

AIの信頼度評価に基づく ダム流入量予測システムの構築

DEVELOPMENT OF A DAM INFLOW PREDICTION SYSTEM BASED ON AI RELIABILITY ASSESSMENT

曾田康秀¹・若松聡²・楊枝秀之³・依田裕紀⁴
Yasuhide SOTA, Satoshi WAKAMATSU, Hideyuki YOJI and Yuki YODA

¹理博 (株)東京建設コンサルタント 環境防災研究所(〒170-0004 東京都豊島区北大塚1-15-6)

²(株)東京建設コンサルタント 東京本社環境防災本部(同上)

³(株)東京建設コンサルタント 東京本社情報技術部(同上)

⁴(株)東京建設コンサルタント 環境防災研究所(同上)

AIを用いたダム流入量予測では、未経験の降雨イベントに対して予測精度が著しく低下することが課題となっている。そこで本研究では、過去の大規模洪水数が限られているAダムを対象にRNNによるダム流入量予測モデルおよびRNNオートエンコーダによるAIの信頼度指標を導入し、AIと同じ教師データで構築された概念的物理モデル(貯留関数法)に対するAIの予測信頼度を評価した。未学習の既往最大洪水に対して、検証用データにより構築されたAIの信頼度が閾値を下回ると、AIモデルの予測精度が概念的物理モデルのそれより低くなることが示された。これにより未経験洪水が起きる前に概念的物理モデルに予測を切り替えることで、AIによる単独モデルよりも予測精度が向上する可能性が示された。

Key Words: encoder, dam inflow, RNN, rainfall-runoff analysis, deep learning

1. はじめに

近年、甚大な被害をもたらす豪雨が多発しており、今後も気候変動の影響により増加していくと考えられている。ダムはこれらの被害を抑えるための事前放流、異常洪水時防災操作、特別防災操作に加え、発電のための後期放流活用操作など、柔軟な操作を求められており、これらの操作を事前に適切に判断するためには、ダム流入量の予測精度が重要となる。その中の取り組みとして、AIによるダム流入量予測は、近年、MLP(多層パーセプトロン)やRNN(再帰型ニューラルネット)のモデルが有効であると報告されている。

MLPによる長時間のダム流入量予測では、これまでN時刻先までを一度に予測するモデルや1時刻先の予測を次の時刻の入力とする1時刻予測モデルが提案されており、前者のほうが精度が高くなることが示されている¹⁾。一方、時系列ネットワークから構成されるRNNでは1時刻前の出力を次の時刻の入力に代入して学習させることが可能であり²⁾、長時間学習にも有効であると考えら

れる。

AIによるダム流入量予測の問題点としては、経験したことのない規模の洪水に対する予測精度が低下することが知られている。これまでに予測対象の変化量に着目するやり方³⁾やデータ拡張の方法⁴⁾が提案されている。データ拡張の方法では、飽和流出係数1.0の条件で、さまざまな規模の定常降雨とそれによるダム流入量の組を教師データに加えて学習させることで、未経験洪水に対する長時間ダム流入量予測精度が向上することが示されている。一方で、精度の上がない例があるなど、検討の余地も残されている。

またMLPでの未来流入量の不定性に対する問題の解決策として入力に概念的物理モデルによる流量や貯留量変化を用いるハイブリッドモデルが提案されている^{5,6)}。概念的物理モデルでは、質量保存が考慮されている分、未経験洪水に対する予測精度はAIモデルよりも良くなる可能性がある。しかしながら、概念的物理モデルの予測精度はモデルパラメータの値に大きく依存し⁷⁾、未経験洪水に対する予測精度がAIモデルを上回る




図-1 RNN オートエンコーダにおけるスライド窓の時間範囲とネットワーク構造. 基準時刻を 0 として、 $-12 \leq i \leq 76$ の時間範囲の流域平均雨量がエンコーダの入力層に入る.

かは自明ではない.

以上から、本研究では対象流域における共通の出水データを用いてAIモデルと概念的物理モデルを構築し、RNNオートエンコーダを用いた信頼度指標を用いて両者の予測精度を比較する. オートエンコーダでは入力と出力が同じになるような学習を行うことで、データの特徴量が捉えられる⁸⁾. もしも教師データの特徴と合わない時系列データが入力されると、入力の復元誤差が増大する. またAIの予測精度は、教師データに用いられた降雨イベントの平均雨量強度にも依存すると考えられる. よって本研究ではRNNオートエンコーダによる降雨パターンの復元誤差と平均雨量強度を信頼度指標として導入し、AIモデルと概念的物理モデルとの予測精度との相関を調べる.

2. 対象流域と教師データの構築

対象となるAダムの上流の流域面積は約80km²で、基底流量は約10m³/sである. 以下では2006年から2020年までの4月から11月までの実績(国土交通省Cバンドレーダ雨量, ダム流入量)の1時間間隔のデータを収集・整理し、Aダム上流の流域平均雨量およびAダム流入量を取得した. また無降雨期の影響を低減するために、以下の手続きで年ごとに降雨イベントを抽出した. (a)年(S)ごとに24時間累加降雨が年最大になる時刻から、過去3日(72h), 未来2日間(48h)を切り出して年最大イベント(S₁)とする.

(b)年最大イベントを除いた期間で、24時間累加降雨が年最大になる時刻から過去3日, 未来2日間を切り出してイベント(S₂)を得る.

(c)以下, 24時間累加降雨が40mmを切るまでこれを繰り返し, S年のイベントS₁, S₂,...を取得する.

ただし先頭から24時間および末尾までの24時間無降

雨期が続くように各イベントの開始時刻と終了時刻を調整し、融雪の影響を除くため先頭の無降雨期での平均流量が15m³/s以上の降雨イベントを排除し、全部で128のイベントを抽出した.

次に学習後のモデルの予測精度を検証するために、ピーク流量値が300m³/sを越える上位4つのイベント(2011_1, 2008_1, 2013_1, 2010_7)のうち上位2つのイベントを含む以下の3出水をテスト用降雨イベントとして選択した.

- 2020_1 ピーク流量 150[m³/s] 多峰性
- 2008_1 ピーク流量 470[m³/s] 単峰性
- 2011_1 ピーク流量 639[m³/s] 多峰性

またテスト用イベント以外の、AI学習に用いる降雨イベントを教師用イベントと呼び、同じ年のデータが訓練と検証に分かれなように、降雨イベントの発生年で教師用イベントを4グループ(i)2008, 2012, 2016, 2020年, (ii)2009, 2013, 2017年, (iii)2006, 2010, 2014, 2018年, (iv)2007, 2011, 2015, 2019年に分類した. 以下では各グループに属する年の教師用イベントを検証用, 残りの年の教師用イベントを訓練用とする4種類のAIモデル(i)~(iv)を構築した. モデル(ii), (iii)は上位イベント2013_1(344 [m³/s]), 2010_8(315[m³/s])をそれぞれ訓練用を含んでいないため、他の2モデルに比べて、テスト用の上位2洪水の予測精度が下がると予想される.

3. AIおよび概念的物理モデルによる信頼度評価システムの構築

(1) RNNを用いた長時間ダム流入量予測モデルの構築

以下ではAダムの操作の実施判断を3日前から行うことを想定し、基準時刻の12時間前から76時間先までの範囲(図-1の時間範囲)をAI学習のスライド窓とする. 各降雨イベントに対し、開始時刻 t_s の12時間後から終




図-2 (a) 教師用 (青点)およびテスト用(赤点)の降雨イベントに対するプロットと直線近似のパラメータ最適解(赤線)。黒線は $R=F$ 。オレンジで囲まれたプロット点はイベント 2013_1 および 2011_1 に相当する。(b) 雨水保留量曲線の直線近似。

端時刻 t_e の76時間前まで基準時刻を1時刻ずつ未来方向にずらして $t_e - t_s - 89$ 個のスライド窓を構築し、125個の全教師用イベントから構築されたスライド窓を併せ、各スライド窓に識別Id (以下 I と表記する) を付与する。AIの学習や予測ではスライド窓単位でデータが入力される(既往文献²⁾ 図-4(a))。以下では各スライド窓 I の基準時刻を0とし、 i 番目時刻での流域平均雨量を $r_i(I)$ 、ダム流入量を $Q_i(I)$ とする。 $r_i(I), Q_i(I)$ の全スライド窓に対する期待値、標準偏差をそれぞれ $\bar{r}_i, \sigma_{r,i}$ および $\bar{q}_i, \sigma_{q,i}$ とし、 $r_i(I) (-12 \leq i \leq 76), Q_i(I) (-12 \leq i \leq 0)$ をそれぞれ $\bar{r}_i, \sigma_{r,i}$ および $\bar{q}_i, \sigma_{q,i}$ で正規化したものを説明変数、 $Q_i(I) (1 \leq i \leq 76)$ を $\bar{q}_i, \sigma_{q,i}$ で正規化したものを目的変数として教師データを構築する。学習時の評価関数は、ダム流入量の76時間先までのLeadTime出力と観測値の間の2乗平均平方根誤差(RMSE)

$$\Delta \hat{Q}_A(I) \equiv \sqrt{\sum_{i=1}^{76} (Q_i(I) - q_i(I))^2 / (76\sigma_{q,i}^2)} \quad (1)$$

とする(添え字AはAIモデルに依ることを指す)。学習時には訓練用イベントの全スライド窓をシャッフルしたものを16のバッチサイズに分割し、各バッチサイズごとにRNNの入力層に値を入れて確率的勾配降下法によりモデルの重みを学習させる。RNNモデルには長時間予測での逆誤差伝搬における勾配消失を回避するため60個のGRUユニットを用いた隠れ層1層のRNNモデルを適用し、その他のハイパーパラメータおよび学習方法については既往文献²⁾ と同様のものを用いた。

(2) RNNオートエンコーダによる信頼度指標の構築

以下ではAIモデルの信頼度を評価するために、RNNオートエンコーダによる信頼度指標を構築する。RNNオートエンコーダは、2つのスライド窓内のRNNネットワークを結合したseq2seq⁹⁾ から構成される(図-1)。以下では、教師データの各スライド窓における正規化された流域平均雨量 $\hat{r}_i(I) \equiv (r_i(I) - \bar{r}_i) / \sigma_{r,i} (-12 \leq i \leq 76)$

をエンコーダの入力およびデコーダのラベルとし(図-1)、入力に対するデコーダ出力 $R_i(I) (-12 \leq i \leq 76)$ の復元誤差

$$\varepsilon(I) \equiv \sqrt{\sum_{i=-12}^{76} (R_i(I) - \hat{r}_i(I))^2 / 89} \quad (2)$$

を評価関数として、前節のダム流入量予測と同様の深層学習を行う。各スライド窓の復元誤差 $\varepsilon(I)$ は、スライド窓 I 内の降雨分布の平均強度に比例して大きくなることから、ここではオートエンコーダの優位性を確認するため、もう一つの信頼度指標として89時刻分の正規化された平均降雨強度 $\bar{r}(I)$ を以下のように設定する。

$$\bar{r}(I) \equiv \sum_{i=-12}^{76} \hat{r}_i(I) / 89 \quad (3)$$

(3) 貯留関数法を用いた概念的物理モデルの構築

AIモデルの概念的物理モデルに対する予測信頼度を評価するために、AIと同一の教師データ、同一の評価関数の下で最適化された概念的物理モデルを構築する。概念的物理モデルとしては、星らによって提案された二価非線形貯留関数法を用いた^{10, 11)}。このモデルではkinematic wave法との対応により、複数のモデルパラメータを一つのパラメータ f_c (流域平均粗度) だけで表現できる¹¹⁾。以下テスト用イベントを除く125の教師用イベントのダム流入量ハイドログラフから直接流出量を求め^{7, 12)}、それから得られる累加有効降雨を累加降雨から差し引いて流域保留量 F を得る。累加雨量 R に対して F をプロットすると、図-2(a)のようになる。この分布を近似するように、雨水保留量曲線¹²⁾ を飽和雨量 R_{sa} で傾きが s_1 から s_2 に変化する折れ線で図-2(b)のように近似し、図-2(a)の分布範囲に合うように (R_{sa}, s_1, s_2) の値を表-1のように離散化し、以下の手順で教師用イベント J の i 番目時刻 ($i_s \leq i \leq i_e$) の直接流出量に対して、計算流量 $Q_{c,i}(J)$ と観測流量 $q_i(J)$ の間の予測誤差




図-3 教師用スライド窓に対するAI優勢指標 μ と(a)信頼度指標 ε および(b)信頼度指標 $\bar{r}$ との関係。 $X(\equiv \varepsilon, \bar{r})$ として赤破線は $X(I) = \langle X \rangle$,黒破線は $X(I) = \langle X \rangle + k\sigma_X (k = 1, 2, 3, 4, 5)$ 。 (c)各区間IDごとのAI優勢なスライド窓の割合(赤), 中立なスライド窓の割合(緑), 物理優勢なスライド窓の割合(青)。 実線は $\varepsilon(I)$,破線は $\bar{r}(I)$ 。

表-1 貯留関数法最適化のためのパラメータ値

パラメータ名	値
R_{sa}	130,150,170
$s_1 R_{sa}$	80,90,100,110,120
s_2/s_1	0.6,0.7,0.8

$\Delta Q_e(J) \equiv \sum_{i=1}^{i_e} (q_i(J) - Q_{c,i}(J))^2$ を以下の手順で最小化する。

- 1) (R_{sa}, s_1, s_2) を固定し, イベントJに対して貯留方程式を解き $\Delta Q_e(J)$ を最小にするような f_c の値 $f_{c,\min}(J, R_{sa}, s_1, s_2)$ および $\Delta Q_e(J)$ の最小値 $\Delta Q_{e,\min}(J, R_{sa}, s_1, s_2)$ を求める。

- 2) 全教師用イベントJに対する総和

$$\sum_J \Delta Q_{e,\min}(J, R_{sa}, s_1, s_2)$$

が最小になるような (R_{sa}, s_1, s_2) の組 R_{sa}^*, s_1^*, s_2^* を求める。

- 3) (R_{sa}^*, s_1^*, s_2^*) を固定し, 各教師用イベントJに対して貯留方程式を解き, $\Delta Q_e(J)$ を最小にするような f_c の値 $f_{c,\min}(J, R_{sa}^*, s_1^*, s_2^*)$ を求める。
- 4) 全ての教師用イベントJに対する $f_{c,\min}(J, R_{sa}^*, s_1^*, s_2^*)$ の分布の平均値を f_c^* とする。

以上の手続きで求めたパラメータの最適値 $f_c^*, R_{sa}^*, s_1^*, s_2^*$ での雨水保留量曲線を描くと図-2(a)の赤線ようになる。以下ではこのパラメータ値の下で, 各教師用イベントJに対して二価非線形貯留方程式を解き, イベント内の各時刻を基準時刻とするスライド窓Iの計算流量 $Q_{c,i}(I)$ と観測流量 $q_i(I)$ の間の正規化されたRMSEを

$$\Delta \hat{Q}_c(I) \equiv \sqrt{\sum_{i=1}^{i=76} (Q_{c,i}(I) - q_i(I))^2 / (76\sigma_{q,i}^2)} \quad (4)$$

と表記する。

4. AIモデルと概念的物理モデルの信頼度と予測精度の比較

(1) AIモデルおよび概念的物理モデルに対する信頼度指標と予測誤差の関係

以下では全教師用イベントのスライド窓(教師用スライド窓)に対して,前章で定義された信頼度指標とAIモデル優勢指標 $\mu(I) \equiv \Delta \hat{Q}_A(I) - \Delta \hat{Q}_c(I)$ との関係について考察する。AI学習時に検証に用いられた教師用スライド窓Iに対して式(2),(3)でそれぞれ定義された信頼度指標 $\varepsilon, \bar{r}$ と $\mu(I)$ の関係をプロットすると図-3(a), (b)のようになる。 $\mu < 0$ ではAIモデルのほうが概念的物理モデルよりも予測誤差が小さくなる。以下では $X(\equiv \varepsilon, \bar{r})$ と表記し, $X(I)$ のIに対する平均値, 標準偏差をそれぞれ $\langle X \rangle, \sigma_X$ とする。図-3(a), (b)の赤の破線は $X = \langle X \rangle$, 黒の破線が $X = \langle X \rangle + k\sigma_X (k = 1, 2, 3, 4, 5)$ を表しており, 各点線の間の区間を下から順に信頼区間ID=0~5とする。図-3(c)に各区間でのAIモデル優勢($\mu < -0.1$), 中立($-0.1 < \mu < 0.1$), 概念的物理モデル優勢($\mu > 0.1$)となるスライド窓の割合を示す。

教師用およびテスト用3イベントのスライド窓に対する信頼度指標 $\varepsilon, \bar{r}$ と $\Delta \hat{Q}_A(I)$ の関係は図-4のようになる。イベント2011_1のスライド窓については, $X(\equiv \varepsilon, \bar{r})$ のいずれにおいても, $X(I) > 3\sigma_X$ で $\Delta \hat{Q}_A(I)$ に不連続な跳びが見られるが, イベント2008_1については, $\varepsilon(I), \bar{r}(I)$ で大きな違いがみられる。 $\varepsilon(I)$ の値は $\varepsilon(I) > 3\sigma_\varepsilon$ となり, 平均降雨強度は教師用イベントのスライド窓と同程度だが, エンコーダの復元誤差が大きくなる例となっている。以下ではテスト用スライド窓の跳びがみられる範囲 $X_c \equiv \langle X \rangle + k\sigma_X (k = 3, 4, 5)$ を信頼度指標の閾値と定義する。




図-4 テスト用3イベントのスライド窓に対する予測誤差 $\Delta\hat{Q}_A$ と(a)信頼度指標 ε および(b)信頼度指標 $\bar{r}$ との関係。灰色の点は教師用スライド窓。 $X(\equiv \varepsilon, \bar{r})$ として赤破線は $X(I) = \langle X \rangle$, 黒破線は $X(I) = \langle X \rangle + k\sigma_X (k = 1, 2, 3, 4, 5)$ 。





図-5 (左)テスト用 3 イベントに対する AI の信頼度 $\eta_\varepsilon(t_I), \eta_{\bar{r}}(t_I)$ 。黒の破線は下から $\eta_C = 1/6, 1/5, 1/4$ を表している。緑色の矢印は $\varepsilon(I)$ が $\eta_\varepsilon(t) < \eta_{C,max}$ となる時刻。(右)テスト用 3 イベントの 76 時間先ダム流入量予測に対するハイドロハイトグラフ。灰色の実線は 1 時間平均されたダム流入量の観測値。紫の実線および破線は、それぞれパラメータ $f_c^*, f_{c,min}(J, R_{sa}^*, s_1^*, s_2^*)$ に対する概念的物理モデル最適解。緑色の矢印は $\eta_\varepsilon(t) < \eta_{C,max}$ となる時点から 76 時間後の時刻。

右図の凡例



(2) テスト用イベントに対する信頼度と予測誤差の関係

以下では $X(\equiv \varepsilon, \bar{r})$ の $\langle X \rangle$ からのずれの逆数として、スライド窓 I の信頼度を

$$\eta_X(I) \equiv \sigma_X / (|X(I) - \langle X \rangle| + \sigma_X) \quad (5)$$

と定義すると、 $0 < \eta_X < 1$ が成り立つ。信頼指標の閾値 X_C に対する信頼度の閾値は、式(5)から X に依らず $\eta_C \equiv 1/6, 1/5, 1/4$ となり、前節の信頼指標の振る舞いから

$\eta < \eta_{C,max} \equiv 1/4 (X_C = \langle X \rangle + 3\sigma_X)$ でAIモデルの予測誤差が増幅し、概念的物理モデルが優勢になると考えられる。

テスト用イベントの時系列に対して、スライド窓 I の基準時刻を t_I として、信頼度 $\eta_\varepsilon(t_I), \eta_{\bar{r}}(t_I)$ をプロットすると、図-5(左)のようになる。2020_1では $\eta_\varepsilon(t_I), \eta_{\bar{r}}(t_I)$ のいずれも閾値を下回らずAI優勢となっている。一方、イベント2008_1, 2011_1では、 $\eta_\varepsilon(t_I)$ が閾値 $\eta_{C,max}$ を下

回った時刻以降, 76時間後のピーク流量は観測値の半分程度になっている(図-5(右)). 2008_1では $\eta_{\varepsilon}(t_i)$ は閾値 $\eta_{c,max}$ を下回らず, 平均雨量強度では特異と判定されなかった. このことは $\varepsilon(I)$ の方が $\bar{r}(I)$ よりも信頼度指標として有効であることを示唆している.

図-5(右)より, 既往最大洪水2011_1に対しては, $\eta_{\varepsilon} < \eta_{c,max}$ となった時点で予測を概念的物理モデルに切り替えることで, 76時間後のダム流入量の予測精度を向上できる. 一方, 2008_1では概念的物理モデルの流量誤差が大きいため, $\eta_{\varepsilon} < \eta_{c,max}$ でも物理優勢にはならない. 図-5(右)の紫の破線は f_c^* による最適化ではなく, イベントごとに個別最適化された $f_{c,min}(J, R_{sa}^*, s_1^*, s_2^*)$ を用いた場合の概念的物理モデル解である. 2008_1の個別最適解では, AIモデルよりも概念的物理モデルが優勢になることが確認できる.

5. まとめ

本研究では, 同一の教師データおよび評価関数でAIモデルおよび概念的物理モデルを構築し, RNNオートエンコーダの復元誤差およびスライド窓の平均雨量強度を信頼度指標とし, AIダム流入量予測誤差との相関を調べた. また信頼度指標に基づく信頼度を導入し, テスト用イベントの信頼度低下とダム流入量予測誤差の関係を調べた.

3つのテスト用イベントのうち, ピーク流量の大きい2イベントでは信頼度 $\eta_{\varepsilon} < \eta_{c,max}$ となった時点で, AIモデルの76時間後の予測誤差が増幅することが示され, エンコーダの復元誤差が信頼度指標として有効であることが示された. また既往最大洪水2011_1では, η_{ε} が閾値を下回った時点で, 予測を概念的物理モデルに切り替えることで予測精度が上がることを示された. 本モデルは, データ拡張モデル⁴⁾と異なり, 概念的物理モデルとの併用により, 流出係数や降雨波形に依らず適用できる. 一方, 2008_1のような中小規模の降雨イベントでは, 概念的物理モデルへの切り替えにより精度が向上せず, パラメータ同化のような概念的物理モデルの個別最適化の必要性が示された.

今後は, パラメータ同化や分布型流出モデルを適用すること等概念的物理モデルの予測精度向上および本モデルの他流域への適用可能性の検討, オートエンコーダの先行降雨への対応等が課題となる.

謝辞: 本論文の作成にあたり, 必要な情報や適切な助言をくださった(株)東京建設コンサルタント環境防災研究所の渡邊明英先生をはじめ同研究所研究員の方々に感謝申し上げます.

参考文献

- 1) 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, 土木学会論文集 B1(水工学) 74 巻, 5 号, 2018.
- 2) 曾田康秀, 成岱蔚, 小島崇, 渡邊明英, 若松聡, 錦織俊之, 中小規模出水に対するエンコーダ付きRNNダム流入量予測モデルの構築とその精度評価, 土木学会論文集B1(水工学), 78巻, 2号, pp.I_157-I_162, 2022.
- 3) 一言正之, 桜庭雅明: 学習事例を上回る大洪水に対する深層学習水位予測モデルの検証, 人工知能学会全国大会論文集(第32回) セッションID:1D1-03, 2018.
- 4) 一言正之, 荒木健, 箱石健太, 遠藤優斗: 深層学習を用いたダム流入予測における学習データ拡張の適用性検証, 土木学会論文集B1(水工学), Vol.78, No.2, pp.I_175-I_180, 2022.
- 5) 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, 土木学会論文集 B1(水工学), Vol.73, No.1, pp.22-33, 2017.
- 6) 中村要介, 関本大晟, 阿部 紫織, 新井 章瑋: RRI モデルとディープニューラルネットワークによる河川水位予測, 土木学会論文集 B1(水工学), Vol.77, No.2, pp.I_313-I_318, 2021.
- 7) 藤村和正, 井芹慶彦, 岡田将治, 鼎信次郎, 村上雅博, 洪水流出を対象とした貯留関数パラメータの不確実性低減に向けた解析的研究, 土木学会論文集 G(環境), Vol.72, No.5, pp.I_35, pp.I_45, 2016.
- 8) 櫻田麻由, 矢入健久: オートエンコーダを用いた次元削減による宇宙機の異常検知, 人工知能学会全国大会論文集(第 28 回), セッション ID:2F3-2, 2014.
- 9) Sutskever, I., Vinyals, O. and V. Le, Q.: Sequence to Sequence Learning with Neural Networks, <https://arxiv.org/abs/1409.3215v3>, 2014.
- 10) 星清, 村上泰啓: 小流域における総合貯留関数法の開発, 第 31 回 水理講演会論文集, pp.107-112, 1987.
- 11) (財)北海道河川防災研究センター・研究所: 実践流出解析ゼミ 講義テキスト編 pp.8-15, 2006.
- 12) 角屋睦, 流出解析手法(その 1), 農業土木学会誌, Vol.47, No.10, pp.811, pp.821, 1979.