

ニューラルネットワークおよび深層学習による 都市流出モデルのエミュレーション性能評価

藤塚慎太郎¹・河村明²・天口英雄³・高崎忠勝⁴

¹ 正会員 工修 東京都 建設局 江東治水事務所 (〒136-0071 東京都江東区亀戸 2-10-7)

E-mail:shintarou_fujizuka@member.metro.tokyo.jp

² 正会員 工博 首都大学東京教授 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)

E-mail:kawamura@tmu.ac.jp

³ 正会員 工博 首都大学東京助教 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)

E-mail:amaguchi@tmu.ac.jp

⁴ 正会員 工博 東京都 土木技術支援・人材育成センター (〒136-0075 東京都江東区新砂 1-9-15)

E-mail:takasaki@doboku.metro.tokyo.jp

近年、都市型水害が頻発しており、都市流出予測の精度向上が喫緊の課題である。都市の流出機構は複雑であり、簡易に精度が良い流出モデルを構築することは困難である。機械学習モデルは入力データと出力データがあれば、モデルのパラメータを自動的に調整してくれることから、簡易にモデルの構築が可能である。そこで本論文では、機械学習モデルによって都市流出モデルをどの程度エミュレーションできるか評価することを目的とし、仮想降雨およびそれを入力として得られる仮想流出量（著者らがすでに公開し真値が既知である）を対象に、従来のニューラルネットワークモデルおよび深層学習モデルを構築し、学習洪水および検証洪水における再現性を比較検証した。また、ハイパーパラメータを変更した場合のエミュレーション性能についても評価した。

Key Words: Artificial Neural Network, Deep Learning, Urban runoff, Emulation, Hyperparameter

1. はじめに

近年、都市型水害が喫緊の社会問題の一つとなっている。都市流域では雨水が浸透しにくい家屋やビル、舗装道路、駐車場などの不浸透域が多く存在するとともに、下水道や人工的排水路などの雨水排水施設による流出経路の存在や、貯留・浸透施設などの流出抑制施設や治水施設の存在により、非常に複雑な流出機構となっている¹⁾。また、都市域では降雨から流出までの時間が短く、事前に精度良く河川水位・流量を予測する手法の開発が重要であるが、流域ごとの複雑な流出機構を精度良くモデル化することは困難であり、簡易で精度が良い都市流出予測モデルの開発が望まれている。

また、他方では深層学習技術の向上にともない第三次 AI ブームと呼ばれるほど人工知能(AI)技術の発展がめざましく、土木分野においても様々な応用が進められている²⁾。人工知能技術の一部である機

械学習は入力データと出力データの関係から自動的にモデルのパラメータを調整(学習という)してくれることから、簡易にモデルの構築が可能である。洪水予測分野においては、過去の洪水事例の観測データをもとに、機械学習の代表的な手法の一つである人工ニューラルネットワーク(以下、ANN という)や深層学習(以下、DNN という)を用いて予測モデルの研究が試みられており^{3),4)}、流域ごとに異なるデータによりモデルが構築されている。しかし、一般に機械学習モデルの入力データセットが異なる場合、精度が入力データによるものかモデルによるものを切り分けることが困難であり、モデルの適切な精度評価ができない状況にある。

次に、洪水予測分野における機械学習モデルは、過去の洪水事例数が限られているという学習データの不足、降雨観測・水位流量観測の誤差という学習データに含まれる誤差の影響、未経験事象に対しての予測精度の低下といった課題がある。それらにつ

表-1 USF モデルパラメータ

パラメータ名	設定値
$k_1(\text{mm}^{1-p_1} \cdot \text{min}^{p_1})$	40
$k_2(\text{mm}^{1-p_2} \cdot \text{min}^{1+p_2})$	1000
$k_3(\text{mm}^{-1})$	0.02
$p_1(\text{無次元})$	0.4
$p_2(\text{無次元})$	0.2
$z(\text{mm})$	10
$\alpha(\text{無次元})$	0.5

いて、詳しく検討した研究はほとんど見受けられない。また、都市流域は上述のように複雑な流出機構を持っており、都市流域を対象とした機械学習モデルの検討も多くは行われていない。

そこで、簡易で精度の良い都市流出モデルの構築を最終目的とし、まず本論文では機械学習モデルによって既存の都市流出モデルをどの程度エミュレーションできるかを評価している。具体的には、高崎らが提案した USF(Urban Storage Function)モデル⁵⁾をエミュレーション対象モデルとし、都市流域の模擬降雨およびそれを USF モデルの入力とした場合の模擬流出量を、ANN および DNN モデルの入出力として与え、ハイパーパラメータを変更した場合のエミュレーション性能を評価する。なお、模擬データを真値として学習することにより、誤差を排除したモデル精度の評価が可能である。

2. エミュレーション対象モデルおよび用いた入出力データの概要

(1) エミュレーション対象モデル

エミュレーション対象の USF モデルは流出機構が複雑な都市中小河川の実時間洪水予測に適した集中型概念モデルである⁵⁾。総貯留高 s と流域からの流出量(河川流出量 Q と合流式下水道による流域外への雨水排水量 q_R の合計)との関係を式(1)に、連続式を式(2)に示す。また、式(1),(2)のうち、地下水関連損失量 q_l は式(3)で、合流式下水道による流域外への雨水排水量 q_R は式(4)で示される。

$$s = k_1(Q + q_R)^{p_1} + k_2(d/dt)(Q + q_R)^{p_2} \quad (1)$$

$$\frac{ds}{dt} = R + I - E - O - Q - q_R - q_l \quad (2)$$

$$q_l = \begin{cases} k_3(s - z) & (s \geq z) \\ 0 & (s < z) \end{cases} \quad (3)$$

$$q_R = \begin{cases} \alpha(Q + q_R - Q_0) & (\alpha(Q + q_R - Q_0) < q_{Rmax}) \\ q_{Rmax} & (\alpha(Q + q_R - Q_0) \geq q_{Rmax}) \end{cases} \quad (4)$$

ここに、 s : 総貯留高(mm), t : 時間(min), Q : 河川流出量(mm/min), q_R : 合流式下水道による流域外への雨水排水量(mm/min), q_{Rmax} : 最大雨水排水量(mm/min), q_l : 地下水関連損失量(mm/min), I : 都市特有の流入量・流域外からの地下水流入(mm/min), E : 蒸発散量(mm/min), O : 取水量(mm/min), Q_0 : 初期河川流出量(mm/min), z : 浸透孔高(mm), α : 下水道排出係数, k_1, k_2, k_3, p_1, p_2 : モデルパラメータ。

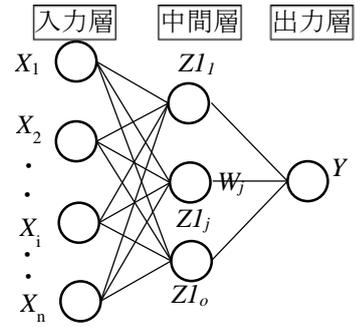


図-1 ANNモデル

USFモデルの7つのモデルパラメータ $k_1, k_2, k_3, p_1, p_2, z, \alpha$ については、Padiyedathら⁶⁾による神田川流域を対象としたUSFモデルの研究より表-1の値を設定した。

(2) 入出力データ

著者らはすでにANN・DNNモデルに入力するための流出モデルに与える模擬の入力降雨(バーチャルハイドログラフ(以下、VHとする))と、模擬の入力降雨をUSFモデルに与えた場合の流出量(バーチャルハイドログラフ(以下、VQとする))を作成し^{7), 8)}、公開している。VH・VQの概略を以下に述べるが、詳細については文献7), 8)を参照されたい。

VHは対象時間を24時間とし、ランダムカスケードモデルを用いて1分雨量の時間分布を発生させている⁷⁾。また、VQは降雨から流出までの時間を考慮し、対象時間を30時間とし、VH(24時間以降は無降雨としている)をUSFモデルに入力し、流出計算を実施した結果を用いている⁸⁾。

本論文では機械学習モデルの学習・テスト・検証データをMaierら⁹⁾より以下のように定義付ける。

- ・学習データ：ネットワークモデルの学習(重み係数やバイアスの調整)に用いるデータ群
- ・テストデータ：学習(重み係数やバイアスの調整)に用いないが、交差検証(Cross-validation: 過学習を防ぐため、目的関数の確認により、学習の停止を判断する)に用いるデータ群
- ・検証データ：学習や交差検証に用いず、構築したモデルにより精度を確認するためのデータ群

VH およびVQは100洪水作成し、80洪水はキャリブレーション(学習、テスト)データに用い、20洪水はバリデーション(検証)データとして使用することを想定し、作成されている。データの偏りをなくするため、VQのピーク流出高を基準に、20洪水毎に様々な規模の洪水が入るように並び替えを実施したものをVQ(1)~VQ(100)とし、それに対応したVHをVH(1)~VH(100)としている。なお、VQ(81)~VQ(100)を検証用洪水として使用することを想定している。

3. 適用したANNおよびDNNモデルの概要

(1) ANN モデル

本論文で用いたANNモデルの基本的な構造を図-

1に示す。文献10)他様々な文献で説明がされているが、ANNモデルでは入力層と中間層、出力層にノードが配置され各ノードで式(5),(6)の計算がされる。

$$\alpha = \sum_{i=1}^N W_i X_i + b \quad (5)$$

$$Y = h(\alpha) \quad (6)$$

ここに、 X : 入力値、 W : 重み係数、 b : バイアス、 α : 出力、 $h(\alpha)$: 活性化関数、 Y : 出力値

ANNは人間の神経系の動作を模したパーセプトロンの考え方を応用したものである。パーセプトロンは与えられた複数の入力層に対して重みやバイアスを与えて伝達し、入力値の合計がしきい値を超えた場合に、出力層に伝達される仕組みとなっている。パーセプトロンとANNとの違いは活性化関数で、パーセプトロンはステップ関数、ANNは式(7)に示すシグモイド関数などが用いられる。各ノードが結合され、ネットワークモデルを構築している。ANNモデルでは、重み係数とバイアスを最適化する手法として、学習データを用いて重み係数とバイアスを更新し、目的関数を最小化させるバックプロパゲーションがよく用いられている。

$$h(\alpha) = \frac{1}{1 + e^{-\alpha}} \quad (7)$$

(2) DNN モデル

本論文で用いたDNNモデルの構造は図-1のANNモデルの中間層が2層以上のものである。DNNモデルはパラメータ数が多いため過学習が生じやすいことや、計算負荷が大きいという課題があるが、近年のよりよい活性化関数の登場や計算機能力の向上により、第3次AIブームを支える主要な技術となっている。DNNモデルにおける活性化関数はHintonら¹¹⁾による式(8)に示すReLU関数(ランプ関数)を用いる。

$$h(\alpha) = \max(0, \alpha) \quad (8)$$

4. モデルの構築

(1) モデルの基本構造

入力層はVHの現時刻～(ノード数-1)分前の1分間降雨量(mm/min)として設定し、出力層のノードは1個でVQの現時刻流出高(mm/min)とした。すなわち現時刻以前の雨量から現時刻の流出量を算出する機械学習モデルである。出力層のノード数は1個で固定するが、入力層のノード数については変更した場合の感度を評価している。

(2) ハイパーパラメータ

ハイパーパラメータとは機械学習モデルの性能に影響を及ぼす調整可能なパラメータのことであり、上述の活性化関数もそのうちのひとつである。本論文では入力層のノード数、中間層のノード数、ドロップアウト率を変更し、比較を実施する。その他のハイパーパラメータは表-2に示すとおりに固定する。勾配降下法の各手法の詳細については表-2に示した参考文献を参照されたい。ハイパーパラメータの感

表-2 固定するハイパーパラメータの設定

項目	ANN	DNN
活性化関数	対数シグモイド関数	ReLU 関数
学習法	バッチ学習	ミニバッチ学習 (ミニバッチサイズ50)
勾配降下法	スケーリング共役勾配法逆伝播 ¹²⁾	Adam ¹³⁾

表-3 モデル学習・実行環境

項目	内容
CPU	Intel® Core i7 9700k
GPU	GeForce RTX 2080 Ti
メモリ	16GB
プログラミング言語	MATLAB
ソフトウェア	MATLAB R2019a (Deep Learning Toolbox)

度分析としては、文献10)で畳み込みニューラルネットワークを対象とした感度分析が行われている。また、DNNを用いた流出モデルのハイパーパラメータについては一言ら⁴⁾においてドロップアウト率や中間層のユニット数を同時に変更した場合の比較を実施しているが、本論文では変更するパラメータ以外は固定して評価を実施する。以下に本論文で変更するハイパーパラメータについて概説する。

入力層のノード数：(1)で述べたとおり入力層のノード数は、現時刻の流出高を表現するにあたり、現時刻以前の降雨データをどの程度前から入力するかということを表す。

中間層のノード数：中間層のノード数を最適に設定する方法は特に決まりが無いが、ノード数の増加に従いパラメータ数が多くなるため、モデルの自由度が上がるが、過学習が発生しやすくなる。

ドロップアウト：ドロップアウトは学習の際にドロップアウト率に従い、ノードを一時的に無効化し学習させることで、モデルの汎化性能を上げることができ、過学習が起これにくくなる¹⁴⁾。

(3) 計算機仕様

本論文で用いるANN・DNNモデルの学習および実行に用いる計算機の仕様は表-3に示すとおりである。学習は並列計算を実行せず、単一GPUで実行した。また、後述の検討ケースのうちパラメータが収束しづらいと考えられる最も複雑なケースで試算をした結果(図-2参照)、2,000エポック(1エポック=入力データを1通り学習に使用した)程度で概ね誤差の

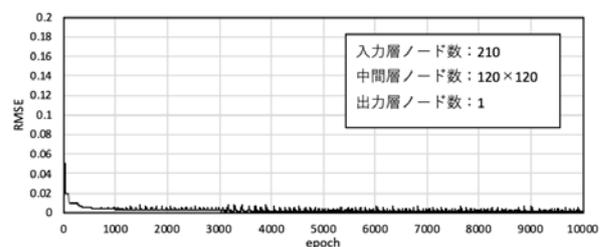


図-2 試算ケースにおける epoch と RMSE

表-4 ハイパーパラメータの検討ケース

項目	ANN	DNN
入力層 ノード数	30,60,90,120, 150,180,210	30,60,90,120, 150,180,210
中間層 総ノード数	10,20,30,60,90, 120,180,240	10,20,30,60,90, 120,180,240
ドロップ アウト率		0%,5%,10%,20%, 30%,40%,50%

低下が見られなくなっていたため10,000エポックで学習を停止させ、学習洪水の誤差が最も小さくなるエポックを最終モデルとして採用した。なお、本論文では交差検証¹⁵⁾による学習の停止は行わなかった。

(4) ハイパーパラメータの検討ケース

学習洪水は20洪水で固定とした。すなわち1分毎に入力層と出力層の関係が得られるため、36,000データ(20洪水×1,800分)で学習を行うこととなる。ハイパーパラメータの検討ケースを表-4に示す。表-4の赤字のケースを基準ケースとし、変更する条件以外は基準ケースのまま固定し、ANN・DNNモデルのそれぞれにおいて入力層のノード数、中間層のノード数を変更し、精度を比較評価した。なお、中間層のノード数については総ノード数を設定し、DNNモデルは中間層1および中間層2に半数ずつを割り振ることとした。また、DNNはドロップアウト率を変更したケースも実施した。

(5) 予測ハイドログラフ再現性の検証方法

学習したモデルに学習用と検証用の各20洪水の入力データを与え、モデルの出力結果とVQをRMSE(二乗平均平方根誤差)・Nash-Sutcliffe係数(以下、NS係数とする)により比較した。それぞれ式(9)、(10)で表される。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (q_{oi} - q_{ci})^2} \quad (9)$$

$$NS係数 = 1 - \frac{\sum_{i=1}^n \{q_{oi} - q_{ci}\}^2}{\sum_{i=1}^n \{q_{oi} - q_{oave}\}^2} \quad (10)$$

ここに、 n : サンプル数, q_o : VQの流出量(mm/min), q_c : ANN・DNNによる流出量(mm/min), q_{oave} : VQの平均値(mm/min)

5. 結果および考察

(1) 入力層ノード数の影響

図-3に、中間層のノード数を180に固定したまま、入力層のノード数を30~210まで変化させた場合の、ANNおよびDNNによる学習用20洪水および検証用20洪水に対するRMSE・NS係数の平均値を示す。図-3より以下のことがわかる。

- ・ANN, DNNともに検証用洪水(図中●●)より学習用洪水(図中○○)のRMSEが小さく、精度が良い。
- ・ANN, DNNともに入力層のノード数が30個の場合はRMSEが大幅に上昇し、精度が大きく低下した。

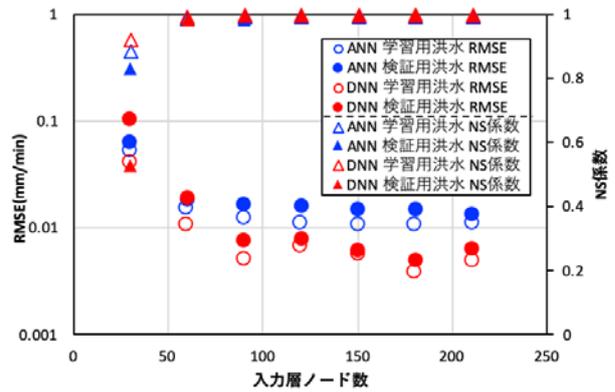


図-3 入力層のノード数と RMSE・NS 係数の関係

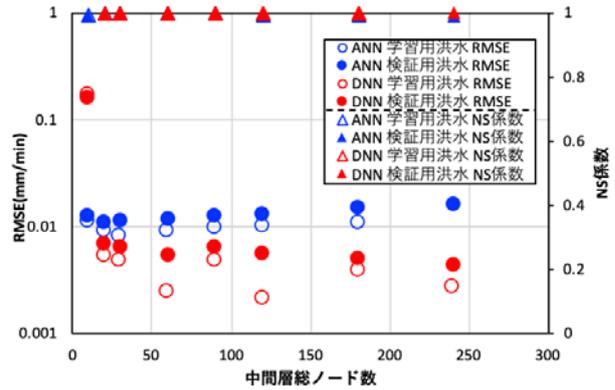


図-4 中間層の総ノード数と RMSE・NS 係数の関係

この場合DNNよりもANNの方が精度が良かった。
 ・DNNで入力層のノード数が90個以上の場合は、入力層ノード数をそれ以上増やしても大きくはRMSEが低下せず、精度はあまり変わらなかった。また、その場合はANN(図中青)よりもDNN(図中赤)の方がRMSEが小さく、精度が良好であった。
 ・NS係数はANNおよびDNNともに学習洪水(図中△△)と検証洪水(図中▲▲)において、入力層ノード数が60個以上の場合に、0.98以上であり、非常に精度が良かった。

以上より、NS係数の確認から本論文の条件では入力層のノード数が60個以上(現時刻~60分前程度以上の降雨を与えた場合)であれば、ANN・DNNともに、USFモデルをエミュレーション可能であった。また、RMSEの確認からDNNでは入力層のノード数が90個以上の場合に精度が大きく向上しなかったことより、現時刻流出高を表現するには現時刻~90分前程度以上の降雨を与えることで十分であると考えられる。そして、この場合DNNの方がANNよりRMSEが小さく、精度が良い結果であった。

(2) 中間層ノード数の影響

図-4に入力層のノード数を180に固定したまま、中間層のノード総数を10~240まで変化させた場合の、ANNおよびDNNによる学習用20洪水および検証用20洪水に対するRMSE・NS係数の平均値を示す。なおDNNモデルは中間層1および中間層2にノードを半数ずつを割り振る。図-4より以下のことがわかる。

- ・総ノード数が同じ場合、ANN(図中青)とDNN(図

中赤)を比較した結果、DNNの方がRMSEが小さく、精度が良かった。

- ・総ノード数が20個程度でもRMSEやNS係数が大きく変化せず、精度は同程度であった。
- ・DNNにおいて、総ノード数が10個の場合は学習洪水(○)よりも検証洪水(●)のRMSEが小さく、学習がうまく収束していないことがわかる。

(3) ドロップアウト率の影響

図-5にDNNモデルを対象として、学習洪水と検証洪水の誤差が乖離していたケースで、ドロップアウト率を変化させた場合の、学習用20洪水および検証用20洪水に対するRMSE・NS係数の平均値を示す。ドロップアウト率を増加させた場合に学習洪水・検証洪水の両方でRMSEが上昇し、精度が低下しているが、0%の場合と比較し、同じドロップアウト率

では誤差に差がなく汎用性が向上している。ただし、検証洪水の精度を基準とすると、精度が低下しない範囲でドロップアウトを設定することが望ましい。

(4) ハイドログラフによる比較

図-6に基準ケースによる ANN および DNN モデ

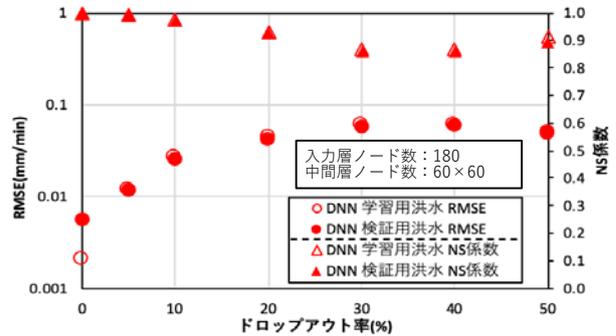


図-5 ドロップアウト率と RMSE・NS 係数の関係

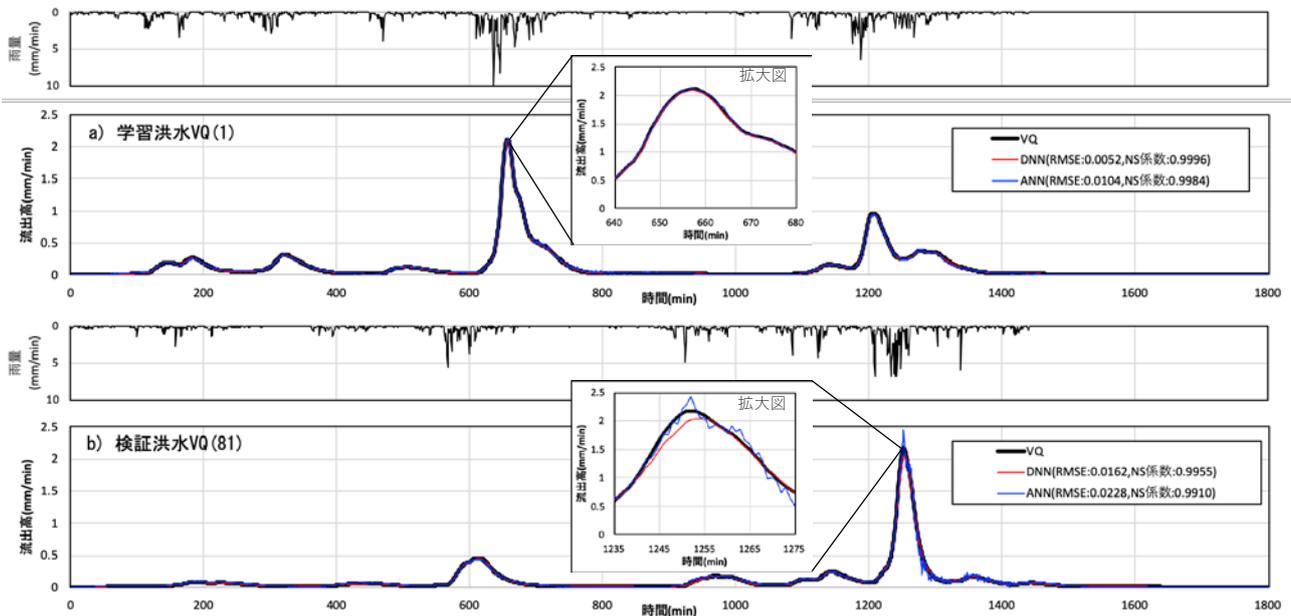


図-6 基準ケースによる ANN および DNN モデルの再現結果 a) 学習洪水 VQ(1), b) 検証洪水 VQ(81)

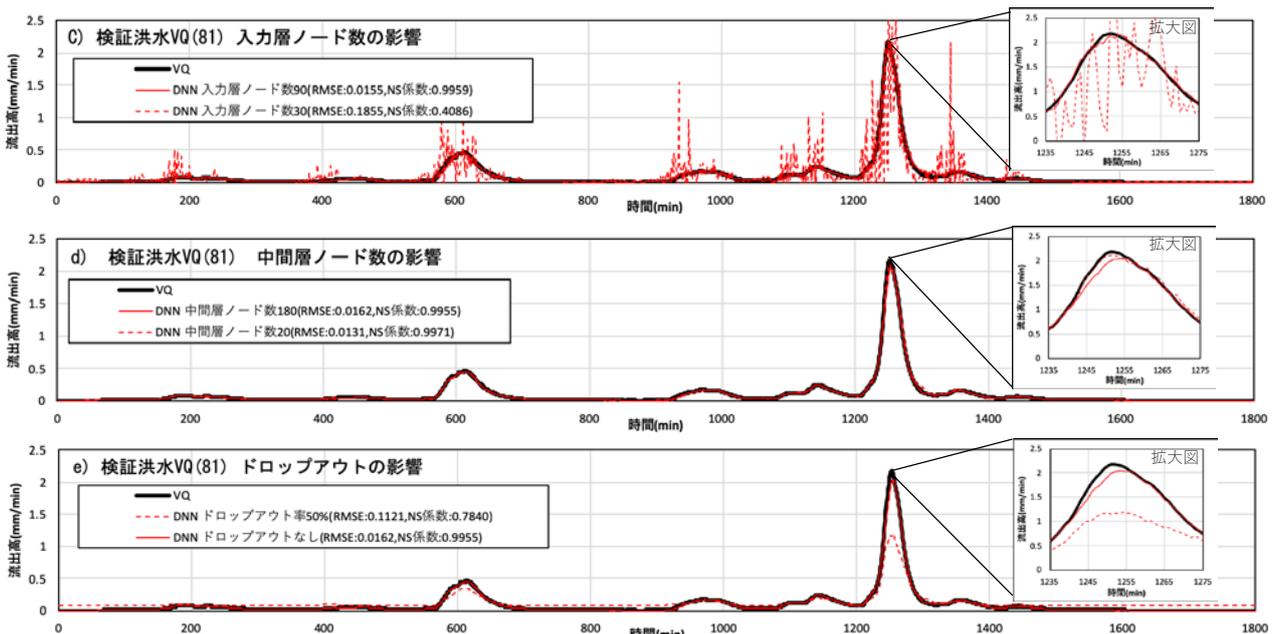


図-7 ハイパーパラメータを変更した場合の DNN モデルの再現結果 検証洪水 VQ(81)

ルの再現結果を示す。図-6 a)より、学習洪水に対しては ANN(青線)、DNN(赤線)ともにピーク値を含め、ハイドログラフを精度良く再現していることがわかる。一方図-6 b)より、ANN モデルの検証洪水ではピーク部分でノイズ形状が確認できる。

次に、図-7 にハイパーパラメータを変更した場合の検証洪水 VQ(81)の DNN モデルの再現結果を示す。各グラフの赤実線が基準ケースを、赤点線が変更後の波形を示している。図-7 c)より入力層のノード数が 30 個の場合はノイズ形状が見られ、また図-7 e)のドロップアウト率を 50%と設定した場合はピークを過小評価するなど、大きく精度が低下していることがわかる。図-7 d)の中間層のノード数を変更した場合は大きな精度の低下は見られない。

6. むすび

複雑な都市流域の流出量を簡易的に精度良く予測できるモデルを構築する手法の開発を最終目的として、本論文ではまず機械学習モデルによる流出モデルのエミュレーションの可能性を確認し、そしてそのエミュレーション性能を評価した。エミュレーション性能の確認のため、仮想降雨と仮想降雨を都市流出モデルに入力することにより作成した仮想流出量を用いて、ANN および DNN モデルを構築した。その結果、ANN・DNN とともに入力層のノード数が十分にあれば、流出モデルの波形と機械学習モデルの波形の NS 係数が 0.98 以上であり、機械学習モデルで都市流出モデルをエミュレーションすることが可能であった。また、中間層のノード総数が同じ場合、ANN よりも DNN の方が精度が良好であった。そして、DNN モデルにおいてはドロップアウトを実施しない方が検証洪水の精度が良い結果であった。今後は入力データに誤差を含ませた場合の再現精度について研究を実施していく予定である。

参考文献

- 1) 河村明:都市流域における洪水流出解析の現状と将来展望, 水文水資源学会誌, Vol.31, No.6, pp.219-234, 2018.
- 2) 深層学習は土木を変える? -AI 活用の可能性を探る-, 土木学会誌, Vol.103, No.2, pp.7-37, 2018.
- 3) 磯部勇, 大河戸輝夫, 羽生田英彦, 小田誠一, 後藤祐輔:

- ニューラルネットワークによる水位予測システムの開発, 水文・水資源学会誌, Vol.7, No.2, pp.90-97, 1994.
- 4) 一言正之, 桜庭雅明, 清雄一: 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 巻, 4 号, p. I_187-I_192, 2016.
 - 5) 高崎忠勝, 河村明, 天口英雄, 荒木千博: 都市の流出機構を考慮した新たな貯留関数モデルの提案, 土木学会論文集 B, Vol.65, No.3, pp.217-230, 2009.
 - 6) Padiyedath, S.G., Kawamura, A, Takasaki, T., Amaguchi, H. and Azhikodan, G., An effective storage function model for an urban watershed in terms of hydrograph reproducibility and Akaike information criterion., Journal of Hydrology, Vol.563, pp.657-668.,2018.
 - 7) 村井雅姿, 高崎忠勝, 河村明, 天口英雄: 東京都の中小河川を対象としたバーチャルハイエトグラフの作成, 第 46 回土木学会関東支部研究発表会講演集, CD-ROM 版(II-21), 2019. (VH・VQ 公開 URL: <http://www.comp.tmu.ac.jp/suimon/virtual/>)
 - 8) 藤塚慎太郎, 河村明, 天口英雄, 高崎忠勝 :AI を用いた都市流出モデルエミュレーションのためのベンチマーク模擬ハイドログラフの構築, 第 46 回土木学会関東支部研究発表会講演集, CD-ROM 版(II-20), 2019.
 - 9) Maier, H.R., Dandy, G.C.:Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, Environmental Modelling & Software, Vol.15, pp.101-124, 2000.
 - 10) 山下隆義:イラストで学ぶディープラーニング, 講談社, 2018.
 - 11) LeCun,Y., Bengio,Y., Hinton,G.E.: Deep learning, Nature, Vol.521, pp.436-444, 2015.
 - 12) Moller, M.F., : A scaled conjugate gradient algorithm for fast supervised learning, Neural networks, Vol. 6, pp. 525-533, 1993.
 - 13) Kingma, D.P., Ba, J.: Adam: A method for stochastic optimization, Proc.of the 3rd international conference for learning representations,2015.
 - 14) Srivastava,N., Hinton,G.E., Krizhevsky,A., Sutskever,I., Salakhutdinov,R.: Dropout: A simple way to prevent neural networks from overfitting, Journal of machine learning research, Vol.15, pp.1929-1958, 2014.
 - 15) Stone, M.,: Cross-validatory choice and assessment of statistical predictions, Journal of the royal statistical society B 36, pp. 111-147, 1974.

(Received May 31, 2019)

(Accepted August 7, 2019)

EMULATION PERFORMANCE EVALUATION OF URBAN RUNOFF MODEL BY NEURAL NETWORK AND DEEP LEARNING

Shintaro FUJIZUKA, Akira KAWAMURA, Hideo AMAGUCHI, and Tadakatsu TAKASAKI

In recent years, urban floods have frequently occurred, and improving the accuracy of urban runoff prediction is an urgent issue. Urban runoff process is complicated, and it is difficult to construct a runoff model with high accuracy. The machine learning model can adjust the model parameters automatically if there are input data and output data, so it is possible to construct the model easily. So, in this paper, we aim to evaluate how much the urban runoff model can be emulated by the machine learning model, and the virtual rainfall and the virtual runoff (with the known true value already published by the authors) obtained from it. The artificial neural network model and deep learning model were constructed for quantity, and the reproducibility in learning flood and verification flood was compared and verified. We also evaluated the emulation performance when changing hyper parameters.