

観測雑音付加バーチャルハイドログラフ を用いた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 (〒124-0023 東京都葛飾区東新小岩一丁目 14-11)

E-mail: shintarou.fujizuka@member.metro.tokyo.jp

2 正会員 工博 東京都立大学教授都市環境科学研究科 (〒192-0397 東京都八王子市南大沢一丁目 1)

E-mail: kawamura@tmu.ac.jp

3 正会員 工博 東京都立大学助教都市環境科学研究科 (〒192-0397 東京都八王子市南大沢一丁目 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 東京都江東区新砂一丁目 9-15)

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

地球温暖化に伴う気候変動により短時間強雨が増加しており、様々な分野へ応用が進められている深層学習モデルの洪水予測分野への適用に対する期待も大きい。そこで本論文では、観測データに観測雑音が存在する場合に、深層学習モデルで流出モデルをどの程度精度良くエミュレーションできるか確認するため、仮想降雨と性質が明らかな観測雑音を付加した仮想流出高を学習データとし、学習洪水数や中間層ノード数などを変化させた場合の深層学習モデルによる流出モデルのエミュレーション性能を評価した。1 洪水を対象に検討した結果、雑音成分にまで合わせるように学習し、また観測雑音を付加しない真値であるハイドログラフの特徴を掴むためには、学習洪水数を増やすことが効果的であることがわかった。

Key Words: deep learning, urban runoff, emulation, benchmark data, observation noise

1. はじめに

IPCC (気候変動に関する政府間パネル) の 5 次評価報告書¹⁾によると、温室効果ガスの排出が主な原因と考えられる地球の温暖化が進んでいることが報告されている。地球温暖化は気候変動を引き起こし、世界中の様々な地域で大雨の頻度・強度や降水量の増加など気候現象の極端化を引き起こしている。また、気象庁の報告²⁾でも、わが国において短時間強雨の増加傾向が明瞭に現れており、気候変動を踏まえた治水計画のあり方が模索されている。

短時間強雨の増加は、洪水のピーク流量の増加・到達時間の短時間化を招くことから、洪水災害リスクの増加につながる。特に都市域は家屋や舗装道路などの不浸透域が多く存在しており、降雨から流出までの時間が短いという特徴があるため、短時間強雨の増加によりさらにそのリスクが高まる。それに加え、都市域は資産・人口が集中しており、潜在的な災害リスクは非常に高い³⁾。

このような状況の中、水位・流量を事前に予測でき

る流出モデルの必要性は非常に高く、都市流域を対象とした様々な流出モデルの開発が進められている。しかし、都市流域は上述の不浸透域や下水道などの流出経路の存在から、流出機構が複雑であり、簡易に精度が良いモデルを構築することが困難な状況にある。

他方、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 (Artificial Intelligence: AI) 技術の発展がめざましく、様々な分野への応用が進められている⁴⁾。AI (特にディープラーニング) の画像認識の分野においては、ImageNet というデータセットが存在し、ImageNet Large Scale Visual Recognition Challenge (ILSVRC) というコンペティションが開かれ、共通のデータによるモデルの構築・精度評価が行われ、機械学習モデルが発展してきた経緯がある⁵⁾。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用いて、ニューラルネットワークやディープラーニングを用いた予測モデルの研究が国内外で試みられており^{6)~8)}、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が異なる場合、予測モデルの再

現結果の精度の低下要因が入力データによるものかモデルによるものか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。

そこで著者らは都市中小河川流域を対象とした模擬の仮想降雨（バーチャルハイトグラフ（以下、VHとする。））と、VHを流出モデルに入力することで得られる仮想流出高（バーチャルハイドログラフ（以下、VQとする。））を深層学習モデルの入出力データとして構築し、公開した⁹⁾。このような仮想データを真値として学習することにより、不確実性を排除したモデルの構築を行うことができ、モデルのそのものの性能について評価することができる。そして、それらを用いて簡易な構造の深層学習モデルを構築し、深層学習による都市貯留関数モデルのエミュレーション（流出モデルの入力データを深層学習に与え、流出モデルの出力結果を再現する）を試みた⁹⁾。すなわち、対象とする流出モデルを用いずに深層学習モデルで同等の出力を得られるかを検証し、流出モデルに取って替わることができるかを評価した。また、VH・VQを用いて従来のニューラルネットワークを用いた場合のエミュレーション性能も評価している¹⁰⁾。

しかしながら、上述の検討は学習データに不確実性を伴わない真値を対象とした簡易な深層学習モデルでの検討である。現実の観測データには必ず観測雑音が含まれるため、観測雑音があるデータを学習データとした場合に、学習洪水において観測雑音にまで合わせるように学習するのか、検証洪水におけるハイドログラフの再現精度はどの程度なのかなどの深層学習モデルによる流出モデルのエミュレーション性能評価を実施した研究は見受けられない。例えば、観測雑音の影響を評価するために特性が明らかな観測雑音を学習データに付加し、深層学習モデルパラメータ数を増減させた場合（入力層ノード数・中間層ノード数を変化させた場合）、学習洪水数・ドロップアウト率などのハイパーパラメータ（機械学習のパラメータのうち、人間が手動で調整する必要があるもの）の値を変化させた場合の影響について、深層学習モデルのエミュレーション性能評価を行う必要がある。

そこで本論文では、VQに正規性の観測雑音を付加したバーチャルハイドログラフ（以下、VQNと呼ぶ）を新たに作成し、VHおよびVQNを学習データとする深層学習モデルを構築する。そして、上述の深層学習モデルパラメータ数やハイパーパラメータを変化させ、どのような場合に雑音成分にまで合わせる（すなわち真値であるVQに対しては過学習（学習データに合わせすぎたために、検証データでは逆に精度が劣る状態）に至る）ように学習するのかなどの深層学習モデルのエミュレーション性能評価を行う。

表-1 USFモデルパラメータ

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

2. エミュレーション対象モデルおよび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都市貯留関数モデル（Urban Storage Function Model（以下、USFモデルと呼ぶ））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¹¹⁾。総貯留高 s と流域からの流出高（河川流出高 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)、式(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。

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

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

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

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

ここに、 s ：総貯留高(mm)、 t ：時間(min)、 Q ：河川流出高(mm/min)、 q_R ：合流式下水道による流域外への雨水排水高(mm/min)、 q_{Rmax} ：最大雨水排水高(mm/min)、 q_l ：地下水関連損失高(mm/min)、 I ：都市特有の流入高・流域外からの地下水流入高(mm/min)、 E ：蒸発散高(mm/min)、 O ：取水高(mm/min)、 Q_0 ：初期河川流出高(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 ：USFモデルパラメータである。

7つのUSFモデルパラメータ k_1 、 k_2 、 k_3 、 p_1 、 p_2 、 z については、Padiyedathら¹²⁾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

著者らはすでに深層学習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(VH)と、模擬の入力降雨をUSFモデルに与えた場合の流出高(VQ)を作成し、公開しているが、それらの詳細については文献13)、14)を参照されたい。以下にVH・VQの概略を述べる。VHは




図-1 観測雑音の有無によるハイエト・ハイドログラフ(VQ(1), VQN(1))

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。また、VQ は降雨から流出までの時間を考慮し、対象時間を 27 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。

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¹⁵⁾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、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(1)~VQ(60) を学習、VQ(61)~VQ(80) をテスト、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) 観測雑音を付加したハイドログラフの作成

誤差には系統誤差によるものと偶然誤差によるものが存在する。系統誤差は偶然によらない一定の傾向を持った誤差であり、偶然誤差は偶然による誤差で、一定の傾向を持たない。系統誤差は偶然誤差と比較し、傾向が明らかであれば取り除くことは可能であるが、偶然誤差は上振れするのか下振れするのかなどの傾向がなく、この誤差を取り除くことは困難である。観測雑音は系統的ではなく偶然誤差に分類される。洪水予測分野を例に挙げると、風などが原因で水位が揺動することによる観測時の誤差などが考えられる。そのため、本検討では取り除くことが困難な偶然誤差である観測雑音を対象にこれらが深層学習モデルの精度に与える影響などについて検討を実施した。本論文では VQ に $N(0, s^2)$ の正規乱数を観測

入力層 中間層1 中間層2 出力層




図-2 採用した深層学習モデルのモデル構造

雑音として加え、VQN とし、深層学習モデルの学習データのうち出力ノード層に VQN を与え、VH から VQN に最適化するように学習させる。ここで、標準偏差 s の値として、VQ のうち最もピーク流出高が大きい VQ(1) のハイドログラフより目視で $s=0.01\text{mm/min}$ を設定した。これは、VQ(1) の最大流出高の 0.5% に相当する。なお、正規乱数を付加した場合に負になる場合は 0 とした。図-1 には参考として VQ と VQN のハイドログラフの比較を示している。

3. 深層学習モデルの構築

(1) 採用した深層学習モデル

本論文で用いる深層学習モデルとしては、図-2 に示すその構造が最も単純な中間層が 2 層の深層学習をまずは用いてエミュレーション性能を評価することとした。深層学習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。モデルの設定および固定するハイパーパラメータを表-2 に示す。学習洪水数は VQN(1) からの洪水数を示し、例えば学習洪水数が 1 の場合は VQN(1) のみを、学習洪水数が 60 の場合は VQN(1)~VQN(60) までの 60 洪水を学習データとして採用することになる。入力層のノード数

表-2 モデル構造および固定するハイパーパラメータ

項目	内容
学習洪水	VQN(1)~VQN(学習洪水数)
入力層	現時刻~(入力層ノード数-1)分前の1分間降雨量(mm/min)
中間層	2層 ノード数を半分ずつに分割
出力層	現時刻流出高(mm/min)
活性化関数	ReLU関数
ミニバッチサイズ	60
最適化手法	Adam




図-3 エポック数とRMSEの関係

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 VQN 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高を算出する深層学習モデルである。中間層は中間層ノード数を中間層1と中間層2に半分ずつ分割することとした。その他のハイパーパラメータは表-2に示すとおりである。

各ノードには式(5)に示す重み係数とバイアスの2種類のパラメータ(以後、深層学習モデルパラメータと呼ぶ)が存在し、学習によりパラメータが更新され、精度が向上していく。次に、式(5)の出力は式(6)に示す活性化関数により出力値に変換される。活性化関数としては、LeCunら¹⁶⁾による式(7)のランプ関数(Rectified Linear Unit: ReLU)を用いる。

$$\alpha = \sum_{j=1}^N W_j X_j + b \quad (5)$$

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

$$h(\alpha) = \max(0, \alpha) \quad (7)$$

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

また、一般に中間層の層数が L の深層学習モデルパラメータ数は次式で表される。

$$N_p = (N_\alpha + 1)N_1 + \sum_{j=1}^{L-1} (N_j + 1)N_{j+1} + (N_L + 1)N_\omega \quad (8)$$

ここに、 N_p : 深層学習モデルパラメータ数、 N_α : 入力層ノード数、 N_j : 中間層 j のノード数、 N_ω : 出力層ノ

表-3 検討ケース

検討ケース	設定	ケース数
学習洪水数変更	1,10,20,40,60	5
入力層ノード数 & 中間層総ノード数	30,60,90,120,150,180,210 10,20,30,60,90,120,180,240	56 (7×8)
ドロップアウト率	0,5,10,20,30,40,50	6

表-4 計算機仕様

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	python
ライブラリ	TensorFlow(keras)

ード数、 L : 中間層の層数である。

(2) 検討ケース

本検討では表-3に示すようにハイパーパラメータのうち、①入力層ノード数と中間層ノード数、②ドロップアウト率、③学習洪水数を変更し、VQNを学習データとした場合のエミュレーション性能を評価した。なお、ドロップアウトとは学習の際に一部の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、過学習が起こりにくくなる手法であり、ドロップアウト率は無効化させる割合のことである。変更するパラメータ以外は下線のパラメータ(標準ケース)に固定し、入力層ノード数と中間層ノード数は組み合わせにより表-3に示す56ケースを実施することとした。

(3) 計算条件

深層学習モデルのハイドログラフの再現精度は次式に示す二乗平均平方根誤差(Root Mean Square Error:RMSE)により評価した。

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

ここに、 n : サンプル数、 q_o : VQN(もしくはVQ)の流出高(mm/min)、 q_c : 深層学習モデルによる河川流出高(mm/min)である。

本論文で用いる深層学習モデルの学習および実行に用いる計算機の仕様は表-4に示すとおりである。計算はGPUを利用して10,000エポック(1エポックは全入力データを一通り学習に使用すること)まで計算を実施し、図-3に示すようなエポック数とRMSEの関係を基に、テスト用洪水のRMSEが最小となるエポックのモデルを最終モデルとした。また、参考までに学習洪水でRMSEが最小となるエポックのモデルも保存し、その精度を確認




図-4 学習結果 VQN(1) (学習洪水数 : 1, 入力層ノード数 : 90, 中間層ノード数 : 90, ドロップアウト率 : 0%)




図-5 検証結果 VQN(81) (学習洪水数 : 1, 入力層ノード数 : 90, 中間層ノード数 : 90, ドロップアウト率 : 0%)

した。学習したモデルによるハイドログラフの VQN に対する再現精度の確認は、学習用と検証用の入力データを深層学習モデルに与え、それぞれの出力ハイドログラフの結果を VQN と比較し、RMSE を算出した。さらに、これらの出力結果を真値のハイドログラフである VQ と比較し、RMSE を算出した。VQ との比較は、雑音を付加したデータで学習した深層学習モデルが真のハイドログラフである VQ をどの程度精度良く再現できているか確認するために実施している。

4. 結果および考察

(1) 入力層・中間層ノード数変更ケース

a) ノード数と RMSE の関係

検討ケースのうち、標準ケース (学習洪水数 1, 入力層ノード数 90・中間層ノード数 90・ドロップアウト率 0%) のハイドログラフによる比較のうち、学習洪水すなわち VQN(1) に対する結果を図-4 に、検証洪水すなわち VQN(81) に対する結果を図-5 に示す。標準ケースの学習結果 (図-4) では誤差成分も含め非常に精度良く VQN を再現できており、検証結果 (図-5) では誤差成分は再現できていないものの大まかなハイドログラフの傾向は再現できていることがわかる。

次に図-6 に、中間層ノード数を表-3 に示すように 10~210 までの 8 ケース変化させた場合のハイドログラフの再現精度の比較を示す。なお、同じ中間層ノード数の




図-6 中間層ノード数の変更による再現精度の比較

場合は、入力層ノード数が表-3 に示すように 30~210 の 7 ケースあるが、7 ケースで算出した RMSE を平均化して示している。学習結果 (図中、○●) において中間層ノード数が 30 以下と少ない場合にハイドログラフの再現精度の低下が見られ、60 以上の場合は RMSE の大きな低下は見られなかった。これより、1 洪水学習した場合について、中間層ノード数は小さすぎると精度の低下を招くものの、ある程度 (今回の場合は 60) 以上であればハイドログラフの再現精度が保たれることがわかった。なお、ハイドログラフの再現精度が保たれる中間層ノード数は後述のパラメータ数とも関係する。

次に、入力層ノード数の影響を確認する。図-7 に上

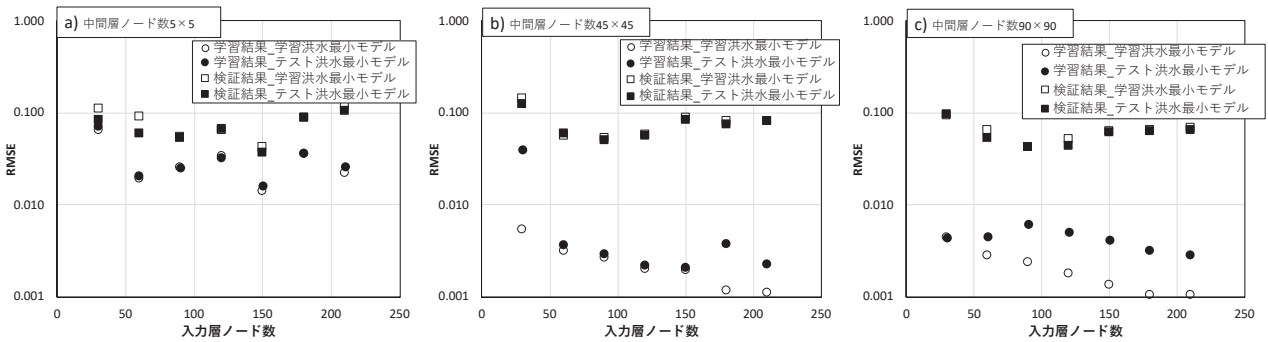


図-7 中間層ノード数 10,90,180 の場合の入力層ノード数の変更による再現精度の比較

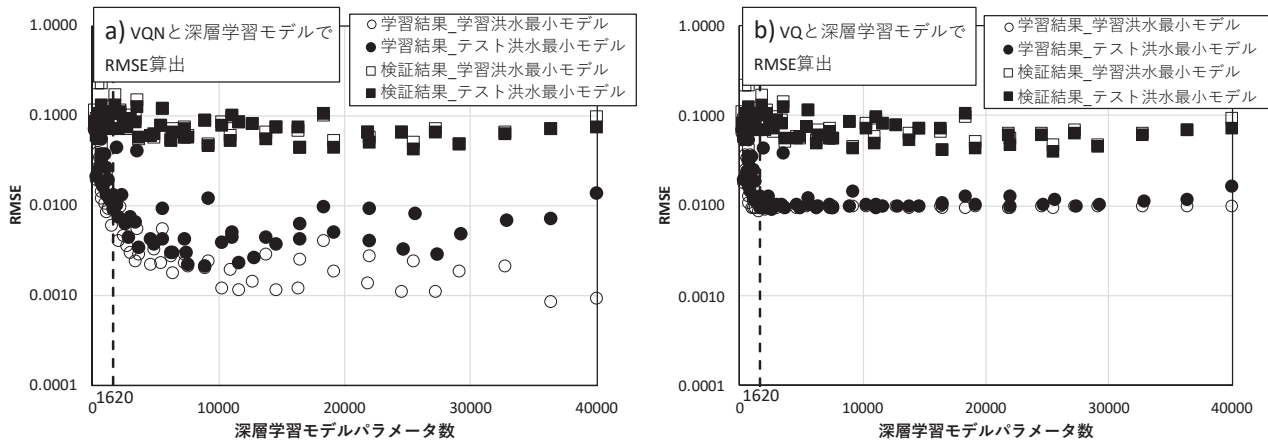


図-8 入力層ノード数・中間層ノード数の変更によるハイドログラフの再現精度

述の中間層ノード数・入力層ノード数の変更ケースのうち、中間層ノード数 10(図-7 a)、90(図-7 b)、180(図-7 c)の場合を示す。図-7 b) に示すように、学習洪水最小モデルによる学習結果(図中、○)では入力層ノード数が多くなるに従い RMSE が小さくなるものの、テスト洪水最小モデルによる学習結果(図中、●)では入力層ノード数がある程度(150)以上になると RMSE の低下が見られない。また、図-7 b) の検証結果(図中、□■)を確認すると、入力層ノード数が極端に少ない 30 の場合は RMSE が 0.1 以上と大きくなっており、そして、入力層ノード数が 90 の場合に RMSE が一番小さくなっている。つまり、今回の学習データの条件下では深層学習モデルにおいては約 90 分前までの降雨で予測するモデルがハイドログラフの再現精度が最も高い結果となった。これは、図-7 c) の場合のように、図-7 a) の極端に中間層ノード数が少ない場合を除き、同様の結果となった。この結果は同じデータに対し、ランダムフォレスト法を用い、流出高に対する入力降雨の寄与度が 90 分前までが高いとした結果と一致している¹⁷⁾。

b) 深層学習モデルパラメータ数と RMSE の関係

図-8 は、表-3 に示した入力層・中間層ノード数を変更した全 56 ケースのハイドログラフの再現性の結果について、深層学習モデルパラメータ数(式(8)で算出)と RMSE の関係を示したものである。図-8 a) に観測雑

音を付加したハイドログラフ VQN に対する RMSE を、図-8 b) には真値のハイドログラフ VQ に対する RMSE を示す。図-8 a) より、学習結果(図中、○●)は、深層学習モデルパラメータ数がおおよそ 1,000 を下回ると RMSE が急激に大きくなっている。一方、パラメータ数が観測データ数であるおおよそ 1,620 以上になると RMSE が 0.01 以下の過学習となっており、その値は概ね 0.01~0.001 の間に位置している。また、検証結果(図中、□■)では概ね学習洪水における再現結果と同様にパラメータ数が少ない場合は RMSE が大きく、パラメータ数がある程度(1,620)以上になると RMSE に明確な変化が見られなかった。

次に、図-8 b) より、検証結果(図中、□■)は図-8 a) と同様の傾向となっているが、学習結果(図中、○●)は、パラメータ数が観測データ数であるおおよそ 1,620 以上になると RMSE が 0.01 程度に集中していることがわかる。RMSE が 0.01 付近に集中していることは、図-8 a) に示されるように、深層学習モデルにより過学習となり、雑音を付加した VQN を精度良く再現したため、真値である VQ に対しては観測雑音の標準偏差 0.01 程度の RMSE となっていることを示している。当初著者らは、テスト洪水最小モデルでは深層学習モデルが VQN の真値である VQ の特徴をつかみ学習すること、すなわち深層学習モデルにより VQN の雑音を取り除いた滑らかな




図-9 ドロップアウト率の変更によるハイドログラフの再現精度




図-10 学習洪水数の変更によるハイドログラフの再現精度

VQに近いハイドログラフが再現されることを期待した。しかし、1洪水の学習ではほとんどのケースで学習結果のRMSEが観測雑音の標準偏差である0.01程度に集中した結果より、VQNの学習によりそのようなモデルを構築することは困難であることがわかった。そして、深層学習モデルパラメータ数が観測データ数以下となった場合、ハイドログラフの再現精度の低下を招くことが示唆される。深層学習はモデルパラメータ数の方がデータ数よりも圧倒的に複雑な構造である場合が一般的であるが、今回は単純な構造の深層学習モデルであるため、パラメータ数がデータ数よりも少ないところまで検討している。その場合、学習の過程においてはモデルパラメータ数の方がデータ数よりも少ない場合にハイドログラフの再現精度が下がることがわかった。一方、検証結果も同様に観測データ数以上パラメータ数があればハイドログラフの再現精度の結果には差がないことがわかった。

(2) ドロップアウト率変更ケース

図-9 にドロップアウト率を変更した場合のハイドログラフの再現精度の比較結果を示す。図-9 は図-8 同様、それぞれVQN(図-9 a)・VQ (図-9 b)) に対する結果を示す。図-9 a) より、学習結果 (図中、●○) では、ド

ロップアウト率を大きくするに従いRMSEが大きくなっているものの、検証結果 (図中、■□) に対してはハイドログラフの再現精度とドロップアウト率の関係に明確な傾向が見られなかった。ドロップアウトは過学習が発生している際に用いられる手法であり、過学習が生じにくくなる効果があるが、今回検討したモデルでは、ドロップアウトを設定することにより、検証洪水のハイドログラフの再現精度の向上は見られなかった。これは、学習データ数や深層学習モデルパラメータ数がそれほど多くなく、それほど複雑な深層学習モデルでないことが原因であると考えられる。また、図-9 b) については、上述までの検討と同様に、学習結果のRMSEが一番小さいドロップアウト率を0にした場合でも、RMSEが0.01になる結果となっていた。

(3) 学習洪水数変更ケース

図-10 に学習洪水数を変更した場合のRMSEの比較結果を示す。図-10 a) は深層学習モデルの出力結果とVQNで算出したRMSEを、図-10 b) は深層学習モデルの出力結果とVQで算出したRMSEを示している。それぞれのグラフの丸印 (中黒, 中抜きに関わらず) は学習洪水に対するRMSEを示し、同様に四角印は検証洪水に




図-11 検証結果 VQN(81) (学習洪水数：60, 入力層ノード数：90, 中間層ノード数：90, ドロップアウト率：0%)

対する RMSE を示している。学習洪水の RMSE は学習した洪水すべての平均 RMSE であり、検証洪水の RMSE は検証洪水のうちピーク流出高が一番大きい VQN(81) に対する RMSE である。また、中黒塗り印 (学習・検証に関わらず) はテスト洪水最小モデルすなわちテスト洪水のうちピーク流出高が一番大きい VQN(61) に対する RMSE が最小となった深層学習モデルを用いた再現結果である。そして、同様に中抜き印は学習洪水最小モデルすなわち学習洪水の平均 RMSE が最小となった深層学習モデルを用いた再現結果である。

図-10 a) において、学習結果 (図中, ○●) は、学習洪水数の減少に従い RMSE が小さくなり、学習洪水数が 1 では RMSE は 0.01 を下回っている。この場合、観測雑音の標準偏差は 0.01 であるので、VQ を真値と考えると学習洪水において RMSE が 0.01 を下回る場合は、観測雑音にまで合わせるように学習した過学習の状態であると考えられる。逆に、検証結果 (図中, □■) では学習洪水数の減少に従い、RMSE は大きくなっており、かつすべての場合で RMSE は 0.01 より大きくなっている。すなわち検証洪水におけるハイドログラフの再現精度を向上させるためには学習洪水数を増やすことが良いことがわかる。次に、図-10 b) において学習洪水の再現結果 (図中, ○●) はすべてのケースで RMSE がほぼ 0.01 となっており、一方、検証結果 (図中, □■) はほぼ図-10 a) と同様の傾向となっている。ここで、VQN を完全に再現できた場合の真値 VQ に対する RMSE は 0.01 となるので、本結果は深層学習モデルが学習洪水の観測雑音にまで合わせていることを示唆している。また、図-10 a), b) の両者においては学習洪水数が 40 洪水以上であれば、学習洪水と検証洪水の RMSE が同程度となり汎用性が高いモデルとなっていることがわかる。

最後に VQN を学習データとして、60 洪水学習した場合の検証洪水 VQN(81) に対するハイドログラフの再現結果を図-11 に示す。1 洪水で学習した図-5 と比較し、観測誤差の影響が少ない滑らかな真値である VQ (図-1 参照) に近い波形となっている。入力層ノード数や中間層

ノード数、ドロップアウト率を変更し検討を実施したが、このことから、観測誤差を含むデータを学習する場合に真値である VQ の特徴を精度良く掴むには、学習洪水数を増やすこと、すなわちデータの多様性 (質) が重要であることがわかった。

5.むすび

本論文では、標準偏差が既知の観測雑音を付加したバーチャルハイドログラフを用いて、深層学習モデルにより都市流出モデルのエミュレーションを実施し、そのエミュレーション性能を評価した。学習洪水数、入力層ノード数、中間層ノード数、ドロップアウト率などのハイパーパラメータを変更した場合のハイドログラフの再現精度の確認より以下のことがわかった。

- ・1 洪水と学習洪水が少ない場合は、観測誤差にまで合わせるように学習が行われ、真値である VQ の特徴を掴むような学習は困難であった。
- ・学習洪水数を多くすることにより、検証洪水におけるハイドログラフの再現精度が向上し、学習洪水と検証洪水の再現精度が同程度となる。VQ の特徴を掴む学習すなわち未経験の洪水について精度が良好なモデルの構築のためには洪水数の増加による学習データの多様性が重要であることがわかった。
- ・1 洪水と学習洪水が少ない場合は、深層学習モデルパラメータ数が学習データ数以下になると、ハイドログラフの再現精度が学習及び検証において急激に低下した。
- ・今回の深層学習モデルの学習データ数や深層学習モデルパラメータ数の条件下では、ドロップアウトを設けてもハイドログラフの再現精度は向上しなかった。
- ・入力層ノード数は多めに設定すればよいわけではなく、流出機構に相関性が高い時間的範囲の降雨データを入力ノード数を設定することにより、検証洪水におけるハイドログラフの再現精度が向上する。

今後は今回の検討結果を活用し、実流域に深層学習モデルを適用し、その性能評価を実施する予定である。

参考文献

- 1) IPCC:IPCC Fifth Assessment Report AR5,2014.
- 2) 気象庁:気候変動監視レポート 2018,2019.
- 3) 河村明:都市水害とその対策, 都市の技術 (改訂版), 技報堂出版,pp.235-249,2016.
- 4) 土木学会誌編集担当委員: 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.
- 5) 山下隆義: イラストで学ぶディープラーニング, 講談社,2018.
- 6) 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.
- 7) 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), Vol.72, No.4, p.1187-1192, 2016.
- 8) Kratzer, F., Klotz, D., Brenner, C., Schulz, K., Hameger, M.: Rainfall-runoff modelling using long-short-term-memory(LSTM) networks, Hydrol. Earth Syst. Sci., 22, 6005–6022, 2018.
- 9) 藤塚慎太郎, 河村明, 天口英雄, 高崎忠勝: ベンチマークバーチャルハイエト・ハイドログラフを用いた深層学習による都市流出モデルのエミュレーション, 土木学会論文集 G (環境), Vol.75, No.5, pp.1289-1296, 2019.
- 10) 藤塚慎太郎, 河村明, 天口英雄, 高崎忠勝: 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, 土木学会論文集 B1 (水工学), Vol.75, No.2, pp.1229-1234, 2019.
- 11) 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.
- 12) 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.
- 13) 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.
- 14) 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.
- 15) 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.
- 16) LeCun, Y., Bengio, Y., Hinton, G.E.: Deep learning, Nature, Vol.521, pp.436-444, 2015.
- 17) 竹内泰裕, 高崎忠勝, 河村明, 天口英雄: ランダムフォレスト法によるバーチャルハイドログラフ再現性に関する一考察, 第46回土木学会関東支部研究発表会講演集, CD-ROM版(II-12), 2019.

(Received April 13, 2020)

(Accepted July 8, 2020)

EMULATION EVALUATION OF URBAN RUNOFF MODEL BY DEEP LEARNING FOR THE VIRTUAL HYDROGRAPH WITH OBSERVATION NOISE

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

Due to climate change associated with global warming, short-term heavy rainfall is increasing, and there are great expectations for the application of deep learning models to flood forecasting, which are being applied to various fields. Therefore, in this paper, it was decided to confirm how accurately the runoff model could be emulated by the deep learning model when the observation data contained observation noise. Virtual rainfall was used as input data, and virtual runoff height including observation noise with clear characteristics was used as teacher data. As the learning data, we evaluated the emulation performance of the runoff model by the deep learning model when the number of learning floods and the number of nodes in the hidden layer were changed. When the number of learning floods is small, we learned to match the noise component. Moreover, it was found that increasing the number of learning floods is effective to grasp the characteristics of the hydrograph, which is the true value without observation noise.