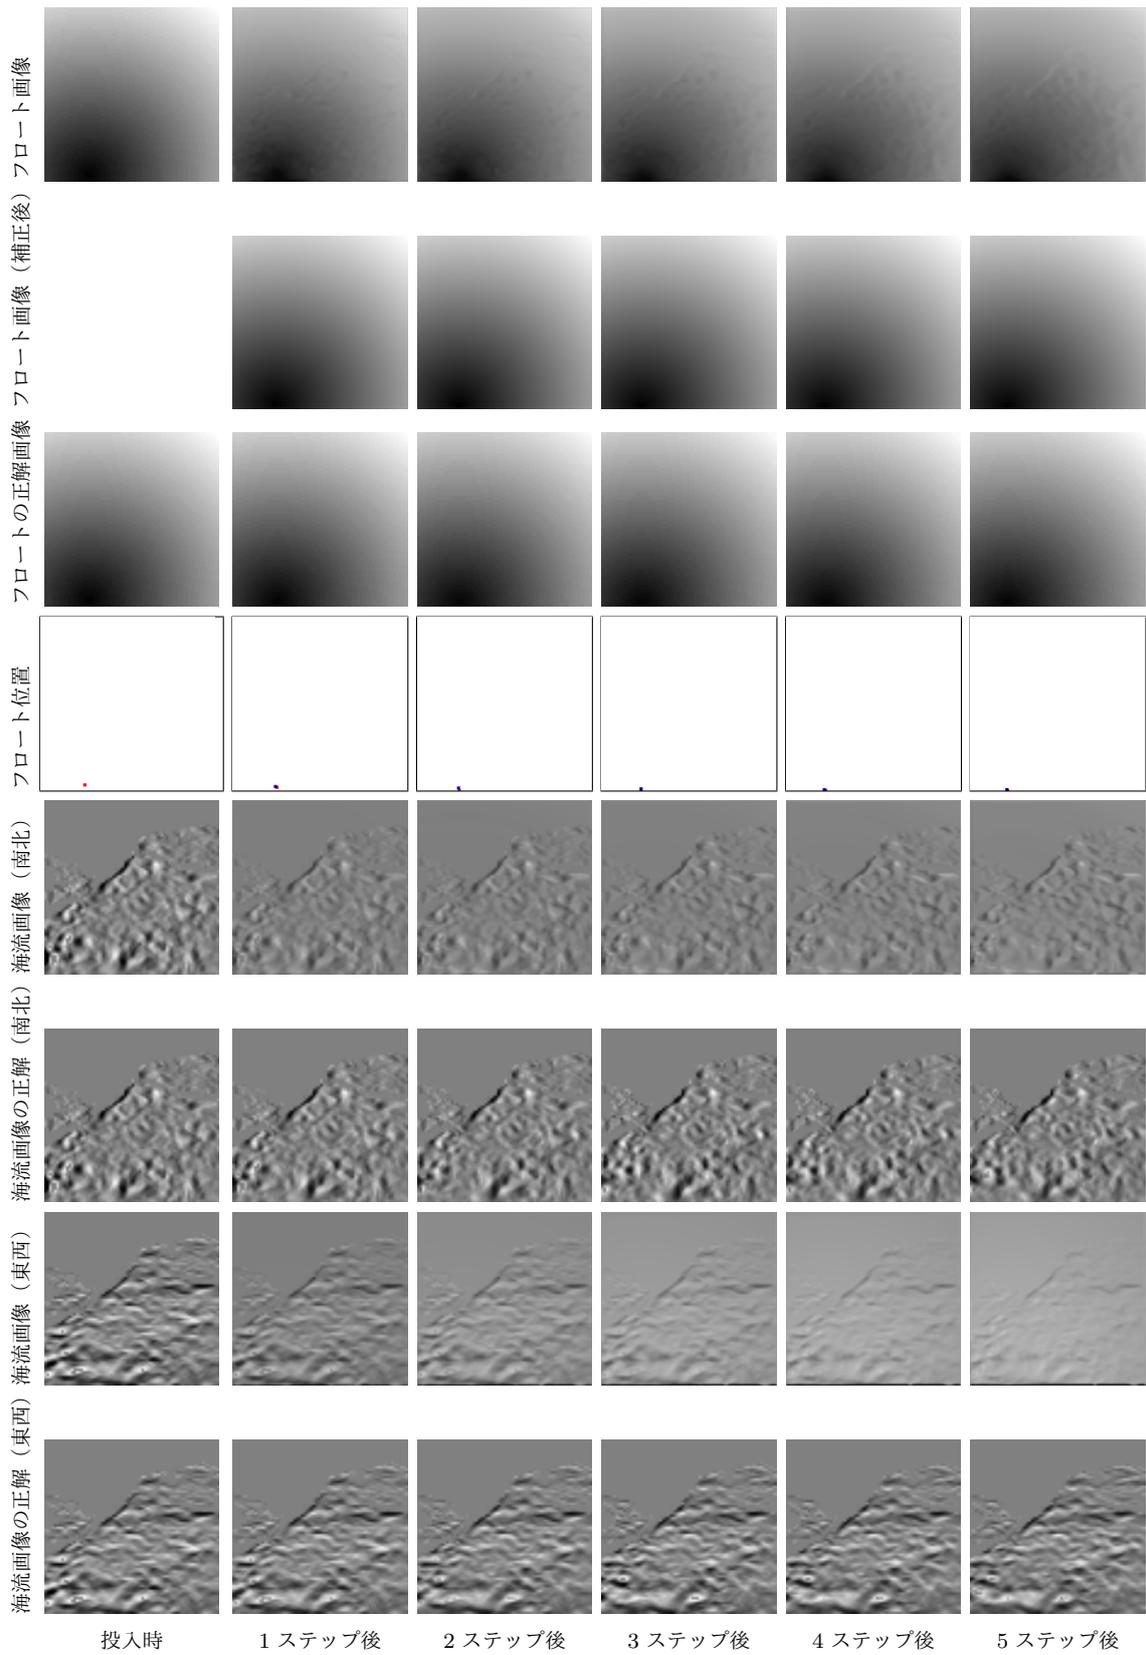


図 10 予測を適切に行えた例

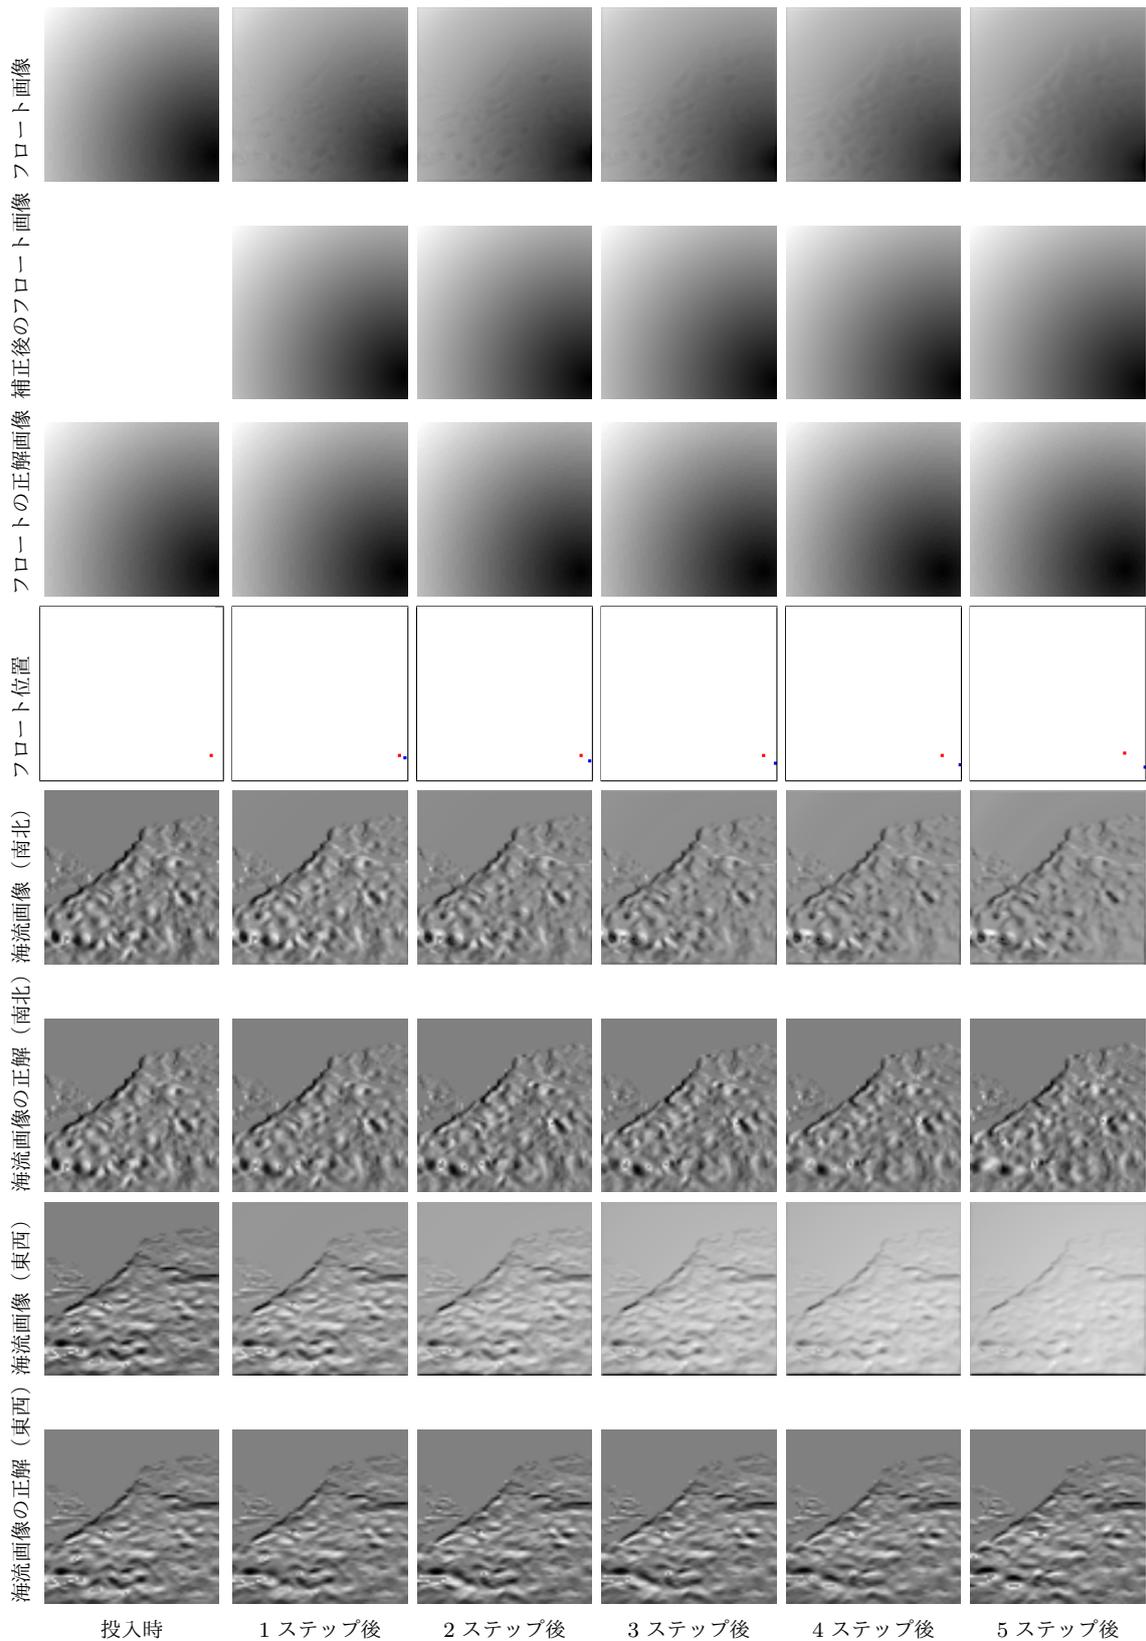


図 11 予測を行えなかった例