

ベイズ深層学習を用いた予報雨量の不確実性を考慮したダム流入量の確率的予測

三浦奈都¹・宮本崇²・天方匡純³・安野貴人⁴・石井明⁵

¹山梨大学大学院 医工農総合教育部 修士課程 工学専攻 土木環境工学コース

E-mail: g21tc011@yamanashi.ac.jp

²山梨大学 工学部土木環境工学科

E-mail: tmiyamoto@yamanashi.ac.jp (Corresponding Author)

³八千代エンジニアリング株式会社 技術開発研究所

E-mail: amakata@yachiyoeng.co.jp

⁴八千代エンジニアリング株式会社 技術開発研究所

E-mail: tk-yasuno@yachiyoeng.co.jp

⁵八千代エンジニアリング株式会社 技術開発研究所

E-mail: akri-ishii@yachiyoeng.co.jp

防災上重要となるダムの高水予測には、物理モデルに加えて深層学習に代表される統計モデルも近年は活用されている。本研究では流入域における観測・予測雨量を入力としてダムへの流入量を予測する深層学習モデルを作成し、パラメトリックスタディを通して適切な入力情報について検討した。また、予測雨量の不確実性やモデル誤差が出力値に与える影響を表現する手法として、ベイジアンニューラルネットワークの利用を提案し、その有効性を検証した。数値実験からは、ベイジアンニューラルネットワークでは学習データの多寡に応じた出力値の不確実性を出力の信用区間に反映しており、学習範囲で稀に発生する極端な降雨による流入量も予測範囲に収めることが出来ることが確認された。

Key Words: deep learning, AI, dam inflow prediction, Bayesian neural network

1. はじめに

近年、豪雨の増加に伴い気象災害が増加・甚大化している¹⁾²⁾。2017年の九州北部豪雨では福岡県・大分県において41名の死者・行方不明者を出し、佐賀・福岡・長崎の3県では600件以上の浸水被害が報告されている³⁾。また、2018年の西日本豪雨では愛媛県の野村ダムと鹿野川ダムの緊急放流により、9名の死者が発生する事態となった⁴⁾。1時間当たり80mm以上の猛烈な雨の発生回数も増加傾向にあり、今後もこのような豪雨に伴う気象災害は増加していくと考えられる。

気象災害対策の一環として、豪雨時においてもダムの正確な水位管理と安全な運用によって下流の被害を軽減するダムの防災操作⁵⁾が挙げられる。適切な防災操作のためには、ダムへの流入量の精緻な予測が重要である。特に非難行動に十分な猶予を与えるうえでは数時間先の流入量の予測情報が必要となるが、そのような予測は現在においても十分な精度に達していない状況にある。

一方で、近年AIや深層学習に関する技術が土木分野においても発達してきており、様々な適応事例が報告されている⁶⁾⁷⁾。また、検討の中で課題として挙げられた誤差の検討手法として、本研究ではベイズ推定を選択し

深層学習に導入した。ベイズ推定を用いたベイジアンニューラルネットワーク⁸⁾⁹⁾¹⁰⁾の適応事例は国内ではまだ数が少ない。本研究では、深層学習を用いた6時間先のダム流入量の予測モデルを開発すると共に、予測雨量の不確実性やモデル誤差が出力値に与える影響を表現する手法としてベイジアンニューラルネットワークの利用を提案し、その性能を検証する。

2. 既往研究

(1) 物理的手法

ダム流入量予測における物理的手法とは、一般に、貯留関数法¹¹⁾やタンクモデル¹²⁾を用いて行う集中型流出モデルや、分布型流出モデル¹³⁾を用いて計算を行う手法のことをいう。

集中型流出モデルでの予測は、必要な降雨データ数も少なく比較的簡単に計算やシステム化が可能である一方で、再現精度・予測精度に課題がある。一方で、分布型流出モデル¹³⁾¹⁴⁾は精度や再現性は高いものの、集中型モデルと比べて計算に必要なデータは多くなり、システム化も複雑になることが実用化に向けた課題として挙げられる。また、モデル誤差、パラメータ誤差、降雨誤差などの様々な誤差要因の考慮も物理的手法の課

題として挙げられる。物理モデルによる予測事例として、陸らによる研究¹⁵⁾では、流出モデルを用いた流量予測を行っている。

(2) 統計的手法

ダム流入量予測における統計的手法とは、一般に、過去の推移・流量の時系列データに基づき将来の予測を行う統計的モデルを用いる手法を指す。深層学習の発達を背景に、近年は特にニューラルネットワークを用いた手法¹⁶⁾¹⁷⁾¹⁸⁾¹⁹⁾²⁰⁾が増加している。

天方らによる研究¹⁸⁾では、入力データの前後関係を保持する機能を有し、時系列データと出力データとの関係を構築することのできる LSTM モデルが用いられている。また田村らによる研究¹⁹⁾では、DNN モデルを活用したダム流入量及び下流水位予測モデルを構築し、DNN モデルのハイパーパラメータのチューニング方法について検討を行った。これにより、48 時間後までの予測について、予測雨量として解析雨量を与えた場合には実務的に適用できるレベルの良好な予測精度が得られている。また、一言らによる研究²¹⁾では、ニューラルネットワークによる予測モデルに分布型流出モデルと粒子フィルターによるデータ同化を加えた水位予測手法が提案されている。

本研究では、既往研究では用いられていない予測雨量を入力値に用い、分布型流出モデルにおいても検討された²²⁾、予測雨量や予測モデルが有する不確実性を統計的手法でも考慮するために、次節に示すベイジアンニューラルネットワークを用いる。

3. 提案手法

本節では、統計的モデルによる予測に含まれる不確実性とベイズ推論によるその評価手法を概説したうえで、本稿において予報降雨量の不確実性やモデル誤差による出力値の不確実性を表現する手法として用いる、ベイジアンニューラルネットワークの手法を説明する。

(1) 予測が有する不確実性とベイズ推論

a) 統計的予測の有する不確実性

一般に、統計的な手法によって回帰モデルを構成するとき、その予測結果には以下に示す 3 種類の誤差要因に起因する不確実性が含まれる。

1 つは、回帰モデルの構成に用いる学習データの多寡に起因する不確実性である。図-1 は、真の関数 $y = 2x - 1$ に対して観測ノイズ $\mathcal{N}(\delta|0, 0.1)$ が乗りながら N 個のサンプルが得られたときに、 $N = 10, 5, 3$ に対して線形回帰モデルを構成した結果を比較したものである。サンプル数が少なくなるほど真の関数と回帰モデルが乖

離していることから分かるように、十分な数の学習データがない状態で構成された回帰モデルは本来のデータの関係から外れている可能性があり、その予測結果にも誤差が生じることを見込む必要がある。

もう 1 つは、回帰モデルの表現能力に起因する不確実性である。図-2 は、真の関数 $y = \sin 2\pi x$ に対して観測ノイズ $\mathcal{N}(\delta|0, 0.1)$ が乗りながら 10 個のサンプルが得られたときに、 D 次元多項式回帰モデルを構成した結果を比較したものである。この数値実験では $D = 3$ の時に最も回帰モデルが真の関数を近似しており、本来のデータの関係に比較して表現能力の低い $D = 1$ や表現能力が必要以上に高い $D = 5$ のケースでは予測値と真の値との間に誤差が生じている。このように、回帰モデルが適切に設計されず、その表現能力と本来のデータの関係に乖離がある場合は、予測結果に誤差が生じうる。

最後は、観測ノイズに起因する不確実性である。図-3 は、真の関数 $y = 2x - 1$ に対して観測ノイズ $\mathcal{N}(\delta|0, \sigma_y^2)$ が乗りながら 50 個のサンプルが得られたときに、 $\sigma_y^2 = 0.1, 0.2, 0.4$ に対して線形回帰モデルを構成した結果を比較したものである。いずれのケースにおいても、観測データ数は十分であり、回帰モデルと真の関数もよく一致しているが、観測ノイズの強さに応じてサンプルデータとの間に誤差が生じている。こうした観測ノイズは、観測量が本質的な確率的変動を有する場合や観測の際にノイズが生じる場合、観測されていない潜在的な説明変数があるために見かけ上の変動が生じる場合などに現れ、十分な観測データ数や適切な決定論的モデル設計の下でも避けることのできない誤差要因となる。

b) ベイズ推論

統計的な回帰モデルを用いて予測を行う上では、上述の誤差要因によって生じる予測の不確実性を考慮する必要がある。本稿では、このような不確実性の影響を評価する手法として、ベイズ推論の枠組みを回帰モデルに適用する。

ベイズ推論は、観測データ D を元に推定対象の量 X を確率的に求める手法である。観測データの従う確率分布を $p(D)$ 、 X の事前分布を $p(X)$ とおくと、 D が得られた後の X の事後分布はベイズの定理より次のように求められる。

$$p(X|D) = \frac{p(D|X)p(X)}{p(D)} \quad (1)$$

ベイズ推論の枠組みでは、観測データに基づく推定量やその不確実性は、事後分布 $p(X|D)$ の有する期待値や分散などの統計量を通じて表現される。以降では、ベイズ推論の枠組みを統計的モデルに適用する方法とその効果を説明する。




図-1 サンプルデータ数に起因した回帰モデルの不確実性




図-2 モデルの表現能力に起因した回帰モデルの不確実性




図-3 観測ノイズに起因した回帰モデルの不確実性

(2) ベイズ線形回帰

ここでは線形回帰モデルに対してベイズ推論の枠組みを適用した事例を通して、統計的モデルに対してベイズ推論を導入する効果を説明する。

今、変数 x と y の間に $y = f(x)$ の関係があり、この関係に従って N 個のサンプルデータ $(x_1, y_1), \dots, (x_N, y_N)$ が与えられているものとする。このとき、サンプルデータから以下の線形回帰モデルを決定する問題を考える。

$$y = w \cdot x + b + \epsilon = \mathbf{w} \cdot \mathbf{x} + \epsilon \quad (2)$$

ただし、 $\mathbf{w} = (w, b)$ 、 $\mathbf{x} = (x, 1)$ とおいた。 ϵ は、出力 y の有する本質的な確率的変動や観測ノイズ、回帰モデル $w \cdot x + b$ と本来の $y = f(x)$ との差から生じる誤差を表したバイアス成分である。

サンプルデータ $\mathbf{X} = (x_1, \dots, x_N)$ と $\mathbf{Y} = (y_1, \dots, y_N)$ を元に、モデルパラメタ $\mathbf{w} = (w, b)$ を確率的に求めることを考える。 ϵ は平均 0、分散 σ^2 の正規分布 $\mathcal{N}(\epsilon|0, \sigma^2)$ に従うものと仮定すると、 $p(\mathbf{w})$ の事後分布 $p(\mathbf{w}|\mathbf{X}, \mathbf{Y})$ はベイズの定理より次のように表現できる。

$$p(\mathbf{w}|\mathbf{X}, \mathbf{Y}) = \frac{p(\mathbf{Y}|\mathbf{X}, \mathbf{w}) \cdot p(\mathbf{w})}{p(\mathbf{Y}|\mathbf{X})} \propto \prod_{i=1}^N \mathcal{N}(y_i|\mathbf{w}\mathbf{x}_i, \sigma^2) \cdot p(\mathbf{w}) \quad (3)$$

ここで、事前分布 $p(\mathbf{w})$ に無情報分布を仮定すると、上式の解析解は次式に示す多次元正規分布となる。

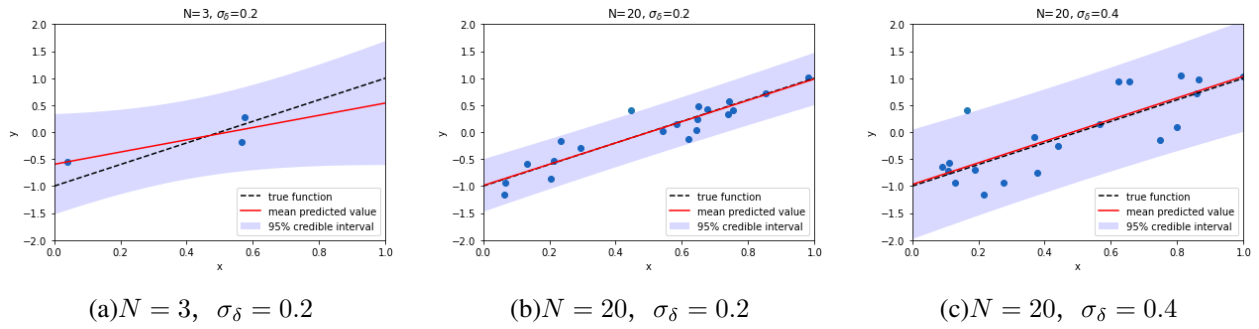


図-4 ベイズ線形回帰モデルによるサンプルデータの学習と予測。サンプルデータの数や回帰モデルの表現能力，観測ノイズの強さに応じた予測の不確実性が，予測分布から評価される確信区間として表現されている。

$$p(\mathbf{w}|\mathbf{X}, \mathbf{Y}) = \mathcal{N}(\mathbf{w}|\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}}) \quad (4)$$

$$\text{where } \hat{\boldsymbol{\Sigma}} = \left(\frac{1}{\sigma^2} \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^T \right)^{-1}$$

$$\hat{\boldsymbol{\mu}} = \hat{\boldsymbol{\Sigma}} \left(\frac{1}{\sigma^2} \sum_{i=1}^N y_i \mathbf{x}_i \right)$$

また，バイアス成分 ϵ の強さを制御する σ^2 も同様にサンプルデータに基づいて確率的に求めることを考える。式の簡略化のために新たに精度パラメータ $\lambda = \frac{1}{\sigma^2}$ を設けると，その事後分布 $p(\lambda|\mathbf{X}, \mathbf{Y})$ は次のように表現できる。

$$p(\lambda|\mathbf{X}, \mathbf{Y}) = \frac{p(\mathbf{Y}|\mathbf{X}, \lambda^{-1}) \cdot p(\lambda)}{p(\mathbf{Y}|\mathbf{X})} \propto \prod_{i=1}^N \mathcal{N}(y_i|\mathbf{w}\mathbf{x}_i, \lambda^{-1}) \cdot p(\lambda) \quad (5)$$

ここで，事前分布 $p(\lambda)$ についても無情報分布を仮定すると，上式の解析解は次式に示すガンマ分布となり，その期待値 $\hat{\lambda}$ は式 (7) として計算される。

$$p(\lambda|\mathbf{X}, \mathbf{Y}) = \frac{\beta^\alpha}{\Gamma(\alpha)} (\lambda)^{\alpha-1} e^{-\beta\lambda} \quad (6)$$

$$\text{where } \alpha = \frac{N}{2} + 1$$

$$\beta = \frac{1}{2} \sum_{i=1}^N (y_i - \mathbf{w}\mathbf{x}_i)^2$$

$$\hat{\lambda} = \frac{\alpha}{\beta} = \frac{N+2}{\sum_{i=1}^N (y_i - \mathbf{w}\mathbf{x}_i)^2} \quad (7)$$

これらの結果が得られたとき，任意の \mathbf{x}_* に対する y の予測値 y_* は，次のような確率分布（予測分布）を有する。

$$p(y_*|\mathbf{X}, \mathbf{Y}, \mathbf{x}_*) = \mathcal{N}(y_*|\mu_*(\mathbf{x}_*), \sigma_*^2(\mathbf{x}_*)) \quad (8)$$

$$\text{where } \mu_*(\mathbf{x}_*) = \hat{\boldsymbol{\mu}}\mathbf{x}_*$$

$$\sigma_*^2(\mathbf{x}_*) = \hat{\lambda}^{-1} + \mathbf{x}_*^T \hat{\boldsymbol{\Sigma}} \mathbf{x}_*$$

図-4 は，真の関数 $y = 2x - 1$ に対して観測ノイズ $\mathcal{N}(\delta|0, \sigma_\delta)$ が乗りながらランダムに N 個のサンプルが得られたときに，上記のベイズ線形回帰モデルによる

$0 \leq x \leq 1$ の範囲での y の予測平均値と 95% 確信区間を示したものである。(a) と (b) からは，観測ノイズの強さ $\sigma_\delta = 0.2$ の値を固定した際の，サンプル数の異なる $N = 3$ と $N = 20$ の 2 ケースが比較される。サンプル数が少ないケース (a) では，予測平均値が真の関数から大きく離れている上に，確信区間も広く評価される結果となっている。また，サンプルデータの存在する $0 \leq x \leq 0.6$ の付近に比較すると，サンプルデータの無い領域では確信区間が広がっていることが分かる。ベイズ推論の枠組みを用いると，このようにサンプルデータの数や分布に応じた予測値の不確実性を自然に評価することが可能となる。

また同図の (b) と (c) からは，サンプル数 $N = 20$ を固定した際の，観測ノイズの強さの異なる $\sigma_\delta = 0.2$ と $\sigma_\delta = 0.4$ の 2 ケースが比較される。2 つのケースとも予測平均値は真の関数とほぼ一致している一方で，予測値とサンプルデータの差の大きさに応じた確信区間が評価されていることが分かる。このように，ベイズ推論の枠組みではモデルの表現能力や観測ノイズに起因する誤差に応じた，予測値の不確実性を評価することも可能である。

なお，本節の検討では事前分布として無情報分布を用いており，この場合は最尤推定と等価であることが知られている²³⁾。ベイズ推論の意義は計算の対象に関する事前知識を事前分布に反映できることであり，最尤推定や MAP 推定などの確率的推定手法を一般化した手法という位置づけにある。

(3) ベイジアンニューラルネットワーク

ニューラルネットワーク内部の全パラメータをまとめたベクトルを \mathbf{w} と置くと，ニューラルネットワークにおける入出力ベクトル \mathbf{x}, \mathbf{y} の関係は形式的に次のように書くことが出来る。

$$\mathbf{y} = f(\mathbf{x}; \mathbf{w}) \quad (9)$$

ベイジアンニューラルネットワークは、ニューラルネットワークに対してベイズ推論の枠組みを適用したものである。すなわち、パラメタベクトルを確率的に推論するものとして、その確率分布を $p(\mathbf{w})$ とおくと、ベイジアンニューラルネットワークにおける出力値の予測分布 $p(\mathbf{y})$ は次のようになる。

$$p(\mathbf{y}) = p(\mathbf{y}|\mathbf{x}, \mathbf{w}), \lambda_{\mathbf{y}} p(\mathbf{w}) \quad (10)$$

ここで、 $\lambda_{\mathbf{y}}$ は予測値の不確実性（バイアス成分）を制御するパラメタである。

ベイジアンニューラルネットワークは、サンプルデータ \mathbf{X}, \mathbf{Y} が与えられた際に、ベイズの定理を通じてパラメタの事後分布 $p(\mathbf{w}|\mathbf{X}, \mathbf{Y})$ やバイアス成分のパラメタ $\lambda_{\mathbf{y}}$ を評価することにより、通常のニューラルネットワークが行う点推定的な予測に加えて、予測の不確実性を算出する手法と言える。その算出結果は、前述のベイズ線形回帰モデルと同様にサンプルデータの数に起因する不確実性を $p(\mathbf{w}|\mathbf{X}, \mathbf{Y})$ に、ニューラルネットワークモデルの有する表現能力や観測ノイズに起因する不確実性を $\lambda_{\mathbf{y}}$ に反映したものとなる。

(4) モンテカルロドロップアウト

ベイジアンニューラルネットワークにおけるパラメタの事後分布 $p(\mathbf{w}|\mathbf{X}, \mathbf{Y})$ は一般に解析的に求めることが困難であるため、種々の近似計算法が提案されている。本稿ではこうした近似計算法のうち、実装の簡単さを考慮して以下に説明するモンテカルロドロップアウトを利用する。

モンテカルロドロップアウトは、ニューラルネットワークの学習時において過学習を防ぐために適用されるドロップアウトを予測時にも適用することで、予測結果を確率的に得る手法である。ドロップアウトの適用によって得られる、同一の入力に対する多数の出力サンプルの有する平均値や分散が、パラメタに対してある種の事前分布を設定した際のベイジアンニューラルネットワークモデルによる近似予測分布の平均値や分散と理論的に等価であることが示されている²⁴⁾。本稿ではこの結果を利用し、モンテカルロドロップアウトから評価されるニューラルネットワークの出力の期待値と分散を、ベイジアンニューラルネットワークによる予測期待値と確信区間の評価結果として利用する。

4. 対象地域と使用データ

(1) 対象地域

本研究では神奈川県相模川水系中津川にある宮ヶ瀬ダムを予測対象とする。宮ヶ瀬ダムは流域面積 101.4km^2 、貯水量約 2 億 m^3 の首都圏最大級の治水を主とした多目的ダムである。ダムは中津川・相模川中下流部の洪

水調節、沿岸農地への農業用水供給、中津川の河川生態系保全のための河川維持放流を目的とした不特定利水や神奈川県への上水道供給、下流に併設された発電所による水力発電が行われている。H11~26 のダム流域の平均降水量は $2,811\text{mm}$ であり、関東地方の平均降水量 $1,475\text{mm}$ に対して比較的多雨地帯で²⁵⁾、流域への降雪もある。降雪量に関する気象庁データは欠測となっており詳細は不明である。

ダム湖である宮ヶ瀬湖からは、相模川、道志川へと導水路が接続されている。相模ダム・城山ダム・道志ダムと連携した管理運営により、貯めきれず無効放流で無駄になっていた水を宮ヶ瀬湖で貯水することにより水資源を確保できる仕組みになっている。相模川・中津川の下流には人口密集地域があり、治水・利水の両面で重要な役割を果たしている（図-5）。



図-5 宮ヶ瀬ダムを含む広域水系の運用関係図²⁶⁾

(2) 使用データ

本研究では、ダム流入量の予測のために用いる入力データとして、対象ダムへの流入量とともに、以下に示す解析雨量と降水短時間予報の2種類のデータを利用する。対象ダムへの流入量は国土交通省関東地方整備局相模川水系広域ダム管理事務所から提供を頂いた。また、データ内の欠損値は、欠損値を除いた流域の平均値に置き換えた。

a) 解析雨量

解析雨量²⁷⁾とは、気象庁・国土交通省が保有する気象レーダーの観測データに加え、気象庁・国土交通省・地方自治体が保有する全国の雨量計のデータを組み合わせ、1時間の降水量分布を 1km 四方の細かさで解析したもので解析雨量は30分ごとに作成される。雨量計は正確な雨量を観測するが、雨量計による観測は面的には隙間がある。一方レーダーでは、雨粒から返ってくる電波の強さにより、面的に隙間のない雨量が推定できるが、雨量計の観測に比べると精度が落ちる。解析雨量は両者の長所を活かし、レーダーによる観測を

アメダスや他機関の雨量計による観測で補正し、面的に隙間のない、より正確な雨量分布を得ている。

今回の検証では、宮ヶ瀬ダムに直接流入する河川を含む、標準地域メッシュのうち3次メッシュ（1km四方）で204km²の範囲の解析雨量を利用した。国土地理院の提供する数値標高モデルより作成した、該当領域の地形を図-6に示す。ただし、標高データの欠損部（ダム湖水面など）は0に置き換えている。

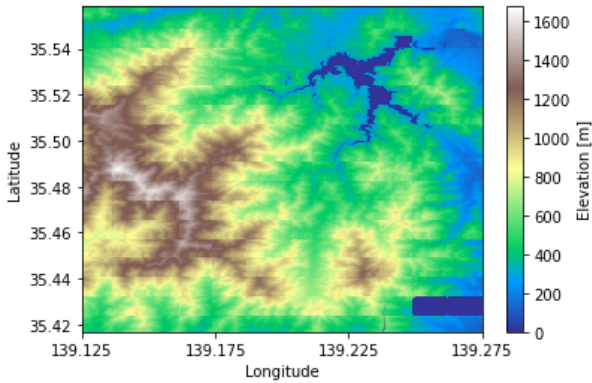


図-6 対象領域の地形

b) 降水短時間予報

降水ナウキャスト²⁸⁾は、迅速な情報として5分間隔で発表され、1時間先までの5分毎の降水の強さを1km四方の細かさで予報するもの。降水ナウキャストによる予報には、レーダー観測やアメダス等の雨量計データから求めた降水の強さの分布および降水域の発達や衰弱の傾向、さらに過去1時間程度の降水域の移動や地上・高層の観測データから求めた移動速度が利用される。予報を行う時点で求めた降水域の移動の状態がその先も変化しないと仮定して、降水の強さに発達・衰弱の傾向を加味して、降水の分布を移動させ、60分先までの降水の強さの分布を計算している。本研究では6時間先までの予報を目標としているため適さない。

降水短時間予報²⁸⁾は、6時間先までと、7時間から15時間先までとで、発表間隔や予報手法が異なる。6時間先までは10分間隔で発表され、各1時間降水量を1km四方の細かさで予報する。7時間先から15時間先までは1時間間隔で発表され、各1時間降水量を5km四方の細かさで予報する。6時間先までの予報手法は、1時間ごとの解析雨量から降水域を追跡すると各所の降水域の移動速度が分かるのでこの移動速度を使って直前の降水分布を移動させて、6時間先までの降水量分布を作成する。予報の計算では、降水域の単純な移動だけではなく、地形の効果や直前の降水の変化を元に、今後雨が強まったり、弱まったりすることも考慮している。また、予報時間が延びるにつれ、降水域の位置や強さのずれが大きくなるため、予報時間の後半には数値予

報による降水予測の結果も加味している。

7時間先から15時間先までの予報手法は、数値予報モデルのうち、メソモデルと局地モデルを統計的に処理した結果を組み合わせ、降水量分布を作成する。予報開始時間におけるそれぞれの数値予報資料の予測精度も考慮した上で組み合わせている。本研究では6時間後の流入量予測を目標としているため、降水短時間予報のうち、6時間先までの予報を用いた。

5. 数値実験

本研究ではダム流域における降雨量を入力値とし、ダムへの流入量を出力値とする深層学習モデルを作成し、以下の表-1から表-3に示す、入力データやモデル構造の異なる4ケース間で予測精度の比較を行った。深層学習モデルは5層の結合層から成るNNモデルで、フレームワークはKerasを使用した。

入力データとして、「現時刻までの解析雨量」「現時刻までの解析雨量に加え、予測雨量に見立てた予報時点までの解析雨量」「現時刻までの解析雨量に加え、現時刻時点で実際に得られる予報時点までの予測雨量」の3つを設定し、予測雨量を用いるモデルではNNモデルとベイジアンNNの2つを作成し、計4ケースを10回ずつ学習・試験を行うことにより、入力となる雨量データが予測精度に及ぼす影響を評価した。ケース2は解析雨量を予測雨量に見立てることにより、予測雨量に誤差がない理想的な状況を想定している。ケース3とケース4は実際に流入量予測を行う際に得られる、誤差を含む予測雨量を利用する状況を想定している。解析雨量と予測雨量には、4節で説明した解析雨量および降水短時間予報を用いた。検討においては、現時刻より過去にさかのぼって利用する時間を「UsageTime」、現在から予測したい時間までを「LeadTime」とし（図-7）、この2つの時間をパラメータとして変化させた。

表-1 入力値一覧

Case	学習データ	学習データ
1	ダム流入量, 解析雨量	ダム流入量, 解析雨量
2	ダム流入量, 解析雨量 予測雨量(解析雨量)	ダム流入量, 解析雨量 予測雨量(解析雨量)
3	ダム流入量, 解析雨量 予測雨量(解析雨量)	ダム流入量, 解析雨量 予測雨量(解析雨量)
4	ダム流入量, 解析雨量 予測雨量(解析雨量)	ダム流入量, 解析雨量 予測雨量(解析雨量)

表-2 深層学習モデルの概要

階層	結合層	素子数
入力層	Flatten 層	-
第1層	Dense 層	1500
プーリング層	Dropout	
第2層	Dense 層	1000
プーリング層	Dropout	
第3層	Dense 層	500
プーリング層	Dropout	
第4層	Dense 層	30
出力層	Dense 層	1

表-3 学習の設定内容

種別	Case1	Case2	Case3	Case4
エポック数	100	100	100	100
バッチサイズ	2000	2000	2000	2000
繰り返し回数	-	-	-	500
活性化関数	relu 関数			
最適化関数	Adam			
ドロップアウト率	0.5			




図-7 現時刻を基準とした時間の表現

(1) 解析雨量のみを用いたモデル

a) 手法

ケース1では入力値に解析雨量のみを用いたモデルを作成する。本ケースで用いるデータは2007年から2018年までの解析雨量とダム流入量である。2007年から2017年までの10年分を学習用データとし、2018年のデータを試験データとする。Usage Time と Lead Time を各6時間分、パラメータとして変化させ検討を行った。

b) 検討結果

予測の結果、過去の雨量（解析雨量のみ）の場合の精度は表-4のようになった。本稿では流入量の実績値と予測値の相関を精度として扱う。表-4からは、Lead Time が長くなるほど精度が低下する傾向が見られ、予報時点が現時刻から遠くなるほど予測が困難になる結果が現れている。一方、Usage Time が長いほど精度が向上するわけではない結果も現れており、特にL=5やL=6といった場合では、U=3もしくはU=4の時に最も高精度な結果が得られている。加えて、対象ダムの洪水到達時間が1時間程度であることから、UsageTimeの情報が多すぎても精度向上には繋がらないと考え

表-4 ケース1の精度 (U:Usage Time, L:Lead Time)

	L=1	L=2	L=3	L=4	L=5	L=6
U=1	0.97	0.91	0.87	0.83	0.77	0.73
U=2	0.97	0.93	0.89	0.85	0.78	0.74
U=3	0.97	0.93	0.91	0.85	0.78	0.75
U=4	0.98	0.93	0.90	0.85	0.79	0.74
U=5	0.98	0.93	0.91	0.85	0.72	0.72
U=6	0.98	0.94	0.90	0.84	0.79	0.70

られる。以上のことから、以降に示すケース2以降では Usage Time を3時間と4時間のみ検討し、最終的に Usage Time は4時間を採用した。

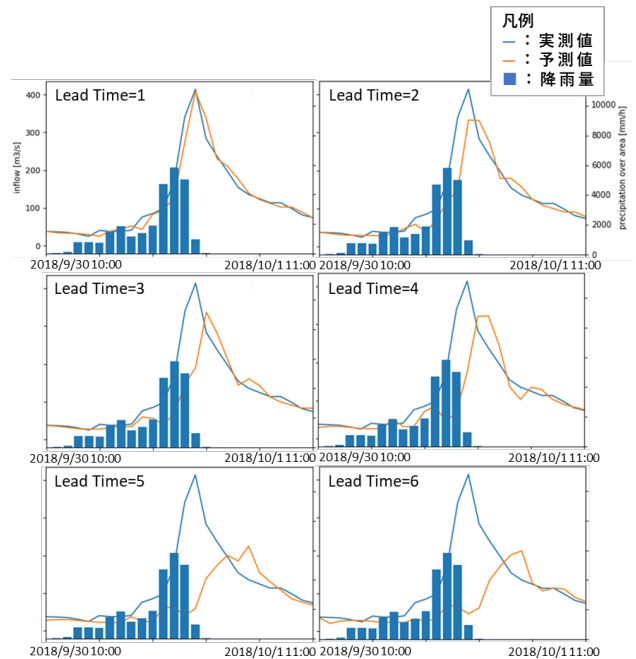


図-8 2018年台風24号時の宮ヶ瀬ダム流入量予測（ケース1）

図-8は、2018年台風24号時の宮ヶ瀬ダム流入量を、Lead Timeを変えながら予測を行った結果である。また、予測対象の最大値は400 m³/s程度であり、それと同程度の流入は10年間の学習データの中には計23回しかなかった。各予測結果を比較すると、LeadTimeが伸びるほど、実際の流入量よりも過小評価されると共に、予測の山が後ろにずれる傾向があり、特にLeadTimeが3時間以上かつ200mm/hを超える流入が発生した際に顕著である。このような結果から、ケース1の段階では実用可能と考えられるのは2時間先までの予測であると言える。

(2) 解析雨量と予測雨量に見立てた解析雨量を用いたモデル

a) 手法

ケース2では、現在までの降雨である UsageTime 分の解析雨量だけでなく、LeadTime 分の予測雨量も用いたモデルを作成した。ケース2では解析雨量を予測雨量と仮定し、入力に用いた。解析雨量を予測雨量に見立てるといのは予測雨量が完全に当たる、つまり、将来の降雨が完全にわかっているという状況を仮定している。前節と同様に、2007年から2017年までの10年分を学習用データとし、2018年のデータを試験データとし、Usage Time と Lead Time をパラメータとして変化させ検討を行った。

b) 検討結果

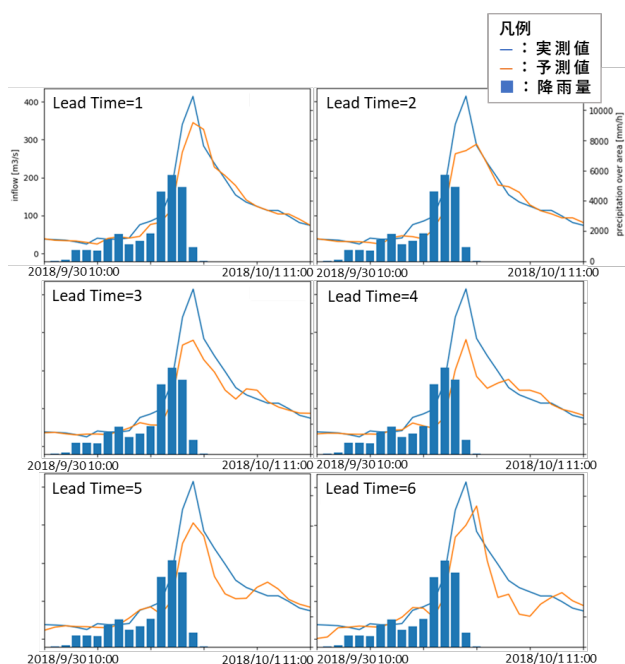


図-9 2018年台風24号時の宮ヶ瀬ダム流入量予測（ケース2）

表-5 ケース2の精度（U:Usage Time, L:Lead Time）

	L=1	L=2	L=3	L=4	L=5	L=6
U=3	0.98	0.97	0.94	0.94	0.90	0.89
U=4	0.98	0.96	0.95	0.94	0.94	0.93

図-9は、2018年台風24号時の宮ヶ瀬ダム流入量を、Lead Timeを変えながら予測を行った結果である。ケース1ではLead Timeが伸びるほど予測の山が実測値より後方にずれていたが、ケース2ではそのずれが小さくなっている様子が同図から見て取れる。また、ケース1と比較して、波形の過小評価も減少している。よっ

て、予測雨量が精度向上に大きく影響を与えることが示された。しかし、ケース2で用いた予測雨量は、予測が完全であると仮定して解析雨量を用いた場合のもので、現実では予測が完全ではないこととのギャップが実用上の問題として挙げられる。さらに、降雨予測が完全な精度を有しているという条件の下でも、流入量の予測結果には誤差が生じている。これは、ニューラルネットワークが頻度の低い事象を予測することを苦手としていることや、モデルの表現能力に起因した誤差と考えられる。

(3) 解析雨量と予測雨量を用いたモデル

a) 手法

ケース3では、ケース2の条件で予測雨量に見立てた解析雨量を用いた部分を実際の予測雨量である降水短時間予報を用いてモデルを作成する。予測雨量は試験データのみを用い、学習データでは解析雨量のままとした。前節と同様に、2007年から2017年までの10年分を学習用データとし、2018年のデータを試験データとし、Usage Time と Lead Time の各パラメータを変化させ検討を行った。

b) 検討結果

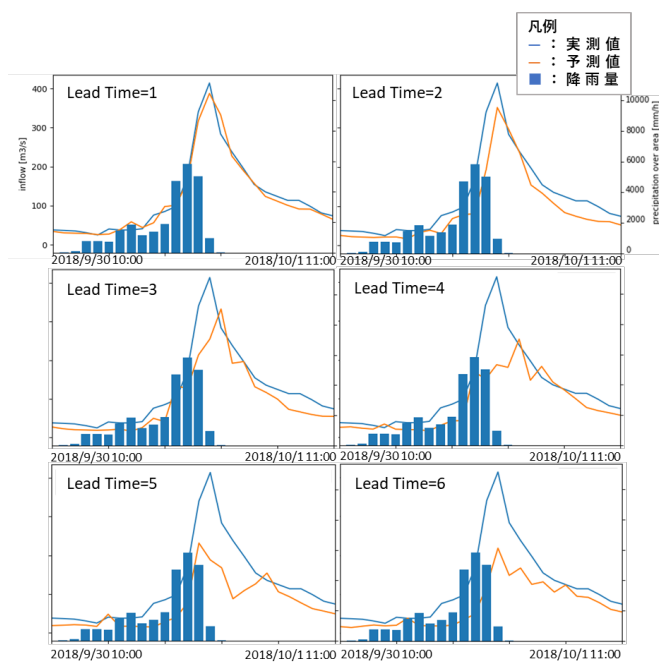


図-10 2018年台風24号時の宮ヶ瀬ダム流入量予測（ケース3）

図-10は、2018年台風24号時の宮ヶ瀬ダム流入量を、Lead Timeを変えながら予測を行った結果である。図-10より、LeadTimeが短い場合の予測結果は、ケース2の予測が完全である場合と大差ない。しかし、LeadTimeが伸びてくると降水短時間予報自体の精度が低下して

表-6 ケース3の精度 (U:Usage Time, L:Lead Time)

	L=1	L=2	L=3	L=4	L=5	L=6
U=3	0.94	0.89	0.89	0.87	0.86	0.85
U=4	0.97	0.92	0.89	0.86	0.87	0.87

くるため、予測精度も低下する。

以上のケース2やケース3より、ニューラルネットワークを用いた流入量予測においては、入力値のノイズ(予報雨量の不完全性)やデータ量(豪雨の低頻度性)、モデルの表現能力に起因する誤差が必然的に生じうる。そこで、これらの誤差要因を考慮した流入量予測を行う方法として、次節の検討で3節で説明したベイジアンニューラルネットワークを適用する。

(4) 予報降雨と BayesianNN の利用

a) 手法

気象庁が発表している降水短時間予報は完全ではなく、地域のずれやピークの不一致などの誤差がある。ケース4では、ケース3で作成したモデルに3節で説明したベイジアンニューラルネットワークを実装し、モデルとデータの誤差を数的に評価した。本研究ではモンテカルロドロップアウトの適用によって単一の入力データに対して500回の予測を行い、得られた結果の平均値と分散を利用した。

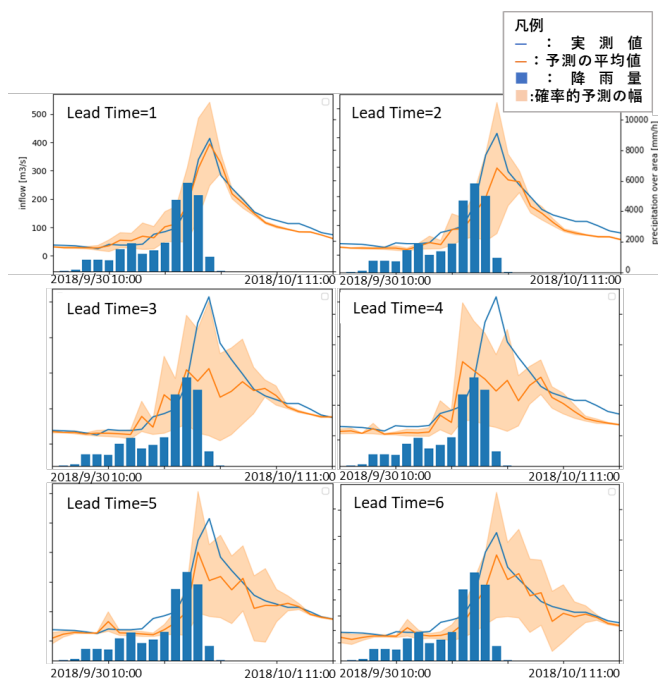


図-11 2018年台風24号時の宮ヶ瀬ダム流入量予測

b) 検討結果

図-11に、ケース1からケース3と同様に2018年台風24号時の宮ヶ瀬ダム流入量を予測した結果を示す。図-11では、分散から評価される95%の信用区間をオレンジ色の幅によって表現している。

ケース3と比較すると予測の平均値であるオレンジの線に大差はない。ケース4の確率的予測の結果は、信用区間の中に実測の流入量の大半の部分が重なっている。ドロップアウトにより試験時の出力結果が繰り返すごとに変化することで、様々なパターンを予測している。よって、ベイジアンNNによる予測の効果が確認された。ケース4でもこれまでと同様にLeadTimeが長くなるほど予測の平均値の精度が低下している様子がうかがえる。さらに、ケース4ではLeadTimeが長くなるほど確率的予測の幅が広がっており、予測結果のばらつきが大きいこともうかがえる。結果として、予測結果の幅が広く、実際の防災操作の判断基準になるとは言えない結果となっている。そのため今後の課題として、ベイズ推定を用いた確率的な予測の幅の縮小のために、説明変数の追加や検討を行う必要がある。また、予測結果の平均値に時系列の連続性があまり見られないことから、ドロップアウトを用いた学習過程において入力に用いた降雨データが0である部分の影響を受けた出力結果となっていると考えられる。この課題の解消のために、地中に浸透した降雨の流れも再現することが可能な流出モデルを用いたNNモデルも検討予定である。

6. おわりに

本研究では、ダムへの流入量を予測する手法として、流域への解析雨量と降雨予報を用い、ベイジアンニューラルネットワークを用いたモデルを作成し、各ケースのデータによる予測性能の検証を行った。

その結果、ケース1からケース3で用いたモデルの場合はデータやモデル自身の誤差が影響し、予測精度が向上しなかったが、ベイジアンニューラルネットワークを用いることによりモデル誤差による出力値の不確実性を表現することができた。この結果から、深層学習を用いたダム流入量予測における、誤差や不確実性の反映する手法としてベイジアンニューラルネットワークが有効であることが明らかになった。今後は、予報降雨量を学習データにも用いることにより、予報降雨量の誤差に伴う不確実性の表現も行いたいと考えている。

謝辞: 本研究の実施に当たり、国土交通省関東地方整備局相模川水系広域ダム管理事務所から多くの協力を

賜りました。記してここに深く感謝いたします。

参考文献

- 1) 田井明: 我が国の集中豪雨発生頻度の変化ならびに過去の水・土砂災害時の人的被害と降雨の関係, 土木学会論文誌 B1 (水工学), 68.4: L1057-L1062, 2012.
- 2) 特集 激甚化する豪雨災害から命と暮らしを守るために, 1 地球温暖化と大雨リスクの増加, 国土交通省気象庁, <https://www.jma.go.jp/jma/kishou/books/hakusho/2020/index1.html>, (最終閲覧日: 2021 年 7 月 1 日)
- 3) 土木学会水工学委員会 2017 年九州北部豪雨災害調査団, 平成 29 年 7 月九州北部豪雨災害調査報告書, 2020
- 4) 土木学会西日本豪雨災害調査団, 河川基金助成事業 2018 年 7 月西日本豪雨災害調査団 (四国地区) 報告書, 2018
- 5) 国土交通省 水管理・国土保全局 河川環境課, ダムの機能を最大限活用する洪水調節方法の導入に向けたダム操作規則等点検要領及び同解説, 2017.
- 6) 古木 宏和, 荒木 光一, 一言 正之, 野村 卓矢, 田方 智: 土木・防災技術者の暗黙知の深層学習と分野適用性の検討, 人工知能学会全国大会論文誌 第 34 回全国大会 (2020), p.205GS1301-205GS1301, 一般社団法人人工知能学会, 2020.
- 7) 全邦釘: 土木工学分野における人工知能技術活用のために解決すべき課題と進めるべき研究開発, AI・データサイエンス論文誌, 1.J1:9-15, 2020.
- 8) Noorbeh, P., Roozbahani, A., Kardan Moghaddam H. Annual and Monthly Dam Inflow Prediction Using Bayesian Networks. *Water Resour Manage* 34, 2933–2951 (2020).
- 9) Khan, M. S., and Coulibaly, P. Bayesian neural network for rainfall-runoff modeling, *Water Resour. Res.*, 42, W07409, doi:10.1029/2005WR003971, (2006).
- 10) Klotz, D., Kratzert, F., Gauch, M., Keefe Sampson, A., Brandstetter, J., Klambauer, G., Hochreiter, S., and Nearing, G.: Uncertainty Estimation with Deep Learning for Rainfall-Runoff Modelling, *Hydrol. Earth Syst. Sci. Discuss.* [preprint], <https://doi.org/10.5194/hess-2021-154>, in review, 2021.
- 11) 木村俊晃: 貯留関数法 (II) (IV-2), 土木技術資料, 4(1, 2, 5, 6, 7), 1962.
- 12) 菅原正巳: 流出解析法, 共立出版, 1972
- 13) 鈴木俊朗, 寺川陽, 松浦達郎: 実時間実時間洪水予測のための分布型流出モデルの開発, 土木技術資料, 38(10), pp.26-31, 1996.
- 14) 陸旻皎, 坂本朝子: 流出モデル予測流量のダム操作への活用に関する検討, 水文・水資源学会研究発表会要旨集, 24(0), pp.118-118, 2011.
- 15) 橋本徳昭, 藤田暁, 椎葉充晴, 立川康人, 市川温: 分布型流出モデルに基づくダム流入量予測システムの構築, 水工学論文誌, 50, pp.289-294, 2006.
- 16) 一言正之, 服部洋佑, 梶正範, 小野寺勝, 桜庭雅明: 斐伊川を対象としたニューラルネットワーク洪水予測の精度向上に関する研究, 河川技術論文誌, 18, pp.441-446, 2012. 土木学会論文誌 B1(水工学), 73(1), pp.22-33, 2017.
- 17) 一言正之, 澤谷拓海, 植西清: 深層強化学習を用いたダム操作モデルのダム流入量予測誤差に対する影響評価, AI・データサイエンス論文誌, 1(J1), pp.459-464, 2020
- 18) 天方匡純, 安野貴人, 藤井純一郎, 嶋本ゆり, 大久保順一: IoT を想定したダム流入量予測精度向上に関わる研究 水文・水資源学会誌, 32(6), pp.287-300, 2019.
- 19) 田村和則, 加納茂紀, 三浦心, 山脇正嗣, 金子拓史: ダム流入量長時間予測への深層学習の適用-ダム防災操作の効率化を目指して- 土木学会論文誌 B1 (水工学), 74(5)L, pp.1327-1332, 2018.
- 20) 関基, 木村晃, 古山一志, 和田高宏, 金子祐, 穴水秀樹, 眞間修一: 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 河川技術論文誌, 19, pp.295-300, 2013.
- 21) 一言正之, 桜庭雅明: 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
- 22) 佐山敬洋, 立川康人, 寶馨: 流出モデルの不確実性評価手法とそのモデル選択への適用. 土木学会論文誌, 789, pp.1-13, 2005.
- 23) 須山敦志: ベイズ推論による機械学習入門, 講談社, 2017.
- 24) Y. Gal.: Uncertainty in deep learning, PhD thesis, University of Cambridge, 2016.
- 25) 国土交通省 関東地方整備局: 第 24 回 関東地方ダム等管理フォローアップ委員会, 宮ヶ瀬ダム 定期報告書の概要, pp.4, 2015.
- 26) 宮ヶ瀬ダムについて, 国土交通省相模川水系広域ダム管理事務所, <https://www.ktr.mlit.go.jp/sagami/sagami00015.html>, (最終閲覧日: 2021 年 6 月 22 日)
- 27) 解析雨量, 国土交通省気象庁, <https://www.jma.go.jp/jma/kishou/known/kurashi/kaiseki.html> (最終閲覧日: 2021 年 6 月 22 日)
- 28) 降水ナウキャスト、降水短時間予報, 国土交通省気象庁, https://www.jma.go.jp/jma/kishou/known/kurashi/kotan_nowcast.html#kotan (最終閲覧日: 2021 年 6 月 22 日)

(Received June 30, 2021)
(Accepted August 31, 2021)

PROBABILISTIC PREDICTION OF DAM INFLOW WITH UNCERTAINTY IN FORECAST RAINFALL USING BAYESIAN DEEP LEARNING

Natsu MIURA, Takashi MIYAMOTO, Masazumi AMAKATA, Takato YASUNO and
Akira ISHII

In addition to physical models, statistical models such as deep learning have recently been used to predict high water levels in dams for the purpose of disaster prevention. In this study, we developed a deep learning model to predict the inflow to a dam using the observed and predicted rainfall in the inflow area as input, and examined the appropriate input information through a parametric study. Moreover, a Bayesian Neural Network was proposed as a method to represent the uncertainty of the predicted rainfall and the effect of the model error on the output values, and its effectiveness was verified. Numerical experiments show that the Bayesian Neural Network reflects the uncertainty of the output value according to the amount of training data in the confidence interval of the output, and that the inflow due to extreme rainfall that is not in the training range can be included in the prediction range.