

排水機場の遊水池の水位を予測する 深層学習ニューラルネットワークモデル

吉 永 育 生／木 村 延 明

近年、AI（Artificial Intelligence）が急速に発展している。総務省によると、現在は第4次 AI ブームに該当しており¹⁾、2022年頃から急速に普及した生成 AI が代表的な事例である。生成 AI は利用が容易である点が大きな特徴であり、例えばテキストで問いかけを行うと、テキストでわかりやすい回答が出力される。このため、気軽に利用している方も多いと思われる。これらは、大量のデータを事前に学習し、そのデータに含まれる特徴をあらかじめ抽出、記憶しておくことで、新たな問いかけがあった際には、即座に回答を出力する仕組みである。あたかも物知りな人とテキストベースで会話しているような錯覚を持つほど、利用の際の入出力は容易に実施されるうえ、間違った回答を行う可能性があるものの、おおよそ的確な回答を得ることができる。これらは、情報処理技術の発展の恩恵であるとともに、膨大なデータがデジタルの状態に蓄積され、コンピューターによる利用が可能になったおかげと言える。

農業農村工学の分野においても、AI や情報通信技術（Information and Communication Technology, ICT）などの先端技術を利用した技術開発が進められている。農研機構 農村工学研究部門の水利工学関連の研究グループでは、農業水利施設の操作の支援を目的として、ICT を用いた水管理や AI を用いたモデルの開発を行ってきた²⁾。特に、筆者らは排水機場のポンプ操作を支援することを目的として、遊水池の水位を予測する様々な AI 予測モデルを構築してきた。なお、ここで言う AI 予測モデルとは、深層学習ニューラルネットワーク（Deep Neural Network, DNN）を実装したモデルである。DNN は、脳の学習メカニ

ズムを模倣した数理モデルであり、深層学習等の計算過程の根幹の部分で広く利用されている。

DNN は、十分な量のデータの学習によって、データに含まれる特徴を抽出することができる。脳神経の情報伝達のネットワークを模倣してモデル化しており、様々な条件が整った場合には人間の勘や感覚と同じような結果を出力することができる。例えば、排水機場の遊水池の水位を対象にする場合、過去のデータを学習することで、“短時間で急に水位が上がった場合は○ m まで水位が上がる人が多い”や、“一度水位が下がって○ m 以下になったら、以後はゆっくりと水位が低下する”といった、変化の特徴を抽出することができる。このように、DNN が水位の変化の特徴を学習できると、直近までの水位の変化の傾向から未来の水位を予測することができる。DNN の利点は、学習用のデータが十分にあればモデルの適用が可能であること、また、予測計算の過程は物理法則に基づくモデル（以下、「物理モデル」という）と比べて極めてシンプルであるため計算負荷が小さいこと、があげられる。

さらに、DNN の利点として、物理モデルで再現することが難しい、人為的な影響も含めて再現可能なことがあげられる。前述の遊水池の水位は、流域に降った雨が流出する水文現象によって生じる変化だけでなく、排水ポンプの運転によって生じる変化が合わさった結果である。流出現象は水文モデルによって再現できるが、排水ポンプは管理者の判断によって運転されるため何らかの物理モデルで表現することは難しい。しかし、DNN はデータに含まれる変化の特徴を抽出するため、“急激に水位が上がった場合は、いったん

水位が下がる”といった、排水ポンプの運転による影響も考慮することができる。そのため、予測計算の際には、「同じ運転者が、過去の降雨と同じようなタイミングでポンプを操作する」と仮定した条件における、未来の水位を予測することができる。

一方、DNN モデルのデメリットは、十分な量のデータが得られない場合は、予測精度が低いことである。ただし、この点に対しては、多数の研究開発が進められており、他地区のデータを学習する、学習用のデータを模擬的に作る等があり、筆者らも取り組んでいることから後に詳述する。その他のデメリットとして、DNN モデルは抽出した特徴を定式化するわけではなく、いわゆる対象のデータに依存したブラックボックスの状態であるため、特徴の一般化が難しい、対象地区の固有の特徴を抽出するため、他地区への適用の際には他地区のデータによる再学習が必要となる等があげられる。

これまで、AI 予測モデルの開発においては、モデルの基盤となる要素を DNN モデルとし、達成目標を、リアルタイムで6時間先の予測（第一期）、学習用のデータが少ない場合の予測精度の維持（第二期）、予測結果に含まれる不確実性の可視化（第三期）、としてきた。筆者らが、これまでに開発した AI 予測モデルについて、開発に取り組んだ経緯やモデルの特徴を紹介する。

1. 第一期の AI 予測モデルの開発

（1）対象とした地区とデータの特徴

水位予測の対象は、信濃川の下流域に位置する排水機場の遊水池（図－1）である。この排水機場では常



図－1 対象とした排水機場とその遊水池

時排水を実施しているため、遊水池の水位の変化は、日常的な排水操作に起因する日周期・半日周期の変化のパターン（以下、「常時排水」という）と、豪雨時の降雨流出に伴って水位が大きく上昇する変化のパターン（以下、「洪水時排水」という）の2種類が確認される。

利用するデータは約7年半の1時間間隔の水位である。このデータをそれぞれ約10か月の10個のグループに分割し、期間最大の洪水イベント（3日間の累積雨量が約300mm、以下、「TOP 1」という）が発生した期間をグループ1として予測用のデータ、残る9個のグループを学習用のデータとした。

予測精度の検証は一連のデータを学習用と予測用に分けて行うホールドアウト法と呼ばれる手法を適用し、二乗平均平方根誤差（Root Mean Square Error、RMSE）によって定量的な評価を実施した。降水量は、近傍に降水量の観測地点があったものの、降水量の変化と水位の変化が対応していない場合が散見されたため、学習および予測時のパラメータとしては扱わず、参考用のデータとしている。降水量と水位のデータ数は約7万である³⁾。

これらのデータを用いて、これ以降に説明する一連のモデルを開発している。

（2）AI 予測モデルの説明とその予測精度の評価

第一期の予測モデルは、水路で観測された水位データのみを用いた、未来の水位の予測である。第一期では2種類の AI 予測モデルを開発し、1つは単純な構造のニューラルネットワークである多層パーセプトロン（Multi-Layer Perceptron、以下、「MLP」という）のモデル、もう1つは文字列のような連続データの推定に利用される長・短期記憶（Long, Short-Term Memory、以下、「LSTM」という）のモデル⁴⁾である（図－2）。

前述の遊水池の水位のデータのうち、9個のグループ（約10か月×9＝約90か月分）を学習し、残るグループ1を対象として未来の3時間先（Lead Time、LT＝3h）の水位を予測して観測値と比較した。

グループ1を予測した結果は、MLPとLSTMのLT＝1～3hについては、常時排水の期間（図－3の左小窓）では概ね同じ精度であったものの、LSTMのほうがMLPよりもRMSEの値が5～8%良好で




図-2 一般的な MLP モデル (左) と LSTM モデルの計算処理のイメージ




図-3 MLP と LSTM の LT = 1 ~ 3h の水位予測結果の比較
(左小窓=典型的な常時排水の期間、右小窓=洪水時排水の期間)


ある (図-3 の右小窓)。これは、LSTM が、過去の情報を記憶・忘却する機能を備えており、時系列データの連続性を反映しやすいため、と考えられる。しかし、いずれのモデルにおいても、水位の最大値の再現は難しい、リードタイムが長い場合の予測精度が低い、洪水の波形の立ち上がり時刻がずれる等の複数の課題が確認された。

2. 第二期 AI 予測モデルの開発

MLP に対して優位性が確認された LSTM の開発を継続することとし、水位の最大値の再現性の改善を目指して、転移学習の手法⁵⁾を導入した。転移学習は、モデルの大幅な改善を行う手法ではなく、あらかじめ予測対象とは異なるデータを学習し、そのデータに含まれる特徴をモデルに取り込んだ後で、モデルの一部を使って予測対象のデータを学習する手法である。

再現の目標としている水位の最大値は、大規模な洪水イベントで発生するものであり、そもそも大規模な洪水イベントが少ないため、十分な学習を行うことが難しい。また、DNN は学習したデータの範囲内で予測を行う補間手法の一種であるため、未学習の大規模な洪水イベントに対する高精度な予測は難しい。そこで、この課題を解決するために、「大規模な洪水イベントの特徴」をモデルに取り込むことができる転移学習の手法を適用した。


はじめに、物理モデルを用いて 300mm/72h の大規模な洪水イベントのデータを 1,000 イベント生成し、このデータを使って LSTM による学習を実施する⁶⁾。これによって、LSTM に大規模な洪水イベントの特徴を取り込むことができる。次に、学習済み LSTM の一部を使って、実際に観測されたデータの再学習を行う⁷⁾。再学習のための観測データは、グループ 1 の



図－4 従来のLSTMと転移学習ありの予測手法のLT＝1 h～6 hの結果比較

区間以外の9つのグループの区間である。一連の手順によって、大規模な洪水イベントと実際の観測データの両方の特徴を取り込んだLSTMのモデルが完成する。この転移学習有りのLSTMモデルによる、グループ1の区間のLT＝6 hまでの水位の最大値の再現性を検証した。

図－4に、転移学習の有り無しの2つのモデルによる予測結果を示す。予測対象としたのはグループ1の10か月であり、約7年半のうち最大の洪水イベントであるTOP 1の期間を含むが、大半は常時排水の期間である。常時排水の期間の予測結果は、2つのモデルとも精度はほぼ同様であり、LT＝6 hの場合には再現性が低下している（図－4左）。一方、TOP 1の期間を対象とした予測結果を比較すると、転移学習有りのほうが再現性が高く、LT＝6 hのRMSEの値で約5%良好である。特に、転移学習有りのほうが水位の最大値の再現性が改善されている。これは、転移学習有りでは、物理モデルを利用してTOP 1で発生するような大規模な洪水イベントを学習しているため、と考えられる（図－4右）。得られた結果により、第一期の課題であった大規模な洪水イベントのような観測データが少ない事象に対する予測精度の改善をある程度達成した。



図－5 内部の一部を不活性化して計算を行うMC Dropoutの処理イメージ

3. 第三期 AI 予測モデルの開発

第三期では、予測結果を1つの値で示すのではなく、ある程度の幅を持たせて示すことに取り組んだ。幅を持たせた出力を行うことは、モデルに含まれる誤差を考慮したうえで、予測結果の妥当性を示すことである。イメージとしては、気象予報において台風の予想される進路の幅を予報円で示すことに近い。なお、台風の進路の予報では、複数の異なる初期条件のもとで複数の計算を行い、得られた結果を統計的に処理することで予測結果の不確実性を表現しており、これはアンサンブル予測と呼ばれる手法である⁸⁾。

そこで、開発中のDNNに対しても、アンサンブル予測のような予測結果に不確実性を与えるべく、改善を行った。DNNのような回帰型モデルで発生する誤差の要因は、データに起因する「偶然の不確実性」と、モデルそのものに起因する「認識の不確実性」の2つに起因しており⁹⁾、後者の認識の不確実性への対応を行った。導入した手法は、不確実性を表現できるベイズ推定の代替手法である、モンテカルロドロップアウト（MC Dropout）の手法¹⁰⁾である¹¹⁾。この手法では、DNNを構成する内部ネットワークの一部をランダムに遮断（不活性化）して計算する（図－5）。同じ条件での計算であっても、内部ネットワークの遮断する場所を変えることで、モデルに起因する認識の不確実性を考慮できるうえ、異なる計算結果が出力される。この結果、アンサンブル予測のように複数の予測




図-6 MC Dropout の実装によって不確実性を考慮した DNN (LT=1 h~6 h) の予測結果

結果が得られるため、予測結果の平均値だけでなく、バラつきに基づく不確実性を表現することができる。

結果を図-6に示す。内部ネットワークを不活性化させる割合であるドロップアウト率が0.3の場合の結果であり、予測のリードタイムが1hと3hの場合に従来型モデルと比較して約10%予測精度が改善している。また、予測結果の不確実性は、標準偏差の3倍と仮定した確信区間によって表現している(図-6の灰色領域)。なお、ドロップアウト率は、人間が調整して最適化する必要があり、DNNのような機械学習モデルにおいてはハイパーパラメータと位置付けられる。


MC Dropoutを実装したDNNは、常時排水の期間においては、白抜き○線である観測値を概ね再現できしており、水位が大きく変化する前後では幅を持った予測結果を出力している。一方、洪水時排水の期間においては、黒線で示す予測結果の平均値は、観測値を良く再現しているとは言い難い。予測のリードタイムが1hと3hのピークの観測値は、確信区間の範囲に収まっていたが、6hでは確信区間との重複は一部に限られている(図-6右側)。リードタイムが6hの予測は課題が残るものの、アンサンブル予測のようにある程度の幅を持たせて予測結果(予測結果の不確実性)を表現できることが確認された。

4. 第四期の開発に向けて

第四期では、2つのモデルの開発を行っており、1つはDNNに物理法則に基づく方程式を組み込むモデルの開発(図-7)¹²⁾と、もう1つはChat GPTに代表されるような生成AIと水文モデル(例:タンクモデル)を連携させたシステム構成で、水位・流量の予測手法の開発¹³⁾を実施している。

前者のDNNに方程式を組み込むモデルでは、水路の流れと水路からの溢水の再現を目的として、1次元の不定流計算の基礎式(Saint-Venant式)を組み込んで、研究開発を行っている。この基礎式を選定した理由は、汜濫解析で広く使われている、計算負荷が小さい、筆者らの研究グループにて開発実績がある等のためである。第二期で用いた転移学習の手法と類似する部分もあるが、転移学習よりもデータの生成や学習などの手順を簡略できることが優位と言える。ただし、水路壁などの境界条件の適切な設定が必要である。

後者の生成AIを活用するモデルは、タンクモデルと連携させた生成AIを用いるモデルであり、利用者はパソコン等の端末で知りたい洪水情報の質問を入力すると、わかりやすい回答が表示される仕組みである。この利点は、タンクモデルや流出解析の専門知識が無くても容易に利用できることである。モデル開発



(x : 位置(m)、 t : 時間(s)、 h : 水位(m)、 u : 流速 (m/s)、 I : 恒等変換演算子、 $\hat{h}$: 水深の推定値 (m)、 $\hat{u}$: 流速の推定値 (m/s)、 L_h : 水位の損失関数、 L_u : 流速の損失関数、 L_{PDE} : 不定流の物理式の損失関数、 g : 重力加速度(m/s²)、 S_f : 摩擦勾配、 S : 水路勾配)

図-7 DNN モデルに1次元の不定流計算の基礎式を導入するイメージ

においては、質問者の意図にあった条件でタンクモデルの計算を行うこと、計算結果をわかりやすく回答すること等を目標にしている。ただし、生成 AI も間違えることがあるため、回答の信頼性などを十分に検討することが必要である。

今後、これらの新たな予測手法についての開発を進めていく予定である。

【引用文献】

- 1) 総務省編 (2024) 令和 6 年版 情報通信白書、308p.
- 2) 木村延明、桐博英 (2025) 低平地における排水機場遊水池の AI 水位予測手法の開発と発展、水土の知、93(1)、pp.19-22.
- 3) 木村延明、中田 達、桐 博英、関島建志、安瀬地一作、吉永育生、馬場大地 (2019) LSTM モデルを用いた低平地排水機場の水位予測、土木学会論文集 B 1 (水工学)、75 (2)、pp.I_139~I_144.
- 4) Hochreiter, S. & Schmidhuber, J.(1997) Long short-term memory. Neural Computation, 9(8), pp.1735~1780
- 5) Pratt, L.Y.(1992) Discriminability-based transfer between neural net-works. Proc. of the Advances in NIPS 5, pp.204~211, Denver, Colorado, USA, Nov.30~Dec.3
- 6) 皆川裕樹、安瀬地一作、木村匡臣、奥村直人、木村延明、馬場大地 (2020) 排水施設の操作支援のための深層学習水位予測モデル構築にむけた模擬データ活用法の検討、土木学会論文集 B1 (水工学)、76 (2)、pp.I_349~I_354.
- 7) 木村延明、皆川裕樹、福重雄大、木村匡臣、馬場大地 (2021) 深層学習モデルに物理モデルを融合させた排水機場水位予測への転移学習の適用、土木学会論文集 B 1 (水工学)、77 (2)、pp.I_319~I_324.
- 8) 気象庁情報基盤部 (2025) 数値予報解説資料集、令和 6 年度数値予報解説資料集、471p.
- 9) Hüllermeier, W. & Waegeman, W. (2021) Aleatoric and epistemic uncertainty in machine learning : an introduction to concepts and methods. Machine Learning, 110 (3) , pp.457-506.
<https://doi.org/10.1007/s10994-021-05946-3>
- 10) Neal, R. M. (1996) Bayesian learning for neural networks, Lecture Notes in Statistics, 118, Springer Science & Business Media
- 11) 木村延明、皆川裕樹、福重雄大、吉永育生、馬場大地 (2024) バイズ推定の代替手法を用いた不確実性を可視化する排水機場遊水池の LSTM 水位予測モデル、土木学会論文集特集号 (土木情報学)、80 (22)、論文 ID : 23-22011
- 12) 木村延明、皆川裕樹、木村匡臣、福重雄大、吉永育生 (2025) 1 次元非定常流計算を導入した Physics-informed neural networks (PINN) の開水路流れへの適用、土木学会論文集特集号 (水工学)、81 (16)、論文 ID : 24-16189
- 13) 木村延明 (2024) 物理情報と連携可能な生成 AI を活用した洪水予測システムの構築、第49回土木情報学シンポジウム講演集、49、pp.33~36.