

Prediction on Water Levels in a Wet Pond for a Drainage System Using an Artificial Neural Network Model

メタデータ	<p>言語: jpn</p> <p>出版者:</p> <p>公開日: 2019-03-07</p> <p>キーワード (Ja):</p> <p>キーワード (En): Artificial neural network model, Runoff model, Drainage facility, Low land, Water level prediction</p> <p>作成者: 木村, 延明, 中田, 達, 安瀬地, 一作, 関島, 建志, 桐, 博英, 馬場, 大地</p> <p>メールアドレス:</p> <p>所属:</p>
URL	<p>https://doi.org/10.24514/00001157</p>

人工ニューラルネットワークモデルを利用した排水機場 遊水池の水位予測に関する研究

木村延明* 中田 達** 安瀬地一作* 関島建志* 桐 博英* 馬場大地***

*水理工学研究領域沿岸域水理ユニット

**国際水管理研究所

*** (株) アーク情報システム

要 旨

近年の温暖化の影響や農作物の作付け変更への対応、また、排水施設の運転コストを抑制するために、効率的・柔軟的な排水施設の運用が必要である。とくに洪水時において、モニタリング地点の水位や流れをリアルタイムで予測できれば、排水システムの最適な運用が実現できる。本研究の目的は、人工ニューラルネットワーク (ANN) モデルを利用して、豪雨時の排水機場遊水池へ流れ込む流量とその水位をリアルタイムで予測可能なシステムを構築することである。このシステムは、179 ha の面積を有し、排水機場、水位調整を行う遊水池を持つ水田地域に適用された。ANN モデルへの入力は、降雨量・水位・ポンプ排水量である。不十分な学習データを補うために、気象庁アメダスからの降雨データを基にして、2年と10年確率降雨イベントを含む人工降雨データを生成し、水位・流量データは、この降雨データを入力値として計算された排水解析モデルの出力結果を利用した。ANN モデルの出力は水位・流量である。10回の交差検証法を用いて ANN モデルの水位予測の検証を行い、30分と2時間後の水位予測は10%以内のエラーが得られた。また、10年確率降雨イベントについて、その学習の有無の比較では、2時間後の最大水位の予測は約10%の差異が見られた。

キーワード：人工ニューラルネットワークモデル、排水解析モデル、排水施設、低平地、水位予測

1 緒 言

近年の気候変動によって頻発する豪雨に伴い災害リスクが増加したこと (IPCC, 2013) や農地の転作化と宅地化に伴い水管理の方法が変化したこと (西原, 2013) などに対処するために、とくに低平地における排水処理の役割が変化してきた (増本, 2012)。従って、ポンプ場などの排水施設 (以下、排水機場という) を近年の環境変化に対応して最適に運用することが喫緊の課題である。たとえば、情報通信技術 (ICT) を利用した農地排水機場の最適化運用によって、降雨後に水田の水位を速やかに適正な高さに維持したり、高収益作物を作る転換畑圃場の湛水被害を軽減したりすることが可能になる (遠藤, 2017)。加えて、排水機場の運転経費は管理者にとって大きな負担となるので、より効率的な運用が求められる (農林水産省農村振興局, 2018)。一般的に、排水機場の流出量を制御するシステムは、排水路等の水位に応じて運転・停止が規定されている (農林水産省農村振興局, 2018)。例えば、ICT で取得されたビックデータと連動する人工知能 (AI) のシステムへの導入によって、水管理のための監視地点の水位や流量を事前に予測することができれば、低平地内の余剰水量について河川への事前放出が可能となる。従って、最大水位の低減によって氾濫軽減を促し、また効率的な運転で複数台のポンプを同時利用する時間を削減すると共に、ポンプの過剰使用に

よる劣化を防ぐことができるなど、排水システムの高度な運用に寄与できる。さらに、農業水利施設の管理者の高齢化に伴う人材不足の問題が近年常態化している (山本ら, 2010)。これらの問題を解決するために、熟練した管理者のノウハウを持った AI 仕様の自動運転システムができれば、管理者不在でも適切な排水システムの運用が可能である。以上のことから、排水機場の流出量を自動的にコントロールできる操作・管理支援システムの構築が求められる。

既存の水位・流量のリアルタイム予測モデルとしては、流域における不定流計算を行った流出解析モデル (例：吉村ら, 2014) や、カルマンフィルタなどのデータ同化手法を適用した流出解析モデル (例：佐山ら, 2007) などが挙げられる。流出解析モデルを利用する場合には、河川・土壌・土地利用などの流域特性であるパラメータを調整するために多大な時間を要する。近年急速に発達した AI のディープラーニング (例：畳み込みニューラルネットワーク, Krizhevsky et al., 2012) にみられるような最新の機械学習アルゴリズムを導入した人工ニューラルネットワーク (ANN) モデルは、過去の観測データの機械学習からリアルタイム予測が可能な様々な分野で適用が始まっている。例えば、流域におけるリアルタイム洪水予測を行うために流出解析モデルとカップリングさせた ANN モデルを利用した事例も見られる (一言ら, 2017)。

しかし、このような機械学習モデルにおいて予測精度を高めるためには、大量かつ多様な分布を持つデータを必要とする。とくに洪水予測については、豪雨時のデータ収集は欠かせないものの現実に豪雨イベントの頻度は高くないために、観測データのみでは学習に不十分な場合も想定される。本研究では、農業用地も含む低平地において、観測データが不足しているために、排水解析モデルで機械学習に必要な人工的なデータセットを生成し、そのデータセットを利用する ANN モデルをエンジンとする水位予測システムの構築を行うものである。人工的なデータセットとして生成された様々な分布を持った降雨に対して出力された排水解析モデルの水位について、ANN モデルによる水位予測の適合性を検討することを目的とする。

2 方法

2.1 調査対象地区

低平地の対象地区とした A 地区は、水田と畑地が混在する農地が主体の流域面積 179 ha、無降雨時も含め常時機械排水されている地区である (Fig. 1)。A 地区からの排水は水路の下流末端に位置する排水機場での 3 台のポンプ (3 台合計排水量: $2.0 \text{ m}^3/\text{s}$) によって河川に排水される。3 台のポンプはそれぞれ規定排水量が異なる。排水機場の吸水槽としての遊水池 (湛水面積 800 m^2) に設置された水位計により、10 分毎の水位データが蓄積されている。なお、観測期間中に一降雨分のデータに対応する水位データが記録された (流量データは記録されていない)。3 台のポンプはそれぞれ規定された遊水池の水位の値に応じて起動し、遊水池の水位が下がるまで自動運転を行う。

2.2 人工ニューラルネットワーク (ANN) モデル

排水機場遊水池の水位予測システムに組み込まれる ANN モデルについて以下に説明する。ANN モデルとは、神経ネットワークを表現する概念に基づくデータ駆動型モデルで、複雑な非線形問題の解を得るために使用されるものである (Simon, 1999)。本研究では、データの流が一方向であるフィードフォワード型 ANN モデル (Schmidhuber, 2015) を採用し、3 層のパーセプトロンモデル (Rosenblatt, 1957) とした。本モデルは、機械学習に用いるためのソフトウェアライブラリーである TensorFlow (www.tensorflow.org) を用いて実装し、重み付けを伴う教師あり学習方法としてバックプロパゲーションのアルゴリズム (Rumelhart et al., 1986)、誤差推定のために連続最適化問題に対する確率的アルゴリズムとしてミニバッチ確率的勾配降下法 (巢籠, 2017) をそれぞれ採用した。

詳細な ANN モデルの構造は Fig. 2 に示した。入力層は、近隣のアメダスから収集した直近の現時点の 3 時間前から 1 時間毎の降雨量 (R [mm/hr])、排水機場に隣接する遊水池における現時点の 30 分前から直近までの 10 分毎の水位変化量 (遊水池水位, h_p [m/s])、排水機場から外水 (河川) へ排水されるポンプの流量 (ポンプ排水量, Q_p [m^3/s])

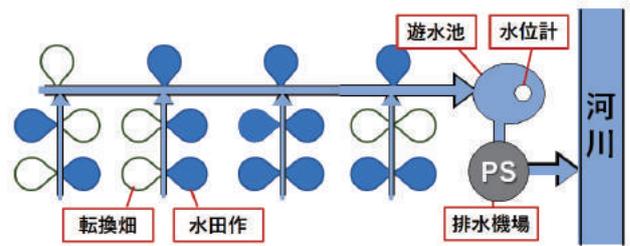


Fig. 1 A地区の排水概要図

Schematic diagram of the A area drainage system

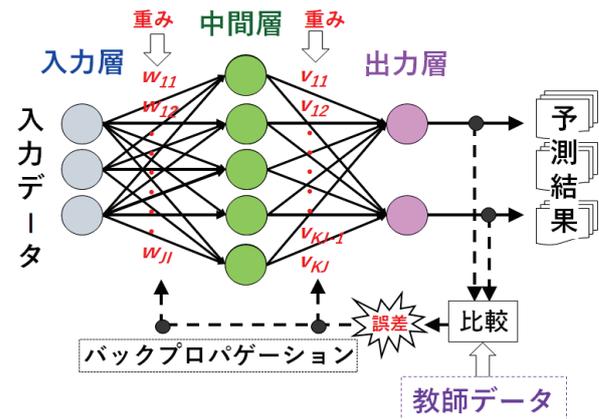


Fig. 2 ANNモデルのデータフロー

ANN model data flow

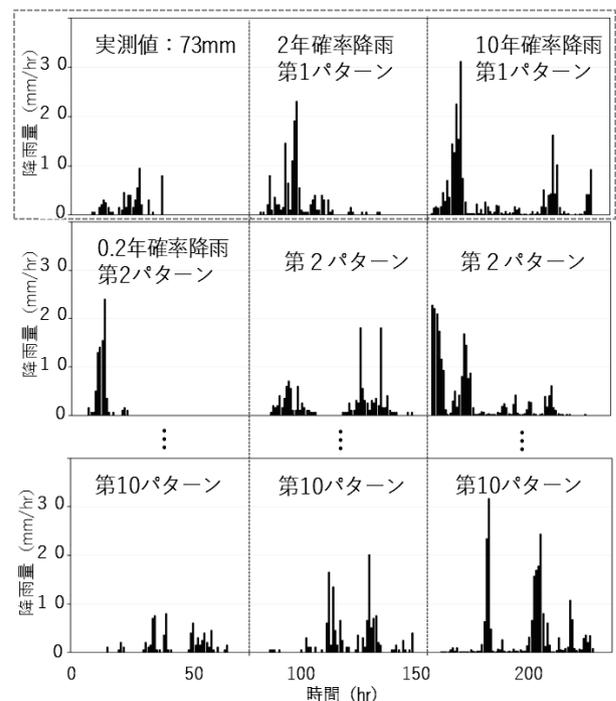


Fig. 3 降雨パターンの時系列図

Several rainfall patterns in time series

の 9 ノードとして、規準化して単位系を持たない数値で与えた。入力データの時間間隔は、各ノードに対応する観測

データの時間間隔に準拠させ、ANN モデルの内部では、10 分間隔のタイムステップに統一して計算される。また、ポンプ排水量は 10 分前、水位は 30 分前までのデータを用意した理由は、ポンプ起動に関する立ち上がりの時間を考慮したからである。それらの入力データの情報は、Table 1 に示される。中間層は 15–30 のノード数をテストし、最適なノード数として 20 を選択した。中間層、出力層への伝達関数は次式のシグモイド関数を用いた。

$$f(y) = \frac{1}{1+e^{-ay}} \quad (a > 0), \quad (1)$$

ここで、 y = 変化量、 a = 任意の正の値である。出力層は、10 分後から 2 時間後までの排水機場遊水池の水位 (H_o [m])、および A 地区から排水機場遊水池へ流れ込む流量 (Q_D [m³/s]) の 10 ノードとした。各入力変数を X (R, h_p, Q_p)、出力変数を Y (H_o, Q_D) としてまとめ、3 層パーセプトロンモデルの場合については、以下の関係式が与えられる。

$$h_j = f\left(\sum_{i=1}^I X_i w_{ji} - \theta_j\right) \quad (1 \leq j \leq J), \quad (2a)$$

$$Y_k = f\left(\sum_{j=1}^J h_j v_{kj} - \theta_k\right) \quad (1 \leq k \leq K), \quad (2b)$$

ここで、 I = 入力層のノード数、 J = 中間層のノード数、 K = 出力層のノード数、 θ, Θ = 閾値、 w = 入力層から中間層への重み付き関数、 v = 中間層から出力層への重み付き関数である (Fig. 2)。出力データの一覧は、Table 2 に示される。なお、本研究の対象領域は低平地なので、降雨と水位との相関からタイムラグは高々数時間程度であるので、最大予測時間は 2 時間後を採用した。機械学習は、訓練データの中からランダムにいくつかのデータを取り出して誤差を計算し、パラメータを更新するためのミニバッチ確率的勾配降下法を利用した。出力変数の内、遊水池の水位と遊水池へ流れ込む流量の教師データは、観測データが不足しているために人工的に生成された降雨イベントを用いて計算された排水解析モデルの水位・流量結果を用いた。以下の節で詳細を述べる。

2.3 模擬豪雨波形の作成による降雨データの構築

観測された水位データだけでは、洪水災害を起こすような大きな降雨 (以下、豪雨という) イベントに対する水位変化の機械学習が不十分であるので、A 地区に適用された排水解析モデルを利用し、ANN モデルの教師データとなる人工的なデータセット (降雨量、ポンプ排水量、水位、流量) を作成する必要がある。まず、排水解析モデルの入力データとなる人工的な豪雨データを作成した。近隣のアメダスから A 地区の観測降雨量 (累積降雨量 73mm、これを便宜上 0.2 年確率降雨量とする) を取得した。この降雨量に対しては観測された水位データを所有している。A 地区の 1976 年から 2015 年までの 40 年間にわたる長期間のアメダス降雨データから、本研究で対象とした観測降雨量に相当する 0.2 年確率降雨量、より頻繁に起こり得る豪雨の代

Table 1 入力層ノード一覧

List of nodes in the input layer

変数	時間	単位
降雨量	2 時間前, 1 時間前, 現時点	mm/hr
水位差 ¹⁾	30 分前, 20 分前, 10 分前	m
水位	現時点	m
ポンプ排水量	10 分前, 現時点	m ³ /s

1) 水位差は、現時点の水位の差分を取った値である。

Table 2 出力層ノード一覧

List of nodes in the output layer

変数	時間	単位
水位	10 分後, 20 分後, 30 分後, 1 時間後, 2 時間後	m
流量	10 分後, 20 分後, 30 分後, 1 時間後, 2 時間後	m ³ /s

Table 3 予測ケースの差異

List of nodes in the input layer

ケース名	10 年確率降雨イベント	排水解析モデルとの比較	関連図
ケース 1	あり	30 分, 2 時間後	Figs. 5, 9, 10
ケース 2	なし	2 時間後	Figs. 6, 11

表として 2 年・10 年確率降雨量について、それぞれ 10 個ずつ降雨波形を変えて生成した。0.2 年・2 年・10 年確率降雨量の推定には、Gumble 分布を用い、その母数は L 積率率により推定した。降雨波形の作成では、長短期の A 地区の降雨特性 (頻度、強度、時間分布) を考慮した波形をモンテカルロ法に基づき模擬発生させる方法 (皆川ら, 2014) を採用した。具体的には、皆川ら (2014) の手法において、総降雨量に上記の年確率降雨の 3 日間累積降雨量をそれぞれ固定させて与え、その雨量を 1 時間雨量に分配し、自己相関性を備えた内部波形パターンを 10 個ずつ生成した。0.2 年確率降雨イベントについて、10 個の内 1 つは観測降雨量を利用した。なお、2 年確率降雨イベントの累積降雨量は 3 日間で 132mm の降雨量、10 年確率降雨イベントは 3 日間で 219mm の降雨量であった。ここで、3 つの確率降雨イベントについて、各確率降雨を重複させないように 3 日間のデータに 8 時間のゼロ値を追加し、比較的多くの降雨波形のパターンで水位予測を可能にするために、単純に時系列に繋げたものを 1 つのパターンとした (Fig. 3 の点線囲みを参照のこと)。この 1 つのパターンは 3 つの確率降雨波形を含む 240 時間の降雨分布に対応し、降雨波形の無作為の組み合わせを行い、全部で 10 個のパターンの降雨分布形データを用意した。第 1 パターンは観測降雨量を含む降雨分布、第 2–第 10 パターンは模擬発生させた降雨分布である (Fig. 3)。

2.4 排水解析モデルによる水位・流量の教師データの構築

本対象地区の排水解析モデルは、圃場タンクモデル、1次元水路モデル、排水機場遊水池モデルからなる (Fig. 4)。圃場タンクモデルは地下浸透による損失を考慮した一段のタンクとした (Fig. 4 の(a))。圃場からの流出 q_L (m/s) は暗渠管を通じた排水路への自由流出を模擬した以下の式 (3b) のようなオリフィス流出を採用した。また、地下浸透による損失量 q_U (m/s) も同様に表した。

$$\frac{dh_L}{dt} = c_0 R - q_L - q_U, \quad (3a)$$

$$q_L = c_L h_L^{1/2}, \quad (3b)$$

$$q_U = c_U h_L^{1/2}, \quad (3c)$$

ここで、 t = 時間 (s), c_0 = 降雨量の単位変換係数, c_L = 流出係数 ($m^{1/2}/s$), c_U = 地下浸透への流出係数 ($m^{1/2}/s$), h_L = 圃場タンク水深 (m) である。次の式(4)で表される観測降雨イベントでの水収支から、 c_L , および c_U を算出した。

$$\sum_i R_i = \sum_i (c_{L,i} + c_{U,i}) h_{L,i}^{1/2}, \quad (4a)$$

$$\sum_i Q_{p,i} = \sum_i c_{L,i} h_{L,i}^{1/2} A_{L,i}, \quad (4b)$$

ここで、 A_L = 圃場面積 (m^2) である。対象地区は水田と転換畑が混在しているため、土地利用毎に、 c_L , c_U は異なる値を取るべきであるが、観測降雨イベントが非灌漑期であったため、土壤の流出特性は地区で一様とみなし、一律の値を用いた。

圃場からの流出 q_L は、圃場面積を乗じた上で、次の式(5)の一次元水路モデルにおける連続式の横流入量として与えた。一次元水路モデルにおける水路延長、水路幅、水路勾配、粗度係数などの水路諸元および圃場からの流出地点は、対象地区の設計図面に従った。式(5)、式(6)を離散化し、1次元不定流計算を行った。水路の下流端は遊水池とし、排水機場遊水池モデルで算出される遊水池水位を与えた。

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(\frac{gA^2}{2B} + \frac{Q^2}{A} \right) - gA(I_b - I_f) = 0, \quad (5)$$

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = q_L A_L / B_L, \quad (6)$$

ここで、 x = 流下方向の座標 (m), I_b = 水路床勾配, I_f = 摩擦勾配, Q = 流量 (m^3/s), A = 河積 (m^2), B = 水路幅 (m), B_L = 水路と接する圃場の長さ (m), g = 重力加速度 (m/s^2) である。排水機場遊水池モデルは単純な水収支タンクで表現した。

$$A_P \frac{dh_p}{dt} = Q_D - Q_P, \quad (7)$$

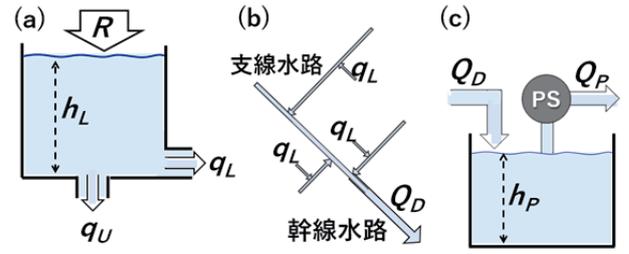


Fig. 4 排水解析モデル (a) 圃場タンクモデル, (b) 一次元水路モデル, (c) 排水機場遊水池モデル
Schematic diagrams for the runoff model, consisting of (a) the field tank model, (b) the one-dimensional open-channel model, and (c) the volume balance model for the pump station and the pond

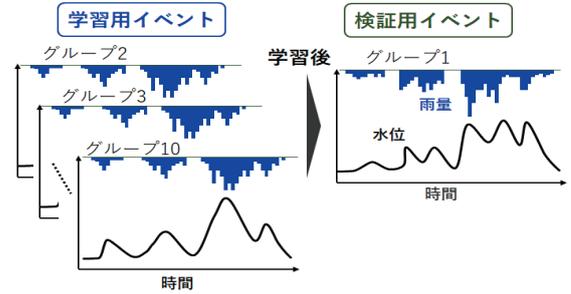


Fig. 5 k 交差検証法の適用事例
Example of the k-fold cross-validation

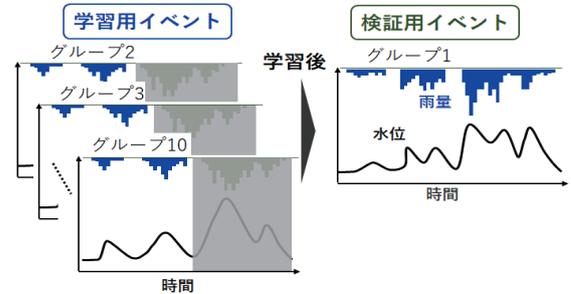


Fig. 6 10年確率降雨イベント (左図グレー枠) を学習しない場合の k 交差検証法の適用事例
Example of the k-fold cross-validation with machine learning data excluding the 10-year probability rainfall (gray covers)

ここで、 A_P = 遊水池面積 (m^2) である。なお、 Q_P は遊水池の水位からそれぞれのポンプにおける起動・停止のための規定値を満たしているかを判断し、複数台稼働している場合にはそれぞれのポンプの規定流量の合計を与えた。

上記 2.3 で構築した 10 個の降雨量パターンを圃場タンクモデルへの入力値として与え、一次元水路モデルとポンプ遊水池モデルによって、流量 (Q_D) および水位 (h_p) を計算した。これらの時系列データが ANN モデルの学習のための教師データとなる。

2.5 ANNモデル予測結果の検証

予測結果を検証するために, k 交差検証法 (Geisser, 1993) を用いた。この方法は標本データを k 個のグループに分割し, k-1 個のグループで最初に訓練して, 残る 1 個のグループでその訓練のテストを行い, ANN モデルの妥当性を検証するものである。本研究では, k=10 を採用し, 10 個のパターンの降雨分布を用いて排水解析モデルを実行し, 得られた予測結果を 10 個のグループとして定義した。降雨パターン 1 に対応する結果を第 1 グループとして, それぞれの降雨パターンに対応するグループを第 10 グループまで定義した。10 回の交差検証法を適用し, 9 個のグループのデータセットを機械学習に使用し, 残りの 1 個のグループを検証用に使用した。検証用になる 1 個のグループのデータセットを変えながら 10 回繰り返し, それぞれの回の検証誤差を求めて最終的に平均値を求めた (Fig. 5)。本研究ではこの検証ケースをケース 1 とする。また, ANN モデルの弱点である「学習していないものは予測ができない」ことを検討するために, ケース 2 として数値実験ケースを設定する (Table 3)。降雨量データの内, 10 年確率降雨イベントを除いたデータと, そのデータを用いて計算された排水解析モデルの結果 (水位) を ANN モデルの入力データとして機械学習を行った。10 個のグループについて, それぞれ 10 年確率降雨イベントを含んだ排水解析モデルの結果と比較

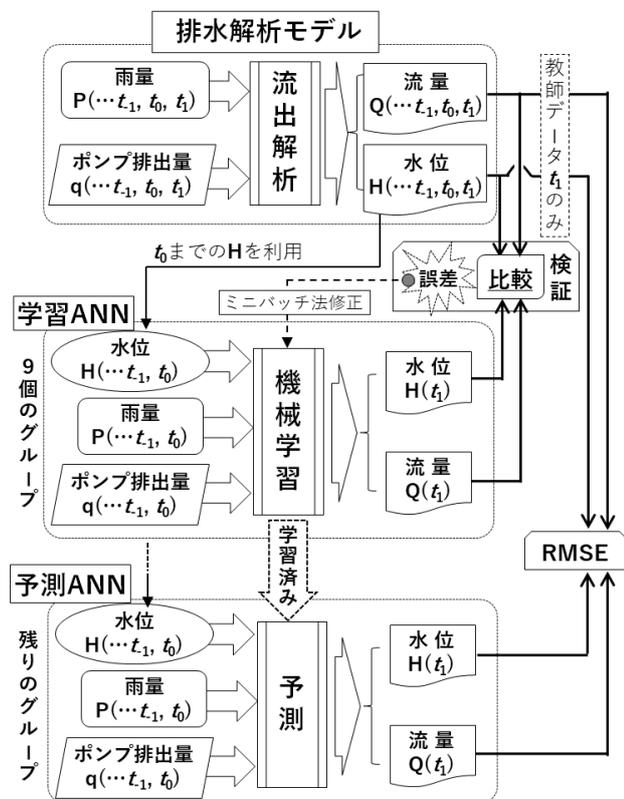


Fig. 7 計算のデータフロー (時刻: t_1 = 過去の時点, t_0 = 現時点, t_1 = 予測時点)

Data flow on the whole system

した (Fig. 6)。なお, 検証で用いた誤差評価と機械学習の収束確認には, 二乗平均平方根誤差 (RMSE)・相対誤差 (RE, 例: 藤原, 2004) と損失係数 (E) がそれぞれ適用された。

$$\text{RMSE} = \sqrt{\frac{\sum_{j=1}^n (V_{cj} - V_{oj})^2}{n}}, \quad (8)$$

$$\text{RE} = \frac{1}{n} \sum_{j=1}^n \frac{|V_{cj} - V_{oj}|}{V_{oj}}, \quad (9)$$

$$E = 0.5 \times \sum_{j=1}^n (V_{cj} - V_{oj})^2, \quad (10)$$

ここで, n = 計算値/観測値の個数, V_o = 観測値 (或いは, 排水解析モデルの結果), V_c = 計算値である。本研究では, 排水解析モデルと ANN モデルの 2 つのモデルを利用した計算が実施された。これらモデルの計算のデータフローは Fig. 7 に示される。

3 結果

3.1 排水解析計算結果

本研究では, 人工的な豪雨イベントを含むデータセットを作成するために, A 地区について排水解析モデルを利用し, 水位 (H_D) と流量 (Q_D) を計算した。この計算結果を観測データと見なし, ANN モデルの機械学習と予測結果の検証を行うために利用した。排水解析モデルの妥当性を評価するために, 観測降雨量の期間に関して, 水位における現地観測値と計算値を比較した (Fig. 8)。RMSE は 0.16m となり, 観測降雨量の期間における観測水位の最大変化量 (水位の最大値と最小値の差) に対して約 16%であった。また, 相対誤差 ($\text{RE} \times 100$) は, 約 6%であった。Fig. 8 に見られるように, 低平地には特有の常時排水ポンプの稼働で, 水位の上下動 (2.0m 付近) が確認できる。これは, 1 台目のポンプの運転と停止を繰り返す時に発生する振動である。約 32 時間目では 2 台目ポンプの起動のタイミングや約 35 時間目に水位がピークを迎えるタイミングは概ね一致した。従って, 排水解析モデルの計算結果は概ね妥当であると言える。ただし, ポンプを停止させる時刻の水位に, 計算値と観測値の差が見みられるが, 設計上の規定水位 (モデルで与えた水位) と観測された水位との齟齬と考えられ, 規定水位まで低下しても, ポンプ停止の判断までにタイムラグがあるために実際の水位は規定水位よりも 10cm 程度低い値まで低下すると考えられる。

第 1 パターンでは観測降雨量に加えて 2 年間・10 年間確率降雨イベントを含めた降雨データ (「2.3 模擬豪雨波形の作成による降雨データの構築」を参照のこと) を排水解析モデルの入力データにして, 水位と流量を計算し, この期間の降雨量とポンプ排水量を合わせて第 1 グループのデータセットを作成した。さらに, 第 2-第 10 パターンまでの 9 つの降雨量に関しても, 水位と流量を計算し, 第 2-第 10 グループの降雨量, ポンプ排水量, 水位, 流量の 9 個のデータセットを作成した。

Table 4 ANN 水位予測の検証結果
Validation of the ANN prediction on water levels

グループ	RMSE (m)		rRMSE ¹⁾ (%)		RE×100 (%)
	30分後	2時間後	30分後	2時間後	
No.1	0.12	0.14	8.8	10.4	5.3
No.2	0.08	0.13	4.2	6.7	4.1
No.3	0.12	0.12	4.9	4.8	4.1
No.4	0.08	0.12	4.0	6.2	3.7
No.5	0.11	0.17	10.7	15.7	4.5
No.6	0.13	0.21	3.1	5.0	4.7
No.7	0.09	0.13	5.1	7.9	4.2
No.8	0.22	0.23	21.1	22.1	8.8
No.9	0.11	0.14	2.4	3.1	4.1
No.10	0.09	0.21	6.1	14.3	4.5
平均値	0.12	0.16	7.0	9.6	4.8

1) rRMSE = RMSE/水位の最大変化量×100 (%)

Table 5 ANN 流量予測の検証結果
Validation of the ANN prediction on discharges

グループ	RMSE		rRMSE ¹⁾ (%)		RE×100 (%)
	(m ³ /s) 30分後	(m ³ /s) 2時間後	(%) 30分後	(%) 2時間後	
No.1	0.23	0.25	10.1	10.7	20.0
No.2	0.20	0.26	9.4	12.5	20.1
No.3	0.18	0.23	8.0	10.2	19.9
No.4	0.18	0.22	8.0	9.9	21.1
No.5	0.23	0.77	10.2	35.0	26.4
No.6	0.16	0.37	6.8	15.8	24.9
No.7	0.21	0.27	9.8	12.6	23.9
No.8	0.22	0.27	9.9	12.6	23.6
No.9	0.17	0.21	7.2	8.9	28.7
No.10	0.20	0.32	9.2	14.7	23.7
平均値	0.20	0.32	8.9	14.3	23.8

1) rRMSE = RMSE/流量の最大変化量×100 (%)

3.2 ANN モデルの予測結果

ANN モデルの機械学習について、ケース 1、及びケース 2 は 1000 回の学習回数で損失係数が収束したと判断した。ただし、損失係数で用いられる観測値は排水解析モデルの出力値である。次に、k 交差検証法で ANN モデルの予測結果の妥当性を評価した。観測降雨を含む降雨パターン 1 から計算された第 1 グループのデータセットについて、30 分後と 2 時間後に予測した水位の出力結果を示す (Fig. 9)。第 1 グループの予測期間の最大水位 (以下、ピーク水位という) については、30 分後の予測値および 2 時間後の予測値と共に概ね良い精度でピーク水位を予測できた。ここで定義されたピーク水位は、時間ステップ毎に計算される 10 分~2 時間後の間の水位の最大値を示してはいない。ANN モデルの水位予測の期間において、排水解析モデルの出力結果との差異は、30 分後に RMSE = 0.12m, 2 時間後に RMSE = 0.14m であった。また、水位の最大変化量に対してそれぞ

れ約 8.8%, 10.4% の誤差であった。予測期間 60 - 80 時間の水位予測は差異が見られるが、この期間の降雨量が 0 であったために、排水路から遊水池への流入量も小さく、結果として遊水池の水位予測値に変動がなかったものと考えられる。

さらに、第 4 グループについては、30 分後・2 時間後の水位予測は共に RMSE = 0.08m, 0.12m, 水位の最大変化量に対してそれぞれ約 4.0%, 6.2% の誤差となり、同様に良好な結果が得られた (Fig. 10)。他の降雨・水位・流量分布の異なるグループについてもそれぞれ検証を行い、30 分後と 2 時間後の予測結果の平均 RMSE は 0.12m, 0.16m であった。水位の最大変化量に対して共に約 10% 以下の誤差であった。また、2 時間後の予測結果について、平均相対誤差

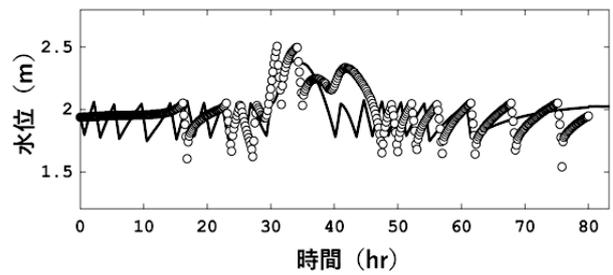


Fig. 8 排水解析モデルの妥当性の評価 (線=モデル結果, ○ =観測値)

Validation of the numerical simulation by the unsteady runoff model, compared with the observed data (line = simulation and ○ = observation)

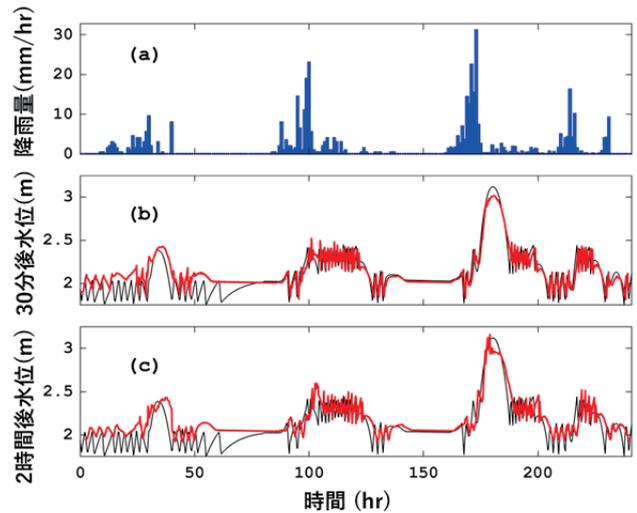


Fig. 9 第 1 グループにおける降雨量・排水解析モデルからの結果 (黒細線) と ANN モデルの予測結果 (赤太線) の比較 : (a) 降雨量, (b) 30 分後の水位予測結果, (c) 2 時間後の水位予測結果

Rainfall and water level (WL) in the first data group predicted by the runoff model (thin line) and ANN model (bold line): (a) rainfall, (b) WL in 30 min behind the present and (c) WL in 2 hr behind

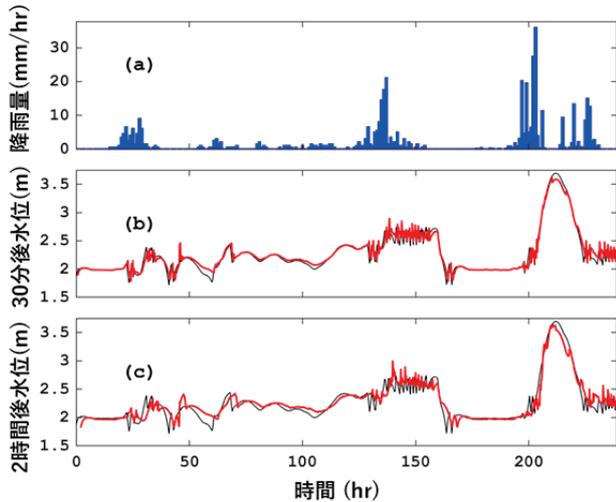


Fig. 10 第4グループにおける降雨量・排水解析モデルからの結果(黒細線)とANNモデルの予測結果(赤太線)の比較: (a) 降雨量, (b) 30分後の水位予測結果, (c) 2時間後の水位予測結果

Rainfall and water level (WL) in the fourth data group predicted by the runoff model (thin line) and ANN model (bold line): (a) rainfall, (b) WL in 30 min behind the present and (c) WL in 2 hr behind

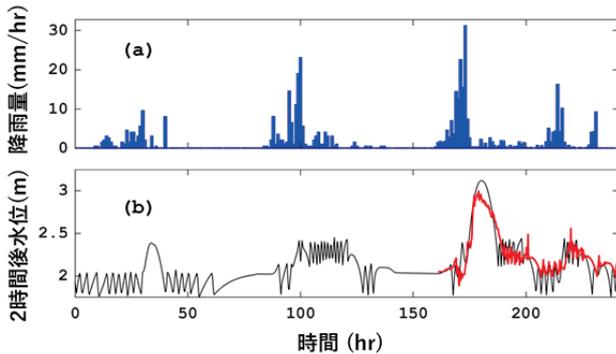


Fig. 11 第1グループにおける降雨量・排水解析モデルからの結果(黒細線)とANNモデルの予測結果(赤太線, 10年確率降雨イベント期間のみ)の比較: (a) 降雨量, (b) 2時間後の水位予測結果, ただし, 10年確率降雨イベントの機械学習なし

Rainfall and water level (WL) in the first data group predicted by the runoff model (thin line) and ANN model (bold line, during the 10-year probability rainfall): (a) rainfall, (b) WL in 2 hr behind the present without machine learning for the 10-year probability rainfall

($RE \times 100$) は, 約 5%であった。各グループの検証結果とグループ全体の平均値は **Table 4** にまとめた。なお, ANNモデルの流量予測の検証については, 水位予測と同等に行い, 排水解析モデルから得られた流量の最大変化量に対して RMSE に基づく評価は, 2時間後の予測は約 14%の誤差

を生じ, また $RE \times 100$ は 23.8%であった。流量予測の誤差の評価は **Table 5** に示した。

ANN モデルの洪水予測に適用する場合の制限について数値実験を行った。10年確率降雨イベントを入力データとして機械学習させずに, 10年確率降雨イベントを予測した場合に, 第1グループにおける2時間後予測ではピーク水位(ここでは, 10年確率降雨イベントの期間における最大水位)を0.2m程度のみ過小評価する結果となった。ピーク水位を迎える時間は, 排水解析モデルからの結果と比較して約1時間のタイムラグが見られた(**Fig. 11**)。また, ピーク水位を含む洪水波形(170–190時間)の再現について, 10年確率降雨イベントの学習有りとなしとの予測結果の比較を行った。それぞれの RMSE は, 学習有りの場合に 0.14m, 無しの場合に 0.17m であった。

4 考察

河川において, 洪水予測を対象に利用される ANN モデルは, 一般的に入力データの降雨量から河川の水位・流量の予測を出力するモデルである。対象流域によってはタイムラグが発生するものの, 時間進行における降雨量の分布と水位の分布は, 強い相関が見られるので, 降雨量と水位の時間変化のパターンは明らかに類似している。この場合に, パターン認識で機械学習を行う ANN モデルにおいて, その機械学習後に妥当な水位予測の結果が得られやすい。しかし, 本研究が対象とする A 地区において, 降雨量の入力に対し遊水池の水位は, 遊水池への流入量とポンプの排水量の体積のバランスで決まるので, 必ずしも降雨量と水位の相関が強いとは限らない。一般的に, シングルイベントの豪雨を対象とした河川水位を予測する ANN モデルよりも複雑な事象を扱い, さらに3つの年確率降雨イベントを同時に扱う本研究の ANN モデルの水位予測は, 約 10%以下の誤差であった。

本研究で用いた3層のパーセプトロンを持つ ANN モデルについて, 他の文献との比較を行う。以下に挙げる文献では, 本研究の ANN モデルの類似モデルについて改良型・発展型を提案している。彼らの研究での定義に習い, 従来型モデルとする。一言ら (2016) の報告によれば, シングル豪雨イベントの出水現象について, 従来型モデルを利用した場合に, 出水期間の水位の最大変化量に対して, 2時間後の水位予測の誤差は約 5%であった。関ら (2013) の報告の中では, 2つの洪水イベントにおいて, 従来型の ANN モデルを用いた2時間後の水位予測の結果が示されており, 水位の最大変化量に対し 3–7%の誤差の精度で観測値を再現した。上記の文献から, 本研究でも類似的な従来型モデルを適用し, ほぼ同程度の予測精度で水位変化を再現できた。さらに, 洪水予測の精度を高めるためには, ANN モデルの中間層 (**Fig. 2**) を2層以上にしたディープラーニングを実装する必要がある。例えば, 一言ら (2016) は, ディープラーニングを実装した ANN モデルを開発し, 従来型モデルの結果と比較した。洪水波形において, 精度向

上が容易なシングルピークを持つ波形の再現計算を行い、2時間後の水位予測では約20%の精度向上が得られたことを報告している。

ANNモデルは物理現象をモデル化したものではないので、一般的な流出解析モデルのように、地形・地質・土地利用情報などのパラメータのチューニングを試行錯誤で行う必要はなく、十分なデータの機械学習を行えば、データのパターンそのものから結果を予測できる点で有用なモデルである。しかし、一般的にANNモデルの弱点は、機械学習したデータの範囲外で予測する場合に、予測精度が悪くなることである(一言・桜庭, 2018)。本研究のケース2では、10年確率降雨イベントの期間に現れるピーク水位は、排水解析モデルからの結果と比較して約10%の差異、ピーク水位を含む洪水波形のRMSEの比較は約15%の差異が見られ、またピーク水位を含む水位波形の立ち上がりのタイミングは約1時間のタイムラグが見られた(Fig. 11)。それらの差異は、機械学習の範囲外で敢えて予測を行ったことが原因であるものの、0.2年・2年確率降雨のみの学習でも10年確率降雨イベント期間の最大水位を良好に捉えている。複数の降雨イベントの時系列パターンを機械学習した際に、水位差が入力データとして与えられたので、水位の時間変化量(=ΔH/Δt)で洪水波形の立ち上がりから水位ピークまでの微分値はプラス、水位ピーク以降はマイナスの微分値となるパターンを学習したことになり、洪水波形を間接的に学習したものと考えられる。この結果は、機械学習の範囲外でも水位そのものの値ではなくΔH/ΔtをANNモデルの入力にすれば、予測精度を向上させることを示した報告(一言・桜庭, 2018)によって裏付けされる。

排水機場の中には、熟練の管理者の人為的な判断に基づく運転が行われる地域もある(例:新潟県亀田郷)。運転ルールはあるものの洪水時に水位調整を行う場合には、管理者の判断が多少なりとも水位・流量の変化に影響を与える。例えば、過去の経験から雨が降り始める前にポンプを早期に稼働させたり、豪雨前に天気予報から判断して事前放流を行ったりする等考えられる。つまり、これらのデータには、「人間の感覚・経験」を含んだものと考えられる。このような人為的な不確定さ含んだ事象に対して、物理モデルを構築するのは困難であるが、ANNモデルを利用し、機械学習を行えば、水位・流量の予測は可能である。本研究では、ポンプ排水量を水位からポンプの起動基準を判断するルールになっているが、もしポンプ排水量のデータに人為的な判断によって流量が変化する状況が含まれるのであれば、本研究で構築したANNモデルを用いた低平地の水位調整システムのプロトタイプを上記の地域にも応用することができる。

5 結 言

本研究では、低平地に存在する農耕地を洪水災害から守り、また排水システムの効率的な運用のために、排水機場のポンプ排水量と隣接する遊水池の水位、遊水池へ流れ込

む流量、および排水対象地区の降雨量を用いて、データ駆動型モデルであるANNモデルで機械学習し、水位予測を行った。観測データが不足しているために、長短期降雨特性を考慮した豪雨の模擬発生方法と排水解析モデルを利用して作成された人工的なデータセットを教師データとして用いた。本研究で得られた成果を以下にまとめる。

- ・観測降雨量、水位、ポンプ排水量を用いて排水解析モデルの妥当性を確認した。
- ・地域特性を持つアメダスの観測降雨量に基づき生成された人工的な豪雨分布データを用いて、排水解析モデルから水位と流量のデータセットを作成した。なお、ここで得られた水位と流量を、観測データと見なして、ANNモデルの予測結果との比較を行った。
- ・降雨量、ポンプ排水量、水位、流量のデータセットを用いて、ANNモデルで機械学習し、その機械学習を終えたANNモデルを用いて水位予測を行った。k交差検証法(k=10)を用いて水位予測の評価を行い、10個のグループに対する30分後、2時間後の平均RMSEは0.11m, 0.14mであった。最大水位変動に対して、共に9%以内の誤差であった。また、2時間後の水位予測の平均相対誤差は、約5%であった。
- ・機械学習したデータの範囲外で水位予測する場合を検討するために、10年確率降雨イベントを機械学習させなかったANNモデルを用いて数値実験を行った。2時間後の水位予測は、10パーセント程度の減少が見られた。

また、本研究で開発されたANNモデルについて、ある流域への実用的な適用例として以下のような案が考えられる。

- ・流域で長期間観測されたデータを直接入力データとして機械学習し、水位予測を行うこと。
- ・流域への実装時には、予測精度の向上のために気象庁からの予測降雨量も入力データとして取り込むこと。
- ・土地利用などの流域環境が変化する場合には、観測値を含むデータベースを更新し、変化前の過去データも利用できる転移学習を実装したANNモデルの機械学習をやり直すこと。

謝辞: 本研究は、農食事業29016C「超過降雨に対応した農業地域の洪水被害を軽減する減災支援技術」の一部として実施された。印旛沼二期農業水利事業所(農水省関東農政局)の皆川裕樹氏には、豪雨イベントデータの作成にご協力いただいた。データの一部は、内閣府 戦略的イノベーション創造プログラム(SIP)委託研究の成果の一部利用させて頂いた。これらの事業からの研究資金提供、および事業関係者のご助言・ご協力等に謝意を表明する。

付録 補足資料

本研究では、ANNモデルを機械学習する際に、教師データとして、観測データを利用する代わりに、人工降雨量と排水解析モデルからの計算結果(水位・流量)の10個のグループ(データセット)

Table A1 降雨量と排水解析モデルの結果の特徴
Characteristics of psudo rainfall data and outputs by the runoff model

グループ	0.2年降雨確率イベント			2年降雨確率イベント			10年降雨確率イベント		
	最大 降雨量 (mm/hr)	ピーク 水位 (m)	ピーク 流量 (m3/s)	最大 降雨量 (mm/hr)	ピーク 水位 (m)	ピーク 流量 (m3/s)	最大 降雨量 (mm/hr)	ピーク 水位 (m)	ピーク 流量 (m3/s)
No.1	9.50	2.39	1.05	23.00	2.45	2.20	31.17	3.12	2.31
No.2	24.00	2.40	2.18	18.00	2.65	2.12	22.70	3.67	2.27
No.3	13.00	2.40	2.09	17.50	2.45	2.07	27.84	4.08	2.28
No.4	9.00	2.45	2.02	21.00	2.75	2.19	35.96	3.70	2.30
No.5	8.50	2.40	2.03	36.50	2.65	2.13	20.74	2.65	2.24
No.6	11.50	2.19	1.02	19.50	2.65	2.21	48.57	5.96	2.32
No.7	11.50	2.73	2.12	37.50	2.75	2.08	31.63	3.39	2.32
No.8	15.50	2.45	1.02	23.50	2.75	2.15	46.67	2.75	2.22
No.9	15.50	2.40	2.02	38.00	2.74	2.25	42.02	6.13	2.36
No.10	8.00	2.44	2.09	20.00	2.75	2.13	31.61	3.19	2.27

における最大降雨量・ピーク水位・ピーク流量（ピーク水位と同時刻の流量）について **Table A1** にまとめた。

引用文献

- 遠藤知庸 (2017) : 灌漑排水施設の今後, 農業土木事業協会-JAGREE, **93**, 13-20
- 藤原洋一 (2004) : 進化した計算方法による流出モデル定数の多目的最適化に関する研究, 学位論文 (甲 3099), 神戸大学, 107p
- Geisser, S. (1993) : Predictive inference: An introduction, Monographs on statistics and applied probability 55, Chapman and Hall, NY (USA), 240p
- 一言正之, 櫻庭雅明, 清雄一 (2016) : 深層学習を用いた河川水位予測手法の開発, 土木学会論文集 B1 (水工学), **72(4)**, I_187-I_192
- 一言正之, 櫻庭雅明 (2017) : 深層ニューラルネットワークと分布型モデルを組み合わせたハイブリッド河川水位予測手法, 土木学会論文集 B1 (水工学), **73(1)**, 22-33
- 一言正之, 櫻庭雅明 (2018) : 学習事例を上回る大洪水に対する深層学習水位予測モデルの検証, 第 32 回人工知能学会全国大会講演要旨,
<https://confit.atlas.jp/guide/event-img/jsai2018/1D1-03/public/pdf?type=in> (閲覧日 : 2018 年 9 月 30 日)
- Intergovernmental Panel on Climate Change (IPCC) (2013) : The physical science basis. Contribution of working group I to the fifth assessment report of the IPCC ; T.F. Stocker, D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, P.M. Midgley, Eds.; Cambridge University Press, Cambridge (UK) and NY (USA), 1535p
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012) : ImageNet Classification with Deep Convolutional Neural Networks, In proceedings of the 25th International Conference on Neural Information Processing Systems, **1**, 1097-1105
- 増本隆夫 (2012) : 気候変動と水田の水利用, *Journal of Rainwater Catchment Systems*, **17(2)**, 79-85
- 皆川裕樹, 増本隆夫, 工藤亮治 (2014) : 長短期降雨特性を備えた豪雨の内部波形の模擬発生法, 農業農村工学会論文集, **291**, 15-24
- 西原是良 (2013) : 農業水利システムの維持管理問題に関する経済分析, 博士論文, 東京大学
- 農林水産省農村振興局 (2018) : 土地改良施設管理基準及び運用・解説—用水機場編—, 194p
http://www.maff.go.jp/j/nousin/mizu/sutomane/pdf/h30wps_zentai.pdf (閲覧日 : 2018 年 9 月 30 日) .
- Rosenblatt, F. (1957) : The Perceptron — A perceiving and recognizing automaton, *Tech Report*, **85-460-1**, Cornell Aeronautical Laboratory, NY (USA)
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986) : Learning representations by back-propagating errors, *Nature*, **323** (6088), 533-536
- 佐山敬洋, 立川康人, 平田智行, 寶馨 (2007) : バイアス補正を行うカルマンフィルタを導入したリアルタイム分布型降雨流出予測, 第 20 回水文・水資源学会総会研究発表会,
https://www.jstage.jst.go.jp/article/jshwr/20/0/20_0_22/_pdf (閲覧日 : 2018 年 9 月 30 日)
- Schmidhuber, J. (2015) : Deep Learning in Neural Networks: An Overview, *Neural Networks*, **61**, 85-117
- 関基, 木村晃, 古山一志, 和田高宏, 金子祐, 穴水秀樹, 眞間修一 (2013) : 河川特性を反映したニューラルネットワーク洪水予測の精度向上, 河川技術論文集, **19** (報告)
- Simon, H. (1998) : Neural networks: a comprehensive foundation, 2nd eds., Prentice Hall, NJ (USA), 842p
- 巢籠悠輔 (2017) : 詳解 ディープラーニング —TensorFlow・Keras による時系列データ処理, マイナビ出版, 328p
- 山本忠男, 喜多丈典, 長澤徹明 (2010) : 農業水利施設の維持管理作業に対する参加促進要因の考察, 農村計画学会誌, **29(2)**, 101-106
- 吉村耕平, 田島芳満, 佐貫宏, 渋尾欣弘, 佐藤慎司, 小池俊雄 (2014) : 低平地都市河川におけるリアルタイム洪水シミュレーションモデルの開発, 土木学会論文集 B1 (水工学), **70(4)**, I_403-I_408

Prediction on Water Levels in a Wet Pond for a Drainage System Using an Artificial Neural Network Model

KIMURA Nobuaki*, NAKATA Toru**, AZECHI Issaku*, SEKIJIMA Kenji*, KIRI Hirohide*
and BABA Daichi***

* Coastal Hydraulics Engineering Unit, Division of Hydraulic Engineering

** The International Water Management Institute

***ARK Information Systems Co.

Abstract

Owing to global climate change, crop plantation-kind changes, and expensive costs on the operation for drainage-facilities in low-land crop fields, the managers for the drainage facilities (e.g., pump stations) have to consider efficient and flexible operations. Real-time numerical predictions on water level and flow at a monitoring point may contribute to the optimized operation of the drainage system for flood controls. Our study performed the development of a real-time prediction system on water level and discharge at a pumping station during heavy rainfall events using an artificial neural network (ANN) model. The system was applied to an actual paddy field, whose area is 179 ha, including a drainage pump that is connected to a river, and a pond that stabilizes water level. The rainfall events were provided by the Japan Meteorological Agency. The ANN model requires numerous data sets, usually observed in the field, but our observed data were insufficient. Instead, we extended the rainfall data by including the artificial two-year and ten-year probability rainfall events because of the creation of heavy rainfall-event data. We ran a runoff model to generate discharges and water levels based on the artificial rainfall. The input data for the ANN model consisted of rainfall, water levels, and discharges. The output consisted of water levels and discharges. After the ANN-model machine learning, the model provided reasonable predictions of water levels within 10% error against the runoff model results in 30 minutes and two hours using the k-fold cross validation. We performed a new test about shorter machine-learning data, in which the 10-year probability rainfall event was excluded. The ANN-model prediction was approximately 10% reduction at the maximum peak for two hours behind, compared with the original ANN-model prediction.

Key words: *Artificial neural network model, Runoff model, Drainage facility, Low land, Water level prediction*