

AutoML で構築し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, 天方 匡純

1. はじめに

近年、水文データの蓄積やAI技術の進展により、河川水位予測においてもAI技術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。最適なAIモデルを構築するためには、ハイパーパラメータのチューニングに多くの労力を払う必要があるが、様々なアルゴリズム毎にパラメータの組合せを全て検証することは非現実的であり、ケース数を限定した検討になっている。一方で、近年、幾つかのAutoMLライブラリが提供され始め、自動化による最適モデル構築も可能となってきた。時系列予測の領域は深層学習によるモデル構築が主流であるが、機械学習モデルでも時系列間の特徴量を前処理で抽出したデータセットを用いることで深層学習モデルと同等あるいは大きく上回る性能が示されている事例もある¹⁾。そこで本稿では、河川水位予測についてAutoMLで構築した機械学習モデルの予測精度と、深層学習モデルで構築した予測精度を比較した。

2. 検証に使用するデータ

2. 1. 対象流域と水文データ

マレーシアのクアラルンプールにある 1 箇所の水位観測所と 7 箇所の雨量観測所 (図-1) について、2021/6/1 0:00 から 2022/6/29 23:55 まで 5 分間隔の約 1 年間の観測値を入手した。マレーシアでは降水短時間予報など数時間先の予測雨量はないため、数時間先の水位を予測する

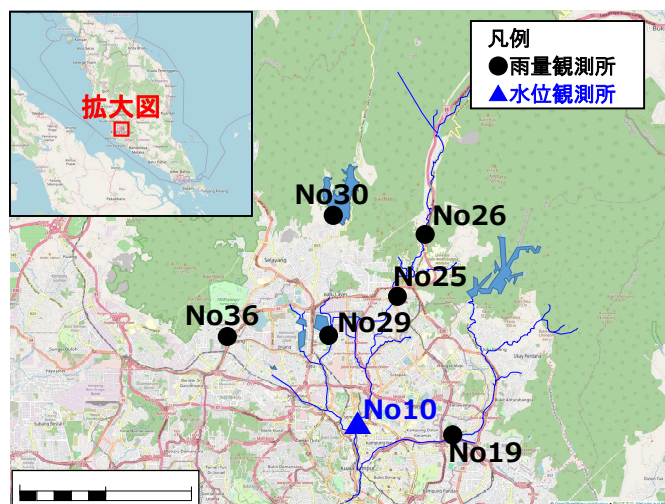


図-1 位置図

には観測値の中に特徴量を見出していく必要がある。

2. 2. 水文データ分析とデータセット

5 分間隔のデータを 15 分間隔に間引き、ある時刻の水位に対して雨量を 0 時間から 6 時間前まで 1 時間毎にスライドさせて相関を整理した (図-2)。No.10 の水位観測所と同流域内もしくは近傍流域の雨量観測所 No.29 と No.25 の相関係数が最も高く 0.4 程度であった。またスライド時間毎にみると、同時刻より 1 時間前との相関関係が最も高く、それよりスライド時間が長くなると精度が低下している。No.10 と No.29 または No.25 の平均的な洪水到達時間は 1 時間以内であると推定される。




図-1 水位データと雨量データの相関係数

以上より、本稿では 0 時間から 2 時間前までの No.10 の水位データと No.25, No.29 の雨量データを使用して、予測先行時間 T の No.10 の水位を予測する (表-1)。また、検証方法はホールドアウト検証とし、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。

表-1 入力と出力変数の関係

入力変数 (現時刻をtとする)	出力変数
・水位: No.10 (t-2~t)	T時間後のNo.10
・雨量: No.25(t-2~t), No.29(t-2~t)	の予測水位(t+T)

3. 予測モデルの概要

3. 1. AutoML の機械学習モデル

本稿では、H2O.ai が提供するオープンソースの機械学習プラットフォーム H2O²⁾の AutoML を使用した。H2O では一般的な機械学習モデルに加え、検討した複数モデルを組合せたアンサンブルモデルによる評価も可能である。構築可能なアルゴリズムは、Distributed Random Forest(DRF), Extremely Randomized Trees(XRT), Generali-

キーワード 河川水位予測, AutoML, 深層学習, DNN, LSTM

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 TEL 03-5822-6844




図-2 AutoMLの検討結果 (RMSEとモデル毎の検討個数)




図-3 水位予測結果 (1時間先予測)

zed Linear Model(GLM), XGBoost, Gradient Boosting Machine(GBM), Artificial Neural Network(ANN)の6つのベースモデルと、ベースモデルを使った Stacked Ensemble Model である。ベースモデルはランダムに40個構築し、更にアンサンブルモデルを2つ構築した。なお、モデル構築では過学習防止のため2乗平均平方根誤差(RMSE)でEarly Stoppingを設定した。

3. 2. 時系列予測の深層学習モデル (DNN, LSTM)

深層学習モデルとして、入力層と出力層を含めて4層以上のDeep neural Network(DNN)と時系列データを1つの入力ニューロンに対応させ、DNNの中間層のニューロンをLSTMブロックと呼ばれるメモリセルに置き換えた再帰型のLong Short-Term Memory(LSTM)の2つ用いた。ニューロン数(LSTMはブロック数)、中間層数、学習率、ドロップアウト率を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。なお、各中間層のニューロン数(ブロック数)は同一とした。

4. 計算結果

各予測モデルによる1時間先、2時間先、3時間先の検証データ全体のRMSEを表-2に、AutoMLで検討されたモデルとその精度を図-2にそれぞれ示す。なお、AutoMLのRMSEは検討したモデルの中で最も精度が高い値としたが、今回の検証ではアンサンブルモデルの優位性は確認できなかった。また、各予測モデルの検証データにおける1時間先予測の水位結果を図-3に示す。

AutoML モデルは洪水ピークの感度も良いため、RMSEが大きくなったと考えられる。深層学習モデルは損失関数をRMSEにしているということもあり、AutoMLと比べて波形全体の適合性が良くなっているが、洪水ピークの再現性は劣っている結果となった。

表-2 RMSE (単位:m)

	AutoML	DNN	LSTM
1時間先予測	0.078	0.042	0.043
2時間先予測	0.128	0.046	0.046
3時間先予測	0.156	0.046	0.047

5. まとめ

本稿では、H2O.aiのAutoMLによる予測モデルと、チューニングした深層学習の予測モデルの精度を比較した。AutoMLでは全体の洪水波形の適合度が少し劣っていた。そのため、今後、AutoMLで洪水予測精度向上を目指すには、時系列の特徴量を考慮した入力データセットに工夫したり、深層学習モデルとのアンサンブルモデルを検討したりすることが考えられる。

謝辞

現地の水位データ取得に関し、マレーシア連邦灌漑局及びSpatialworks社にご協力頂いた。

参考文献

- 1) ELSAYED, Shereen, et al. Do we really need deep learning models for time series forecasting?. arXiv preprint arXiv:2101.02118, 2021.
- 2) H2O AutoML:Automatic Machine Learning, <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/automl.html> (最終確認日:2024年3月29日)