

口頭発表 | [共通セッション] 土木分野におけるAIの活用

2025年9月12日(金) 9:00 ~ 10:20 3階 D1 (熊本城ホール)

土木分野におけるAIの活用 (その2)

座長：石内 鉄平 (宮城大学)

9:30 ~ 9:40

[CS14-24] 時系列基盤モデルの降水量予測結果を用いた河川水位予測モデルの精度検証*石井 明¹、渡辺 肇¹ (1. 八千代エンジニアリング株式会社)

キーワード：時系列基盤モデル、TimesFM、降水量予測、河川水位予測、深層学習、DNN

地球温暖化による気温上昇に伴い大気中の水蒸気量が増加し、豪雨による洪水災害が頻発している。洪水の人的・社会的被害を最小化するためには、洪水予兆をいち早く察知する水位予測が重要である。しかし、洪水到達時間を超える予測先行時間において精度の高い水位予測のためには予測降雨情報が必要であるが、その提供状況は地域によって異なり、かつ長期間の蓄積がないなど必ずしも有効に活用できるとは限らない。そこで本研究では、時系列データに特化した基盤モデルの一つであるTimesFMを用いて降雨量を推論・評価し、さらにその推論結果を深層学習モデルの説明変数として加えることで、河川水位予測モデルの推論精度の評価を行った。

As global temperatures rise due to climate change, increased rainfall has led to serious flooding disasters. To minimize the damages from floods, accurate water level predictions that can quickly detect flood warnings are essential. However, reliable rainfall forecasts, essential for accurate predictions, vary by region and often lack long-term data. This study utilizes TimesFM, a time series foundation model, to infer and evaluate rainfall amounts. The inferred results are incorporated as explanatory variables in a deep learning model to enhance the accuracy of river water level predictions.

時系列基盤モデルの降雨量予測結果を用いた河川水位予測モデルの精度検証

八千代エンジニアリング株式会社 正会員 ○石井 明, 渡辺 肇

1. はじめに

近年, 地球温暖化に伴う気温上昇により大気中の水蒸気量が増加し, 世界各地で豪雨による洪水被害が頻発している. 人的・社会的洪水被害の最小化のために, 洪水予兆をいち早く察知し, 避難や浸水防御施設の稼働といった行動へ迅速に移すことが重要である. 洪水予兆の把握方法の一つに河川水位予測があり, 特化型のAIを活用して予測精度向上を目指す研究が多く報告されている. しかしながら, 洪水到達時間を超える予測先行時間の水位予測には降雨量予測情報が不可欠であるが, 降雨量予測情報提供は地域によって異なり, また長期間の蓄積がないことから, 必ずしも有効に活用できるとは限らない.

一方, GPT-4に代表される自然言語処理に特化した汎化型の基盤モデルの開発やサービス提供が急速に進展しており, 更に, 時系列データに特化した幾つかの時系列基盤モデルも開発・提供され始めている. そこで本稿では, 時系列基盤モデルを用いて推論した降雨量および河川水位の評価を実施する. また, 推論した降雨量を説明変数として追加して深層学習モデルを構築し, 河川水位の推論精度についても評価を行う.

2. 時系列基盤モデルの概要

主な時系列基盤モデルを表-1に整理した. 本稿では, 10分間隔の気象データを含む多様な時系列データと合成データを使って事前学習モデルが構築されており, ゼロショット予測で入力長(コンテキスト長)および出力長に柔軟性のある Google Research によって開発された TimesFM (Time Series Foundation Model) ¹⁾ を使用する.

3. 推論

3. 1. データセットおよびモデル設定

本稿では, 図-1に示すマレーシアのクアラルンプール

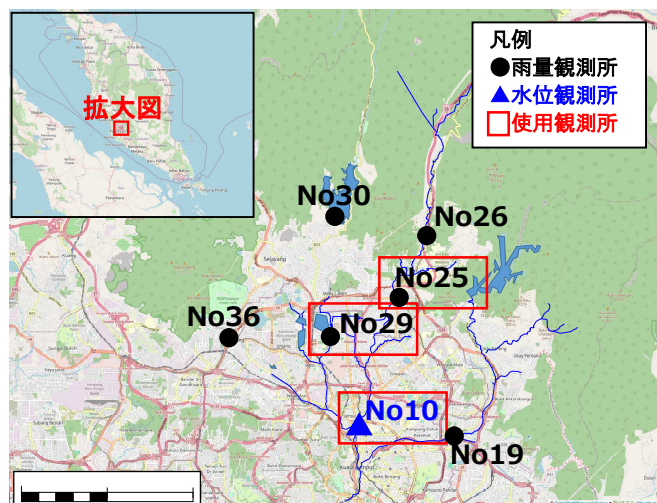


図-1 水位・雨量観測所位置図

のNo.10の水位観測所, No.25およびNo.29の雨量観測所の2021/6/1 0:00から2022/6/29 23:55まで5分間隔の観測データを使用する. 過年度検討²⁾では, No.10の現時刻水位とNo.25およびNo.29の現時刻から2時間前迄の雨量に相関があることを確認しており, 本稿でもこのデータを使用する. また, TimesFMは最大2,048のタイムポイントのコンテキスト長を持った「timesfm-2.0-500m」の事前学習モデルを使用した. また, 頻度インジケータは日単位までの時系列に対応する高頻度を選択した.

3. 2. 降雨量予測

TimesFMによるNo.25およびNo.29の降雨量予測は, 5分間隔の降雨データを10分間隔の降雨データに変更し, 1時間毎に3時間先まで10分間隔で単変量推論を実施した. また, 入力するタイムポイントのコンテキスト長の違いによる推論精度への影響を確認するため, コンテキスト長は, 6時間分, 12時間分, 24時間分, 48時間分, 72時間分の5パターンで推論を実施する.

推論結果は1時間雨量に集計し, 実測の1時間雨量と

表-1 時系列基盤モデルの比較

モデル	開発元	モデルサイズ	アーキテクチャー	事前学習データ
TimesFM	Google Research	500M	エンコーダー/デコーダー	・実データセット (Googleトレンド, Wikipedia, M4, 気象データ) ・合成データ (ARMA, 季節パターン, トレンド, ステップ関数)
MONENT	AutonLab	385M	エンコーダー/デコーダー (固定長のみ)	Timeseries-PILE
TTM	IBM	80K	エンコーダー/デコーダー	Monash, LibCity
Chronos	AWS	710M	エンコーダー/デコーダー (言語モデル仕様)	Monash Time Series Forecasting Repository, M-competitions, Kaggle

キーワード 時系列基盤モデル, TimesFM, 降雨量予測, 河川水位予測, 深層学習, DNN

連絡先 〒111-8648 東京都台東区浅草橋5-20-8 CSタワー 八千代エンジニアリング株式会社 TEL03-5822-6844

表-2 相関係数

地点	コンテキスト長	1時間先	2時間先	3時間先
No.25	6時間分	0.393	0.083	0.036
	12時間分	0.419	0.036	0.097
	24時間分	0.445	0.112	0.045
	48時間分	0.433	0.122	0.053
	72時間分	0.349	0.064	0.017
No.29	6時間分	0.422	0.089	0.045
	12時間分	0.435	0.097	0.025
	24時間分	0.393	0.070	0.026
	48時間分	0.365	0.048	0.025
	72時間分	0.380	0.021	0.007




図-2 相関関数 (左: No.25, 右: No.29)

相関分析した(表-2)。また、図-2にNo.25およびNo.29の最も相関が高いケースの散布図を示す。1時間先の時間雨量の予測値はやや関係性があることが確認できたが、2時間先および3時間先の相関は確認できなかった。

3. 3. 水位予測

水位予測では、現時刻から予測先行時間 T 時間先の水位を推論する。本稿では、TimesFM による単変量推論と、入力層と出力層を含む 4 層以上の深層学習モデル (DNN: Deep Neural Network) による推論の 2 手法を実施した。なお、深層学習モデルは入力変数の組み合わせの違いにより 2 ケース (Case1 および Case2) で実施し、Case1 では観測値のみの入力変数、Case2 では Case1 の変数に加えて前述の TimesFM で推論した降雨量予測の中から相関を確認した No.25 および No.29 の 1 時間先雨量の推論値を追加した(表-3)。ニューロン数、中間層数、学習率、ドロップアウト率はハイパーパラメータとして、その組合せを検証データの損失関数 (RMSE) が最小となるように Tree-structured Parzen Estimator 検索にてチューニングした。ただし、各中間層のニューロン数 (ブロック数) は同一としている。また、検証方法はホルダアウト検証とし、学習データは 2021/6/1 ~ 2022/4/30 の 10 ヶ月、検証データは 2022/5/1 ~ 6/29 の 2 ヶ月とした。

各水位予測手法による 1 時間先、2 時間先、3 時間先の検証期間の RMSE を表-4 に示す。なお、TimesFM は入力するタイムポイントのコンテキスト長の中で最も良い成果を示した。また、一例として深層学習モデルの

表-3 深層学習モデルの入力と出力変数の関係

Case	入力変数 (現時刻)	出力変数
Case1	・水位 (観測値): No.10(t-2~t) ・10分雨量 (観測値): No.25(t-2~t) No.29(t-2~t)	T 時間後の No.10 の予測水位(t+T)
Case2	・水位 (観測値): No.10(t-2~t) ・10分雨量 (観測値): No.25(t-2~t) No.29(t-2~t) ・10分雨量 (1時間先推論降雨量): No.25(t~t+1) No.29(t~t+1)	

表-4 RMSE (単位:m)

	TimesFM	DNN (Case1)	DNN (Case2)
1時間先予測	0.675(12h)	0.023	0.021
2時間先予測	0.334(12h)	0.038	0.036
3時間先予測	0.189(12h)	0.043	0.043




図-3 水位予測結果 (1時間先予測)

1 時間先の水位予測結果を図-3 に示す。TimesFM は深層学習モデルと比較して精度が大きく劣り、深層学習モデルでは説明変数に 1 時間先推論雨量を追加することで、若干の精度改善効果を確認できた。しかしながら、洪水到達時間が 1~2 時間程度であり、3 時間先予測ではその効果は確認できなかった。

4. まとめ

本稿では時系列基盤モデルの一つである TimesFM を用いて降水量の推論・評価した。また、深層学習モデルの説明変数に推論降水量を追加した河川水位予測モデルの精度改善を検証した。河川水位の予測精度改善には、予測雨量の精度改善や不確実性の低減が不可欠である。時系列基盤モデルで降水量予測の精度改善に取り組む場合は、使用するモデルやバージョンに留意する必要があるが、fine-tuning や多変量解析の検討が考えられる。

参考文献

- 1) Abhimanyu DAS, Weihao kong, Rajat Sen, Yichen Zhou: A decoder-only foundation model for time-series forecasting, arXiv:2310.10688, 2023.
- 2) 石井明, 渡辺肇, 天方匡純: AutoML で構築した河川水位予測モデルの精度検証, 土木学会第 79 回年次学術講演会, CS14-61, 2024.