

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

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。そこで本論文では、著者らが開発した都市流出モデルを、深層学習モデルによってエミュレーションできるか確認することを目的とし、まずその入力データとなる仮想降雨（バーチャルハイエトグラフ）および都市流出モデルを用いた流出量（バーチャルハイドログラフ）を構築した。そして、作成したバーチャルハイエトグラフおよびバーチャルハイドログラフを用いて、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検証した。また、入力データとして使用できる洪水の観測データは限られているため、学習洪水数を減らした場合の再現特性について検討した。

Key Words : AI, Deep Learning, urban runoff, emulation, benchmark data

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、駐車場などの不透水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⁾⁴⁾。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課題となっている。

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、様々な分野への応用が進められている⁵⁾。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(イメージネット)というデータセットが存在し、ILSVRC(ImageNet Large Scale Visual Recognition Challenge)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⁶⁾。

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⁷⁾⁹⁾、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観測誤差を持った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。

そこで、本論文では誤差のない真値の明らかな入出力データを構築し、その入出力データを用いて深層学習モデルにより流出モデルのエミュレーションが可能か、完全再現が可能か確認した。具体的には誤差のない真値の明らかな入力データとして流出モデルに与える模擬の入力降雨(バーチャルハイトグラフ(以下、VHとする))を用い、出力データとして模擬の入力降雨を著者らが開発した都市貯留関数(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))を用いた。模擬の入出力データを用いることにより観測誤差に起因する誤差を排除することが可能であり、また模擬データを活用することにより、学習洪水数などの増加・減少が容易であることから、エミュレーションに必要な洪水数の検討も実施した。このような模擬データによる深層学習モデルを用いた流出モデルのエミュレーションの研究は、著者が知る限り国内外ではじめての試みである。また、今回作成したデータは、ImageNetのように洪水予測分野における機械学習を用いた流出予測モデルの他の研究に活用されることが望ましい。

2. VHの構築

(1) 対象流域

対象流域は流出機構が複雑な東京都の中小河川を対象とする。都市部の中小河川流域では市街化が進んでおり、合流式下水道による流域外への雨水排水などの特有の流出機構を有しているため、流出モデルで流出特性を再現するにはそれらの機構を適切にモデル化する必要がある。

(2) ランダムカスケードモデルの概要

本論文ではVHを構築するための降雨の時間分布を発生させるモデルとして、ランダムカスケードモデル(以下、RCMとする)を用いた¹⁰⁾。RCMは降雨波形の自己相似性に着目したモデルであり、Olssonにより、RCMを用いた1分雨量の実用性が確認されている¹¹⁾。

RCMは図-1に示すように設定期間 L に設定雨量 R を割り当て、期間を b 分割して雨量を割り当てていくモデルである。本論文では $L=1,440$ 分(=24時間)、 $b=2$ とした。2分割した雨量をさらに2分割し、分割を合計11回繰り返すことにより0.703分ごとの雨量を作成した。さらにそれを703で割ることにより0.001分ごとの雨量にし、これを1,000個累積することにより、1分間雨量を作成した。1分間雨量は小数点2桁で四捨五入し、0.1mm単位で作成した。ある設定雨量 R を次の2つの雨量に割り当てる時に、前半に割り当てる割合を x_1 、後半に割り当てる割合を x_2 とすると式(1)が成り立つ。

$$x_1 + x_2 = 1 \quad (1)$$

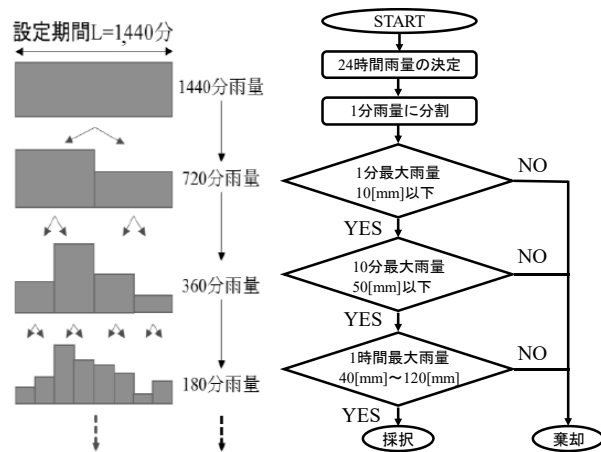


図-1 RCMの概要

図-2 VHの作成手順

二つに分けられる雨量を R_1 、 R_2 とすると、

$$R_1 = x_1 R \quad (2) \quad R_2 = x_2 R = (1 - x_1) R \quad (3)$$

と表される。よって、 x_1 を決定すれば x_2 も求まる。 x_1 はまず分配比率の範囲を決めた後に乱数を用いて決定する。本論文では、乱数は線形合同法¹²⁾を用い、式(4)、(5)に $a=1,664,525$ 、 $c=1,013,904,223$ 、 $\mu=2^{32}$ を代入し求めた。

$$X_{n+1} = \text{mod}(aX_n + c, \mu) \quad (4) \quad X_n = X_n / (\mu - 1) \quad (5)$$

これにより、4,294,967,296の周期が得られる。本論文では、初期値を $X_0=1$ と設定した。

(3) VHの作成手法

図-2に示すフローチャートに従いVHを作成する。まずは、VHの対象期間を24時間と設定した。24時間雨量については、東京都の中小河川における可能最大降雨は595.6mmと推定されており¹³⁾、また東京管区気象台の確率年2年の雨量を文献¹³⁾に示された降雨強度式を用いて算定すると129.1mmとなることから、130mm以上600mm以下を対象とすることとし、130mm、200mm、300mm、400mm、500mm、600mmの6種類を設定した。次に、設定した24時間雨量をもとにRCMにより1分雨量まで分割する。以下の条件に合わないVHは棄却し、全ての条件を満たしているものをVHとして採用した。

(i)著者らの東京都水防災総合情報システム1分値雨量データを用いた検討¹⁴⁾によると、雨量が1分間で10mm以上の値は点検作業等によるもので異常値として扱い除外している。よって、1分最大雨量が10mm以下のものを採択する。

(ii)日本の過去最大の10分値雨量は49mmである¹⁵⁾ことより、10分最大雨量が50mm以下のものを採択する。

(iii)東京都の中小河川流域では、可能最大降雨が60分雨量は119.6mmと推定され¹³⁾、東京管区気象台における確率年2年の60分雨量が40.4mmであることから、60分最大雨量が40mm以上120mm以下のものを採択する。

以上の方法によりVHを100事例作成したものを、VH₀(1)~VH₀(100)とした。

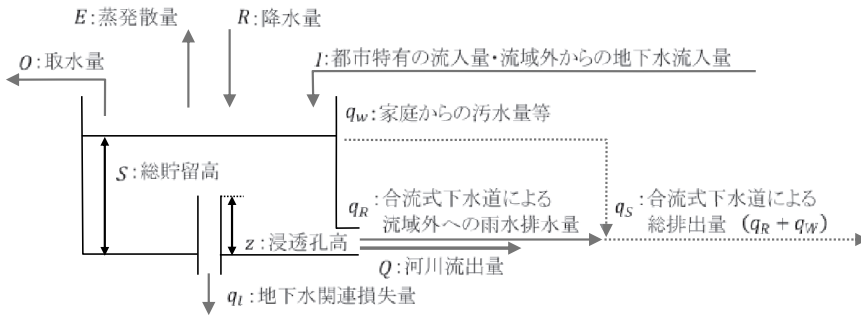


図-3 USFモデルの概念図

表-1 USFモデルパラメータ

パラメータ名	設定値
$k_1(\text{mm}^{-1} \cdot \text{p}^1 \cdot \text{min}^{\text{p}^1})$	40
$k_2(\text{mm}^{-1} \cdot \text{p}^2 \cdot \text{min}^{1+\text{p}^2})$	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

3. VQの構築

(1) 採用した流出モデル

高崎らが提案したUSF(Urban Storage Function)モデル¹⁶⁾をVQ作成のための流出モデルとして採用した。図-3にUSFモデルの概念図を示す。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。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(6)に、連続式を式(7)に示す。また、式(6),(7)のうち、地下水関連損失量 q_l は式(8)で、合流式下水道による流域外への雨水排水量 q_R は式(9)で示される。

$$s = k_1(Q + q_R)^{p_1} + k_2(d/dt)(Q + q_R)^{p_2} \quad (6)$$

$$\frac{ds}{dt} = R + I - E - O - Q - q_R - q_l \quad (7)$$

$$q_l = \begin{cases} k_3(s - z) & (s \geq z) \\ 0 & (s < z) \end{cases} \quad (8)$$

$$q_R = \begin{cases} \alpha(Q + q_R - Q_0) & (\alpha(Q + q_R - Q_0) < Q_{Rmax}) \\ q_R = Q_{Rmax} & (\alpha(Q + q_R - Q_0) \geq Q_{Rmax}) \end{cases} \quad (9)$$

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。

このうち $k_1, k_2, k_3, p_1, p_2, z, \alpha$ については、同様に都市域においてUSFモデルを構築した事例であるPadiyedathら¹⁷⁾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の値を参考に設定した。

(2) VQの作成

作成したVHをUSFモデルに入力し、流出計算を実施した。VHは対象期間を1,440分(24時間)としているが、流出計算を実施する期間は降雨から流出までの時間を考慮し、1,800分(30時間)と設定し、24時間以降は無降雨

として設定した。VHo(1)~VHo(100)を用い、流出計算を実施したVQをVQo(1)~VQo(100)とした。なお、VQは小数点6桁の単位で作成した。

(3) VH・VQの並び替え

VH・VQのうち、80洪水(洪水番号1~80)はキャリブレーション(学習、テスト)データに用い、20洪水(洪水番号81~100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ている。本論文では学習データ・テストデータ・検証データについてMaierら¹⁸⁾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

VHoの各洪水の60分最大雨量を比較した場合、60分最大雨量が大きい洪水が洪水番号が大きい洪水に偏るとい特徴を持っている。これは作成方法に起因するものであるが、詳しくは文献10)を参照されたい。VQoの各洪水のピーク流出高も、VHoの60分最大雨量が大きいことから、洪水番号が大きい洪水に偏る。一般にAI予測モデルにおいて、学習・テスト・検証データの偏りは精度の低下を招くことから、検証データにピーク流出高の大きな洪水が偏ることを防ぐことや学習データ抽出の際の利便性向上のため、学習用の80洪水および検証用の20洪水は、20洪水ごと(VQ(1)~VQ(20), VQ(21)~VQ(40), VQ(41)~VQ(60), VQ(61)~VQ(80), VQ(81)~VQ(100))にデータの偏りがないようにする。

並び替えの方法はまずVQo(1)~VQo(100)をピーク流出高の順番(降順)で並び替えを実施し、VQp(1)~VQp(100)とする。最もピーク流出高が大きいVQp(1)を検証用の洪水のVQ(81)とし、次に学習用の洪水に20洪水ごとにピーク流出高の大きな洪水が偏りなく配置されるようVQp(2)をVQ(1)に、VQp(3)をVQ(21), VQp(4)をVQ(41),




図-4 モデル構造

表-2 計算機仕様

項目	内容
CPU	Intel® Xeon® CPU E5-2687W v3 (10-Core, 3.10GHz)
メモリ	64GB
プログラミング言語	MATLAB
ソフトウェア	MATLAB R2018b (Deep Learning Toolbox)

VQp(5)をVQ(61)と並び替えた。その後は、同様に繰り返すことでVQp(1)~VQp(100)をVQ(1)~VQ(100)に並び替えることとした。また、VQに対応した降雨をVH(1)~VH(100)とした。ただし、学習に用いる際には20洪水内でピーク流出高が降順に並んでいることに注意が必要である¹⁹⁾。

4. 深層学習モデルの構築

(1) ネットワークモデルの概要

本検討で用いる機械学習モデルは入力層と中間層、出力層で構成されたニューラルネットワークモデルのうち、図-4に示すように中間層が2層の深層学習モデル（ディープニューラルネットワークモデル）とした。ニューラルネットワークモデルは神経系の動作を模したモデルであり、与えられた入力層に対して重みやバイアスを与えて伝達し、出力層に結果が出力される仕組みとなっている。各ノードの計算イメージは図-5のとおりであり、式(10),(11)の計算が行われる。

$$\alpha = \sum_{i=1}^N W_i X_i + b \quad (10)$$

$$Y = h(\alpha) \quad (11)$$

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。

ニューラルネットワークモデルでは、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よう調整することにより精度を向上させる手法がよく用いられており、この手法は誤差逆伝播法と呼ばれている。目的関数は予測問題で用いられるRMSE(二乗平均平方根誤差)を用いることとする。中間層の活性化関数




図-5 各ノードの計算イメージ

表-3 モデル構造と洪水イベント

項目		内容	
モデル構造	入力層	ノード数180 179分前~現時刻 雨量 (mm/min)	
	中間層	層数2 ノード数90×90	
	出力層	ノード数1 現時刻流出高 (mm/min)	
洪水イベントと用途	キャリブレーション	学習用	VQ(1)~VQ(60)
		テスト用	VQ(61)~VQ(80)
	検証用		VQ(81)~VQ(100)

については、Hintonら²⁰⁾により精度の良い関数と報告されているReLU関数（ランプ関数）を用いることとした。ReLU関数は以下の式で表される。

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

(2) 学習方法

目的関数を最小化させるパラメータ（重み係数・バイアス）の探索には、ミニバッチ確率的勾配降下法を用いた。ミニバッチ確率的勾配降下法は全サンプルデータのうち、一部（ミニバッチと呼ぶ）をランダムに取り出して、目的関数を評価し、誤差を更新するものである。本検討におけるミニバッチサイズは50を設定した。すべてのデータを用いて目的関数を評価し、誤差を更新する最急降下法と比較すると、局所解に陥りにくく、計算時間が短くなるという利点がある。また、ミニバッチ確率的勾配降下法のうちAdam (Adaptive moment estimation) により、最適化を実施した。Adamは、勾配の1次モーメントと2次モーメントを用いることにより、収束が早くなるという利点がある²¹⁾。

また、過学習による精度低下を防ぐ手法として、ドロップアウトがある。ドロップアウト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、過学習が起きにくくなる²²⁾。ただし、本論文ではドロップアウトは実施しない条件で計算を実施した。

(3) 計算機仕様

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-2に示すとおりである。学習は単純な計算時間の比較のため、並列計算を実行せず、単一CPUで実行し、




図-6 深層学習モデルによるVQの再現結果




図-7 各洪水イベントにおけるRMSE・NS係数

交差検証による学習の停止は行わず、10,000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）で学習を停止させる条件で実施した。

(4) 深層学習モデルの構築

上述の深層学習モデルを用いて、VHを入力層とし、VQを出力層とした深層学習モデルを構築し、学習を実施した。構築したモデルの設定については表-3に示すとおりであり、現時刻以前の降雨量から現時刻の流出高を出力するモデルである。なお、中間層のノード数は多いほど表現力は向上するが、過学習が生じやすくなるため、今回の場合2層の合計ノード数が入力層のノード数と同等になるよう設定した。

構築した100洪水イベントのうち、深層学習のパラメータの更新に用いる学習洪水はNo.1～60洪水とし、検証洪水をNo.81～100洪水とした。なお、本論文では交差検証は実施しないため、テスト洪水は使用しない。

(5) 再現性の確認

学習した深層学習モデルに学習用の60イベントの入力データを与え、出力層を再現させ、精度を評価した。精度確認のための指標はRMSE（Root Mean Square Error）とNash-Sutcliffe係数（以下、NS係数とする）とした。NS係数は洪水の立ち上がり部に着目した係数であり、1に近

表-4 CASEごとの学習洪水数とデータ数

ケース	学習洪水数	学習データ数
CASE1	60 (VQ(1)～(60))	1,800分×60イベント
CASE2	40 (VQ(1)～(40))	1,800分×40イベント
CASE3	20 (VQ(1)～(20))	1,800分×20イベント
CASE4	10 (VQ(1)～(10))	1,800分×10イベント
CASE5	1 (VQ(1))	1,800分×1イベント

いほど精度が良く、0.7以上でモデルの再現性が高いとされる²³⁾。RMSE・NS係数は以下の式で表される。

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

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

ここに、 n ：サンプル数、 q_o ：実測流量、 q_c ：計算流量、 q_{oave} ：実測流量の平均値。

再現結果を図-6に示す。学習洪水と検証洪水でそれぞれVQのピーク流出高が一番大きい洪水（イベントNo.1とNo.81）の深層学習モデルの出力結果とVQの波形は目視ではほとんど一致していることが確認できる。また、図-7に各洪水のRMSE・NS係数を示すが、RMSEは学習洪水で平均0.002程度、検証洪水で0.002～0.009程度、NS係数はすべての洪水イベントで1.00であり、流出規模と比較し、非常に精度良くUSFモデルをエミュレーションできていることがわかった。




図-8 学習洪水数とRMSE・NS係数の関係

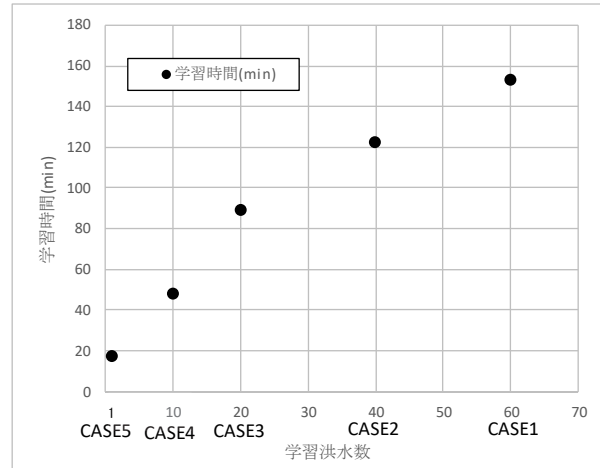


図-9 学習洪水数と学習時間の関係




図-10 CASEごとの学習用洪水(VQ(1))の再現波形の比較

5. 学習イベントの減少による再現性の確認

(1) 深層学習モデルの構築

上述の深層学習モデルは60洪水を学習（パラメータの調整）に用いた結果である。実流域では、水文データの観測体制が整ってから観測された洪水イベント数は限られており、また観測される洪水規模ごとのイベント数も基本的には流出規模が大きいほど少ない。そこで本検討では学習イベント数と予測精度の関係を確認するため、上述の学習洪水数60洪水をベースとして、学習する洪水を減少させた場合の再現精度を確認した。

学習を実施したケースを表-4に示す。すなわち、上述の60洪水を学習させた場合をCASE1とし、20洪水ごとに学習洪水を減少させたケースをCASE2, CASE3に設定した。また、CASE4, CASE5は洪水イベント数を減らすと同時に、VQは20洪水ごとにピーク流出高が大きいものから順に並んでいるため、流出規模が大きめの洪水だけを学習させたケースとなっている。

(2) 再現性・計算時間の確認

モデル精度の比較はすべてのCASEで学習対象となっているVQ(1)と、検証洪水の中でVQ(1)と同等のピーク流出規模であるVQ(81)について、RMSEおよびNS係数を比




図-11 CASE ごとの検証用洪水 (VQ(81)) の再現波形の比較

較した。図-8にCASEごとのRMSEおよびNS係数の比較結果を、図-9に学習に要した時間を示す。

図-8より、NS係数で比較すると学習用洪水 (図中△) においては、学習洪水数の減少にともないNS係数が低下し、精度が低下する傾向であるが、1洪水のみ学習した場合は学習用洪水の精度が向上した。また、検証用洪水(図中○)は学習洪水数の減少にともない、NS係数が低下し、精度が低下する傾向であった。ただし、学習用洪水も検証用洪水もNS係数は0.97以上であった。

RMSEで比較すると学習用洪水 (図中●) については、学習洪水数の減少によりRMSEが上昇し、精度が低下する傾向であったが、CASE5のみ精度が向上している結果であった。また、検証用洪水のRMSE (図中▲) については、学習洪水数の減少によりRMSEが低下し、精度が低下する傾向であった。これは学習した1洪水のみに合うように最適化された過学習の状態であると考えられる。

次に、図-10に学習洪水VQ(1)をケースごとに再現したハイドログラフを、図-11に検証洪水VQ(81)をケースごとに再現したハイドログラフを示す (なお、CASE1については図-6に前述している)。例えば図-10のCASE5の学習用洪水は良好な精度を持っているが、図-11の検証用洪水は精度が若干低下しているなど、RMSEおよびNS係数の確認と同様の傾向が見られた。ただし、図-11の検証用洪水ではすべてのケースで波形を精度良く再現できていることが目視で確認できる。

以上より、様々な洪水規模を一通り学習できる20洪水以上を学習させた場合はRMSEが0.02以下、NS係数が0.99以上と非常に精度良く予測できる結果であり、学習洪水数が1洪水の場合でも検証用洪水のNS係数が0.97以上と精度良く予測できていることがわかった。これより、深層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ると言える。ただし、都市流出モデルの完全再現が可能であるかという視点で見た場合は、VQは小数点6桁の精度であるのに対し、学習洪水数が少ない場合(CASE5)の学習洪水のRMSEは小数点3桁程度であり、完全再現はできていない結果であった。

なお、図-9より学習に必要な時間は、学習洪水数の減少により線形に短くなる関係にあった。また、学習したモデルを用いた予測に要する時間は1秒以内であった。

6. むすび

本論文では、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エト・ハイドログラフを構築し、構築したVHとVQを用いて深層学習モデルを構築した。様々な洪水規模を一通り学習できる20洪水以上を学習させた場合は非常に精度良く、学習洪水数が1洪水の場合でも精度良く予測できていることがわかった。これより、深層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ると言える。ただし、深層

学習モデルで都市流出モデルを完全再現することはできなかった。

今後は観測誤差を付与した場合のベンチマークデータを作成し、観測誤差がある場合のエミュレーション性能について研究を実施していく予定である。また、ニューラルネットワークモデルとの比較や、中間層のユニット数などの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研究を実施していく予定である。

作成したベンチマーク用のVH・VQは文献19)のURLよりダウンロード可能である。今後AIを用いた洪水予測モデルを作成する際、構築した予測モデルのベンチマークテストデータとして活用していただければ幸いである。

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, 第31巻第6号, pp.219-234, 2018.
- 2) 米勢嘉智,河村 明,天口英雄,戸野塚章宏: 1分値地上観測雨量データを用いた都市中小河川流域におけるXバンドMPレーダ雨量の精度評価, 土木学会論文集 B1(水工学), Vol.72, No.4, pp.I_217-I_222, 2016.
- 3) 米勢嘉智,河村 明,天口英雄,戸野塚章宏: 雨域移動に着目した都市流域におけるXバンドMPレーダ雨量の時空間相関特性, 土木学会論文集 B1(水工学), Vol.73, No.4, pp.I_217-I_222, 2017.
- 4) 米勢嘉智,河村 明,戸野塚章宏,天口英雄: 都市中小河川流域におけるXRRAINを用いた豪雨流出特性, 土木学会論文集 B1(水工学), Vol.74, No.4, pp.I_97-I_102, 2018
- 5) 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.
- 6) 山下隆義:イラストで学ぶディープラーニング, 講談社, 2018.
- 7) 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.
- 8) 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.
- 9) Kratzert,F.,Klotz,D.,Brenner,C.,Schulz,K.,Hemeger,M.,:Rainfall-runoff modelling using long-short-term-memory(LSTM) networks, Hydrol. Earth Syst. Sci., 22, 6005-6022, 2018.
- 10) 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, II-21, 2019. (Received April 9, 2019)
- 11) Olsson,J.:Evaluation of scalling cascade model for temporal rainfall disaggregation,Hydrology and Earth System Science, 2(1), pp.19-30, 1998.
- 12) 石川達也,内田善彦:モンテカルロ法によるプライシングとリスク量の算出について-正規乱数を用いる場合の適切な実装方法の考察-, IMES Discussion Paper No.2002-J-4, pp.8, 2012.
- 13) 中小河川における今後の整備のあり方検討委員会:東京都内の中小河川における今後の整備のあり方について最終報告書, p.41, 2012.
- 14) 坊田裕美,河村明,天口英雄:東京都水防災システム1分降水量データの補正および欠測値時空間特性, 第36回土木学会関東支部技術研究発表会公演概要集,II-38, 2008.
- 15) 国立天文台:理科年表平成31年, p.211, 丸善出版, 2019.
- 16) 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.
- 17) 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.
- 18) 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.
- 19) 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, II-21, 2019. (VH・VQダウンロードHP: <http://www.comp.tmu.ac.jp/suimon/virtual/>)
- 20) LeCun,Y., Bengio,Y., Hinton,G.E.: Deep learning, Nature, Vol.521, pp.436-444, 2015.
- 21) Kingma, D.P., Ba, J.: Adam: A method for stochastic optimization, Proc.of the 3rd international conference for learning representations, 2015.
- 22) 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.
- 23) Ragab, R., Moidinis, D., Albergel, J., Khouri, J., Drubi, A. and Nasri, S.: The HYDROMED model and its application to semi-arid Mediterranean catchments with hill reservoirs 2 : Rainfall-runoff model applications to three Mediterranean hill reservoirs.Hydrology and Earth System Sciences, pp.544-562, 2001. (Accepted July 8, 2019)

EMULATION OF URBAN RUNOFF MODEL BY DEEP LEARNING FOR BENCHMARK VIRTUAL HYETO AND HYDROGRAPH

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

In recent years, flood disaster in urban area have frequently occurred, and improving the accuracy of urban runoff prediction is a pressing issue. The urban runoff mechanism is complicated, and it is difficult to construct an accurate prediction model. So, in this paper, we aim to confirm whether the urban runoff model can be emulated by using the deep learning model, first of all, runoff volume (virtual hydrograph) using the urban runoff model and virtual rainfall (virtual hyetograph) was constructed. Then, using the created virtual hyetograph and virtual hydrograph, we constructed a deep neural network model and verified the reproducibility in the training data and the validation data. In addition, since the observation data of floods used as input data is limited, the reproduction characteristics when the number of training data was reduced were examined.