

技術報 WGAN-GP を用いた MSM 降水量の統計的ダウンスケーリングと洪水予測精度の評価

ダウンスケーリング研究グループ

ダムの事前放流の実施判断や水害リスクラインなどの洪水予測では、気象庁メソ数値予報モデル (MSM) の 39 時間先予測雨量が広く用いられている。この予測雨量には降雨強度・空間分布・時間推移等に関する誤差を含む。また、その空間解像度は 5km 程度であり、予測雨量は局地的な強雨を表現できない。一方、洪水予測の現場では、リアルタイム運用に活用可能な、高精度かつ高解像度の予測雨量が求められている。本稿では、雄物川上流の玉川ダム流域を対象に、WGAN-GP を用いて MSM 予測雨量を解析雨量相当の空間解像度へ統計的にダウンスケーリングし、併せて深層学習により誤差や系統的偏りの低減を図ることで、RRI モデルを用いた洪水予測精度の改善に寄与する可能性について検討を行った。

キーワード：統計的ダウンスケーリング、WGAN-GP、MSM、解析雨量、RRI

1. はじめに

地球温暖化の影響により水害の頻発化・激甚化が進んでおり、流域治水の重要性が増している。その一環として、降雨予測に基づく洪水予測の高度化が進められている。国が令和 2 年に公表した「事前放流ガイドライン」や水害リスクラインを含む洪水予報においても、数日先の予測計算には MSM 数値予報が利用されている。このように、数日先の予測降雨は、ダムの運用と避難情報の発令の双方の判断に直結する重要な情報となっている。一方、気象予測の特性上、数日先の予測雨量には降雨強度・空間分布・時間推移等に関する誤差が含まれ、また、流域面積が数値気象モデルの解像限界に近い流域では、降雨場の誤差が流入量予測の誤差の要因となりやすい。

近年、深層学習を用いた降水ダウンスケーリングの研究が進んでいる。例えば、敵対的生成ネットワーク GAN の発展形である Wasserstein GAN with Gradient Penalty (WGAN-GP) を用いて、高解像度降雨場を生成する試みが報告されている^{2, 3)}。現在のところ、これらの研究は主として降雨場の再現性評価に焦点が当てられている。このような先駆的研究は、洪水予測 (流入量) など水文応答への効果が期待されるが、いまだそれを運用上の観点から検証した例はない。

本研究では、機械学習を用いた統計的ダウンスケーリング (Statistical Downscaling; SDS) により、流域面積の狭いダム流域における MSM 予測雨量の高精度化および高解像度化を実現し、洪水予測精度の向上を図ることを目的とする。具体的な手法としては、WGAN-GP を用いて MSM 予測雨量を解析雨量相当の空間解像度へダウンスケーリングする機械学習モデルを構築し、降雨場の再現性を評価する。また、生成した降雨データを降雨流出氾濫 (RRI) モデルへ入力し、ダム流入量の予測精度を検証する。

表-1 学習と検証に用いた洪水事例

No	洪水日	学習期間	ピーク流入量 (m ³ /s)	区分
1	2017/7/23	7/15~7/24	1,030	学習 洪水
2	2017/8/25	8/21~8/31	1,196	
3	2018/5/16	5/16~5/19	635	
4	2020/7/12	7/1~7/31	378	
5	2022/8/3	8/1~8/21	1,116	
6	2022/8/12		561	
7	2023/7/15	7/1~7/21	741	
8	2024/7/1	6/28~7/31	455	
9	2024/7/24		407	
10	2024/7/26		456	
11	2025/8/20	-	1,064	検証 洪水
12	2025/9/2		770	

2. 対象流域および使用データ

本研究の対象流域は、雄物川上流域に位置する玉川ダム流域とした。また、気象庁メソ数値予報モデル (MSM)、解析雨量および地形データとして日本域表面流向マップ⁴⁾を使用した。学習には、玉川ダム流域の実績洪水のうち、融雪による影響がなく、ダム地点の実績ピーク流入量が概ね 400 m³/s を超えた 10 の洪水事例を用いた。学習において、弱雨時のサンプルが支配することを避けるため、解析雨量の流域平均 1 時間雨量が 1 mm/hr 以上となる時刻を学習サンプルとして採用した。

検証には、学習に含まれない独立な 2 つの洪水事例を用い、最大 36 時間先までの降雨場を評価した。学習洪水および検証洪水に採用した洪水発生日を表-1 に示す。

3. 解析フロー

本研究の解析フローを図-1 に示す。MSM の予測降水量を共通入力量とし、湿度・風などの他気象要素および地形データ (DEM) を選択的に追加した複数の入力条件を設定した。それぞれの入力条件に対し、WGAN-GP により解析雨量スケール (約 1 km) の降雨場を生成し、再現性を定量的に評価した。間を複数設定し、学習条件の違いが生成降雨に与える影響を比較した。また、設定し

(a) 入力要素の感度分析 (学習洪水)	
入力要素 (候補)	①降水,②降水+湿度,③降水+湿度+風,④降水+湿度+風+地形
学習対象FH	FH01~FH06
モデル	WGAN-GP
評価	解析雨量との降雨再現性 (RMSE等)
↓ 入力要素の決定	
(b) 学習対象FHの感度分析 (学習洪水)	
入力要素	④降水+湿度+風+地形
学習対象FH (候補)	①FH01~FH06,②FH01~FH18,③FH01~FH36
モデル	WGAN-GP
評価	解析雨量との降雨再現性 (RMSE等)
↓ 入力要素・学習対象FHの決定	
(c) CNNとの比較 (学習洪水)	
学習条件	④降水+湿度+風+地形,①FH01~FH06
モデル	WGAN-GP,CNN
評価	解析雨量との降雨再現性 (RMSE等)
↓	
(d) RRIによるダム流入量評価 (学習洪水・検証洪水)	
学習条件	④降水+湿度+風+地形,①FH01~FH06
モデル	WGAN-GP,RRI
評価	ダム流入量 (観測) との再現性 (RMSE等)

図-1 解析フロー図

最適な学習条件を CNN にも適用し、同一条件下で降雨場を生成して WGAN-GP との比較を行った。最後に、MSM および WGAN-GP で生成した降雨場を RRI モデルへ入力し、玉川ダム地点のダム流入量を算定して、最大 36 時間先までの洪水予測精度を評価した。

4. 生成モデル

WGAN-GP は、生成器 G と識別器 D から構成される。本研究では、G は MSM 格子上的入力気象場から解析雨量格子上の降雨場を生成し、D は解析雨量 (真値) と生成降雨に対してスカラー値を出力する Critic として機能する。学習の安定化のため、Wasserstein 距離に基づく損失関数に加え、Gradient Penalty を導入した^{5,6)}。生成器の出力は非負の降雨量となるよう活性化関数を設定し、局地的強雨域の表現向上を目的として、強雨域に重みを付けた L1 損失⁷⁾を併用した。これにより、強雨域における過度な平滑化を抑制しつつ、解析雨量への整合を図った。また、Deep Learning を用いた画像解析の代表例として、入力および出力設定を WGAN-GP と同一とした CNN (Convolutional Neural Network) モデルを構築し降雨場生成を実施した。

5. 入力データと学習条件

学習に用いる要素として、①降水のみ、②降水+湿度、③降水+湿度+風 (東西風・南北風)、④降水+湿度+風 (東西風・南北風)+地形 (DEM) の 4 条件を設定した。なお、湿度および風は地表面に加え、900hPa 面も学習対象とした。DEM は静的変数であるため、MSM 格子へ一度サンプリングした上で、全サンプル共通の入力チャンネルとして与えた。

また、学習に用いる予測時間 (FH) として、①FH01 (予測 1 時間) ~FH06 (予測 6 時間)、②FH01~FH18、

表-2 玉川ダムにおける RRI モデルパラメータ

河道モデル		粗度係数	(m ^{-1/3} ・s)		0.03					
斜面 モデル	共通	土地利用		水田	畑地	都市	水域	山地(浸透性)		
		等価粗度	(m ^{-1/3} ・s)	0.6	0.4	0.1	0.1	0.04	0.04	0.04
		土層厚	(m)	0.5	1	0	0	0.5	0.5	0.5
		飽和空隙率	(-)	0.2	0.48	0	0	0.26	0.26	0.26
	斜面 側方	飽和水平透水係数	(m/s)	0	0	0	0	0.481	0.482	0.483
		不飽和空隙率	(-)	0	0	0	0	0.25	0.25	0.25
		透水係数比	(-)	0	0	0	0	4	4	4

表-3 入力要素別の RMSE (WGAN-GP)

予測時間 (hr)	RMSE(mm/hr)				
	入力 ①	入力 ②	入力 ③	入力 ④	MSM 元データ
1	3.45	3.65	3.44	3.51	3.89
3	4.43	4.21	3.76	4.01	4.48
6	5.25	5.00	4.86	5.10	5.27
12	5.60	5.46	5.47	5.51	5.96
18	5.24	5.37	5.21	5.08	5.32
24	5.57	5.47	5.46	5.33	5.57
30	5.30	5.39	5.33	5.31	5.39
36	5.82	5.76	5.67	5.53	5.71

赤字：予測時間別の RMSE 最小値

③FH01~FH36 の 3 条件を設定し、予測時間が降雨場の再現性に与える影響を検証した。

6. RRI モデルによるダム流入量の推定

流入量予測に対する降雨入力の影響を評価するためには、実績雨量に対して RRI モデルが一定の再現性を有することが前提となる。本研究では解析雨量を入力として RRI パラメータを同定し、以降の検討では同パラメータを固定した上で、現時刻までの実績雨量に解析雨量を、現時刻以降の予測雨量に MSM または WGAN-GP 生成雨量を与え、最大 36 時間先までの流入量を算定することで相対比較を行った。玉川ダム流域の山地を 3 分類 (浸透性大中小) に分類し、河道粗度係数、山地の斜面粗度係数、飽和空隙率、水平透水係数、不飽和空隙率を最適化対象パラメータとし、SCE-UA 法⁸⁾および手動により実績ダム流入量を概ね再現できるパラメータのチューニングを行った。RRI のパラメータセットを表-2 に示す。

7. 入力要素および学習対象予測時間の検討結果

流域平均雨量の再現性を二乗平均平方根誤差 (RMSE) により評価し、入力要素の組合せが生成降雨の再現性に与える影響を整理した (表-3)。

深層学習による生成雨量は、MSM と比較して、多くの予測時間において RMSE が小さくなる傾向を示した。また、12 時間先以降の予測における RMSE 平均値では、入力④ (降水+湿度+風+DEM) が最も高い精度を示した。

次に、学習対象予測時間の影響を整理した。FH01~FH06 のみを対象とした場合、前述の通り学習の収束が




図-2 WGAN-GP と CNN による生成雨量の比較例
(2017/7/22 9:00 時点(MSM は 1 時間先予測値))




図-3 検証洪水における WGAN-GP による生成雨量の例
(2025/8/27 8:00 時点(MSM は 2 時間先予測値))




図-4 検証洪水における予測時間別の RMSE

安定し、無降雨時に無降雨を生成する傾向が保たれるなど、再現性のばらつきが小さい結果となった。以上より、以降の検証では、入力要素として「降水+湿度+風+DEM」を採用し、学習対象予測時間は FH01～FH06 とした。

8. WGAN-GP と CNN の比較結果

7. で選定した最適条件を用いて、WGAN-GP と CNN の降雨場再現性を比較した。図-2 に 2017 年 7 月洪水の代表時刻における降雨分布を示す。CNN は降雨域の大局的な分布を概ね再現する一方、強雨域のピークが平滑化され、局地的な集中が弱まる傾向があった。これに対し WGAN-GP は、強雨域の集中度及び発生位置が解析雨量に近く、強雨域の過度な平滑化が抑制された。降雨場の空間構造および流域平均雨量の再現性の観点から、WGAN-GP は CNN に比べて局地的強雨の表現に優れることが示された。

9. 検証洪水における降雨場の再現性結果

7. で選定した WGAN-GP の最適条件下での学習モデルを検証洪水に適用し、降雨分布の改善が定性的に認められた例を図-3 に示す。一方、図-4 に検証洪水の予測時間別 RMSE を示すが、WGAN-GP による精度向上効果は小さい結果となった。これは、元々の MSM 予測雨量が実績と比較して空振り・見逃し傾向にある場合、WGAN-GP 生成雨量も同様の傾向となっており、補正しきれていないことが要因である。




図-5 ダム流入量の予測時間ごとの RMSE




図-6 学習洪水によるダム流入量の改善例




図-7 検証洪水によるダム流入量の改善例

(2025/8/19 9:00 時点の予測結果)

10. ダム流入量予測への効果 (RRI)

ダム流入量の評価指標を図-5 に示す。各予測時間における全体の RMSE では、WGAN-GP 生成雨量による精度向上効果は小さい結果となった。RMSE が大きく改善しなかった要因には、空振り・見逃し傾向にある MSM 予測雨量を、WGAN-GP において完全に補正しきれていない点が挙げられる。

一方で、ハイドログラフの観点では、WGAN-GP はダム流入量の再現性向上に一定程度寄与した。学習洪水によるダム流入量の改善例を図-6 に、検証洪水によるダム流入量の改善例を図-7 に示す。MSM を用いた場合、ピーク流入量の過小や立ち上がりの遅れが見られるが、WGAN-GP 生成雨量を用いた場合、降雨ピークの再現性向上に伴い、流入量の立ち上がりおよびピーク流入量の再現性が向上する傾向が確認された。また、2022/8/2 9:00 時点 (学習洪水) と 2025/8/19 9:00 時点 (検証洪水) の予測 36 時間先までの RMSE を比較したところ、ともに MSM より WGAN-GP の方が高い精度を示した。

11. 考察

本研究では、降水のみの入力に比べ、湿度・風を追加することで 1～6 時間先の流域平均雨量の再現性が改善

し、さらに DEM を追加することで 12~36 時間先の再現性が向上した。湿度・風は降水の発生・維持に関わる大気場の状態を反映しており、降水量単独では表現しきれない降雨の発達・衰弱過程を補助的に説明する情報として機能した可能性がある。加えて、DEM は地形性降雨の空間的な偏りに関する静的情報を与えるため、長時間先ほど不確実性が增大する予測降雨に対し、強雨域の発生位置や集中度の推定を安定化させた可能性が考えられた。

学習対象予測時間を FH01~FH18 または FH01~FH36 までに設定した場合、無降雨に近い条件でも局所的に極端な降雨を生成する過学習傾向が確認された。長時間先ほど弱雨サンプルが増加し、降雨の出現頻度が低下することで学習データの分布が偏り、少数の強雨事例に引きずられる形で生成が不安定化した可能性がある。また、本研究のモデルでは予測時間そのものを入力として与えていないため、予測時間ごとに異なる誤差特性（降雨域の位置ずれや強度の偏り等）を明示的に条件付けできず、学習が難しくなった可能性も考えられる。本研究条件下では FH01~FH06 を学習対象とすることが、安定した学習および過学習の抑制に有効であった。

本研究では MSM の予測降雨場を入力としており、元の MSM が解析雨量に対して空振り・見逃し傾向を示す場合、生成雨量もその影響を強く受け、最適条件下でも補正しきれない事例が確認された。

以上の結果から、入力対象の動的データを MSM に限定した場合、SDS により空振り・見逃しを補正することには限界があることが示唆された。

RRI モデルによる流入量算定では、予測雨量に WGAN-GP 生成雨量を用いることで、MSM をそのまま用いた場合と比べて、一部事例においてピーク流入量および立ち上がり時刻の誤差が縮小した。

1 2. まとめ

本研究では、WGAN-GP による MSM 予測雨量の SDS が、一部事例において、降雨場の再現性の向上および RRI モデルによるダム流入量予測精度の改善に寄与することを確認した。今後の課題として、①他流域への適用性の検証、②予測時間を条件情報として扱うモデル化等による過学習の抑制、③アンサンブル予報（MEPS、LEPS 等）への適用による長時間先予測の見逃し・空振り低減効果の検証が挙げられる。

本研究で対象とした玉川ダム流域は急峻な山地に位置し、地形性降雨の影響を受けやすい流域条件である。このため、湿度・風・地形データを入力要素として追加

することが、降雨場の再現性改善に寄与した可能性がある。したがって他流域へ適用する際には、流域の地形・土地利用・降雨特性に応じて最適な入力要素や学習条件が変化する可能性がある点を踏まえ、十分な検証を行うことが望ましい。また、長時間先予測における空振り・見逃しの低減については、さらなる検証が必要である。メソアンサンブル予報（MEPS）や、局地アンサンブル予報（LEPS）に本手法を適用し、アンサンブル情報を活用することで、空振り・見逃しの影響低減に加え、降雨場の不確実性評価の高度化に資する可能性がある。

参考文献

- 1) 岡田七美：洪水予測の高度化に向けて、令和6年度中部地方整備局管内事業研究発表会，2024.
- 2) Shiraishi, K., Muto, Y., Okazaki, A. and Kotsuki, S.: Wasserstein GAN-Based Precipitation Downscaling with Optimal Transport for Enhancing Perceptual Realism, arXiv preprint, arXiv:2507.17798, 2025.
- 3) Iotti, M., Davini, P., von Hardenberg, J. and Zappa, G.: RainScaleGAN: A Conditional Generative Adversarial Network for Rainfall Downscaling, Artificial Intelligence for the Earth Systems, Vol.4, Issue3, (AIES-D-24-0074.1), 2025.
- 4) 山崎大, 富樫冨佳, 竹島滉, 佐山敬洋：日本全域高解像度の表面流向データ整備, 土木学会論文集B1 (水工学), Vol.74, No.5, I_163-I_168, 2018.
- 5) Arjovsky, M., Chintala, S. and Bottou, L.: Wasserstein Generative Adversarial Networks, Proceedings of the 34th International Conference on Machine Learning (ICML 2017), Vol.70, pp.214-223, 2017.
- 6) Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V. and Courville, A.: Improved Training of Wasserstein GANs, Advances in Neural Information Processing Systems 30 (NeurIPS 2017), pp.5767-5777, 2017.
- 7) Isola, P., Zhu, J.-Y., Zhou, T. and Efros, A.A.: Image-to-Image Translation with Conditional Adversarial Networks, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017), pp.1125-1134, 2017.
- 8) 福井治, 西澤諒亮, 岩見収二, 山田真史, 佐山敬洋, 瀧健太郎：流域治水検討に適用するためのRRIモデルのパラメータ設定手法, 河川技術論文集, Vol.30, pp.531-536, 2024.

謝辞：本研究に際し、北海道大学 稲津将教授にご支援及び協力を得た。