

低平地湖沼における降雨流出予測への深層学習の適用

Application of deep learning method to estimation of runoff into the low-lying lake

石川貴大* 木村匡臣* 木村延明** 安瀬地一作** 飯田俊彰*

Takahiro Ishikawa* Masaomi Kimura* Nobuaki Kimura** Issaku Azechi**

Toshiaki Iida*

1.はじめに

農業用水の確保や洪水抑制などに関して大きな役割を担っている湖沼やため池の役割を適切に担保し続けるためには排水機場による水位の管理が必要不可欠である。運転士は流入量のある程度予測し、排水量を調整して湖沼への適切な水位を維持している。しかし、今後は少子高齢化の中、熟練運転士が減少することが予測され、システムの自動化が求められる。

本研究では、出水時の低平地湖沼への流入量の予測を深層学習によって行う可能性について検証し、特にモデルの設定と学習に用いる入力値の選択方法について考察を行う。

2.対象地

対象地は新潟県新潟市の鳥屋野潟である。流域面積は 99.8 平方キロメートル、潟面積 1.37 平方キロメートルで、平均水位が海拔 -2.0 から -2.5m と低く、常に機場により隣接する河川へと排水を行っている¹⁾。また、鳥屋野潟の水位に関しても 1 時間ごとに観測・記録されている。

3.モデルの設定

a)ネットワーク構造

入力層、隠し層 2 層、出力層の計 4 層のネットワークを作成した。ノード数については隠し層 1 層目を 60、2 層目を 30 とした。

b)入出力データ

出力データはある時刻 t における鳥屋野潟へ



図-1.鳥屋野潟流域内の地図と機場の位置関係

fig1.Location of Pump station

の流入高 q_t (mm/h) とした。流入高は時刻 $t-1$ から t までの鳥屋野潟の水位変化 Δh_t (mm/h)、および鳥屋野潟から図-1 上の排水機場①によって河川へ排水される水量 D_t (m³/h) から以下の式により算出した。なお A_L (km²) は潟面積、 A_C (km²) は流域面積を表す。

$$q_t = (\Delta h_t \times A_L + D_t \times 10^6) / A_C$$

入力データは排水機場①からの排水水量を $t-1$ 時間前から $t-Q_t$ 時間前まで、8 か所の機場で観測した降水量をまで $t-1$ 時間前から $t-R_t$ 時間前まで 1 時間単位でさかのぼって、一つの出力に対して合計 $Q_t + (R_t \times 8)$ 個のデータを選択した。

c)学習データとテストデータ

学習データは 2010 年 3 月から 2017 年 11 月までの降雨イベント時のデータ、テストデータは 2018 年 3 月から 2018 年 11 月までの降雨イベント時のデータから作成した。降雨イベント

*東京大学大学院農学生命科学研究科 Graduate School of Agricultural and Life Sciences, The University of Tokyo,**農研機構、農村工学研究部門 Institute for Rural Engineering, NARO

【キーワード】水文統計、用水管理、排水管理

は、1)累積降水量 12 mm以上、 2)前後に 8 時間以上の無降雨期間が存在する、という 2 つの基準から抜粋した。また、降雪の影響を無視するために 12 月～2 月までのデータについてはデータの作成には含めなかった。

以上の条件下で約 7000 件の学習データセットが作成された。

d)学習の終了

深層学習における学習は学習データ内の誤差を数学的に減少するようになっていくが、学習の回数を大きくしすぎるとテストデータなどの未学習のデータに対して正しく答えを出力できなくなる過学習という現象が発生する。

本研究では、学習一回ごとにテストデータに対して答えを出力し、実測値との RMSE を算出する。この RMSE が低く更新されなくなった段階で計算を終了するように設定した。

e)事前学習とドロップアウト

過学習を抑制するための手法として事前学習とドロップアウトが知られている²⁾。ドロップアウトとは、一定の割合でノードを不活性化する手法である。本研究では、自己符号化器という事前学習手法について検討し、ドロップアウト率を 0、0.3、0.5 の 3 段階で変更して学習を行った。

結果、事前学習を行ったほうが学習の精度があがるが、事前学習を行うという条件下ではドロップアウト率による違いはほとんど見られなかった。

4,入力データの検証

入力データについて Δt_r を 1 から 20、 Δt_d を 0 から 5 まで変化させてその精度を比較した。図-2 にその結果を示す。

Q_t については値が 0 の場合には RMSE が大きくなり、精度が低くなるが 1 から 5 の間では有意な差は見られなかった。このことより、ある時刻における流入高は 1 時間前の排水量のみより大きな影響を受け、それ以前の

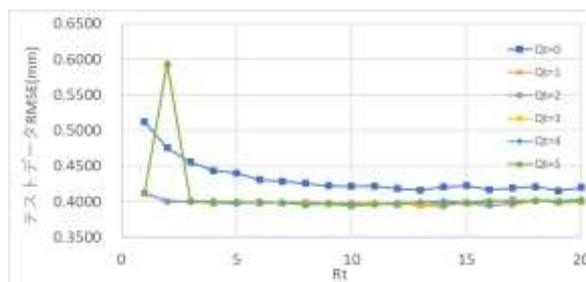


図-2 入力データによる精度の比較

Fig2 Difference of accuracy between input data

排水量は入力データに含んでも学習の際に影響が無視されていると考えられる。 Δt_r については値が 10 を超えたあたりから精度の上昇は落ち込みある程度まで収束する様子が観測された。

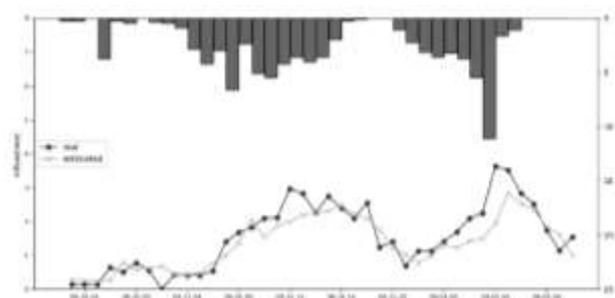


図-3 ある日の実測値と予測値の比較

Fig3 Comparison between real and estimated runoff

図3はテストデータ内で最も降水の多かった 2018/08/20 における実測値と予測値の比較である。

5.おわりに

本研究では、深層学習による湖沼流入量の予測について実際のフィールドにもとづいて検討を行った。今後の課題として、隠し層の数や隠し層のノード数などモデルの構造についてさらに検討する余地がある。

参考文献

- 1) 新潟市 潟の博物館 <<http://www.niigata-satokata.com/learn/toyano/>> (参照 2019-04-09)
- 2) 岡谷貴之:深層学習,講談社サイエンティフィック,2015