

河川水位データの異常値検出システムの開発

Development of the anomaly detection method of water level
data

田所 正 Tadashi Tadokoro (一財)河川情報センター 審議役

岡田 治 Osamu Okada

(一財)河川情報センター 河川情報研究所 研究第2部 主任研究員

渡辺 有 Yu Watanabe

(一財)河川情報センター 河川情報研究所 研究第2部 研究員

辻本 哲郎 Tetsuro Tsujimoto

(一財)河川情報センター 河川情報研究所 所長

目次

I. はじめに

II. 異常値検出モデルの開発

1. ベクトル自己回帰 (VAR) モデルの開発
2. 標準偏差 (3σ) モデルの開発
3. 上流に水位観測所のない場合の比較データの取り方
4. 従来の異常検知手法からのフィードバック

III. モデルの精度検証

1. 3σ モデルと VAR モデルの比較検証
2. 大規模洪水時における 3σ モデルの効果検証

IV. AI (深層学習) モデルの開発

1. LSTM-Encoder Decoder の概要
2. モデルの構築
3. 検証結果

V. テレメータ異常値検出システムの構築

VI. 今後の課題

VII. おわりに

I. はじめに

近年豪雨災害が多発し、毎年のように河川氾濫による甚大な被害が繰り返されている。この状況を踏まえて、国土交通省では「流域治水」を主要施策に掲げ、従来の河川改修やダム建設等によるハード対策だけでなく、土地利用規制や避難誘導等のソフト対策を強化し、流域毎に関係機関が連携して効果的な施策展開を図ることとしている^{1),2),3)}。

この方針に沿って地域住民の防災・減災活動を促進していくためには、迫り来る洪水の危険度を速やかに伝えることが必要となり、全国に配置されている約 6,800 箇所のテレメータ水位観測所のデータを迅速・的確にわかりやすく提供することが重要となる。このため現在では、10 分毎に観測される水位データをテレメータシステムで即時に集約し、国土交通省等の web サイト



図-1 国土交通省-川の防災情報 web サイト

から、危険度が直感的に把握できるように情報発信している(図-1, 図-2, 表-1 参照)。

一方で、水位計は河道内に設置されて厳しい自然環境の中で計測を続け、洪水流等による強い外力も受けるため、センサの流失・土砂による埋没・テレメータ機器の故障等が生じて異常値がいつ発

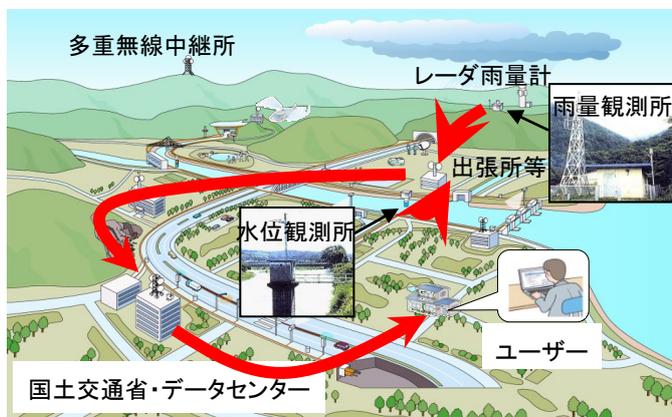


図-2 テレメータシステム概要図

表-1 テレメータ観測所数
(2022年3月末現在)

所管	雨量	水位
国土交通省	2,402	2,010
都道府県	5,050	4,774
気象庁	1,286	-
合計	8,738	6,784



図-3 水位計の異常事例
(左：土砂堆積，右：ゴミの付着)

生してもおかしくない状況にある（図-3 参照）。特に，データの急上昇・急降下は住民避難のタイミングを大きく誤らせる可能性があるため，早期に発見し

なければならない。

表-1 に示すとおり，テレメータ水位観測所は全国に約 6,800 箇所配置されており，テレメータ雨量観測所（約 8,700 箇所）等のデータとともに，全国の各地方センターにおいて 24 時間体制でリアルタイムデータに異常値が含まれていないか監視が行われている。

異常値を見つけるためには，まず計算システムによって異常の疑いのあるデータの抽出を行い，それを人間（技術と経験を持つ技術者）の目で判定することが必要になる。ところが，従来の計算システムにおける異常値の抽出方法は，対象とする一観測所だけのデータを使ったものであり，近隣観測所のデータとの比較がなされないため抽出精度が低く，正常値を異常値とみなす「空振り」が多発し，特に大規模出水が発生すると人間の目で判断するのに膨大な時間を要する状況にあった。

このような現状を踏まえて，筆者らは近隣観測所データを取り込むことによって高精度に異常値を抽出する計算手法の開発に取り組み，複数のモデルを比較検証しながら，災害時においても実用性の高いモデルを構築した。以下の章で詳述するが，洪水予測手法を援用した「ベクトル自己回帰 (VAR) モデル」と水文データの品質照査手法を援用した「標準偏差 (3σ) モデル」をそれぞれ開発し，比較検証を行った結果「 3σ モデル」が高い精度を示すこととなった。これらのモデルの開発と検証は 2020～2021 年度に行われ，2022 年度より 3σ モデルが全国のリアルタイム監視体制の中で実用に供されている。

本論文は，これらの異常検知モデルの開発から実用化に至るまでの取組みについて，技術的な観点を中心としてとりまとめたものである。なお，2018 年以降に洪水時のみデータ観測する危機管理型水位計が全国に広まり，約 8,500 箇所のデータがテレメータ水位観測所データに加えて配信されている。データ特性が異なることから本論文の対象にしていないが，今後研究を進め精度の高い

異常値検出システムを検討してまいりたい。

II. 異常値検出モデルの開発

10分毎に収集される全国の観測データを使って異常検知を行うために、以下の観点からモデルの検討を行った。

- ・重要な異常値の「見逃し」がなく、「空振り」をできるだけ減らすこと
- ・数分以内に全観測所の計算を終える必要があるため、計算時間の比較的短い計算式を用いること
- ・リアルタイム監視の担当技術者にも理解できるよう、河川管理等の実務上使用実績のある計算式を極力選ぶこと

水文・水理解析に用いる各種の計算手法のうち、計算時間を要する非線形モデル等を除外して検討した結果、以下に示す2通りの計算式を候補とすることにした。

モデル1：ベクトル自己回帰 (VAR (Vector Auto Regression)) モデル

時系列分析に用いられる統計モデルで、2つ以上の変数 (Vector) の過去データから自己回帰 (Auto Regression) 式を求め、1時刻先のデータを予測し、一定の許容範囲を超える1時刻先のデータを異常とみなすもの。

簡易な洪水予測モデルでも活用されている。

モデル2：標準偏差 (3 σ) モデル

統計学の基本指標である標準偏差 (σ) を2つ以上の変数の過去データから求め、平均値 $\pm 3\sigma$ の許容範囲を超える1時刻先のデータを異常とみなすもの。

水文データの品質照査実務においても活用されている。

以下に各モデルの計算手法等について詳述する。

1. ベクトル自己回帰 (VAR) モデルの開発

時系列データ $x_{1:n} = (x_1, x_2, \dots, x_n)$ と時系列データ $y_{1:n} = (y_1, y_2, \dots, y_n)$ の関係性を p 時点前までの古い情報を用いて求める場合、ベクトル自己回帰モデルの基本式は以下の通りとなる。

$$Y_t = C_1 + \phi_{11}Y_{t-1} + \dots + \phi_{1p}Y_{t-p} + \phi_{21}X_{t-1} + \dots + \phi_{2p}X_{t-p} + \epsilon_{1t}$$

$$X_t = C_2 + \phi_{31}Y_{t-1} + \dots + \phi_{3p}Y_{t-p} + \phi_{41}X_{t-1} + \dots + \phi_{4p}X_{t-p} + \epsilon_{2t}$$

この関係式を上下流に位置する複数の水位観測所データに適用し、以下の方法で異常の疑いのあるデータに VAR フラグを立てて抽出することにする。

チェック対象観測所水位 (H_a) と、主にその上流に位置する近傍観測所水位 (H_b, H_c, \dots) の、過去 2 時間 (10 分毎に 12 個)*1 の観測水深 (= 観測水位 - 観測所毎の平水位) を合わせたデータを上式に適用し、データの二乗平均誤差 $\sigma^2(H_{at-1}, \dots, H_{at-12}; H_{bt-1}, \dots, H_{bt-12}; H_{ct-1}, \dots, H_{ct-12}; \dots)$ が最小となる回帰係数 $\alpha, \beta, \gamma, \dots$ を算出し、下式より H_{at} を推定する。

$$H_{at} = \alpha + \beta H_{bt} + \gamma H_{ct} + \dots$$

A の推定値が観測値と比べて 30cm*2 以上乖離する場合に、フラグを立てる。近傍水位観測所は、当該河川の直上流にあるものと主要な支川の最下流観測所を選び、洪水到達時間 (観測所間距離を流速 3m/s*3 で割り戻し算定) 相当過去に遡った観測値を同一時刻のデータと見なして扱った。

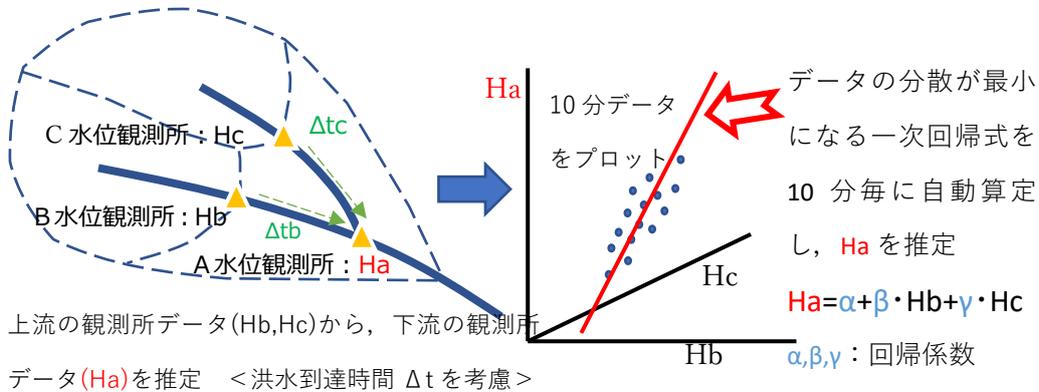


図-4 ベクトル自己回帰 (VAR) モデル概念図

*1 : 計算の初期条件となる各種パラメータを定めるために、全国の水位観測所から約 10 箇所のデータを選んで比較計算を行った。過去に遡る時間を 30 分, 1 時間, 2 時間, 3 時間, 6 時間の各ケースで計算を行い、最も適合度の高い (空振りが少なく見逃しが無い) ケースとして 2 時間を採用した。

*2 : *1 と同様に約 10 箇所のデータを対象に、10, 20, 30, 40, 50cm の各ケースで計算を行い、最も適合度の高いケースとして 30cm を採用した。

*3 : 観測所間の流下時間は雨の降り方によってさまざまに変化するが、上流側の

変化を見逃すことがないように、速めの流速値を採用した。

2. 標準偏差(3σ)モデルの開発

標準偏差(σ)の計算式は以下のとおりである。

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

n: データの総数 x_i : 各データの値 \bar{x} : データの平均

データ群からσを求め、例えば平均値±3σの許容範囲を超えるものを外れ値とすることは、工業製品の品質管理等さまざまな産業分野で古くから導入されており、国土交通省が定める「水文観測データ品質照査の手引き」においても降水量と水位データの外れ値を抽出する手法として活用されている。

「水文観測データ品質照査の手引き」においては、一つの対象観測所における時間毎のストックデータを対象にσを求めているが、本モデルでは10分毎に受信する複数観測所の過去2時間分のデータ*1(12個×観測所数)からσを求めることとした。具体的な計算手法は以下のとおりとする(図-5参照)。

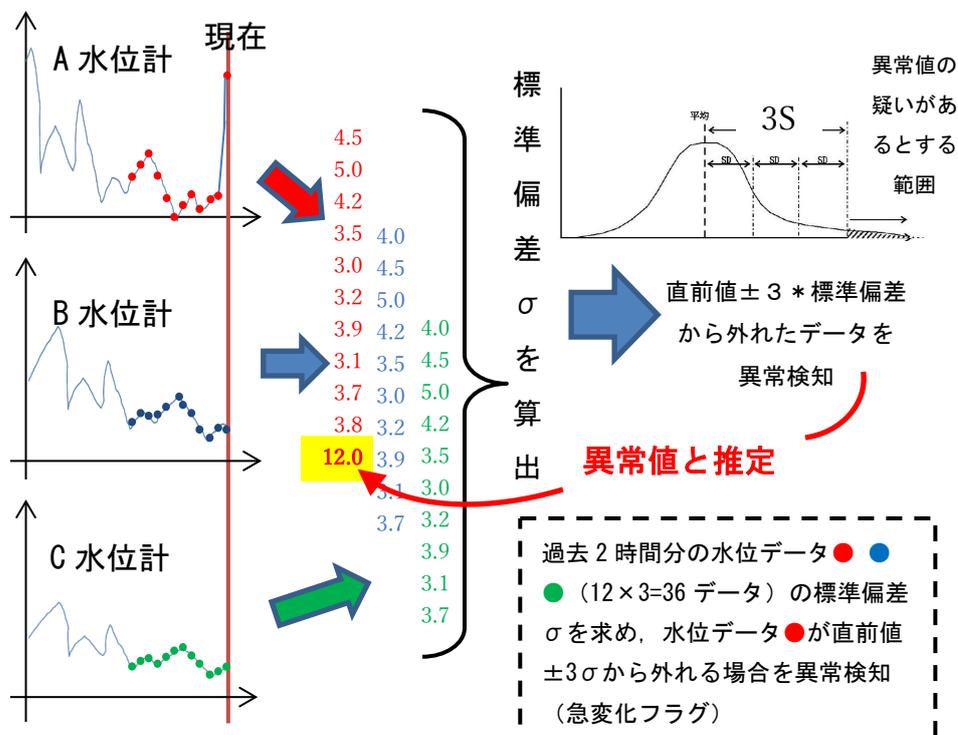


図-5 標準偏差(3σ)モデル概念

チェック対象水位観測所（A）と、主にその上流に位置する近傍水位観測所（B, C...（配置は図-4 参照））の、過去2時間(12個)の観測水深（＝観測水位－観測所毎の平水位）*4を合わせたデータ群の標準偏差 σ を自動的に求め、「現在水位A」が「直前水位A $\pm 3\sigma$ 」を超える場合に、異常の疑いがあるデータとして抽出する（急変化(3 σ)フラグを立てる）。

*4：当初、標準偏差 σ を求める対象データは、以下の2種類を候補とした。

①観測水位（観測所毎のゼロ点高からの差）

②観測水位の10分間の増減値

しかし、①の場合には、全国の観測所の中にはゼロ点が河床付近に設定されていないものがあり、ゼロ点を一律 T.P. 0m にしている地域も見られるため、 σ が想定外に大きくなる。このため、観測所毎に統計値として整理されている平水位を用いて（観測水位－観測所毎の平水位）を対象データとすることとした。

また、②のデータを用いて簡単に試算を行ったが、 σ が小さくなりやすいことから洪水の立上り時の許容範囲（ $\pm 3\sigma$ ）が狭くなり、フラグの空振りが生じやすいことがわかったため、この方法も棄却した。

3. 上流に水位観測所のない場合の比較データの取り方

モデル1：VARモデル、モデル2：3 σ モデル共に、チェック対象水位観測所Aの上流側に水位観測所が無い場合には、観測所上流域のレーダ雨量計データから疑似的な比較水位データを以下の方法で作ることとした*5（図-6参照）。

国土交通省の水防災オープンデータ提供サービス（河川情報数値データ配信事業）*6によって、オンラインCバンドレーダ合成雨量データ（5kmメッシュ、5分間隔）が提供されている。観測所上流域内のメッシュ番号をGISソフトによって抽出し、メッシュ番号に該当するデータから自動的に洪水到達時間内の流域平均雨量を求める。

以下に示すとおり、水位から流量を求めるマニング式ⁱと雨量から流量を求める合理式ⁱⁱを結合し変換することによって、雨量から水位を求める換算式ⁱⁱⁱを作ることができる。これによって比較データとなる換算水位 ($H_t = C \times R_t^{3/5}$) *7を求める。

i. マニング式

$$Q_t = (\text{河積}) \cdot (\text{径深})^{2/3} \cdot i^{1/2} / n \doteq (H_t \cdot B) \cdot (H_t)^{2/3} \cdot i^{1/2} / n$$

$$= (i^{1/2} \cdot B / n) \cdot H_t^{5/3}$$

ii. 合理式

$$Q_t = A \cdot f \cdot R_t / 3.6$$

iii. 両式の右辺を結合し変換

$$H_t = (n \cdot A \cdot f / (3.6 \cdot i^{1/2} \cdot B))^{3/5} \cdot R_t^{3/5} = C \cdot R_t^{3/5}$$

H_t : 時刻 t の観測水位,

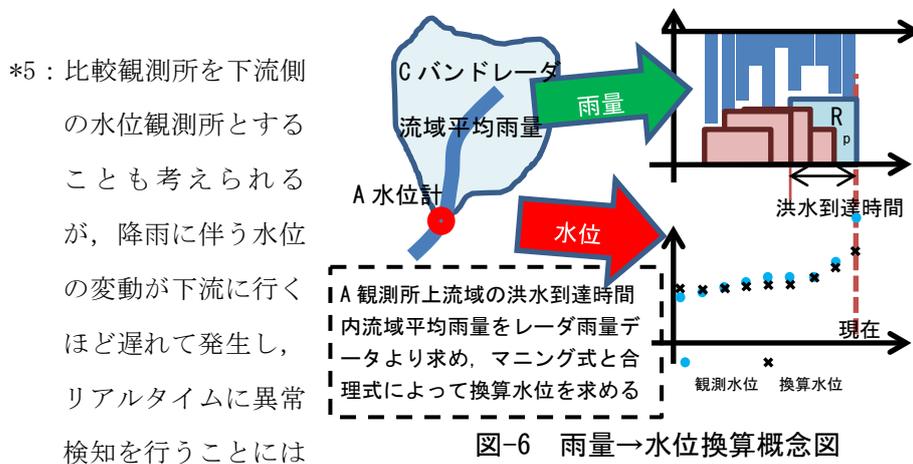
R_t : 時刻 t の洪水到達時間内平均降雨強度 (mm/h) , f : 流出率

A : 水位計地点の流域面積 (km²) , B : 川幅 (m) , i : 河床勾配,

n : マニングの粗度係数 (m-s 単位)

なお、降水量のデータから上記の簡易式で水位を求めても精度は十分ではなく、正確性を求める予測計算等に適用することはできない。本研究の目標は異常値を効率的に見つける実用的なシステムを開発することにあるため、ある程度の空振りは許容しながら、降水量も比較対象データとすることにした。

また、全国の観測所を対象にレーダデータを自動的に取得し流域平均雨量を算出するためには、新たなシステム開発が必要となるため、III章に示す検証においては手法を簡略化し、流域内の代表的なテレメータ雨量観測所データを降水量 R として、V章のシステム再構築の時にレーダ雨量データを扱うシステムを併せて開発することとした。



適さないため、棄却した。降水量から水位を疑似的に算出することは、水位予測等を行うためには正確性に欠けるが、異常検知の比較データとして降雨に伴う波形の変化を遅滞なく確認するためには十分に目的を達成できると判断した。

*6：水防災オープンデータ提供サービス

(<http://www.river.or.jp/koeki/opendata/>)

*7：iii式右辺の定数Cは、河道特性や流域面積等によって観測所毎に変化する性格を有する。流域面積が100km²程度の観測所を10カ所程度抽出して、実洪水時のデータから逆算してみたところ、Cは概ね0.3~0.6の値を示した。異常検知の比較観測所データとして詳細な精度は求められないことから、全ての観測所にC=0.5を適用することとした。

4. 従来の異常検知手法からのフィードバック

これまでのリアルタイム監視実務においては、主に以下の方法で異常の疑いのある水位データを抽出していた。

- ① 急変化フラグ：50cm/時間*⁸以上の増減
- ② スパイクフラグ：30cm/10分*⁸以上の増加と減少の連続
- ③ 無変化フラグ：洪水時は2時間*⁸以上の無変化

平常時は72時間*⁸以上の無変化

*8：地方別の特性や観測所の特性によって数値を変えている

リアルタイム監視の実務を担当する技術者からのヒアリングの結果、「①急変化フラグの空振り件数が多く実務に支障を来しやすい」「②スパイクフラグ③無変化フラグは実務上有用である」という意見が多かったため、①の代わりにVARフラグか3σフラグを採り入れ、②③の計算式は以下の通り改良を加えて、引き

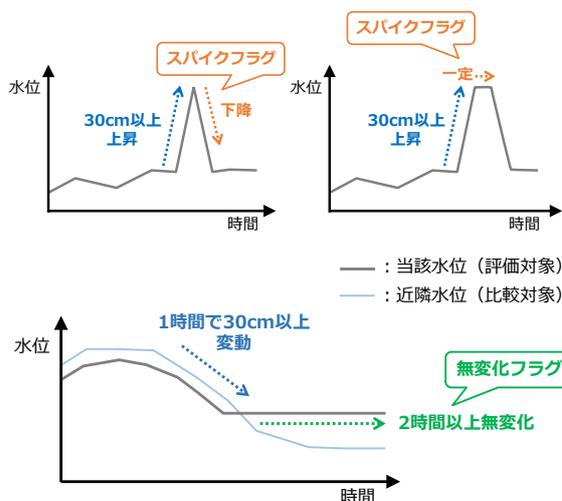


図-7 スパイク・無変化フラグ概念図

続き活用することとした。

②スパイクフラグ (図-7 上) : 「水文観測データ品質照査の手引き」におけるスパイクノイズの上限値が 0.3m であることを踏まえ、10 分間で 30cm 以上水位が上昇 (または下降) した直前か直後に水位が上昇 (または下降) していない時に「スパイクフラグ」を立てる。

③無変化フラグ (図-7 下) : 現行のデータ監視ツールにおいて出水時に 2 時間以上水位変動が無い観測データを抽出している観測所が多いことを踏まえ、当該または近隣観測所の水位が 1

時間で 30cm 以上変動した後、当該水位が 2 時間以上無変化の場合に、無変化フラグを立てる。

また、ダムや堰の操作や潮汐の影響を受ける観測所では、流水の自然な時間変化と異なる急

表-2 観測所特性による閾値の増減

項目	急変化フラグ	スパイクフラグ	無変化フラグ
通常の観測所	$0.1\text{m} < \sigma < 0.5\text{m}$	10分間で30cm	2時間以上無変化
ダム・堰操作の影響がある観測所	$0.2\text{m} < \sigma < 1.0\text{m}$	10分間で60cm	4時間以上無変化
潮汐の影響がある観測所	$0.2\text{m} < \sigma < 1.0\text{m}$	10分間で60cm	2時間以上無変化

変化や無変化が生じやすい。このような観測所に対しては、表-2 のとおり各フラグの閾値 (正常値とする許容範囲) を当面倍に設定することとした。

これらの閾値は、今後モデルの実運用を数年程度行った後に、観測所毎の周辺環境特性等を踏まえて、観測所毎に細かく設定する予定である。

Ⅲ. モデルの精度検証

1. 3σ モデルと VAR モデルの比較検証

2019 年 7~9 月の期間に、リアルタイム監視における異常値が確認された下記の 4 観測所を対象に、①3σ モデル②VAR モデルとリアルタイムデータ監視の現行手法である③50cm/hr 超過チェックの 3 手法で異常検知計算を行い、各フラグに④無変化フラグ⑤スパイクフラグを加えた異常検知結果の精度検証を行った。

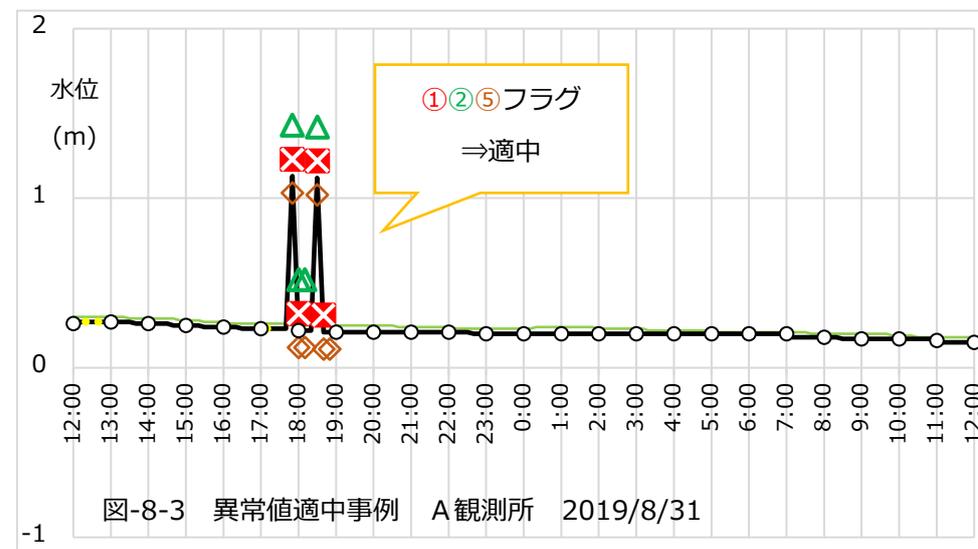
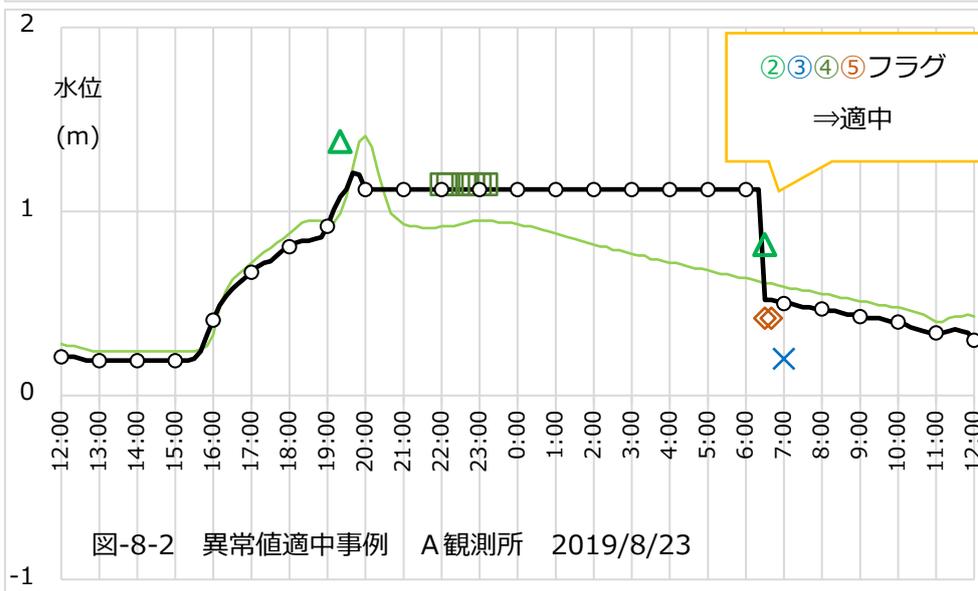
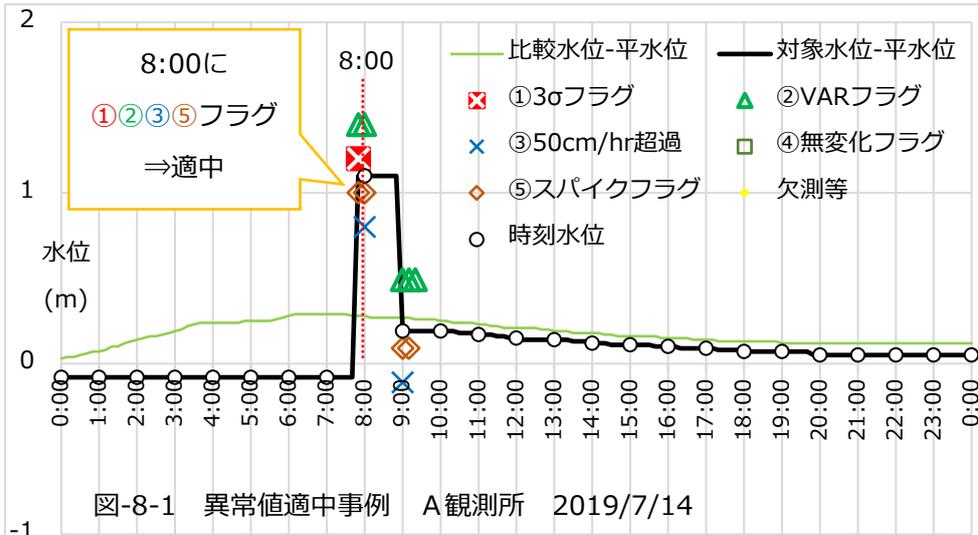
3 ヶ月間の計算結果として、4 観測所毎に「検知」されたフラグ数と監視員による異常値判定と「適中」した数を表-3 に示し、「適中」した 6 件の事例を図-8-1~6 に示す。

図-8-1～6 から見て取れるように、監視で異常が確認された 6 件の事例とも何等かのフラグが立っているが、表-4 の様に①～⑤のフラグの有無を整理すると、1 種類のフラグだけで全ての異常を抽出することはできていない。

表-3 の結果から見ると、②VAR フラグが最も適中数が多いこと、①～③とも④と⑤を併用すれば全てを適中することができることがわかった。

表-3 フラグ発生状況 2019 年 7～9 月

対象観測所	比較データ	異常件数	フラグ件数	①3σフラグ	②VARフラグ	③50cm/hr 超過	④無変化フラグ	⑤λ°イフ
A	水位	3	検知	3	4	3	1	3
			適中	2	3	2	1	3
B	水位	1	検知	3	2	9	0	1
			適中	1	1	1	0	1
C	降水量	1	検知	0	1	7	1	0
			適中	0	0	0	1	0
D	降水量	1	検知	1	7	5	0	2
			適中	0	1	0	0	1
合計		6	検知	7	14	24	2	6
			適中	3	5	3	2	5



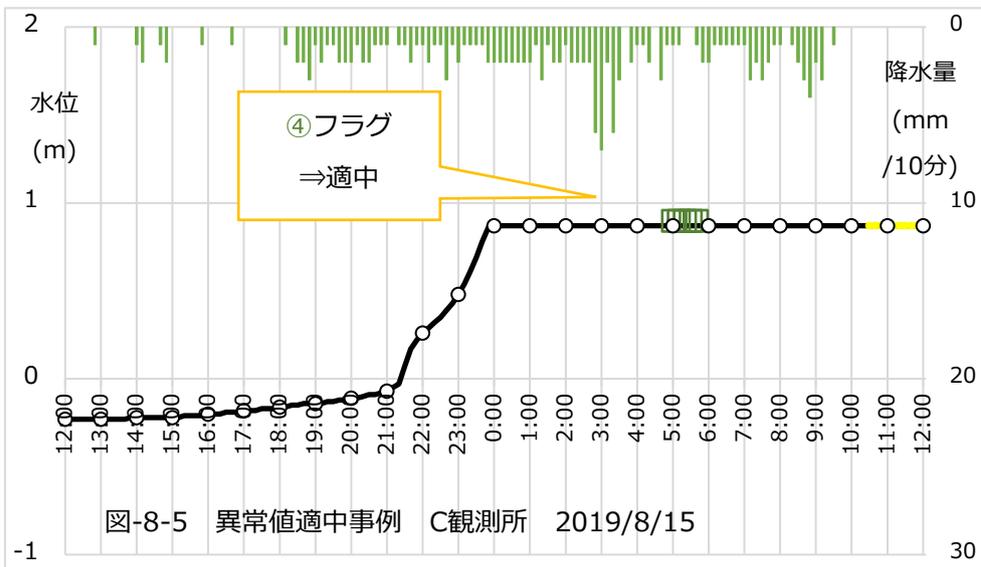
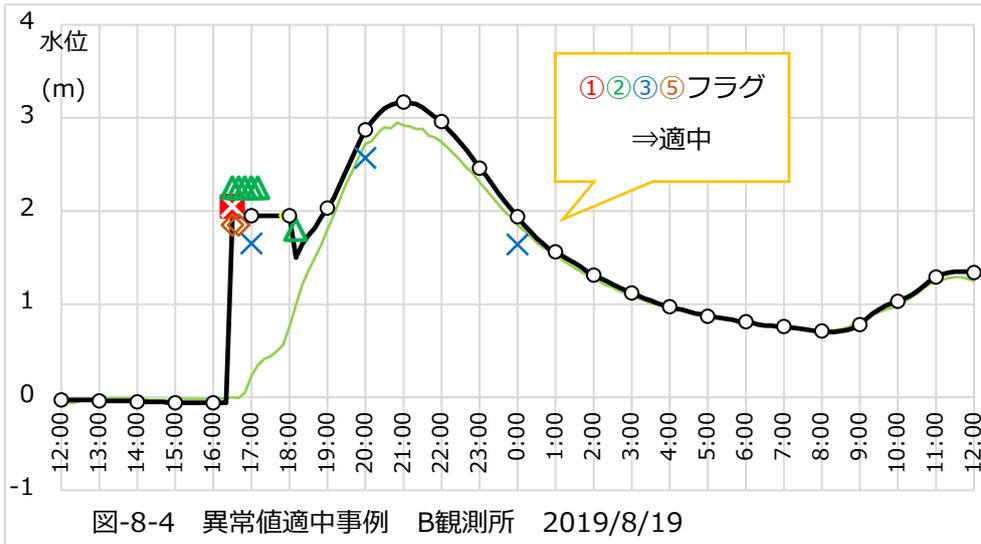


表-4 異常事例におけるフラグ発生状況

異常事例	観測所	発生日	①3σ フラ グ	② VAR フラ グ	③ 50c m/hr 超過	④無 変化 フラ グ	⑤ス パイク フラ グ
1	A	7月14日	○	○	○		○
2	A	8月23日		○	○	○	○
3	A	8月31日	○	○			○
4	B	8月19日	○	○	○		○
5	C	8月15日				○	
6	D	8月16日		○			○

4観測所の検証期間(7~9月)内に①~⑤のいずれかのフラグが立った事例は、上記の異常6件を含めて全体で30件確認された。言い換えれば、異常でないものにフラグを立てる「空振り」が24件発生したことになる。①~③の

フラグそれぞれに④と⑤を併用した場合のフラグ発生状況を整理すると、表-5のように、各モデルの「空振り」や「見逃し」の状況を確認することができる。

表-5 各モデルの精度評価

		A.適中 (異常)	B.見逃し	C.空振り	D.適中 (正常)	A+D. 適中合計
監視判定		×(異常)	×	○(正常)	○	
フラグ		×(あり)	○(なし)	×	○	
①3σ +④+⑤	件数	6	0	4	20	26
	比率	20%	0%	13%	67%	87%
②VAR +④+⑤	件数	6	0	9	15	21
	比率	20%	0%	30%	50%	70%
③50cm/hr +④+⑤	件数	6	0	22	2	8
	比率	20%	0%	73%	7%	27%

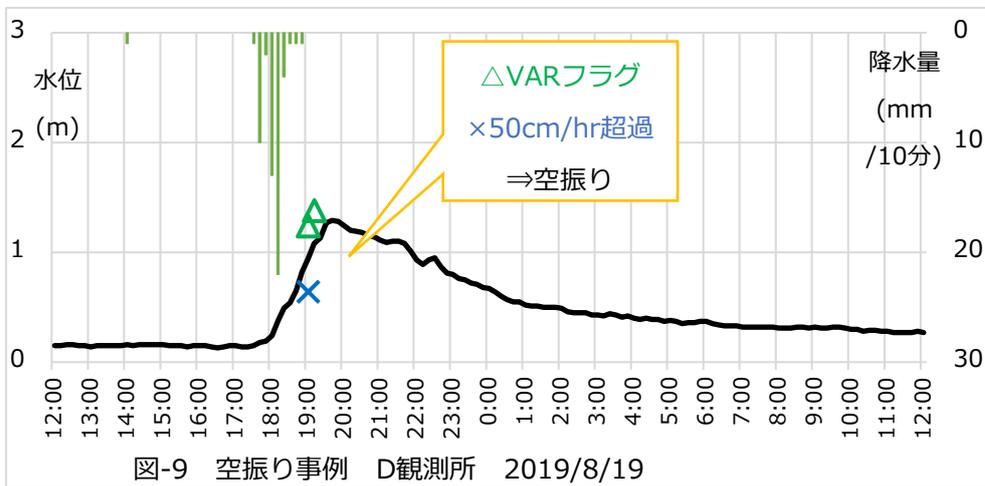
表-4と表-5から読み取れる結果を整理すると以下の通りになる。

- ①~③とも、④と⑤を併用すると、30件中6件の異常値を見逃すことなく確実に捕える(すべてA.適中しB.見逃しなし)ことができた
- C.空振り(正常値を異常検知)の発生数は①<②<③となり、①でA.適中の0.7倍の4件、②で1.5倍の9件、③で3.7倍の22件に上った。
- フラグの発生は特に出水時に集中する傾向があり、図-9の事例に見られ

るように、②と③のフラグは洪水初期のハイドログラフが立ち上がる時に空振りを多発することがわかった。

- ▶ 洪水発生中の繁忙時にリアルタイムデータ監視を確実に遂行させることが本検討の最大の目標であるため、見逃しがなく空振りの最も少ない① 3σ モデルを採用し、④無変化フラグ⑤スパイクフラグを併用して運用することとした。

(なお、今回の検証で確認した6件の異常値に限れば④無変化フラグ⑤スパイクフラグだけでも全てを適中できるが、近隣観測所データを含めたチェックがないと見逃しが生じることが過去からの課題であったため、①または②は必須なフラグとして残すことにした)



モデルの開発当初には、現在時刻の水位を予測して実際の観測値と乖離する時にフラグを立てる VAR モデルを本命と捉えていたが、種々のデータで計算して行く内に、以下の2つの事象に现阶段ではうまく追従できず空振りを多発することが明らかになった。

- ①急に発生した豪雨等により洪水波形が急激に立ち上がる時
- ②洪水のピーク時に水面のうねり等によって水位が上下動を繰り返す時

一方、 3σ モデルは予測値を計算するのではなく、直前のデータのバラつきから10分毎に閾値を求め、前時刻データから乖離する時にフラグを立てるものであり、上記①②の事象にも比較的うまく対応できていることがわかった。

3σ モデルは、洪水波形が立ち上がった後は閾値($\pm 3\sigma$)が上限値まで次第に広がるため、洪水時の精度は平水時に比べて低下するとも言える。しかしながら、実際の多様なデータを観察すると、洪水時の多くのデータは平常時にはあまり見られない急変動等が様々な形で発生しているのが現実である。このた

め、洪水時における閾値を広めに設定できる 3 σ モデルが、本来の目的である「大きな見逃しをなくし、空振りをできるだけ減らす」という課題により適合することとなった。

今後さらなるモデルの開発と改良の余地は十分に残されているが、実用化に向けて、3 σ モデルを基本として検討を進めて行くこととした。

2. 大規模洪水時における 3 σ モデルの効果検証

2019年10月に、近年の上陸台風としては最大級となる台風19号(東日本台風)が各地で深刻な被害をもたらした。この時のテレメータデータを用いて、関東地方の全観測所を対象に3 σ モデルの有効性について検証を行った⁴⁾。

結果は図-10に示すとおり、全245観測所中37観測所で3 σ (急変化)フラグ・スパイクフラグ・無変化フラグが立ち、その内62%に上る23観測所で異常値を適中させることができた。また、10/12~15の4日間に従来の方(50cm/hr超過)では合計886回のフラグが立ち、全数の処理が不可能な状況となることが明らかになった。急変化(3 σ)フラグも103回立っており、さらに絞り込む必要があるため、大規模洪水時には氾濫注意水位を超える場合のみを優先して抽出できるよう、実運用時にシステムを改良することとした(V章参照)。

期間：2019年10月12~15日(令和元年東日本台風による出水時)
 対象：関東地方整備局のテレメータ水位観測所(245箇所)
 検証方法：本手法と、リアルタイム監視および品質照査^{*}の結果を比較

検証結果 ※「水文観測業務規程」で義務付けられている水文観測データの品質照査

- ✓ スパイク・急変化・無変化フラグが検出：**37 観測所**
- ✓ **適中：23 観測所**
(リアルタイム監視での異常値：13 観測所をすべて検出)
- ✓ **空振り：14 観測所(明かな異常値でない)**
- ✓ **見逃し：1 観測所(品質照査での異常値)**
(リアルタイムで検出が困難な異常値であるため検討外)

⇒ 本手法の有用性を確認できた

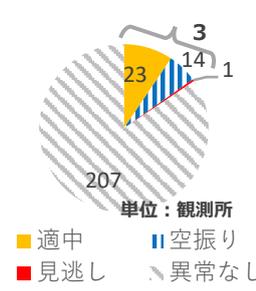




図-10 2019年東日本台風時における3 σ モデルの検証⁴⁾

代表的な事例(適中事例2件、空振り事例1件、見逃し事例1件)を図-11-

1~4 に示す.

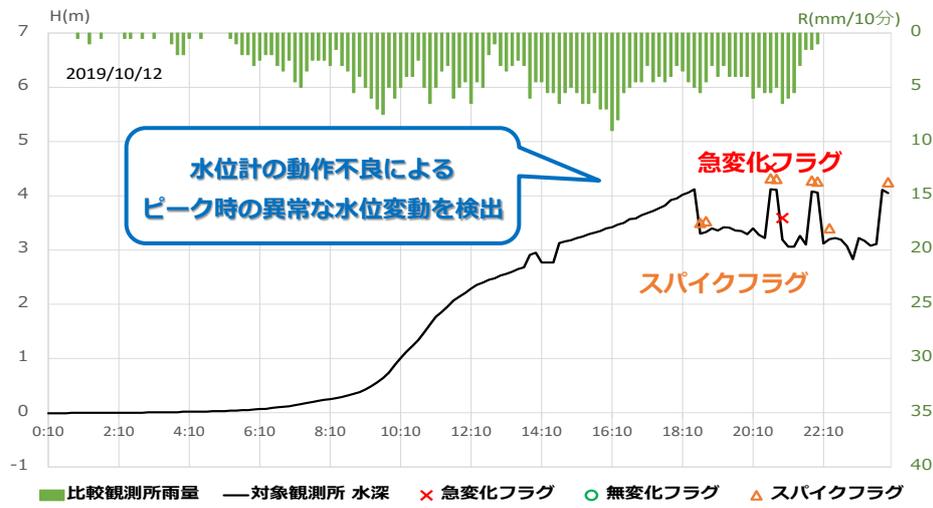


図-11-1 2019年東日本台風時 適中事例(1)⁴⁾

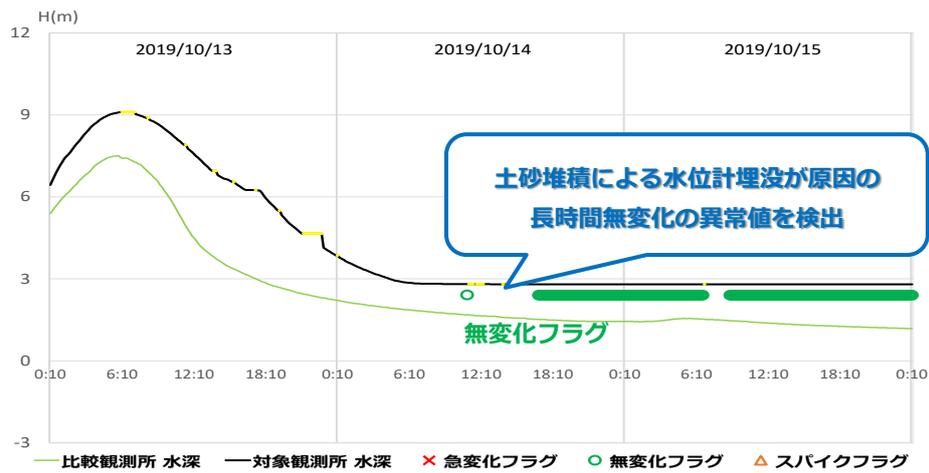


図-11-2 2019年東日本台風時 適中事例(2)⁴⁾

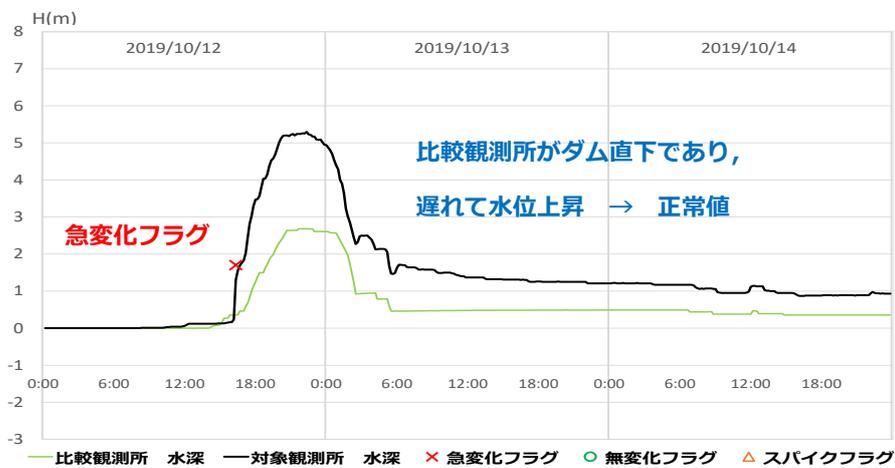


図-11-3 2019年東日本台風時 空振り事例⁴⁾

東日本台風の通過に伴って、関東平野の多くの河川では過去最大級の洪水となった。このため、センサの流失や埋没をはじめとして多くの観測所で近年見られなかった激しい水位変動を伴う異常値が発生した。245 観測所中の 37 観測所で異常値が発見されたことは、リアルタイム監視に関わる技術者にとって、想定を大幅に上回る衝撃的なものとなった。

図-11-3 のような空振りも、流域の小さい上流部の観測所を中心として 14 観測所で発生した。洪水の立上り時に多発しやすいフラグを最大限絞り込むことを主眼に置いて開発した 3σ モデルであるが、空振りを無くすことは簡単ではない。表-2 に示した観測所特性に応じた閾値設定をよりきめ細かく行うことなどによって、空振りを減らしていくことが今後の課題となる。

図-11-4 は本検証における唯一の見逃し事例である。このハイドログラフを



図-11-4 2019 年東日本台風時 見逃し事例⁴⁾

見ると、洪水ピーク後の水位遞減時に河道堆積等によって緩やかな水位上昇が発生したと推察される。このように、徐々に変化の発生する事例については、今回のモデルでは検出が難しいことが明らかになった。これに対処するため異常値を細かく検出できるようにモデルを改良する（許容範囲を狭める）ことも可能ではあるが、空振りの件数が大幅に増大することになるため、短時間に情報の錯綜することの多いリアルタイムデータ監視のためのモデルとしては扱わないことにした。このような長期的に発生する異常値等については、半年毎に行う水文観測データの品質照査作業で活用できるモデルを今後検討していくこととした。

IV. AI（深層学習）モデルの開発

時系列データから異常値を検出する技術として、AI を用いる様々な手法が提案されている。Malhotra らは、LSTM を予測モデルとして用いる手法⁵⁾、LSTM とオートエンコーダを組み合わせる再構築モデルとして用いる手法（LSTM-Encoder Decoder）⁶⁾、Zhang らは、Conv LSTM を用いて、ベクトル時系列データから異常値を検出する手法⁷⁾を提案して、従来の ARIMA モデル等を用いる手法よりも高い精度が得られると報告している。この内、LSTM-Encoder Decoder を用いる手法は、異常値検出のアイデアが明瞭であること等から、時系列データから異常値を検出する技術において、ベースラインの一つと見なされている。

異常値検出技術の研究では、様々なモデルが示す精度を効率的に比較して評価する観点から、公開されているデータセット（電力需要、心電図等）が用いられている。しかし、水位時系列データは、公開されているデータセットとは異なる特徴を持ち、正常値と見なされる時系列データにおいても、非出水時と出水時、非感潮区間と感潮区間、雨の降り方の違い等によって様々な形状を示す。このため、例えば、単一の学習済モデルを用いる場合に、非感潮区間と感潮区間の違いが異常値検出精度にどう影響するかは、興味深い疑問点であるが、十分な評価が実施されていない。

このような背景を踏まえ、筆者らは 2019 年より水位データの異常検知と洪水予測を対象にした深層学習モデルの開発を進めてきた⁸⁾。本章では、LSTM-Encoder Decoder を用いたモデルを開発し、3 章 (2) の検証と同じ 2019 年東日本台風時のデータを用いて、異常値の検出を行った結果を紹介する。学習データと検証データが共に 2019 年東日本台風時のデータであり、リアルタイムデータ監視を経て分類された正常データを抽出して学習データとしているため、単純な比較はできないが、概ね 3σ モデルの精度に近い結果を得ることができた。

1. LSTM-Encoder Decoder の概要

LSTM は、Hochreiter らが提案したニューラルネットワーク⁹⁾で、手書き文字認識、音声認識、音声合成等の系列データを扱う AI で用いられている。LSTM 内

部の LSTM セルにメモリ機能, ゲート機能を有していることにより, 従来の RNN モデルの勾配消失問題を効果的に解消している.

オートエンコーダは, Hinton らが提案したニューラルネットワーク¹⁰⁾で, 画像ノイズ除去, 異常値検出の AI で用いられている. このオートエンコーダは, エンコーダとデコーダにより構成されている. エンコーダは, 入力多次元ベクトルを潜在表現の別の多次元ベクトルに変換する役割を担っている. デコーダは, 潜在表現の多次元ベクトルを別の出力多次元ベクトルに変換する役割を担っている. エンコーダで次元数を絞り込んで, デコーダで入力多次元ベクトルの次元数に戻す砂時計型の構造とすることで, 入力多次元ベクトルに含まれる重要な特徴量を自己学習 (半教師有り学習) により自動抽出できるとされている.

LSTM-Encoder Decoder は, Sutskever らが提案したニューラルネットワーク¹¹⁾で, 機械翻訳等, 系列データから別の系列データを再構築する AI で用いられている. オートエンコーダのエンコーダに系列データの扱いに優れる LSTM, デコーダにも LSTM を用いている.

LSTM-Encoder Decoder を用いて, 時系列データから異常値を検出するアイデアは明瞭である. 自己学習には正常な時系列データのみを用いる. LSTM-Encoder Decoder に正常な時系列データをを入力して, 入力時系列データと LSTM-Encoder Decoder で再構築される出力時系列データとの平均絶対誤差が小さくなるように自己学習させる. 自己学習済 LSTM-Encoder Decoder では, 正常な時系列データが入力されると, 似た形状を学習済のため, 入力時系列データと出力時系列データとの平均絶対誤差が小さい時系列データが再構築されると期待される. 異常値を含む時系列データが入力されると, 未学習のため, 入力時系列データと出力時系列データとの平均絶対誤差が大きい時系列データが再構築されると期待される. 推定時には, 入力時系列データと LSTM-Encoder Decoder で再構築される出力時系列データとの絶対誤差を用いて, 絶対誤差が閾値以上の場合に入力時系列データに異常値が含まれていると判別する.

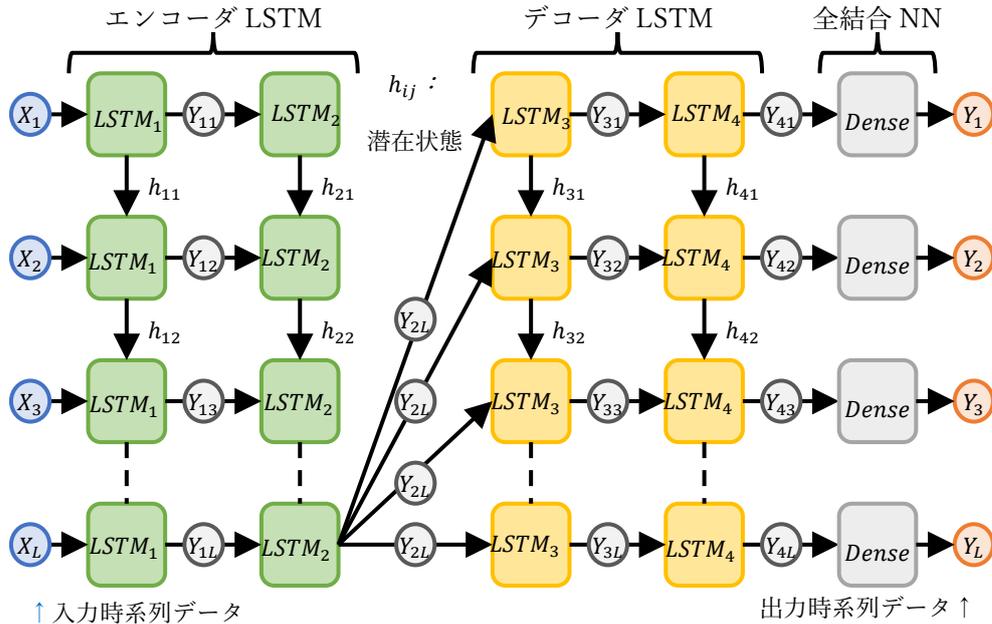


図-12-1 LSTM-Encoder Decoder の構造

図-12-1 に LSTM-Encoder Decoder の構造を示す. 入力データをウィンドウの長さ L の時系列データ $X = \{X_1, X_2, X_3, \dots, X_L\}$ とする. 左側 2 列の箱は, エンコーダ LSTM, その右隣 2 列の箱はデコーダ LSTM, 右側 1 列の箱は, 通常的全結合ニューラルネットワーク層を表す. X_i は入力時系列データ, $Y_{1i}, Y_{2L}, Y_{3i}, Y_{4i}$ は LSTM から出力される潜在表現の時系列データ, Y_i は出力時系列データを表す. X_i は 1 次元のベクトルである. Y_{1i} はウィンドウの長さ L に合わせて, 32 次元等のベクトル, Y_{2L} は 16 次元等のベクトル, Y_{3i} は 32 次元等のベクトルとする. Y_i は 1 次元のベクトルである. $h_{1i}, h_{2i}, h_{3i}, h_{4i}$ は LSTM の隠れ状態のベクトルである. 32 次元, 16 次元, 32 次元のように, オートエンコーダと同じような砂時計型の構造とする.

2. モデルの構築

GPU (NVIDIA GeForce GTX1080Ti) 内蔵の PC に, OS/Ubuntu20.04.1, 言語/Python3.8.10, ライブラリ/TensorFlow2.9.1 の環境, Valkov が GitHub に公開しているチュートリアル¹²⁾をベースに改良を加えた LSTM-Encoder Decoder モデルを構築した. ハイパーパラメータについては, 最適化のための特別な探索を行わずに, 損失関数が平均絶対誤差, 最適化アルゴリズムが Adam オプティマイザ, エポック数が 1000 とした. エンコーダ LSTM の入力形状は, (36, 1) で

タイムステップ数が 36 (10 分データ 6 時間分), 特徴量が 1 次元とした. エンコーダ LSTM の出力形状は, (36, 32), (16), デコーダ LSTM の出力形状は, (36, 16), (36, 32) で特徴量の次元数を 32, 16, 16, 32 の砂時計型とした.

Ⅲ章 2 において 3σ モデルの検証に用いた 2019 年東日本台風時の 248 観測所の水位時系列データを, 学習用の正常な水位時系列データ 192 件, 精度評価用の正常な水位時系列データ 28 件, 精度評価用の異常値を含む水位時系列データ 28 件に分割した. 学習と精度評価に用いた合計 248 件のデータは, それぞれ 4 日間 (10 分データで 576 タイムステップ) の水位時系列データである. 各水位時系列データは, 平均値と標準偏差を用いて, 平均値が 0, 標準偏差が 1 となるように前処理した. 閾値は F_1 が最大になるように選んだ.

ここで,

$$F_1 = 2 \times P \times R / (P + R),$$

$$P = \text{適中(異常)} / (\text{適中(異常)} + \text{空振り}),$$

$$R = \text{適中(異常)} / (\text{適中(異常)} + \text{見逃し}) \text{ である.}$$

河口部に近く感潮区間に位置する水位観測所では, 洪水時でなくても水位変動が繰り返される. 将来的には感潮区間と非感潮区間の学習データを分類して 2 つのモデルを構築することも可能であるが, 本研究ではデータを分類せずにどれだけの精度が得られるか, 1 つのモデルで学習と検証を行うこととした.

3. 検証結果

図-12-2 に非感潮区間と感潮区間の異常値検出結果, 表 6 に LSTM-Encoder Decoder による異常値検出の精度評価結果を示す.

LSTM-Encoder Decoder において, 短いタイムステップ数は学習時間をより短くして, 正常時の誤差をより小さくする効果がある. このため, 図-12-2 のとおり, 単一の学習済モデルを用いる場合でも, 非感潮区間と感潮区間の異常値を検出することができた.

表-6 のとおり, 本来異常の 28 件の内, A. 適中 (異常) は 28 件, B. 見逃しは 0 件, 本来正常の 28 件の内, C. 空振りは 12 件, D. 適中 (正常) は 16 件であり, A+D. 適中合計の比率は 79%となった.

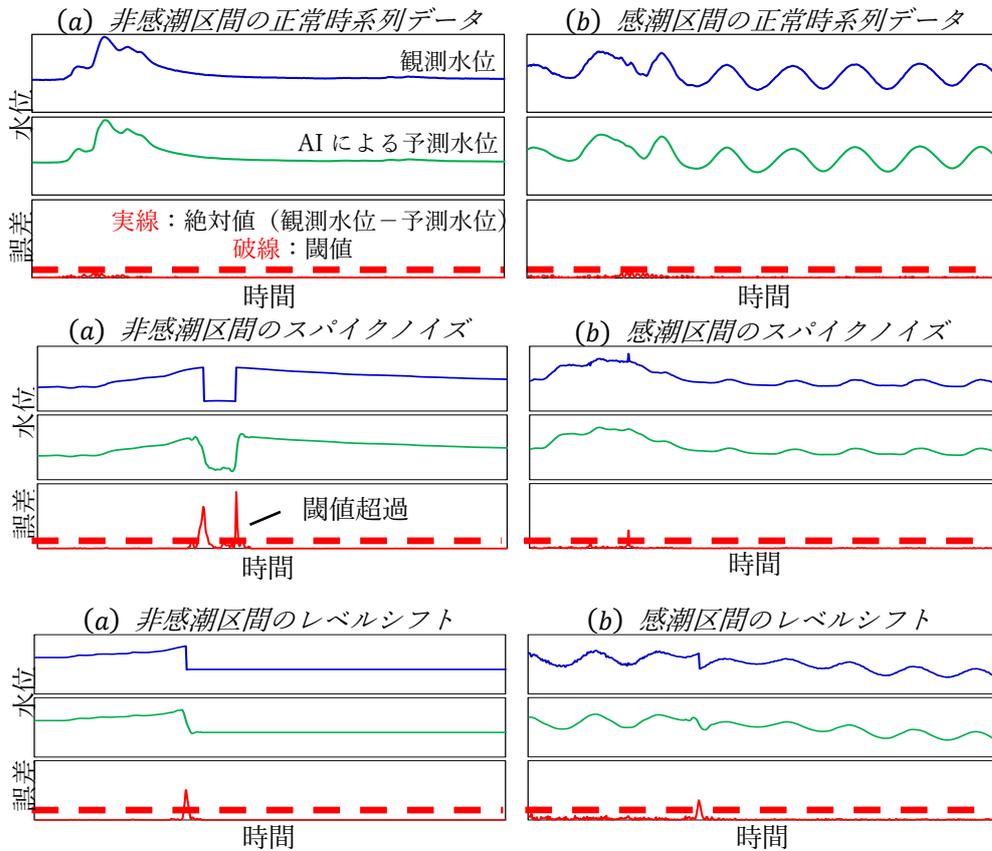


図-12-2 非感潮区間と感潮区間の異常値検出結果

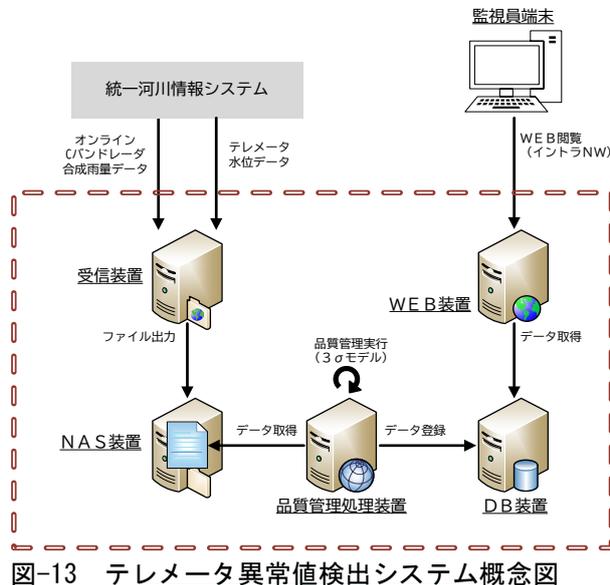
表-6 LSTM-Encoder Decoder による異常値検出の精度評価

		A. 適中 (異常)	B. 見逃し	C. 空振り	D. 適中 (正常)	A+D. 適中合計
AI モデル	件数	28	0	12	16	44
LSTM-ED	比率	50%	0%	21%	29%	79%
3 σ モデル	件数	6	0	4	20	26
III章1:表-5	比率	20%	0%	13%	67%	87%
3 σ モデル	件数	23	1	14	207	230
III章2:図-10	比率	9%	0.4%	6%	85%	94%

3章(1), (2)に示した 3σ +無変化フラグ+スパイクフラグによる精度検証とは対象データの取り方等の条件が異なるので、単純な比較評価はできないが、遜色のない適中比率を示すことができた。今後はモデルの改良や学習データの増加等によって精度向上を図り、将来的には実用性を十分有するシステム構築につないでいきたい。

V. テレメータ異常値検出システムの構築

以上詳述した開発と検証の結果を踏まえ、 3σ モデル（急変化（ 3σ ）フラグ）にスパイクフラグと無変化フラグを加えて、従来運用されてきたリアルタイムデータ監視システムをベースにしたテレメータ異常値検出システムを図-13 のとおり構築した。



主な装置は以下のとおりであり、1 台のサーバ内に各装置の仮想領域を確保し一体的に運用管理することとした。

①テレメータ水位・レーダ雨量受信装置

異常値抽出の自動計算に必要なテレメータ水位(TM)とレーダ雨量(RD)のデータを国土交通省の統一河川情報システムからリアルタイムに受信する機能を有する。

受信したデータはファイル形式で出力され、NAS 装置に保存される。

②品質管理（異常値検出）処理装置

「 3σ モデル」をベースとした自動計算を行い、異常値を検出する機能を有する。計算のためのデータはNAS 装置から取得し、自動計算結果はDB 装置に保存される。

③WEB（異常値検出結果出力）装置

図-14 に示す異常値検出結果を表示する「一覧画面」と異常値の検出された時の当該観測所データ・グラフを表示する「個別事例画面」を作成する機能を有する。

出力画面はイントラネットワーク上の端末からリアルタイム監視職員がweb 画面で閲覧できる機能を有する。

図-14 はリアルタイム監視実務で使用する画面であり、フラグ発生一覧表の

中の観測所名をクリックすると、フラグ発生事例毎の詳細なデータ一覧とハイ
ドログラフを確認することができるようになっている。

また、東日本台風を対象にした検証において、即時に対応すべきフラグをさ

①地方・河川等で
対象範囲を絞り込み

②クリック

個別事例画面

③異常の状況を
表とグラフで確認
(■がフラグ)

警戒フラグ一覧

観測日時	種別	管理者	観測所名
2022/8/18 5:10	SP2	京都府京都市土木事務所	鴨川
2022/8/18 4:30	SP2	京都府京都市土木事務所	鴨川
2022/8/17 21:50	SP2	関東建設事務所	正立川
2022/8/17 20:40	SP1	相模川水系広域ダ...	才戸橋
2022/8/17 20:30	SP2	相模川水系広域ダ...	
2022/8/17 19:30	SP1	相模川水系広域ダ...	
2022/8/17 19:20	SP1	相模川水系広域ダ...	
2022/8/17 4:40	SP2	中郡土木事務所	

観測日時	水位
2022/8/4 8:20	8.46
2022/8/4 8:30	8.45
2022/8/4 8:40	8.45
2022/8/4 8:50	8.43
2022/8/4 9:00	8.39
2022/8/4 9:10	8.36
2022/8/4 9:20	8.34
2022/8/4 9:30	8.31
2022/8/4 9:40	8.29
2022/8/4 9:50	8.33
2022/8/4 10:00	8.41
2022/8/4 10:10	8.51
2022/8/4 10:20	8.70
2022/8/4 10:30	8.70
2022/8/4 10:40	9.57

図-14 テレメータ異常値
検出システム 操作画面

上：一覧画面

右：個別事例画面

らに絞り込む必要があることが示されたため、観測所毎に設定された氾濫注
意水位を超過したデータ等を「警戒フラグ」として一覧画面の左側に示し、右
側に示す氾濫注意水位を下回る「注意フラグ」に優先して異常値処理等の対応
ができるようにした。

新しいシステムは2022年度より運用することを目標にして、2020年度にプ
ロトタイプモデルの構築を開始した。2021年度には、全国各地方でリアルタイム
データ監視を担当している技術者による試行運用を行い、良好な試行結果を
得ることができた。また、操作性・精度向上のための細かなシステム改良や諸
元（観測所特性等に応じた閾値等）の見直し等を行い、予定通り2022年4月よ
り新しいシステムへの移行を終えることができた。

2022年度の出水期は6月以降絶え間なく前線性降雨が続き、線状降水帯等による被害が多発した。これまでのシステムであれば、空振りとなるフラグの多発によりリアルタイム監視の現場が忙殺される状況が続いたと想定されるが、新しいシステムによって迅速で的確な対応を行うことが可能になっているという報告がなされている。

しかし、新しいシステムはまだスタートしたばかりであり、今後も改良の余地があることを念頭に置いて、リアルタイム監視を続けていく必要がある。

図-15は2022年7月を中心に発生し、いずれも水位が10分間で1.5m程度の急上昇を示し、観測所毎に設定している「氾濫危険水位」近くまで到達し、フラグが発生した3回の事例を示している。

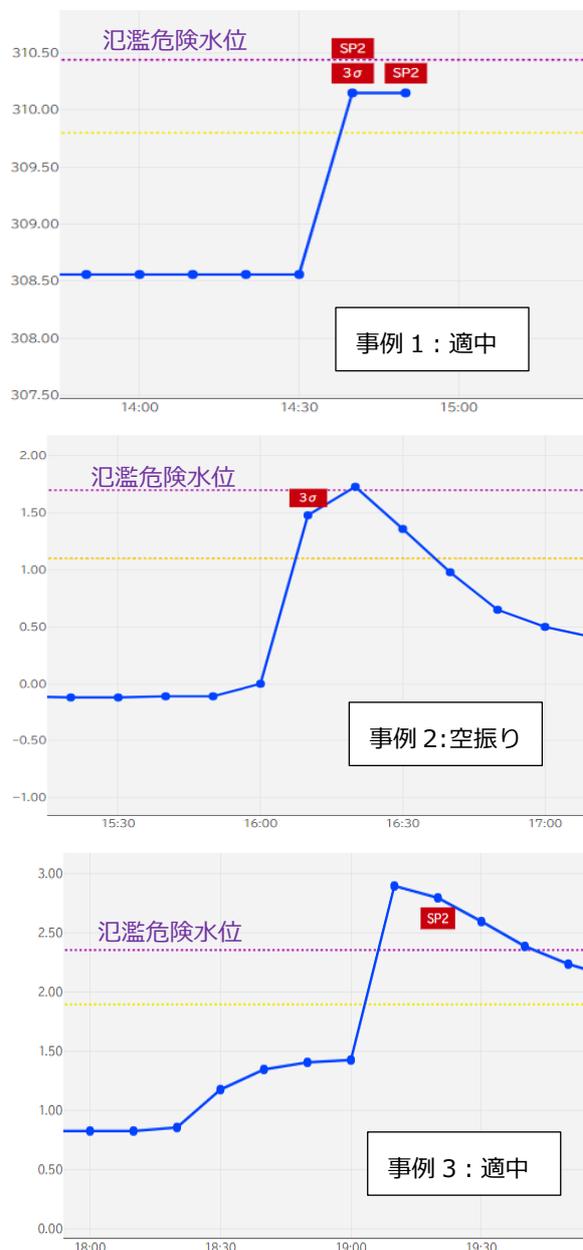


図-15 異常値検出事例

事例1は、フラグが発生し監視員により異常値と判定された適中事例である。この時には顕著な降雨が観測所周辺に認められなかったため、水位計の機械的か電気的な不具合によるものと判断された。

事例2は、フラグが発生したが監視員により正常値と判定された空振り事例である。この時には降雨強度の高い状態がレーダ雨量等から確認できていたため、洪水の立上りが急激ではあるが、波形自体に問題はないと判定された。3σフラグは洪水の立上りに多発しやすい空振りを大幅に減らすことは可能になっ

ているが、流域の小さな都市河川や砂防河川等で発生しやすい水位の急上昇に対してはまだ十分に対応しきれていない。

事例 3 は、事例 1 と同じく適中事例であるが、比較的軽微な事例となる。洪水波形がなめらかでないため、センサが水位変動に追従せずピーク水位を捉えられていないことが疑われるため、水位計を管理する河川事務所等に異常を伝えて、早期の点検や改善措置を促すこととしている。国の管理する主要な水位観測所には副水位計が設置されているため、後で品質照査を行う段階で正・副の両データを確認の上、より正確なデータに置き換えることが必要になる。

いずれにしても、2 や 3 のような事例に対して異常値検出システムの改良ですべてを自動判定することは、現段階では不可能と言わざるを得ない。リアルタイム監視員のノウハウを最大限に活かして、気象状況の変化や観測所の特性（周辺にダムや堰等がないか、流出が速くないか、潮位の影響を受けていないか、最近異常を多発していないか等）を踏まえた判断を行うことが、データの信頼度を維持するためには必要不可欠である。

VI. 今後の課題

1. 品質照査への反映

以上に述べたとおり、新しくシステム構築した 3σ モデルによって、リアルタイムデータ監視の精度と効率性を高めることができた。国の管理する水文観測所のデータは、第一段階として「リアルタイムデータ監視」を行うが、最終的に水文水質データベース (<http://www1.river.go.jp/>) に保存し公開するために、時間データを対象にした「品質照査」を行うこととなっている。

この品質照査は、河川事務所等で行う「標準照査」と地方整備局等で行う「高度照査」の 2 段階で構成されているが、そのチェック方法の原形は観測所のテレメータ化が十分進んでいない時期に構築されているため、近傍データと 10 分毎に比較分析することができずに現在に至っている。

今日では、国土交通省の管理する水文観測所の約 9 割はテレメータ化されているので、長年使われてきた方法から 3σ モデルを主軸とするチェック方法に見直して効率化を図り、河川事務所等の負担を軽減して行くことが有効と考えられる。

2. リアルタイムデータの即時補正

防災・減災活動を万全に行うためには「異常値の発信を未然に防ぐ」ことが重要になるが、これまで述べてきた取り組みの中からはその目的を達成できるだけの計算システムは構築できていない。現時点では、発信直後に重大な異常値を示した観測所を閉局処理して速やかに点検することまでが行われている。

新しく構築したシステムの中では、前章で述べたとおり氾濫注意水位を超えるフラグを「警戒フラグ」としているが、さらに絞り込んだ計算条件を設定して「重大で明白な異常値（人間の目で確認するまでもないもの）」のためのフラグ設定を行うことが今後の課題と考えられる。ただし、そのためには、実際に発生した異常値の事例を十分に分析することが必要になるので、2022年度以降にリアルタイムデータ監視システムの出力結果がベースとなって蓄積される異常値事例を活用しながら、今後の検討につないでいく必要がある。

3. 新たなデータ解析技術の導入

本報告では、比較的簡易な計算手法である 3σ モデルを中心として、開発から検証を経て実用化されるまでの過程を詳細に記述した。AI（深層学習）モデルについては十分な検証を行うことができなかったが、AI 分野の研究・開発は今後も飛躍的に進化していくことが予想されるため、引き続き実用性の高いモデルを構築できるよう研究を進めていきたい。

これまでは品質管理された（正常値と異常値の区分けがなされた）10分毎のデータを得ることは困難であったが、今後はテレメータ異常値検出システムの運用に伴って蓄積が進んで行くので、学習データとして活用しながら AI モデルの改良につないでいきたい。

VII. おわりに

本論文の要点を整理すると以下のとおりとなる。

- (1) テレメータ水位観測所データ監視の効率化と精度向上を図るため、ベクトル自己回帰 (VAR) モデルと標準偏差 (3σ) モデルを開発した。両モデルの比較

検証の結果、空振りを抑制する効果の大きい3 σ モデルの優位性が認められた。⇒第II章，第三章－1

(2)3 σ モデルにスパイクフラグと無変化フラグを追加し，フラグの多発しやすい大規模洪水時の検証を行った結果，実務に十分適用できる効率性と精度を確認できた。⇒第三章－2

(3)3 σ モデルを既存のリアルタイムデータ監視システム上に構築し，2022年度より実運用を開始した。前線性降雨等が多発する出水期においても，異常値検出に効果を発揮した。⇒第V章

(4)AIモデルとしてLSTM-Encoder Decoderモデルを構築した。3 σ モデルと比較するとまだ少し精度が劣るが，今後の改良により精度向上を図り実用性を高めていきたい。⇒第四章

本論文において記述した各種の異常検知モデルは，(一財)河川情報センターの自主研究として開発した。これらのモデル開発は全国のリアルタイムデータ監視において実用化することを目標としていたため，3 σ モデルとVARモデルの精度検証は国土交通省から委託された「河川情報データ監視業務」の一環として行い，とりまとめの過程において全国の地方整備局等の職員からの意見等もいただいた。実用性の高いモデルを構築するための貴重なアドバイスもいただいたので，この場を借りて感謝申し上げたい。

本論文では，テレメータ水位観測所のデータを対象としたが，降水量データや近年導入の進んでいる危機管理型水位計データの異常検知についても併行して研究を進めている。今後は3 σ モデルやAIモデルの改良をさらに進めるとともに，降水量等の異常検知モデルの開発も鋭意続けていきたい。

参考文献

1) 「特定都市河川浸水被害対策法等の一部を改正する法律」

(令和3年，法律第31号)

2) 「総力戦で挑む防災・減災プロジェクト」

https://www.mlit.go.jp/sogoseisaku/sosei_point_tk_000034.html

3) 「流域治水プロジェクト」

https://www.mlit.go.jp/river/kasen/ryuiki_pro/index.html

- 4) 「水位データの異常値検出手法の開発」(渡辺・田所・栗城：2020 河川情報シンポジウム講演集)
- 5) Malhotra, Pankaj et al. (2015). Long Short Term Memory Networks for Anomaly Detection in Time Series. In Proceedings of the 23rd European Symposium on Artificial Neural Networks, 89-94.
- 6) Malhotra, Pankaj et al. (2016). LSTM-based Encoder-Decoder for Multi-sensor Anomaly Detection. In ICML Workshop.
- 7) Zhang, Chuxu et al. (2019). A Deep Neural Network for Unsupervised Anomaly Detection and Diagnosis in Multivariate Time Series Data. Proceedings of the AAAI Conference on Artificial Intelligence, 33(01), 1409-1416.
- 8) 「AIによる洪水予測と水位データの異常検知」(岡田・柿澤・田所・中安：2017 河川情報シンポジウム講演集)
- 9) Hochreiter, Sepp et al. (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735-1780.
- 10) Hinton, Geoffrey et al. (2006). Reducing the Dimensional Data with Neural Networks. Science, 313(5786), 504-507.
- 11) Sutskever, Ilya et al. (2014). Sequence to Sequence Learning with Neural Networks. Advances in Neural Information Processing Systems, 27, 3104-3112.
- 12) <http://github.com/curiously> (閲覧日：2022年9月16日)