OUKA
The University of Osaka
Institutional Knowledge Archive

Title	AIモデルと水理モデルのハイブリッド活用による洪水予測技術の高度化に関する研究
Author(s)	渡辺, 健
Citation	大阪大学, 2026, 博士論文
Version Type	VoR
URL	https://doi.org/10.18910/105477
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

https://ir.library.osaka-u.ac.jp/

The University of Osaka

博士学位論文

AI モデルと水理モデルのハイブリッド活用による洪水予測技術の高度化に関する研究

渡辺　健

2025 年 12 月

大阪大学大学院工学研究科

目次

第１章　序論 1
1.1　研究の背景 1
1.2　研究の目的および特色 4
1.3　論文構成 5

第２章　ハイブリッド流出予測モデルの高度化に関する検討 7
2.1　はじめに 7
2.2　主要な流出予測手法の分類 8
2.2.1　降雨流出過程に基づく物理モデルの概要 8
2.2.2　観測データに基づく AI モデル（データ駆動型モデル）の概要 10
2.3　ハイブリッド流出予測手法の既往研究 10
2.4　研究対象とするハイブリッド流出予測モデル 11
2.4.1　ハイブリッド流出予測モデルの構成 11
2.4.2　本ハイブリッドモデル構成における課題点 13
2.4.3　RRI モデルの概要 14
2.4.4　深層学習モデルの概要 20
2.5　ハイブリッド流出予測モデルの構築 25
2.5.1　対象流域と検証条件 25
2.5.2　RRI モデルの構築 28
2.5.3　DNN モデルの構築とハイブリッド化 32
2.6　ハイブリッドモデルの効果的な構築方法の検討 34
2.6.1　効果的な計算流量連携地点の検討 34
2.6.2　物理モデルの予測精度が与える影響の分析 38
2.7　ハイブリッド入力に適した DNN 構造の検討 42
2.7.1　ハイブリッド DNN 構造の設計 42
2.7.2　候補構造の比較評価 44
2.7.3　選定構造の性能検証 45
2.8　まとめ 52

第３章　リアルタイム予測に向けた実用性向上に関する検討 57
3.1　はじめに 57
3.2　多地点同時予測方式によるモデルの軽量化 58
3.2.1　多地点同時予測方式へのモデル拡張 58
3.2.2　検証設定 59
3.2.3　検証結果 61

3.3 入力データ欠損影響の軽減 65
3.3.1 検討の概要と目的 65
3.3.2 検証設定 65
3.3.3 検証結果 67
3.4 まとめ 69

第 4 章 縦断予測とデータ同化に向けた PINNs 河道モデルの検討 71
4.1 はじめに 71
4.2 河道水理モデルの概要 72
4.2.1 河川における洪水流計算手法 72
4.2.2 一次元不定流解析モデルの概要 72
4.2.3 河川水位予測におけるデータ同化手法 77
4.3 PINNs を用いた河道モデルの定式化 78
4.3.1 PINNs の概要 78
4.3.2 一次元不定流式に対する PINNs の定式化 80
4.3.3 本問題設定に関連した既往研究と課題点 83
4.4 一般的な河道条件での順解析に関する開発と検証 84
4.4.1 計算手法の開発と改良 84
4.4.2 実河川の既往出水データを用いた適用検証 89
4.4.3 PINNs 学習設定に関する感度分析 97
4.5 データ同化・逆解析に関する開発と検証 103
4.5.1 多地点観測水位データ同化の問題設定 103
4.5.2 粗度係数の逆推定に関する検証 103
4.5.3 データ同化による縦断水位補正挙動の分析 115
4.6 まとめ 119

第 5 章 結論 123

謝辞 125

第１章　序論

1.1　研究の背景

近年，日本では気候変動の影響によって洪水災害が激甚化している．気象庁のデータ[1)]では，時間雨量50mm を超える短時間強雨の発生件数は直近 40 年で約 1.5 倍に増加しており(図-1.1)，局所的な集中豪雨や線状降水帯の形成に伴う長期豪雨の頻発は，従来の治水計画を超える規模の洪水被害を多くもたらしている．2018 年西日本豪雨は広域で河川氾濫や土砂災害を引き起こし，200 人超が犠牲となった[2)]．2020 年熊本・球磨川氾濫では堤防決壊により人吉市中心に甚大な浸水被害が発生し[3)]，2024 年石川豪雨では線状降水帯による記録的降雨で河川氾濫や内水氾濫が相次ぎ，住宅や交通網も大きな被害を受けた[4)]．これらは近年の豪雨災害の激甚化を象徴する事例である．

日本の洪水リスクの高さは，気候変動だけでなく地理的特徴にも起因する．我が国では国土の 7 割が山地であり，多くの河川が急勾配かつ流路延長も比較的短いことから，降雨が短時間で流下して下流部に集中しやすい．加えて，下流部の低地や河川沿いには人口や資産が集中しており，氾濫が発生すれば都市部のインフラ，住宅地，産業施設が直接的な影響を受け，経済的損失も甚大となる．また，高齢化社会の進展によって避難行動が難しい人々が増加しており，人的被害を抑えることは一層困難になっている[5)]．

日本の治水対策は長らく，堤防の増強や河道の拡張，ダム建設といったハード対策を中心に進められてきた．これらは洪水を直接的に抑制する効果が高く，地域住民や都市の安全を支える基礎として重要なものである．しかし，ハード対策には莫大な費用と長い整備期間が必要であり，完成までに数十年単位を要する場合も少なくない．特に近年のように気候変動の影響で豪雨の頻度や強度が急速に増大し，線状降水帯や巨大台風による想定外の降雨が相次いでいる状況では，ハード対策と並行してソフト対策を充実させる必要性が高まっている．

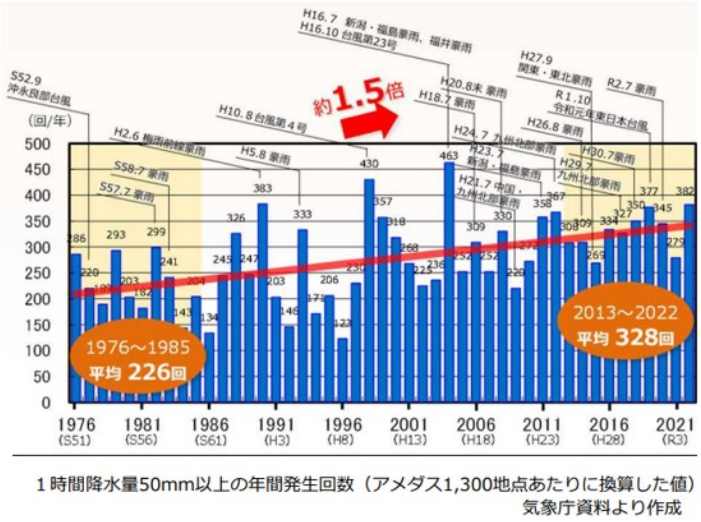

図-1.1　気候変動による降水量変化の概況
（出典：文献[1)]）



図-1.2　令和 6 年奥能登豪雨の被害状況
（出典：文献[4)]）



図-1.3　水害リスクラインシステム（出典：文献[10]）

ソフト対策とは，施設整備を伴わず，人や　近年では XRAIN レーダー観測網の整備が進み[6]，数値天気予報モデルを用いた降雨予測の精細化[7]や，河川水位のリアルタイム観測網の拡充[8]，降雨流出計算モデルの高度化[9]などにより，現在から数時間先の豪雨リスクを精度よく把握できるようになりつつある．これらの技術を活用した洪水予測システムの事例として，国土交通省が運用する「水害リスクラインシステム（Flood Risk Line: FRL）」が挙げられる[10]（図-1.2）．FRL は洪水による被害の危険性を河川ごとに連続的に把握できるようにした情報提供システムであり，堤防越水や溢水の危険度をモデル計算と観測値を組み合わせて算出し，色分けした線で地図上に表示する．危険度は河川ごとに定められた避難判断水位や氾濫危険水位などに応じて段階的に示され，特に河川管理者向けには現況情報に加えて 6 時間先までの予測情報が提供されている．これにより観測所のない区間でも，住民や自治体が氾濫・浸水の危険度を直感的に把握することが可能となっており，早期の避難行動や水防行動の判断情報として活用されている．

一方，現行の予測リードタイムでは垂直避難のような緊急行動の判断には対応できるものの，広域的な避難判断や水防活動には不十分であり，より長時間の予測リードタイムが求められている．こうした対応を可能にするため，予測降雨の不確実性を適切に評価するとともに，予測モデルのさらなる高精度化を図り，予測リードタイムを延長することは重要な課題の一つである．

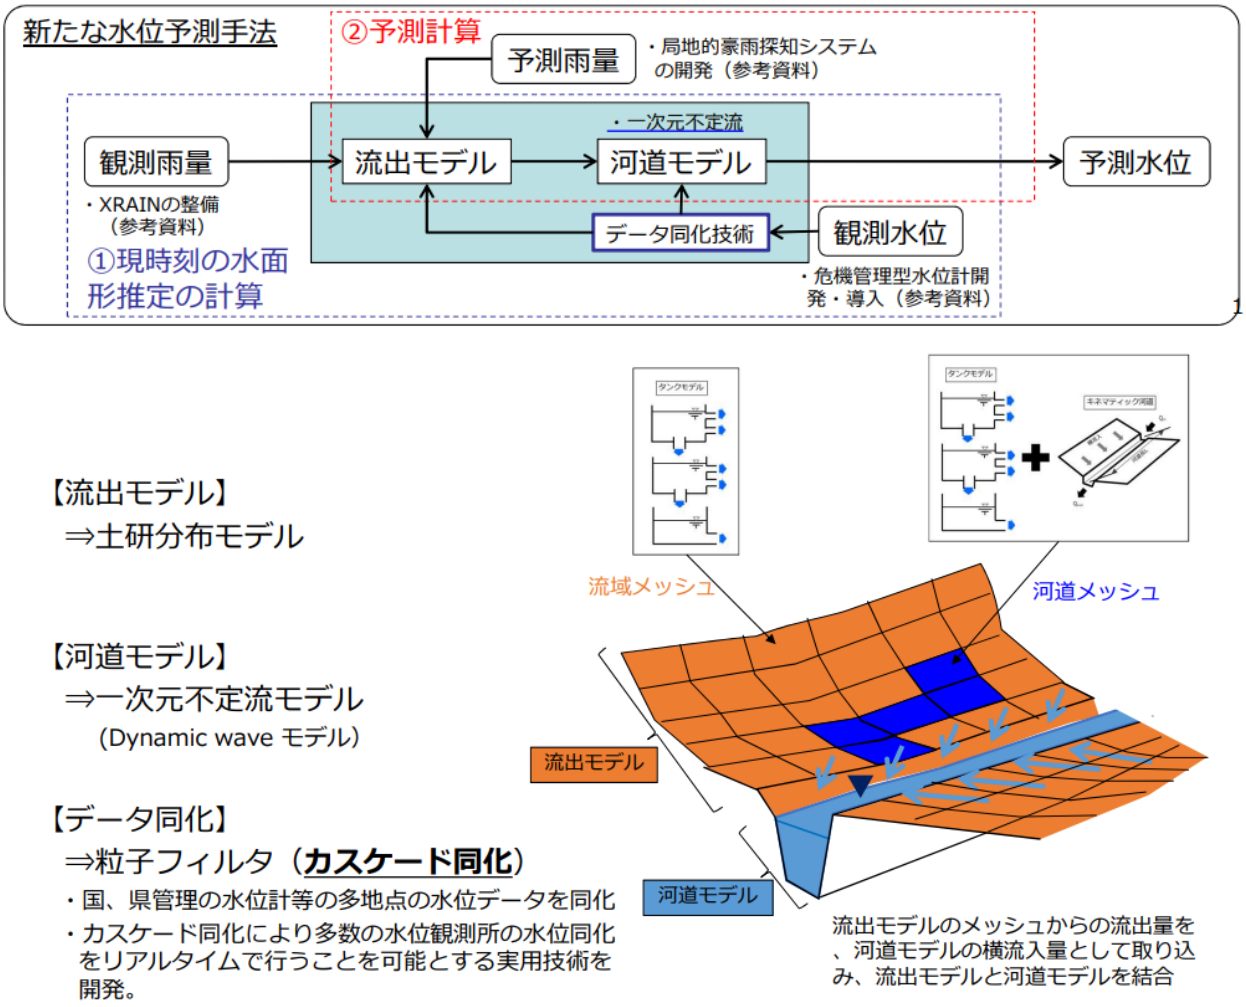

図-1.4　日本における洪水予測モデルの標準構成（出典：文献 [9]）

国土交通省が標準とする洪水予測モデルは大きく 3 つの技術要素から構成されている [9](図-1.3)．まず「分布型流出解析モデル」により，流域を細かいメッシュに分割し，地形や土地利用，土壌条件を反映させて降雨がどのように地表流・地下水流として流出するかを計算する．これにより，流域全体の流出特性を詳細に表現できる．次に，河道に流入した水の挙動を「河道の不定流解析モデル」で解析し，水位や流量の時間変化をシミュレーションする．この不定流解析は洪水波の伝播や貯留効果を捉えることが可能で，河川ごとの氾濫リスク評価に直結する．さらに予測精度を高めるために「粒子フィルタによるデータ同化」が導入されている．これは観測所で得られる水位や流量データをリアルタイムに取り込み，モデル計算値との誤差を修正する手法であり，降雨や流出の不確実性を補正する役割を果たす．これら三つの要素を統合することで，河川全域を対象とした動的かつ信頼性の高い洪水予測が実現されている．

しかし，本モデル構成に対してはいくつかの課題が存在する．主要課題の 1 つは，分布型流出モデルが分割メッシュごとに異なるパラメータを設定可能なため，同定対象のパラメータ数が膨大になりやすい点である．このことに起因して，様々な出水に対して汎用的に再現精度が高いパラメータセットへのキャリブレーションは容易ではなく，予測システム構築時の課題となりやすい．またパラメータ設定の自由度

が大きいことから，粒子フィルタを用いたデータ同化においては，同化結果を安定させるために同化対象を一部パラメータに限定するなどの工夫が必要であり，物理的に一貫性のある同化結果を得ることが難しい傾向にある．さらに，分布型流出モデルにおける分割メッシュ間の流動計算，河道不定流解析モデルとの連携処理，粒子フィルタによるデータ同化処理などを統合的に扱う必要があることから，計算量が大きくなりやすく，特に複雑な大流域での長期間実行や，洪水予測システムでのリアルタイム運用では，計算時間や計算資源が問題となりやすい課題を有している．

上述のモデルは降雨流出に伴う水理的な過程をモデル化した物理モデルであるが，近年では AI（Artificial Intelligence）技術の発達と各種観測データベースの充実に伴い，AI による洪水予測モデルも実用化が進みつつある [11]．AI による洪水予測モデルは，大量の観測データや気象予測データを機械学習により学習し，将来の水位や流量を推定する手法であり，統計的予測手法の一種とみなせる．メリットとしては，学習済みモデルは計算コストが低く高速で予測できる点が挙げられ，上述の物理モデルと比較して大規模流域や多数の地点のリアルタイム予測への適用性が高い．また，観測データが豊富に存在すれば，複雑な流出過程や局所的特性を経験的に捉え，物理モデルよりも予測精度が高くなるケースが多く，物理モデルのように物理過程に即した詳細なパラメータ設定・調整が不要であることから，モデル構築が比較的容易である点もメリットである．一方でデメリットは，モデル性能が学習データに強く依存するため，未経験の豪雨や気候変動下の極端事象に対する予測精度が保証されにくく，学習に必要な長期かつ高精度な観測データが揃わない流域では精度が大きく低下する点である．さらに，物理的な因果関係が明示されないため，結果の解釈性や適用範囲の判断が難しい点もデメリットである．これらの点に関して物理モデルは対照的であり，水文学や水理学の理論に基づくため，未経験の条件にも相対的に適応しやすく，予測の根拠を説明可能であるという特長を有している．

以上のように，物理モデルと AI モデルは互いに補完が可能な性質を持ち，両者を統合したハイブリッド手法は洪水予測精度の向上に向けた重要な方向性であると位置付けられる．実際，近年では予測根拠が明確な物理型手法と，予測精度と計算速度に優れる AI モデル（データ駆動型モデル）の双方の利点を組み合わせた様々なハイブリッド型のアプローチが提案されている．しかし，現在提案されている手法は，特定条件では単独モデルの性能を上回るものの，汎用的な性能底上げを実現できているかは不透明なケースや，ハイブリッドモデルが有する構成の自由度に対する適切な設定方法が不明なケースが多く，様々な流域への横展開に向けては，モデル特性に関する情報や適用事例が未だに大きく不足している状況にある（これらの点に関しては次章以降で詳述する）．このため，現在実用化されている洪水予測システムにおいては，物理モデルか AI モデルのいずれかが単独で利用されている場合が多く，全体傾向としては前述の国土交通省の標準モデル構成に代表されるように，説明性に優れる物理モデルの採用が中心となっている．このような状況から，今後は，両者の強みを組み合わせるモデル統合技術のさらなる研究を通じた知見の蓄積により，実務におけるハイブリッド利用の本格化が期待される．

1.2 研究の目的および特色

本研究では，現在の洪水予測システムにおいて主に単独で使用されている AI モデルと水理解析モデルに対し，両者の利点を統合したハイブリッド手法の改良と開発を行うことにより，河川水位を対象とした洪水予測技術の高度化を図ることを目的とする．

研究対象とするのは，降雨量を外力として特定地点の水位や流量を予測する降雨流出予測モデルと，予測流出量を境界条件として河川の縦断的な水位変化を予測する河道モデルならびにそのデータ同化手法である．降雨流出予測モデルについては，水理解析モデルにより算出された主要地点の流量を AI 予測モデルの追加入力として活用するハイブリッド手法を対象とし，ハイブリッドモデルの効果的な構築方法の検討，ハイブリッド入力に適した DNN（Deep Neural Network）構造の検討，ならびにハイブリッド化による改良効果と有効範囲の明確化を行う．本研究では RRI モデル（Rainfall-Runoff-Inundation モデル）[12)]を水理解析モデルとして採用したが，ハイブリッド活用に際して得られた知見は RRI モデル固有の特性に依存するものではないため，他のあるいは既存の流出解析モデル資産を活用する場合においても，本ハイブリッド予測モデル構成の採用と展開が期待できるものである．また本手法に対し，リアルタイム予測システムでの実運用に向けた改良検討を実施し，実務現場での利便性と実用性の向上を図る．

さらに特定地点に対する流出予測から，河川の縦断的な予測ならびに水位データ同化への展開に向けて，物理法則を組み込んだ深層学習手法である PINNs（Physics-Informed Neural Networks）を河道モデルへ適用することを試み，複数地点における水位観測データの簡便かつ効率的なデータ同化技術の開発を目指した．現時点では，河道モデルへの PINNs 適用や水位データ同化への応用に関する先行研究は希少であり，本検討は今後の河川管理分野における PINNs の応用展開へ向けた基礎的な知見を提供するものである．

1.3 論文構成

第 1 章では，序論として本研究の背景，目的，および論文の構成について述べた．

第 2 章では，特定地点の河川水位予測（流出予測）の性能向上に向けて，AI モデルと水理モデルを併用した主要なハイブリッド手法について整理し，分布型流出解析モデルである RRI モデルと深層学習モデルを組み合わせたハイブリッド予測方式の改良について検討する．検討の主な焦点は，ハイブリッドモデルの効果的な構築方法の確立と，ハイブリッド入力を処理する DNN 構造の改良であり，単独モデルの課題に対する改良効果を，実河川の既往出水事例を用いて比較評価する．

第 3 章では，第 2 章で検討したハイブリッド流出予測モデルについて，今後のリアルタイム予測システムへの実装・運用を見据え，モデル構築および維持管理に要するコストを低減するとともに，リアルタイム処理における計算負荷を抑制するために，多地点を対象とした同時予測方式の有効性を評価する．あわせて，出水時には観測水位データの欠損が生じる可能性が高いことから，そのようなデータ欠損が予測精度に与える悪影響を緩和する手法についても検討を行う．

第 4 章では，縦断的な予測水位の計算に必要となる河道モデルに対して，効率的な多地点水位データ同化の実現に向け，物理法則を組み込んだ深層学習手法である PINNs の適用を検討する．ここでは，河道モデルとして広く用いられている一次元不定流式を対象に，現状で先行事例が存在しない一般的な条件下での順解析に関する開発検証を行う．さらに，この順解析を前提とした多地点水位データ同化・逆解析手法について開発検証を行う．多地点水位データ同化では，粗度係数，縦断水面形の補正推定を目的とし，実河川の既往出水事例を用いた双子実験等によりその性能を評価する．

第 5 章では，各章で得られた知見を総括して結論を述べ，今後の課題と展開について述べる．

参考文献（第１章）

1) 国土交通省水管理・国土保全局：河川事業概要 2023: Ⅰ　我が国の水害リスクの現状, 2023. Available: https://www.mlit.go.jp/river/pamphlet_jirei/kasen/gaiyou/panf/pdf/2023/kasengaiyou2023_1.pdf
2) 国土交通省：水害リスクを踏まえた流域治水のあり方検討会 第 1 回 資料 2-1, 2023. Available: https://www.mlit.go.jp/river/shinngikai_blog/hazard_risk/dai01kai/dai01kai_siryou2-1.pdf
3) 国土交通省：河川整備基本方針検討小委員会 第 112 回 配付資料 2, 2021. Available: https://www.mlit.go.jp/river/shinngikai_blog/shaseishin/kasenbunkakai/shouiinkai/kihonhoushin/dai112kai/06_shiryou2_reiwa2nengouu.pdf
4) 四国新聞社:【能登豪雨、孤立１１５集落　死者６人、行方不明２人　２３河川氾濫、全容把握難航】, 四国新聞デジタル, 2024/09/22. Available: https://www.shikoku-np.co.jp/bl/digital_news/photo.aspx?id=K2024092300000007900
5) 片田敏孝, 山口宙子, 寒澤秀雄：洪水時における高齢者の避難行動と避難援助に関する研究, 福祉のまちづくり研究, Vol. 4, No. 1, pp. 17–26, 2002, doi: 10.18975/jais.4.1_17.
6) 山地秀幸, 土屋修一, 川﨑将生:C バンド MP レーダ雨量計と XRAIN による高精度広域雨量観測, 土木技術資料, Vol. 58-7, 2016. Available: https://www.pwrc.or.jp/thesis_shouroku/thesis_pdf/1607-P026-029_yamaji.pdf
7) 北村祐二：数値予報モデルの予測精度向上の取組, 第 20 回 ESI シンポジウム講演資料, 東京大学生産技術研究所エネルギーシステムインテグレーション社会連携研究部門, 2024.3.4. Available: https://www.esisyab.iis.u-tokyo.ac.jp/symposium/20240304/20240304-02.pdf
8) 土屋修一, 川﨑将生：危機管理型水位計データを活用した河川水位予測, 土木技術資料, Vol. 63-1, 2021. Available: https://www.pwrc.or.jp/thesis_shouroku/thesis_pdf/2101-P036-039_tsuchiya.pdf
9) 気象庁：防災気象情報のあり方に関する検討会 資料 3-1_3, 2024. Available: https://www.jma.go.jp/jma/kishou/shingikai/kentoukai/arikata/part3/siryou3-1_3.pdf
10) 国土交通省：水害リスクラインによる水位情報の提供, 報道発表資料, 令和 7 年. Available: https://www.mlit.go.jp/report/press/content/001307906.pdf
11) 一言正之：河川・水防災における AI 技術の活用―AI と物理の融合への挑戦, 環境情報科学, Vol. 52, No. 2, pp. 45–50, 2023, doi: 10.11492/eis.52.2_45
12) 佐山敬洋, 藤岡奨, 牛山朋來, 建部祐哉, 深見和彦：インダス川全流域を対象とした 2010 年パキスタン洪水の降雨流出氾濫解析, 土木学会論文集 B1（水工学）Vol. 68, No. 4, I_493–I_498, 2012.

第２章　ハイブリッド流出予測モデルの高度化に関する検討

2.1　はじめに

リアルタイム洪水予測において基盤となるのは，降雨流出過程の理解とその数値的表現である．降雨が流域に到達すると，まず一部は植生や地表面に付着・保持され，さらに土壌への浸透が進む．浸透能を超える降雨は表面流として流出し，浸透水の一部は土壌中の中間流や地下水として貯留され，遅延して河道へ流入する．降雨から流出への変換は多段階かつ相互に関連するプロセスであり，地形，土地利用，土壌条件，さらには降雨の強度や継続時間などによって流出形態や時間スケールが大きく異なる．したがって洪水予測の精度を高めるには，これらの複雑な過程を適切に数理的に表現することが不可欠である．

これらの流出過程をモデル化した従来の流出解析モデルは，流域全体を単位系として経験的に扱う集中型モデルと，流域を格子やサブ流域に分割し，地形や土地被覆，水文過程を空間的に表現する分布型モデルに大別される．集中型モデルはパラメータが比較的少なく，限られた観測情報で簡便に適用できる利点があり，行政や実務に広く利用されてきた．一方，分布型モデルは物理過程に基づき降雨の時空間分布や流域特性を詳細に反映できるため，近年の高解像度降雨データの整備や計算機性能の向上に伴い，研究のみならず実用現場でも適用が拡大している．さらに河道の流れについては，一次元浅水流方程式と組み合わせることで，降雨から河川流量や水位に至るまでの連続的なシミュレーションが可能となっている．

近年はこれらの物理モデルに加えて，入出力データ間の相関関係を統計的にモデル化する機械学習モデル（AI モデル）の導入が進み，既往観測データから直接的に流量や水位を予測する試みも盛んに行われている．機械学習モデルの中でも近年発展が著しい深層学習モデルは，非線形な応答の再現や大規模データからのパターン抽出に優れ，学習後の推論処理も高速であることから，従来モデルでは困難であった大規模流域に対する短時間での予測出力や，複雑な非線形挙動の再現による予測精度向上への有効性が報告されている．しかし一方で，物理法則に基づく一般性や因果関係の解釈性に乏しいという課題も指摘されている．そこで近年注目されているのが，物理モデルと AI モデルを結合したハイブリッド型アプローチである．これは物理モデルによって流出過程の整合性を確保しつつ，降雨予測の不確実性や流域特性の未解明部分を機械学習で補う手法であり，両者の長所を組み合わせることで，洪水予測の精度と即時性を一層高めることが期待されている．

本章では，はじめに，降雨流出予測モデルの性能向上を目的として，まず AI モデルと物理モデルを組み合わせた主要なハイブリッド手法を整理する．次に，その中でも有望な手法と考えられる分布型流出解析モデルと深層学習モデルを組み合わせたハイブリッド予測手法の改良について検討する．検討の主眼は，ハイブリッドモデル構築における自由度に対して効果的な設定方法を確立すること，ならびにハイブリッド入力を処理する DNN（Deep Neural Network）構造の改良である．また，単独モデル適用時や既往のハイブリッド構成における課題を踏まえ，改良手法の効果を実河川の既往出水事例を対象として比較評価する．

2.2　主要な流出予測手法の分類

本研究では降雨流出過程をモデル化する物理モデルと，観測データ間の関係性をモデル化する AI モデル（データ駆動型モデル）のハイブリッド活用を主眼としている．この観点に基づく主要な流出予測手法の分類[1)]を表-2.1 に示す．また以下では，それぞれの手法に関する概要を紹介する．

2.2.1　降雨流出過程に基づく物理モデルの概要

降雨流出過程に基づく物理モデルは大きく 2 系統に大別できる．1 つは流域全体を単位系とみなし，降雨流出関係を経験的・概念的に扱う概念モデル（集中型モデル）である．概念モデルでは，流域全体における代表的な降雨量（たとえば降雨観測点の平均値や補正値）を入力変数とし，流域末端での流出量を出力する．このようなモデルの代表例には，木村による貯留関数法[2)]や，菅原らによる直列タンクモデルなどがある[3)]．こうした概念モデルの最大の利点は，観測データが比較的限られていても適用可能で，計算コストも低く，実務的に扱いやすい点にある．実際，水資源や洪水予測・管理を目的とした実務用途では，過去データを用いてモデルパラメータを校正（キャリブレーション）すれば，十分な性能を発揮することが少なくない．また，複雑な水理過程を詳細に記述する代わりに流域全体を一体と見なすため，モデル構造が単純化され，運用・保守も比較的容易である．

一方で，こうした単純化による弊害として，土地利用変更や土壌改変，都市化といった局所的変化をモデルに反映させることが難しい点が挙げられる．また，流出過程を構成する個別の物理過程（例えば斜面浸透，表面流出，中間流出，地下水流など）を空間的に区別して扱うことはできず，流域特性の空間的分布や降雨の時空間変動を直接反映する能力も限られている．また，概念モデルでは，降雨流出応答を再現する方程式（貯留関数形やタンク流出特性式など）が仮定的・経験的になることが多く，各モデルパラメータの物理的な意味付けが曖昧となりやすいことも課題の 1 つである．

表-2.1　流出予測モデルの分類（出典：文献[1)]）

大分類	中分類	小分類	長所	短所
流出モデル	概念モデル	タンクモデル	計算が比較的簡単，様々な流出波形を表現できる	パラメータの物理性が弱い
		貯留関数法	計算が比較的簡単，全国の洪水予測システムで実績	パラメータの物理性が弱い
	物理モデル	分布型モデル	降雨－流出の過程を詳細に表現，地形や降雨の分布を反映	モデル構築やパラメータチューニングの労力が大きい
	その他	概念モデルを分布させたモデルや，要素集合型などが提案されている．		
直接水位予測手法	統計的手法	時系列解析（AR, ARMA, ARIMA など）	モデル構築が簡便，計算が簡易	降雨－流出の非線形性を表現できない
		機械学習（線形回帰，ANN, SVM など）	非線形性を含めた高い表現能力，豊富な使用実績	計算過程がブラックボックス，データが多く必要
	その他	ファジィ，事例ベースなど，様々な手法が提案されている．		

日本国内において概念モデルは長年の実用実績を持っており，特に洪水解析分野では貯留関数法やタンクモデルを用いた手法が標準的に採用されてきた[4]．概念モデルのパラメータ推定には，近年では遺伝的アルゴリズムを用いたSCE-UA（Shuffled Complex Evolution - University of Arizona）法[5]などによる大域最適化手法を用いる研究も展開されており，従来の局所探索法に比べて収束性・安定性の向上が報告されている[6]．

もう 1 つの系統は，流域を格子やサブ流域に分割し，各要素の水収支や伝播過程（降水，蒸発散，浸透，土壌水流，地表流，地下流など）を時間発展方程式で追跡する分布型モデルである．分布型モデルでは流域内の水位・流速・流量などの空間分布を出力できるため，任意地点での予測が可能であり，降雨の時空間変動や流域条件の非均質性を忠実に反映できる点が最大の強みである．また，近年は X バンド MP(マルチパラメータ)レーダ網の整備[7]により高時間解像度・高空間解像度の降雨解析データが利用可能になったことや，計算機性能や数値解法の改良により高解像度での分布型シミュレーションが現実的になってきたことから，都市域流出予測，洪水浸水解析，流域内流量分布予測，土地利用変化シミュレーションなど，分布型アプローチの応用範囲が拡大している．

しかし，分布型モデルも万能ではなく，いくつかの課題が存在する．主要課題の 1 つは分割要素ごとに異なるパラメータを設定可能なため，同定対象のパラメータ数が膨大になりやすい点である．数値標高モデル（Digital Elevation Model：DEM）や土地利用などの地形的な情報から直接全パラメータを同定することは困難な場合が多く，水位・流量の観測データを用いたパラメータキャリブレーションが不可欠となるが，これらの観測量に対して調整対象パラメータの自由度が非常に大きいため，汎用的な再現パラメータを同定することは容易ではない[8]．次に，分割格子に対する差分法や有限要素法による時間発展計算，境界条件処理，セル間流動計算，データ同化などを統合的に扱うため，計算量が集中型モデルよりも大きくなる傾向がある．特に複雑な大流域での長期間実行や，洪水予測システムでのリアルタイム運用などでは，計算時間や計算資源が課題となりやすい[9]．

これらの課題と関連して，降雨流出の主要要素（土壌浸透，表面流出，中間流出，地下水流，地表流・地下流の合流など）の物理的表現をどう簡略化・パラメタリゼーションするかという選択によって分布型モデルは細分化される．降雨流出過程を物理過程に忠実に三次元で水理解析する手法以外に，中間流出と地下水を流量流積関係式により近似表現する手法[10]や，セル要素をタンクモデル的に扱う分布型タンクモデルのような折衷型手法[11]が利用されている．

日本国内では，概念モデルから分布型モデルへの移行が進んでおり，特に ICHARM を中心に開発された Rainfall–Runoff–Inundation（RRI）モデル[12,13]は，降雨から氾濫までを統合的に解析可能な日本発の分布型モデルとして広く用いられている．リアルタイム洪水予測用途では，粒子フィルタやアンサンブルカルマンフィルタ（EnKF）などのデータ同化手法を組み合わせた研究も盛んであり[14–16]，観測水位やレーダ雨量を用いたモデル状態量の逐次更新を通じて，流出・氾濫の時空間予測精度をリアルタイムに改善する取り組みが進められている．

2.2.2 観測データに基づく AI モデル（データ駆動型モデル）の概要

観測データに基づく統計的手法（データ駆動型モデル）では，降雨量や上流地点水位などの説明変数と，予測対象地点水位などの目的変数の相関関係を観測データから統計的にモデル化する．この系統のモデルとしては水位相関法や重回帰分析，自己回帰型の時系列モデル(AR，ARIMA)などが古くから利用されているが[1)]，近年は特に深層学習（Deep Learning）の発展により，AI モデル（機械学習モデル）による降雨流出・洪水予測モデルの研究と実用化が進展している．

国内では，気象庁や国土交通省を中心に，レーダ雨量や河川水位などのデータを活用した機械学習モデルの開発が進められており，基本的な全結合型ニューラルネットワークや再帰型の深層ニューラルネットワークである Long Short-Term Memory（LSTM）モデルを用いた時系列予測の研究が盛んである[17–20)]．また深層学習モデル以外ではランダムフォレストなどの決定木系手法[21)]や，力学系手法を用いた予測手法[22)]もデータ駆動型モデルとして研究報告がある．これらは，過去の降雨や流量系列から洪水ピークの発生時刻や規模を高精度に推定でき，既存の物理モデルよりも軽量で高速な予測が可能な点が実務的に評価されており，類似タスクとなるダム流入量予測へも適用が拡がっている[23–25)]．

AI モデル(データ駆動型モデル)の利点として，学習済みモデルを用いれば極めて高速に予測可能であること，観測データが豊富な流域では高い精度を維持できること，物理モデルのように詳細な地形・土地利用パラメータを設定する必要がなく，モデル構築が比較的容易であること，などが挙げられる．

一方で，AI モデルにはいくつかの課題や限界も指摘されている．具体的には，学習に必要な長期かつ高精度な観測データが揃わない流域では精度が低下すること，ブラックボックス的性質が強く，予測結果の物理的妥当性や因果関係の解釈が困難であること，学習データの範囲外の降雨・流出条件（極端事象など）では外挿性能が不安定であること，などが挙げられる．また，モデル更新には再学習が必要であり，気候変動や土地利用変化などの環境変化に対して継続的なチューニングが不可欠である点も運用上の制約となる．

2.3 ハイブリッド流出予測手法の既往研究

前述の物理モデルと AI モデル双方のデメリットを解消するため，近年では予測根拠が明確な物理型手法と，予測精度と計算速度に優れるデータ駆動型モデルの双方の利点を組み合わせたハイブリッド型のアプローチが提案されている．様々なハイブリッド型のアプローチが提案されているが，大別すると，(a)物理モデルの計算結果を学習させる方式（学習データ増強への物理モデルの利用），(b)物理モデルの計算結果を AI モデルの入力特徴量に追加する方式，(c)物理モデルと AI モデルを用途によって使い分ける or 組み合わせる方式，の 3 形態が主流である．

(a)の事例としては，仮想的な大規模洪水に対する流出量を物理モデルで計算し，これを深層学習モデルに学習させることで未経験洪水への予測適用性を高める方式の適用例が報告されており[26–27)]，未経験規模出水に対する AI モデルの弱みの改善が図られている．(b)の事例としては，降雨流出過程に物理モデルを適用することで降雨に関する特徴量を抽出し，これらの特徴量と水位観測値を深層学習モデルへ入力して水位予測を行う方式[1, 28, 29)]や，分布型流出モデルをベースに不確実性の高い HQ 換算過程を深層学習モデルに置き換えることで予測精度を高める方式[30)]などの報告事例がある．(c)の事例としては，

出水規模に応じて採用モデルを切り替える方式 [25]や，深層学習モデルによる地点予測結果を一次元不定流モデルの流入境界条件に利用し，縦断水位予測値を得る方式 [31]などが提案されている．その他，損失関数に流量保存則の拘束式を加えることで未経験洪水への適用性を高める方式 [32]の報告などがある．

2.4 研究対象とするハイブリッド流出予測モデル

提案されている前述のハイブリッド型手法の中でも，一言・桜庭. (2017)，Konapala et al. (2020)， Lu et al. (2021) らが提案している，物理モデルの計算結果を追加特徴量として深層学習モデルへ入力する手法は，多様な降雨の時空間分布に対して物理モデルにより効率的に水位変化に寄与する特徴量(各地点流量)を抽出することが可能と考えられ，不確実性の大きい河道形状や粗度係数変化を含む河道モデルによる計算と HQ 換算による精度低下を深層学習モデルにより回避することが期待できる点から，非常に有望なアプローチの 1 つである．また，この手法では既に整備された貯留関数モデルや分布型流出モデルを有効活用できる利点もある．このため，本研究ではこのハイブリッドアプローチを対象に，以降の検討を実施した．

2.4.1 ハイブリッド流出予測モデルの構成

本研究で対象としたハイブリッドモデル構成(図-2.1)を定式化すると，現在時刻を$t = 0$，予測対象時刻を$t = T_f$として，下記の 2 段階の計算過程となる．

$$Q_{calc}(t) = f(\, r_{obs}, r_{forecast}, h_{init}, q_{boundary}\,) \tag{2.1}$$

$$H_{forecast}(T_f) = g(Q_{calc}(T_f - 1), Q_{calc}(T_f - 2), \dots, Q_{calc}(T_f - k), h_{obs}\,) \tag{2.2}$$

ここで$Q_{calc}(t)$は時刻 t における降雨流出モデルによる各地点の計算流量(m³/s)，f は降雨流出モデル，r_{obs}は観測降雨量，$r_{forecast}$は予測降雨量，h_{init}は水位初期条件，$q_{boundary}$は境界流量条件であり，$H_{forecast}(T_f)$は時間T_fにおける深層学習モデルによる予測水位，g は深層学習モデル，h_{obs}は各地点の観測水位である．kは降雨流出モデルによる計算流量について，予測対象時間からどの時間範囲まで参照するかを決めるパラメータである．まず式(1)では，降雨流出モデルfを用いて降雨情報から水位変化に寄与する主要特徴量である各地点流量を計算する．次に，式(2)では対象地点の計算流量(主に河道流量)と観測水位情報を入力として，深層学習モデルgによって対象地点の水位予測を行う．これは降雨流出モデルにより各流域の地形情報を考慮した河道への流出量を計算し，各河道地点の予測流出量から対象地点までの河道流下過程を深層学習モデルで近似・予測するモデル構成とみなすことができる．

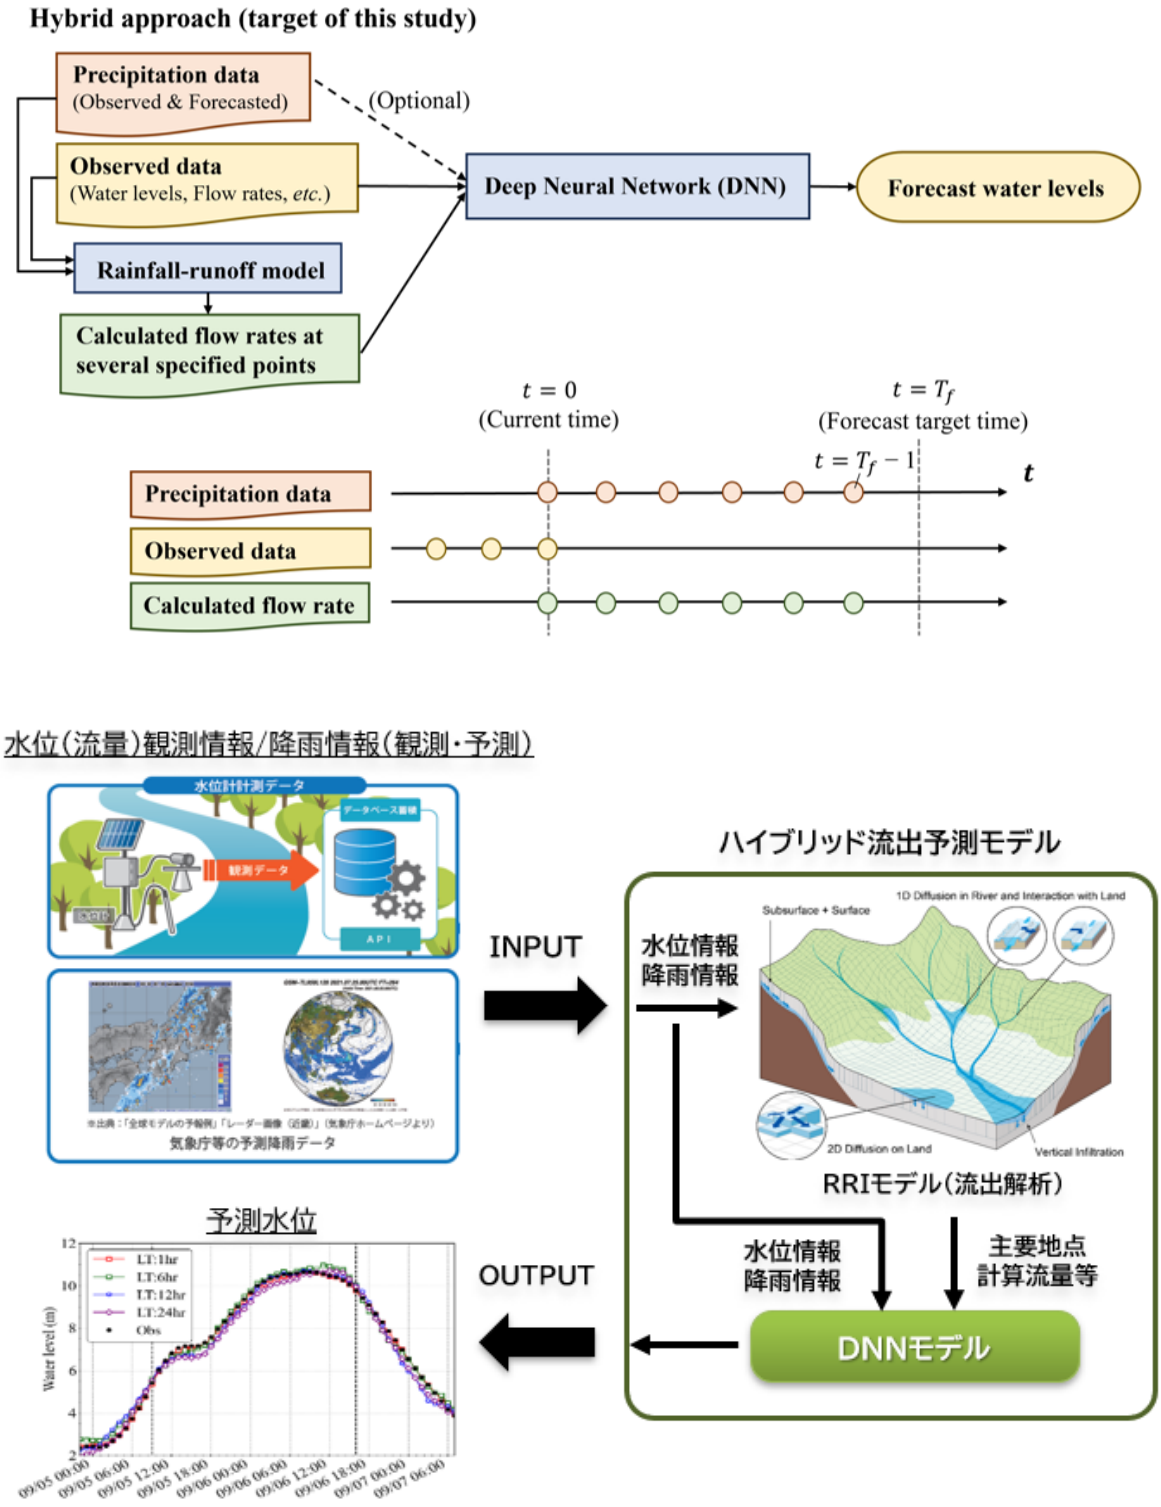

図-2.1　　本研究で対象とするハイブリッド予測構成の概要

2.4.2　本ハイブリッドモデル構成における課題点

本手法は前述の通り，降雨流出モデルによって地形情報に基づき，多様な時空間降雨分布から水位変動に直接的に寄与する各地点流量や貯留量を効率的に抽出できること，深層学習モデルによりこれらの情報を河川水位に直接変換することで河道流下過程での時間位相ずれや HQ 換算による精度低下の回避が期待できること，整備済みの貯留関数モデルや分布型流出モデルなどの既往資産を有効活用できることなどから，有望なハイブリッドモデル構成の 1 つである．

一方で，本ハイブリッド構成における主な課題点は下記の通りである．

(1)　降雨流出モデル計算値の適切な連携入力条件が不明

本ハイブリッド構成における重要な自由度の一つは，深層学習モデルへ連携入力する計算流量（あるいは貯留量変化）地点の選択である．しかし，深層学習モデルへ入力する計算流量点の選択基準に焦点を当てた研究はほとんどなく [33]，特に分布型流出モデルでは選択地点の自由度が高いことから，新しい流域に対してモデルを効率的に構築することが困難となっている．また物理モデルの計算精度自体が，どの程度ハイブリッドモデルの精度に影響を及ぼすかも明確になっていない．

(2)　AI 単独モデルに対して完全上位互換となっていない

既往研究 [1)]では物理モデルを利用しない AI 単独モデルに対して，必ずしも上位互換とはなっておらず，出水によっては AI 単独モデルの方が高精度となるケースが存在している．この原因としては，物理モデル計算結果が誤差を有するため，出水によっては予測に対してかえって悪影響を与えてしまう可能性や，入力変数の増加に伴って過学習を誘発しやすくなっている可能性が考えられる．本ハイブリッドモデル構成では，AI 単独時には入力されていない降雨流出モデルによる計算流量が追加入力されているため，この追加入力が精度向上に寄与しないケースではこれを無視することで，原理的には AI 単独モデルの完全上位互換が実現できると期待される．本手法は水位，降水量，計算流量といった異なる種類の入力情報を DNN モデルが統合するが，先行研究ではこれらの情報を MLP や LSTM といった典型的な DNN 構造へ単純に入力する構成となっている．したがって、これらの入力変数をより効率的に統合・処理できる DNN 構造の探索により，完全上位互換を実現可能な DNN 構造の存在が期待される．

(3)　学習条件(学習データ量や学習の出水規模)に対する感度が不明

既往研究 [1, 28, 29)]では学習条件に対する感度分析は行われておらず，学習データ量や学習データセットに含まれる出水規模によって予測精度がどのように変化するかが不明である．実用化に際しては，妥当なモデル構築のためにどの程度の学習データが必要となるかは重要なポイントの 1 つである．

上記の課題点を踏まえ，本研究では，1）深層学習モデルへ入力する流量地点の選択，ならびに物理モデルの予測精度が最終的な予測精度に与える影響の検討，2）ハイブリッド構成に伴う追加入力情報をより効果的に統合できる DNN 構造の検討，および 3）学習条件に対する感度分析，の検討を行った．また物理モデルには，日本を中心に利用実績が多い分布型流出モデルである RRI モデルを採用した．

以降では，本ハイブリッドモデルの構成要素となる RRI モデルと DNN モデルの概要を示す．

2.4.3　RRI モデルの概要

RRI(Rainfall-Runoff-Inundation)モデルは降雨から流出，氾降雨から流出，氾濫までの過程を一貫して解析可能な二次元分布型流出モデルである．流域を格子状に離散化し，各グリッド上で浅水方程式の拡散波近似を解くことで，地形勾配や地表条件に応じた水の流動を再現する．従来よく用いられてきたキネマティックウェーブ近似に比べ，流れの方向を事前に固定せず，水面勾配を考慮して動的に決定するため，氾濫原や低平地における複雑な水理現象を高精度に表現できる点が特徴である．また，河道をグリッド中央の線分として表現し，河道と陸域の水位差および堤防高に基づく越流公式を用いて両者間の水交換を計算することで，河道氾濫や内水氾濫を統合的に扱うことが可能である．陸域では表面流に加え，側方地中流および鉛直浸透流を考慮しており，後者は Green–Ampt モデルを用いて浸透能や土壌水分条件を反映する．RRI モデルは，ICHARM を中心に開発され，現在では，洪水ハザード評価やリアルタイム予測など，国内外の水防災分野で広く活用されている．

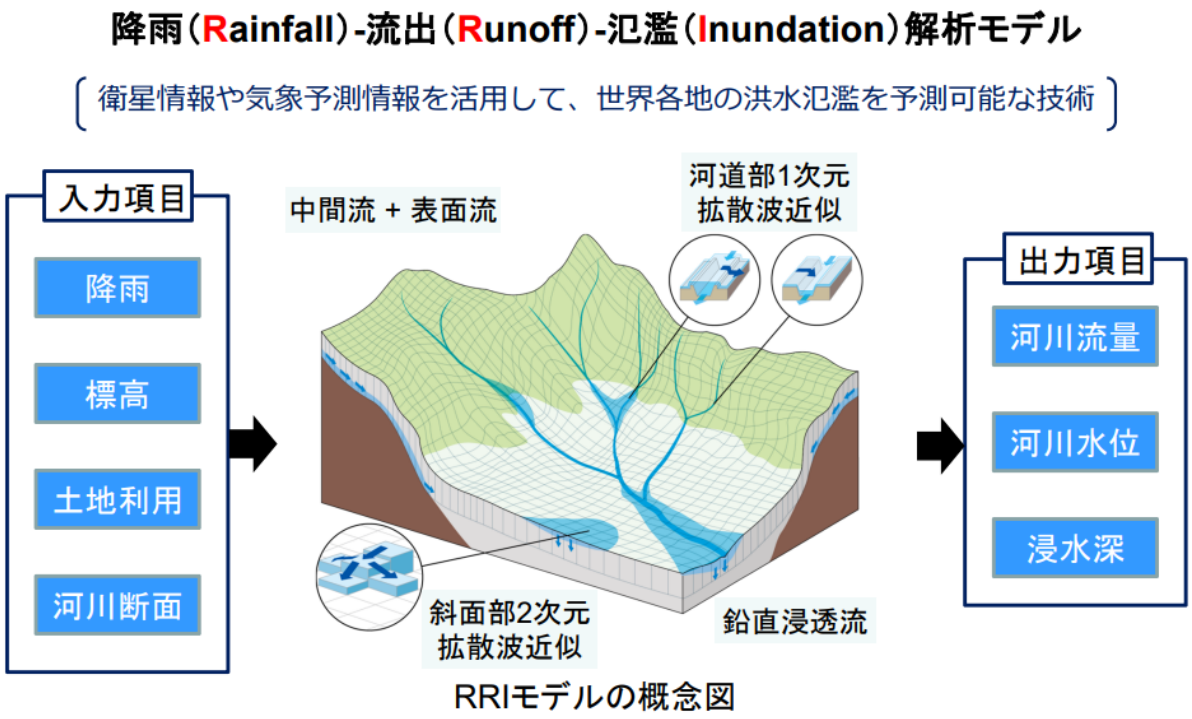

図-2.2　　RRI モデルの概要（出典：文献[13]）

(1)　斜面部の流れ

流域斜面を流れる表面流を扱う基礎式として以下の連続式と 2 次元の浅水方程式を扱う．

$$\frac{\partial h}{\partial t}+\frac{\partial q_x}{\partial x}+\frac{\partial q_y}{\partial y}=r-f \tag{2.3}$$

$$\frac{\partial q_x}{\partial t}+\frac{\partial u q_x}{\partial x}+\frac{\partial v q_y}{\partial y}=-gh\frac{\partial H}{\partial x}-\frac{\tau_x}{\rho_w} \tag{2.4}$$

$$\frac{\partial q_y}{\partial t}+\frac{\partial u q_y}{\partial x}+\frac{\partial v q_y}{\partial y}=-gh\frac{\partial H}{\partial y}-\frac{\tau_y}{\rho_w} \tag{2.5}$$

ここで，用いた各変数は以下の通りである．

h	：水深（m）
u，v	：x，y方向の流速（m/s）
q_x，q_y	：x，y方向の流量フラックス（$q_x=uh$，$q_y=vh$）（(m^3/s)/m）
r	：降雨強度（mm/h）
f	：鉛直浸透強度（mm/h）
g	：重力加速度（kg・m/s^2）
t	：時間（s）
H	：基準面からの水位（m）
ρ_w	：水の密度（kg/m^3）
τ_x，τ_y	：x，y方向のせん断力（N/m^2）

式(2.4)，(2.5)の右辺第二項は，Manning 則を用いて次のように計算する．

$$\frac{\tau_x}{\rho_w}=\frac{gn^2u\sqrt{u^2+v^2}}{h^{\frac{1}{3}}},\qquad \frac{\tau_y}{\rho_w}=\frac{gn^2v\sqrt{u^2+v^2}}{h^{\frac{1}{3}}} \tag{2.6}$$

ここで，n：マニングの粗度係数（$m^{-1/3}$・s）である．

(2)　浅水方程式の拡散波近似

RRI モデルでは上述の浅水方程式(2.4)，(2.5)の左辺の慣性項を十分に小さいものとして無視する拡散波近似を用いる．さらに x方向と y方向の流れを分離して扱うと下記の表式となる．

$$q_x=-\frac{1}{n}\cdot h^{\frac{5}{3}}\cdot\sqrt{\left|\frac{\partial H}{\partial x}\right|}\,sgn\left(\frac{\partial H}{\partial x}\right) \tag{2.7}$$

$$q_y=-\frac{1}{n}\cdot h^{\frac{5}{3}}\cdot\sqrt{\left|\frac{\partial H}{\partial y}\right|}\,sgn\left(\frac{\partial H}{\partial x}\right) \tag{2.8}$$

ここで，sgn は符号関数である．

(3)　地中側方流の扱い

RRI モデルでは表面流と不飽和・飽和側方流を一体的に扱い，上記(2.7)，(2.8)式の流量式を h の関数で考慮する以下の流量流積関係式で置き換える．

$$q_x = \begin{cases} -k_m d_m \left(\dfrac{h}{d_m}\right)^{\beta} \cdot \dfrac{\partial H}{\partial x}, & (h \le d_m) \\ -k_a (h - d_m) \cdot \dfrac{\partial H}{\partial x} - k_m d_m \cdot \dfrac{\partial H}{\partial x}, & (d_m < h \le d_a) \\ -\dfrac{1}{n}(h - d_a)^{\frac{5}{3}} \cdot \sqrt{\left|\dfrac{\partial H}{\partial x}\right|}\, sgn\left(\dfrac{\partial H}{\partial x}\right) - k_a (h - d_m) \cdot \dfrac{\partial H}{\partial x} - k_m d_m \cdot \dfrac{\partial H}{\partial x}, & (d_a < h) \end{cases} \tag{2.9}$$

$$q_y = \begin{cases} -k_m d_m \left(\dfrac{h}{d_m}\right)^{\beta} \cdot \dfrac{\partial H}{\partial y}, & (h \le d_m) \\ -k_a (h - d_m) \cdot \dfrac{\partial H}{\partial y} - k_m d_m \cdot \dfrac{\partial H}{\partial y}, & (d_m < h \le d_a) \\ -\dfrac{1}{n}(h - d_a)^{\frac{5}{3}} \cdot \sqrt{\left|\dfrac{\partial H}{\partial y}\right|}\, sgn\left(\dfrac{\partial H}{\partial y}\right) - k_a (h - d_m) \cdot \dfrac{\partial H}{\partial y} - k_m d_m \cdot \dfrac{\partial H}{\partial y}, & (d_a < h) \end{cases} \tag{2.10}$$

ここで，用いた各変数は以下の通りである．

k_a	：飽和透水係数（m/s）
d_a	：土層厚×有効空隙率（m）
d_m	：マトリックス部の層厚（m）
k_m	：$= k_a/\beta$. マトリックス部の飽和透水係数（m/s）
β	：不飽和時の透水係数の減少程度を表すパラメータ（-）

土層は重力水が発生する大空隙部と，毛管移動水の流れの場であるマトリックス部からなると考え(図-2.3)，土層厚を D（m），体積含水率をθとし，毛管移動水が支配的な体積含水率の範囲を$0 \le \theta < \theta_m$と考える．ここで，θ_mは大空隙部を除いたマトリックス部の飽和体積含水率であり，$d_m(= D\theta_m)$はマトリックス部の最大水分量を水深で表したものである．重力水が支配的な体積含水率の範囲を$\theta_m \le \theta < \theta_a$とする．$\theta_a$は空隙率であり，$\theta_a - \theta_m$が有効空隙率となる．ここで，$d_a = D\theta_a$とし，$\theta$に対応する水深を h として$h = D\theta$である．以上をまとめると，$h < d_m$ のとき(第 1 式)は不飽和流のみを，$d_m < h < d_a$のとき(第 2 式)は飽和流(第 1 項)と不飽和流(第 2 項)を，$d_a < h$の時(第 3 式)は表面流(第 1 項)，飽和流(第 2 項)，不飽和流(第 3 項)，を考慮していることとなる．

$0 \le h < d_m,$	$(0 \le \theta < \theta_m)$	：不飽和状態
$d_m \le h < d_a,$	$(\theta_m \le \theta < \theta_a)$	：飽和（中間流）
$d_a \le h,$	$(\theta_a \le \theta)$	：飽和（表面流）

(2.9)，(2.10)式で表される流量流積関係を図-2.4 に示す．

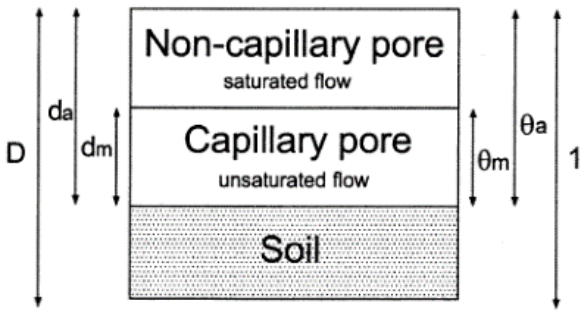

図-2.3　　土層中の空隙率の取り扱い（出典：文献[10]）

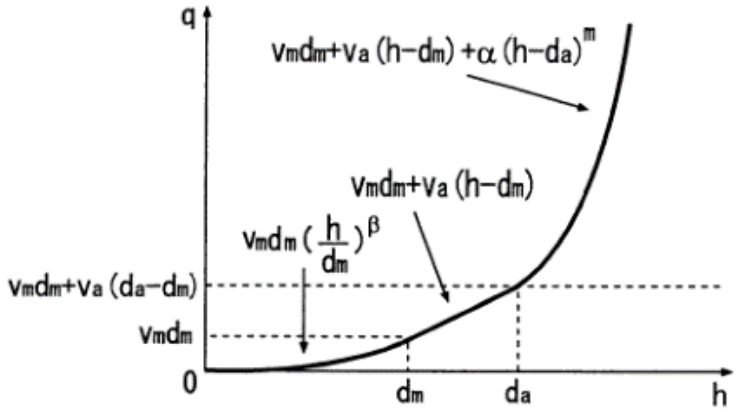

図-2.4　　流量・流積関係式（出典：文献[10]）

（4） 鉛直浸透モデル

鉛直方向の浸透強度 fは Green-Ampt モデルで計算し，地下への損失として取り扱う．Green-Ampt モデルの式は以下で表される．

$$f = k_v \left[1 + \frac{(\phi - \theta_i) \cdot S_f}{F} \right] \tag{2.11}$$

ここで，用いた変数は以下の通りである．

k_v　　：鉛直方向の飽和透水係数（m/s）
ϕ　　：土壌の空隙率（-）
θ_i　　：初期の体積含水率（-）
S_f　　：湿潤前面における吸引水頭（m）
F　　：累積浸透量（m）

上述した中間流・表面流モデルと Green-Ampt モデルを組み合わせると，土層から基盤岩に浸透する量を Green-Ampt モデルで計算し，残りの水が中間流・表面流として側方に流れることになる．

（5） 河道部の流れ

河道では，一次元の拡散波近似モデルを用いる．河道のあるセルでは河道を線分として表現し，河道と斜面の両方を配置する．

（6） 河道断面形状の扱い

RRI モデルの河道断面形状としては，幅 W [m]，深さ D [m]の長方形形状が基本となるが，任意の断面形状を用いることもできる．本検討では幅と深さは Regime 理論に基づき流域面積との関係からべき指数関数で簡易的に仮定する．

$$W = C_W \cdot A^{S_W} \tag{2.12}$$

$$D = C_D \cdot A^{S_D} \tag{2.13}$$

ここで，A [km^2]は当該河道区間の集水面積であり，C_W, C_D, S_W, S_D はパラメータである．

（7） 斜面部と河道部の流入出

河道が存在するグリッドでは，図-2.5 の(a)から(d)の場合に分けて河道の単位長さ当たりの流量を計算し，各セル中の河道ベクトルの長さをかけて流入出量を計算する．河道は各セルの中心線として扱われ，左右岸で異なる堤防高さを設定することはできない．

(a) 河道水位が地盤高より低い場合

段落ち式によって斜面から河道に流入する流量 q_{sr} を計算する．

$$q_{sr} = \mu_1 \cdot h_s \cdot \sqrt{g h_s} \tag{2.14}$$

ここで，μ_1 は定数（$= (2/3)^{3/2}$），h_s は斜面の水深である．堤防がある場合でも，河道水位が地盤高よりも低く，斜面水位が堤防高より低い場合には，斜面の水が河川に流入することを想定し，同式で河川への流量を計算する．

(b) 堤防があり，河道水位が地盤高より高く，かつ河道・斜面水位の両方とも堤防高より低い場合

河道と斜面は水のやりとりをしない．

(c) 河道水位が堤防高（無提の場合は地盤高）および斜面水位より高い場合

越流式によって河道から斜面への流量 q_{rs} を計算する．

$$q_{rs} = \begin{cases} \mu_2 \cdot h_1 \cdot \sqrt{2gh_1}, & h_2/h_1 \le 2/3 \\ \mu_3 \cdot h_2 \cdot \sqrt{2g(h_1 - h_2)}, & h_2/h_1 > 2/3 \end{cases} \tag{2.15}$$

ここで，μ_2，μ_3 は定数（=0.35，0.91），h_1：河道水位と堤防高の差，h_2：斜面水位と堤防高の差である．

(d) 斜面水位が堤防高（無提の場合は地盤高）および河道水位より高い場合

式(2.15)によって斜面から河道に流入する量 q_{sr} を計算する．この場合，h_1：斜面水位と堤防高の差，h_2：河道水位と堤防高の差である．

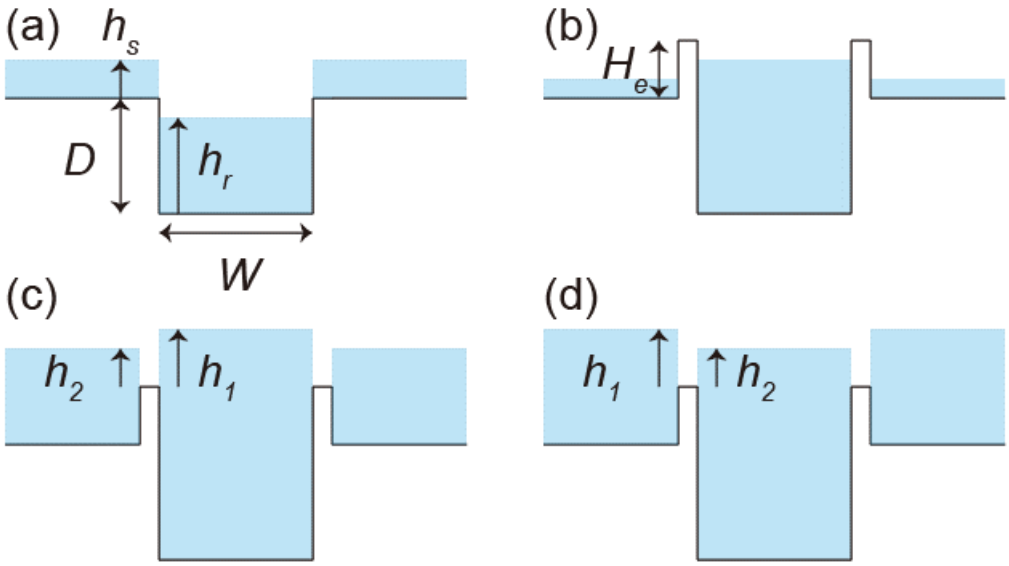

図-2.5　　河道・斜面の水の流出入を計算するための場合分け（出典：文献[12]）

（8）　数値計算スキーム

RRI モデルでは微分方程式の時間発展を，Cash and Karp[60]の提案した適応時間ステップルンゲクッタ法を用いて計算する．適応時間ステップルンゲクッタ法は，通常のルンゲクッタ法で常微分方程式を時間発展させると同時に，その誤差を推定して計算時間ステップを動的に調整する手法である．具体的には，5 次の精度を有する 6 ステップルンゲクッタで次の時間ステップにおける水深を推定するとともに，4 次の精度で計算した場合の水深を求めることによって両者の差から計算誤差を推定する．

5 次精度のルンゲクッタ法は以下で表される．

$$
\begin{aligned}
k_1 &= \Delta t \cdot f(t_n, h_n) \\
k_2 &= \Delta t \cdot f(t_n + a_2\Delta t, h_n + b_{21}k_1) \\
&\cdots \\
k_6 &= \Delta t \cdot f(t_n + a_6\Delta t, h_n + b_{61}k_1 + \cdots b_{65}k_5) \\
h_{n+1} &= h_n + c_1k_1 + c_2k_2 + c_3k_3 + c_4k_4 + c_5k_5 + c_6k_6 + \mathrm{O}(\Delta t^6)
\end{aligned}
\tag{2.16}
$$

また，同じ k_1 から k_6 の値を用いて，

$$
h^*_{n+1} = h_n + c^*_1k_1 + c^*_2k_2 + c^*_3k_3 + c^*_4k_4 + c^*_5k_5 + c^*_6k_6 + \mathrm{O}(\Delta t^5) \tag{2.17}
$$

のように 4 次精度の h_{n+1} を推定することができるため，4 次精度を仮定したときの誤差は，k_1 から k_6 を用いて以下で計算できる．

$$\delta \equiv h_{n+1} - h_{n+1}^{*} = \sum_{i=1}^{6} (c_i - c_i^{*}) k_i \tag{2.18}$$

いま，δ_dを許容誤差とし，δがδ_dを超える場合には，Δtをより小さいΔt_{post}に変化させて h_{t+1} を再度計算することで，動的に適切なタイムステップへの調整が行われる．

$$\Delta t_{post} = \max(0.9 \cdot \Delta t \cdot \left|\frac{\delta_0}{\delta}\right|^{0.25}, 0.5 \cdot \Delta t) \tag{2.19}$$

RRI モデルは河道，斜面，河道と斜面の水のやり取りを計算するが，河道は斜面に比べて小さい時間ステップを必要とすることが多いため，河道は斜面と独立した時間ステップで計算を進める．モデル利用者は河道と斜面のやり取りを計算する時間ステップΔt_sを設定することができ，その値が斜面の計算時間ステップの初期値として用いられる．また，河道の計算時間ステップはΔt_sの公約数を設定する必要がある．

2.4.4　深層学習モデルの概要

深層学習モデル（ディープニューラルネットワーク（Deep Neural Network: DNN））は，多層の人工ニューロン（ノード）を用いて，入力データから高次の特徴を自動的に抽出・学習する機械学習モデルである．基本的には，人間の脳の神経回路を模した人工ニューラルネットワーク（Artificial Neural Network: ANN）を多層化・拡張した構造を持つ．基本的な構造は，入力層，複数の隠れ層，出力層から構成される順伝播型ニューラルネットワーク（Feedforward Neural Network）であり，各層のユニット（ニューロン）は，前の層からの信号に重みを乗じ，バイアスを加えた上で，活性化関数を通して次の層へ伝達する．この活性化関数に非線形性を導入することで，DNN は線形モデルでは表現できない複雑で非線形な入力と出力の関係性を捉えることが可能である．DNN の持つ高い表現能力は万能近似定理（Universal Approximation Theorem）で裏付けられており [34–36]，隠れ層が 1 層のニューラルネットワークでも，そのユニット数（幅）を十分に大きくして非線形活性化関数を用いれば，任意の連続関数を任意の精度で近似できることが示されている．ただし，現実の深層学習モデルにおいては，単に幅を広げるだけでなく，層を深くする（ディープにする）ことによって，より少ないパラメータで複雑な関数を効率よく近似できることが知られている．

近年，深層学習モデルは画像認識，音声認識，自然言語処理，時系列予測など多様な分野で高精度を実現している．入力構造やタスク特性に応じた DNN 構造が用いられており，代表的なものとして画像処理に長けた畳み込みニューラルネットワーク（Convolutional Neural Network: CNN）[37, 38]や時系列データの処理に長けた再帰型ニューラルネットワーク（Recurrent Neural Network: RNN）[39, 40]，時系列や文脈依存のデータ解析に優れ，大規模言語モデル(Large Language Models: LLM)等で利用が拡大しているトランスフォーマーモデル [41, 42]などが挙げられる．DNN の強みは，特徴量設計を人手に頼らずデータから自動抽出できる点にある．一方で，学習には大量のデータと高い計算コストを要し，過学習のリスクや解釈性の低さが課題とされる．

本研究では基本的な DNN である全結合型 DNN を用いるため，以下では，全結合型 DNN の概要と学習アルゴリズムを示す．

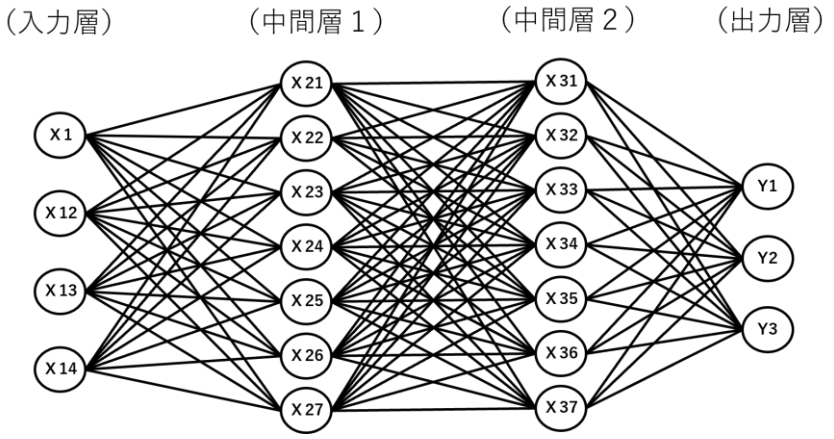

図-2.6　　全結合型 Deep Neural Network の模式図

（1） 全結合型 DNN の構造

全結合型 DNN は入力層，中間層（2 層以上），出力層から構成され，各層に属する複数のユニットセル（ニューロン）が全結合したネットワーク構造となっている（図-2.6）．全結合型 DNN は，FCN（Fully-Connected Neural Network）や MLP（Multi-Layer Perceptron）と呼ばれることもあるが，いずれも同じ構造を意味する．ネットワークを構成する各ユニットセルでは下記の計算が行われる．

$$u = \sum_i W_i x_i + b_i \tag{2.20}$$

$$z = f(u) \tag{2.21}$$

ここで，x_iはi番目の入力値，W_i，b_iはi番目の入力値に重み係数とバイアス，uは重み付き入力和，fは活性化関数，z はユニットセルの出力値であり，W_i，b_iが学習対象パラメータである．上記の計算を入力層から出力層に渡って各層のユニットセルで行うことにより，全結合型 DNN の最終出力が得られる．

入出力間の非線形関係を表現可能とするため，活性化関数fには一般に非線形関数が用いられる．活性化関数の種類は層ごとに選択されるケースが多く，回帰問題に適用する場合の出力層では，変換を行わない恒等関数（$u = f(u)$）が用いられることもある．

（2） 学習アルゴリズム

深層学習モデルでは，目的に応じて設定された評価関数を最小化・最大化するようにネットワーク内のパラメータ（重み：W_i，バイアス：b_i）を最適化（学習）する．評価関数は目的に応じて様々な設定が可能であるが，最も一般的な学習方法である教師あり学習では，入力と出力のペアで構成されるデータセットに対して，同じ入力に対するデータセット出力（正解ラベル）とモデル出力の残差を評価関数（損失関数）として設定し，これを最小化するようにモデル学習が行われる．

深層学習モデルのパラメータ学習は，損失関数を対象とした勾配法により実現される．最も単純なパラメータ更新式は，損失勾配を用いた次式の最急降下法である．

$$\theta_{new} = \theta - \eta \frac{\partial E(\theta)}{\partial \theta} \tag{2.22}$$

ここで，θは最適化対象のパラメータ（重みやバイアス），Eは損失関数，ηは学習率を表す．学習率は，1 回あたりのパラメータ更新の大きさを表すハイパーパラメータである（アルゴリズムによる最適化対象パラメータと区別するため，これらの人が決定するパラメータはハイパーパラメータと呼ばれる）．上記のパラメータ更新の繰り返しにより，損失関数の最小化が実現される．

勾配法については最急降下法を改良した様々な手法が提案されているが，近年の深層学習においては，最急降下法から収束性能などが改善された Adam（Adaptive Moment Estimation）[43]がデファクトスタンダードとして用いられている．Adam は，確率的勾配降下法（SGD）[44]を拡張した深層学習用の最適化アルゴリズムであり，学習率の自動調整とモーメント推定を組み合わせることで，学習の安定性と収束速度を両立している．特に，勾配の方向が不安定な深層ネットワークの訓練において，過学習を抑えつつ効率的に最適点へ到達する特徴をもつ．

Adam では，t回目の更新におけるパラメータ θ_tに対して損失関数の勾配 $g_t = \nabla_\theta E_t$を計算し，その勾配履歴を一次モーメント（平均）と二次モーメント（分散）として蓄積する．まず，一次モーメント m_tは次式で表される「勾配の移動平均」であり，過去の勾配の傾向を滑らかに追跡する．

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t. \tag{2.23}$$

ここで，β_1（一般に 0.9 程度）は慣性の強さを決めるパラメータであり，値が大きいほど過去の勾配の影響が長く残る．これは局所的なノイズを平均化し，パラメータ更新方向を安定化させる役割を持つ．

次に，二次モーメント v_tは次式で表される「勾配の平方の移動平均」であり，勾配の大きさのばらつきを表す．

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \tag{2.24}$$

ここで，β_2（一般に 0.99 程度）は過去の勾配分散をどの程度考慮するかを制御する．勾配が大きいパラメータでは更新量を小さく，勾配が小さいパラメータでは更新量を大きくするため，学習率を自動的にスケーリングする仕組みを提供している．初期段階では m_tと v_tがゼロ初期化されていることに起因して値が小さく見積もられるため， Adam では次のようなバイアス補正式を用いる．

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}. \tag{2.25}$$

これらを用いた最終的なパラメータ更新式は次式で表される．

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \tag{2.26}$$

ここで ηは学習率，ϵ は数値的不安定を防ぐための小さな値（一般に 10^{-8}程度）である．

Adam はこのように，勾配の一次・二次統計量を動的に推定して更新幅を調整するため，急峻な損失地形でも振動せず，収束が速い特徴があり，現在では深層学習における標準的な最適化手法の一つとなっている．なお，深層学習モデルでは最適化対象のパラメータ数が膨大となるため，2 次以上の勾配情報（ヘッセ行列）を用いる手法（ガウス・ニュートン法や Levenberg-Marquardt 法など）はメモリ量の問題などから用いられないことが多い．

深層学習モデルにおける損失勾配は，誤差逆伝搬法（バックプロパゲーション）により求めることができる．バックプロパゲーションは計算グラフ上で微分の連鎖律（chain rule）を適用してニューラルネットワークの出力誤差を各ユニットセルへ逆向きに伝搬させ，各重みを更新することで損失関数を最小化するアルゴリズムであり，深層学習モデルの効率的な学習を可能にする基盤技術の 1 つである．

前述のユニットセルにおける計算を層に拡張すると，各層 lにおけるユニットセル jの出力を $z_j^{(l)}$，その重み付き入力和を $u_j^{(l)}$，前層のユニット iからの入力信号を $z_i^{(l-1)}$，対応する重みを $w_{ji}^{(l)}$，バイアスを $b_j^{(l)}$として，順伝搬は下記で表される．

$$u_j^{(l)} = \sum_i w_{ji}^{(l)} z_i^{(l-1)} + b_j^{(l)}, \qquad z_j^{(l)} = f(u_j^{(l)}) \tag{2.27}$$

最終層 Lの出力 $z_j^{(L)}$と教師データ y_jの間の誤差は，例えば損失関数に二乗誤差関数を用いた場合には下記となる．

$$E = \frac{1}{2}\sum_j (y_j - z_j^{(L)})^2 \tag{2.28}$$

次に誤差を出力層から逆向きに伝播させる．出力層の各ユニット jにおける誤差（デルタ）は次のように定義される．

$$\delta_j^{(L)} = \frac{\partial E}{\partial u_j^{(L)}} = (z_j^{(L)} - y_j) f'(u_j^{(L)}) \tag{2.29}$$

ここで f'は活性化関数の導関数である．隠れ層のユニット jの誤差は，次層 $l+1$のユニットの誤差を用いて再帰的に求められる．

$$\delta_j^{(l)} = f'(u_j^{(l)}) \sum_k w_{kj}^{(l+1)} \delta_k^{(l+1)} \tag{2.30}$$

以上から，各ユニットにおける重みとバイアスの勾配は次のように表すことができる．

$$\frac{\partial E}{\partial w_{ji}^{(l)}} = \delta_j^{(l)} z_i^{(l-1)}, \qquad \frac{\partial E}{\partial b_j^{(l)}} = \delta_j^{(l)} \tag{2.31}$$

この勾配を用いて，Adam 等の勾配法により各パラメータが最適化される流れとなる．以上のように，バックプロパゲーションでは各ユニットが独立に「自分の出力が全体の誤差にどの程度寄与したか（$\delta_j^{(l)}$）」を計算し，それに基づいて各重みが調整される．これを全ユニット・全層について繰り返すことで，ネットワーク全体として損失関数が最小化され，入力から出力への最適な非線形写像が学習される．

（3） 過学習と正則化手法

深層学習モデルを始めとした機械学習モデルで留意すべき問題に過学習（overfitting）がある．過学習とは，ニューラルネットワークなどの学習モデルが訓練データに過度に適応しすぎることで，未知のデータ（テストデータや実運用データ）に対する汎化性能が低下する現象である．モデルが訓練データ中のノイズや偶然のパターンまで学習してしまうと，訓練誤差は小さくなる一方で，検証誤差（テスト誤差）は増大する．この状態を把握する代表的な指標が学習曲線（learning curve）である．

学習曲線とは，横軸にエポック数（学習の繰り返し回数），縦軸に損失関数値または精度を取り，訓練データと検証データのそれぞれに対する誤差を時系列で可視化したものである．通常，学習初期では両者の誤差がともに減少するが，ある時点から訓練誤差だけが減少し続け，検証誤差が増加に転じると過学習が発生していると判断できる．また，訓練誤差が高止まりしている場合は未学習（underfitting）の可能性がある．したがって，学習曲線を観察することでモデルの学習状態を視覚的に評価できる．

過学習を防ぐためには，モデルの自由度を制御し，汎化性能を高める正則化（regularization）が重要である．深層学習モデルにおける代表的な正則化手法は以下の通りである．

a） L2 正則化（Ridge）
損失関数E に各重みw_iの二乗和を加え，大きな重みを抑制することで滑らかなモデルを生成する．λは適当な正の実数であり，0.01 程度の値が一般的に用いられる．

$$E' = E + \lambda \sum_i w_i^2 \tag{2.32}$$

b） L1 正則化（Lasso）：損失関数に重みの絶対値和を加え，不要な重みを 0 に近づけることでスパースなモデルを得る．

c） Dropout：学習中に一部のユニットセルを確率的に無効化し，特定のユニットセルへの依存を防ぐ．

d） Early Stopping（早期終了）：検証誤差が増加に転じた時点で学習を停止し，最も汎化性能が高いモデルを採用する．

e） データ拡張（Data Augmentation）：ノイズ付加やデータ合成などで訓練データを多様化し，モデルの汎化性能を高める．

（4） DNN モデルの構築手順

深層学習モデル構築手順は次の通りである．まず目的に応じた十分な量と多様性をもつデータを集め（データ収集），次に，収集データに対して欠損値や外れ値の処理，正規化，スケーリングなどを行い，モデルが効率的に学習できる状態に整える（データ前処理）．その後，前処理後のデータを学習対象の学習データ，学習中の汎化性能を確認する検証データ，最終評価を行うテストデータに分割する（データセット作成）．

データセットの整備後は，課題に適したネットワーク構造や学習手法（DNN 種別，層数やユニット数，活性化関数，損失関数，最適化手法など）を選択し（モデル設計），モデルの最適化を試行する（モデル学習）．学習過程における学習曲線（訓練誤差と検証誤差）を観察して過学習や未学習を検出し，必要に応じて正則化やデータ拡張，ハイパーパラメータのチューニングを実施する（モデルチューニング）．最後にテストデータで精度等を評価し，最も汎化性能の高いモデルを採用する（モデル評価・選定）．

2.5　ハイブリッド流出予測モデルの構築

2.5.1　対象流域と検証条件

本検討における対象流域は複数の先行研究事例[1, 22)]が存在する宮崎県大淀川流域（流域面積 861 km²）とし，樋渡観測所水位を予測対象として選定した（図-2.7）．これは，先行研究との比較によるモデル精度の妥当性確認を容易にするためである．このため，検証条件（観測データおよび洪水事象）もこれらの先行研究における条件設定を踏襲し，水文水質データベース[45)]より取得した 14 か所の雨量観測所と樋渡地点を含む 5 か所の水位観測所の時系列観測データ（1 時間間隔）から学習・検証用のデータセットを構築した．データセットは，1990 年から 2014 年の間に樋渡観測所の氾濫注意水位 6.0 m を超過した 24 洪水のうち，欠損データが多い 4 洪水を除外した 20 洪水で構成される（表-2.2，図-2.8）．各洪水における抽出期間は，ピーク水位の 72 時間前から 48 時間後までの 120 時間とした．また，分布型流出モデルである RRI モデルに入力するメッシュ雨量データは，14 か所の雨量観測所データを用いたティーセン分割により生成した．

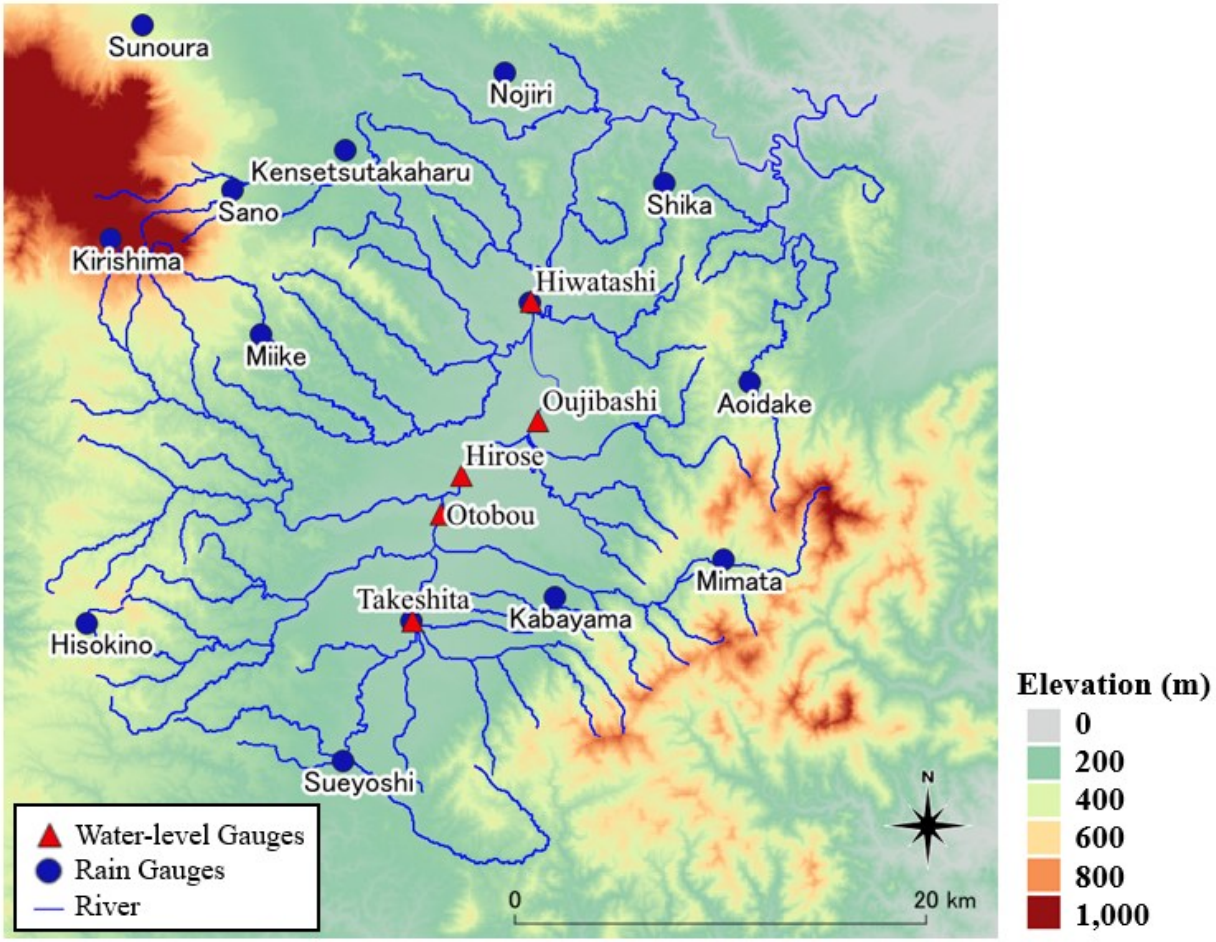

図-2.7　　検証対象の大淀川流域

表-2.2　対象出水と各観測地点のピーク水位

対象洪水	樋渡 (m)	王子橋 (m)	広瀬 (m)	乙房 (m)	岳下 (m)
1990/09/19	7.47	7.05	5.34	6.06	3.02
1990/09/29	9.44	8.47	6.60	7.49	4.91
1993/08/01	9.50	7.94	6.12	6.55	3.97
1993/08/10	8.04	7.07	5.88	6.35	4.47
1993/09/03	6.99	7.12	6.00	6.38	4.90
1995/06/25	6.90	6.45	5.37	6.08	4.57
1996/07/18	6.84	6.13	4.84	5.53	3.55
1999/07/27	6.72	6.59	4.96	5.72	3.82
1999/08/17	6.03	5.66	4.16	4.64	3.12
1999/09/14	8.26	7.48	5.64	5.81	5.27
2000/06/03	6.53	6.18	4.81	5.56	4.37
2003/08/08	6.79	6.48	4.39	4.99	3.34
2004/08/30	9.80	8.89	6.64	7.43	5.08
2004/10/20	7.70	7.09	5.07	5.44	3.10
2005/09/06	10.65	9.32	6.82	7.45	4.90
2007/07/14	7.11	7.05	5.24	5.94	3.50
2010/06/20	6.30	6.49	4.98	5.62	3.48
2010/07/03	9.16	7.86	6.14	6.43	2.91
2014/07/31	6.61	6.61	4.99	5.04	4.41
2014/08/09	6.08	6.65	4.48	4.58	3.03

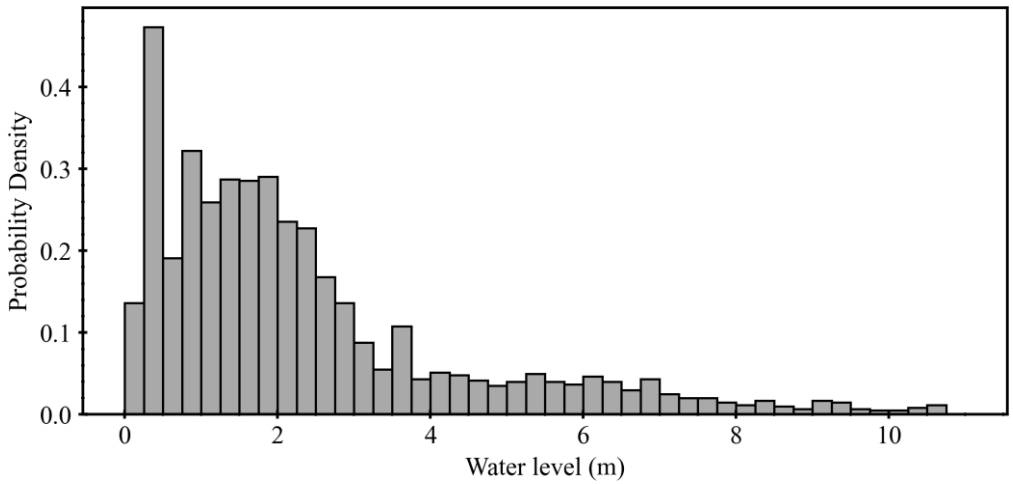

図-2.8　　対象データセットにおける樋渡地点水位（目的変数）の頻度分布

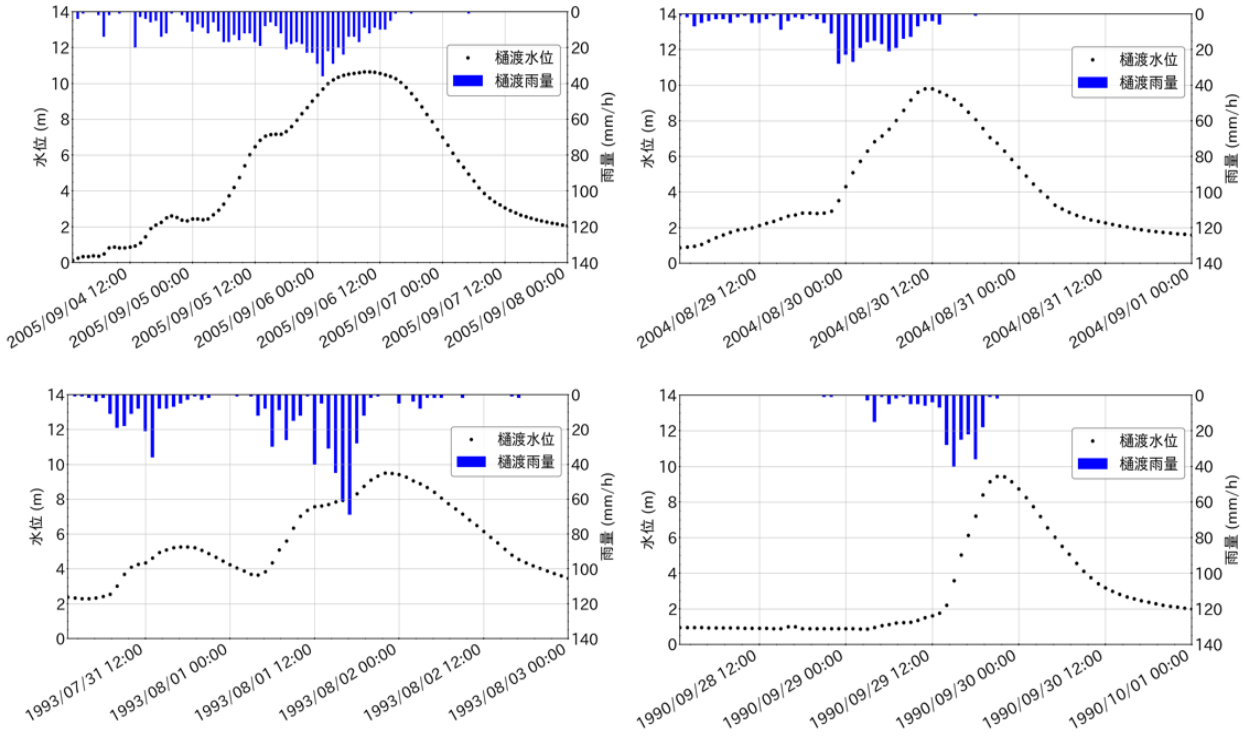

図-2.9　　検証対象出水のハイエト・ハイドログラフ（樋渡地点）

本検討では降雨流出モデルの予測精度が主眼となるため，外力にあたる入力降雨については実績雨量を予測降雨として用いる完全予測条件下で検討を行った．検証対象出水は構築データセットにおける樋渡地点ピーク水位上位 4 出水（図-2.9）とし，予測精度評価は検証対象出水に対する Leave-one-out 交差検証により実施した．すなわち，検証洪水のうちの 1 つを検証データ，これを除く 19 洪水を学習データとした学習・検証を 1 セットとし，これを検証対象 4 出水のそれぞれに対して実施した結果の平均値により精度を評価した．精度評価期間は先行研究 [55, 58] と同様に水位上昇が開始した時刻からピーク水位の 6 時間後までの期間とし，予測精度指標には精度評価期間における RMSE（Root Mean Squared Error：2 乗平均平方根誤差）を用いた．RMSE の表式は下記の通りである．

$$RMSE = \sqrt{\frac{1}{n}\sum_{t}^{n}(H(t) - H_{forecast}(t))^2} \tag{2.33}$$

ここで$H(t)$は時刻tにおける観測水位，$H_{forecast}(t)$は時刻tにおける予測水位，　nは評価対象期間である．

2.5.2 RRI モデルの構築

（1） 地形データとモデルパラメータ設定

RRI モデルの構築にあたり，地形データは J-FlowDIR（Japan Flow Direction Map）データセット[46]を利用した．J-FlowDIR は国土地理院の標高データ・水域データ等を基に日本全国を対象に高解像度（約 30 m：1 秒角）で整備されたデータセットであり，各グリッドセルの流向データ，水文補正標高，上流集水面積，上流集水グリッド数，河道幅などの地形・水文データが整備されている．オリジナルデータは 1 秒（約 30m）の空間解像度であるが，本検討では計算負荷を考慮して 4 秒（約 120m）にアップスケーリングを行い，標高と集水セル数（集水面積）メッシュデータを作成した（図-2.7，図-2.10）．対象流域の計算メッシュ数は 337×320 の 107840 メッシュである．

対象流域の土地利用については，国土数値情報の土地利用データ[47]（図-2.10）より，山地，農地，建物用地が流域の大半を占めていることが確認できる．分布型流出モデルではこれらの土地利用に応じてメッシュごとに等価粗度係数や浸透率等の斜面部パラメータを決めるのが通常であるが，次項に示す SCE-UA 法を用いたパラメータキャリブレーションにおいて，複数の土地利用設定を反映させた場合に最適化結果の分散が大きく不安定化することが判明したため，本検討ではパラメータ最適化の安定性を優先して斜面部パラメータセットは 1 種別とし，表面流出と側方地中流出を考慮するパラメータケース（図 2-11：(C) ケース）を採用した．

河道設定については，河道断面形状の設定は RRI モデルで標準のレジーム則に基づく矩形設定を採用し，河道セルを決定する集水セル数閾値パラメータ（riv_thresh）とレジーム則パラメータは次項に示すパラメータキャリブレーションにより決定した．集水セルサイズは約 120m 四方となるため，集水セル数N_{acc}と集水面積A_{acc}（km^2）の概算関係は$N_{acc} = 0.0144\ A_{acc}$となる．

（2） モデルパラメータのキャリブレーション

モデルパラメータのキャリブレーションは RRI モデルに対する適用事例が多い SCE-UA 法により実施した．最適化対象の洪水にはハイブリッドモデルで検証対象となる 4 出水（1990/09/29，1993/08/01，2004/08/30，2005/09/06）を除いた中で最も樋渡地点のピーク水位が大きい 2010/7/3 洪水を採用し，最適化対象の評価関数は樋渡地点水位における 2 乗平均誤差とした．

最適化対象パラメータと最適化前後のパラメータ値の一覧を表-2.3 に，最適化前後の検証対象 4 洪水に対する樋渡地点水位の再現波形を図-2.12 に，図示期間における RMSE とピーク水位誤差を表-2.4 に示す．パラメータキャリブレーションによって水位の過小評価傾向と RMSE が改善していることが確認できる．より詳細なパラメータチューニングにより RRI モデル自体の再現精度をさらに向上させることは可能であるが，本検討の趣旨とは外れるため，本検討では表-2.3 に示した調整後の RRI パラメータセットによる計算値を以降では用いることとした．

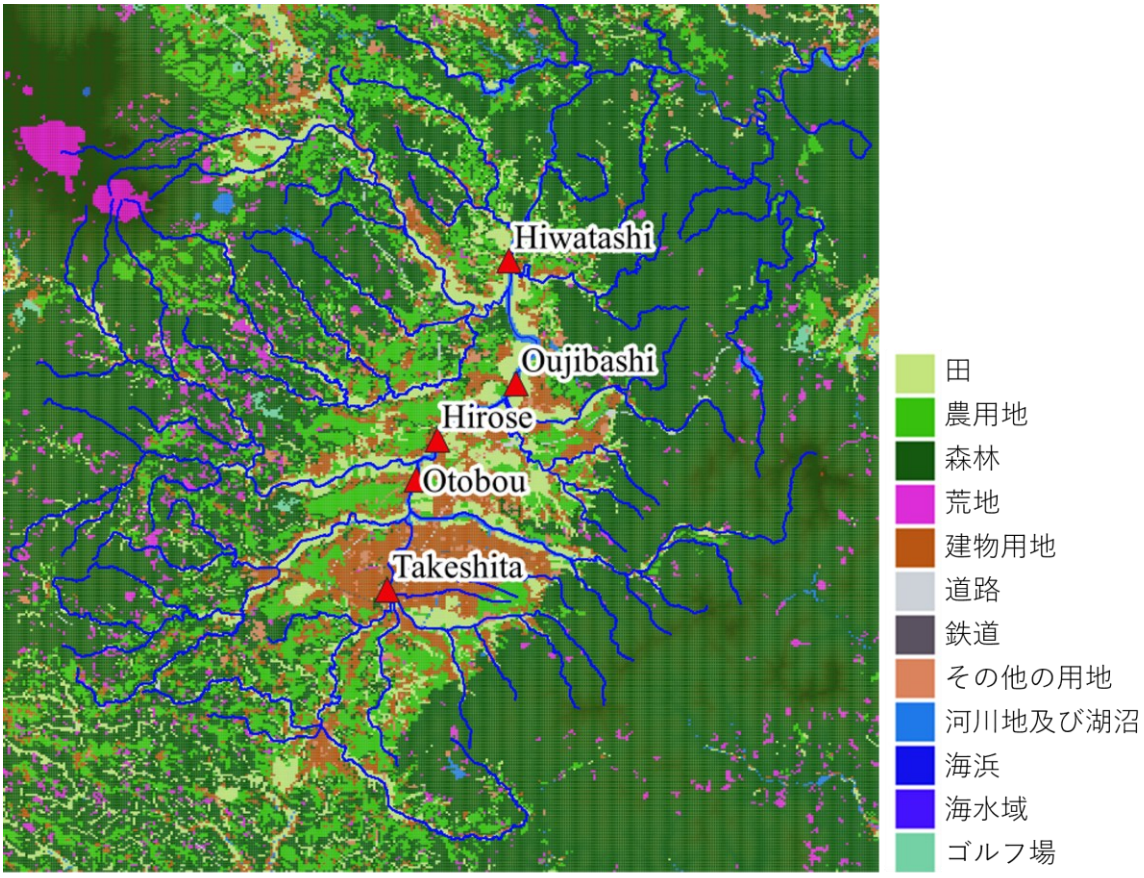

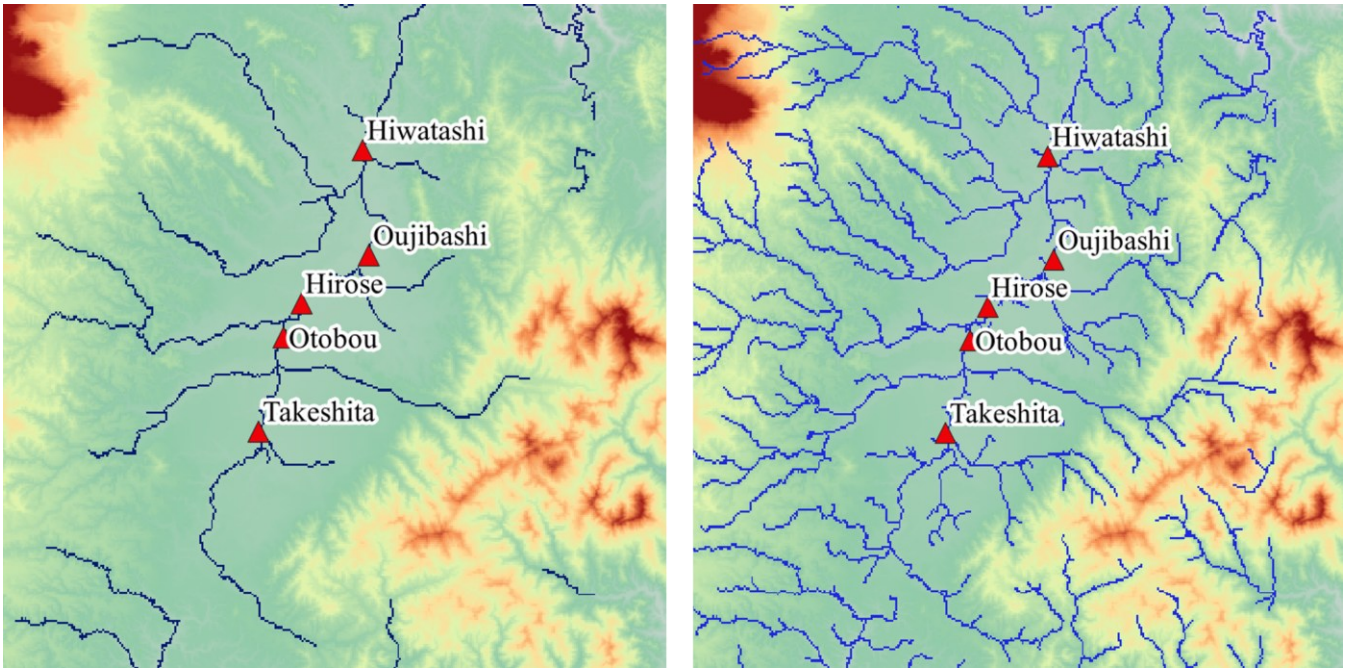

図-2.10　上：土地利用，下：河道セルの設定基準となる集水セル数 ※基準値以上を青線で表示
（左下：1633（約 24km^2 ）以上，右下：150（約 2km^2 ）以上）

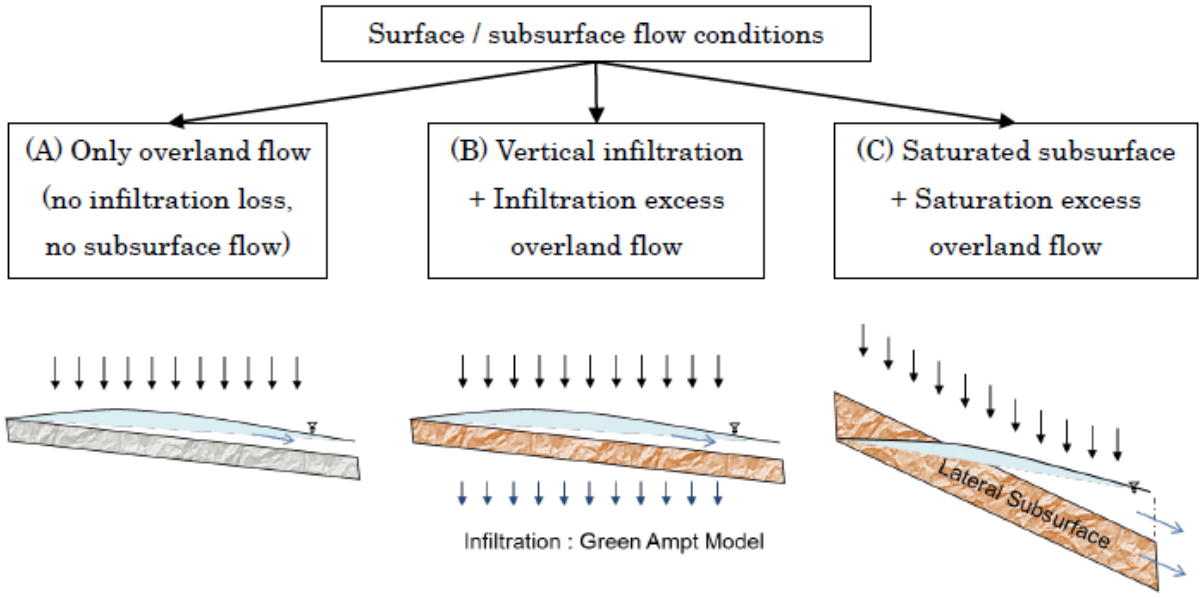

Example of parameter values (their recommended ranges)

Parameters	Notation	(A)	(B)	(C)
n (River) ($m^{-1/3}s$)	ns_river		0.03d0 (0.015 ~ 0.04)	
n (Land) ($m^{-1/3}s$)	ns_slope		0.3 d0 (0.15 ~ 1.0)	
Soil depth (m)	soildepth		1.0 d0 (0.5 ~ 2.0)	
Porosity (-)	gammaa		0.471d0 (0.3 ~ 0.5)	
k_v (m/s)	kv	0.d0	5.56d-7	0.d0
S_f	Sf	inactive	0.273d0	inactive
k_a (m/s)	ka	0.d0	0.d0	0.1d0 (0.01-0.3)
Unsat. porosity (-)	gammam		Inactive	0.d0
β	beta	inactive	Inactive	inactive

Note: 0.d0 is used in RRI_Input.txt to represent double precision of 0.0.

図-2.11　RRI モデルのパラメータ設定例（出典：文献[12]）

表-2.3　RRI モデルパラメータ一覧

パラメータ	記号	設定値 (初期)	設定値 (調整後)	単位
河道の粗度係数	n_r	0.040	0.025	$m^{-1/3}$・s
斜面の粗度係数 (等価粗度)	n_s	0.30	0.57	$m^{-1/3}$・s
土層厚	D	1.0	0.81	m
空隙率	γ_a	0.471	0.319	-
鉛直方向の飽和透水係数	k_v	0.0	0.0	m/s
湿潤前面における吸引圧	S_f	- (inactive)	- (inactive)	m
側方の飽和透水係数	k_a	0.0	0.485	m/s
空隙率（不飽和層）	γ_m	0.0	0.0175	-
定数 β	β	4.0	12.0	-
河道設定集水セル数閾値	r_{thresh}	1500	111	-
レジーム則：河道幅係数	C_W	5.1	3.4	m
レジーム則：河道幅指数	S_w	0.65	0.48	-
レジーム則：河道深さ係数	C_D	0.42	0.33	m
レジーム則：河道深さ指数	S_D	0.42	0.52	-
差分時間間隔（斜面）	dt	600	600	s
差分時間間隔（河道）	ddt	60	60	s

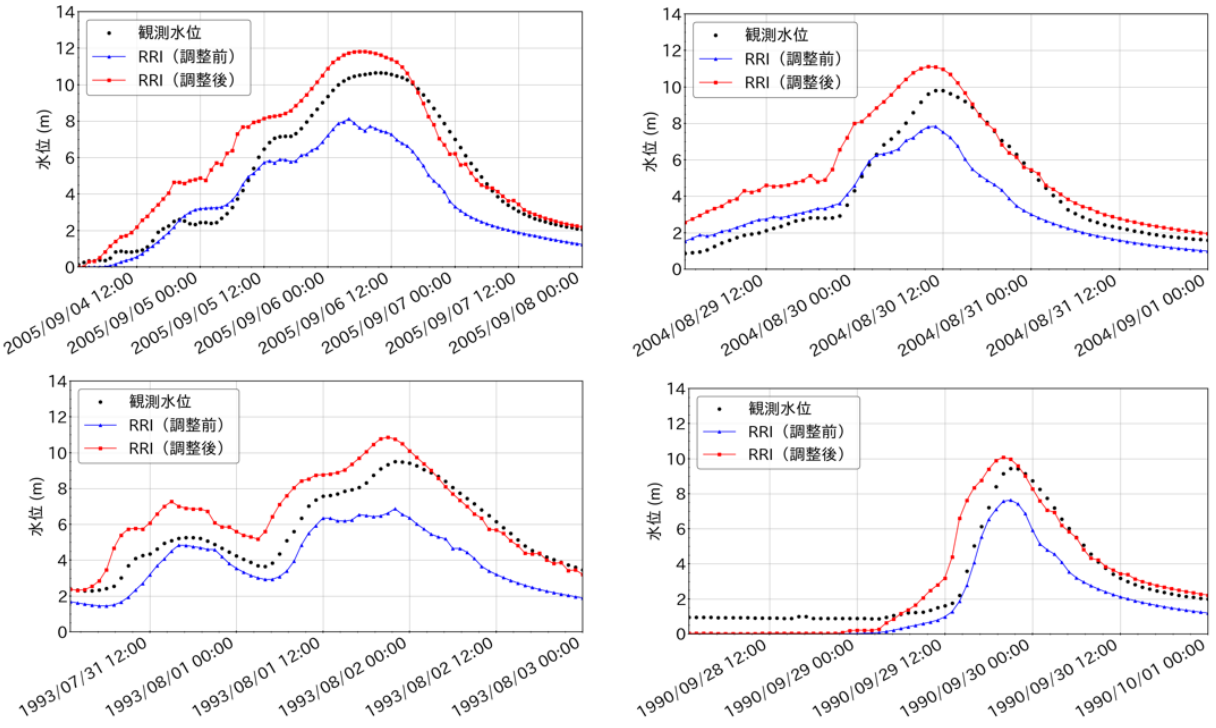

図-2.12　検証 4 洪水に対する再現計算結果

表-2.4　検証洪水に対する RMSE（m）　※()内はピーク水位誤差（m）

対象洪水	1990/09/29	1993/08/01	2004/08/30	2005/09/06
調整前	1.17 (−1.80)	1.69 (−2.63)	1.13 (−1.96)	1.78 (−2.52)
調整後	1.03 (+0.65)	1.12 (+1.36)	1.40 (+1.31)	1.30 (+1.17)

2.5.3　DNN モデルの構築とハイブリッド化

(1)　DNN モデルの予測方式

AI モデルによる時系列予測には，予測方法の違いから主に三つの方式がある．

a）予測対象時間ごとにモデルを構築する方式

各予測時点に特化した個別モデルを作成する手法である．例えば 1 時間後，2 時間後などの各リードタイムに対して専用のモデルを訓練するため，各時間帯の特徴を反映した高精度な予測が可能となる．一方で，モデル数が多くなり学習・維持のコストが増大するという課題がある．

b）単ステップ予測を繰り返し適用する方式（逐次予測方式）

直近の観測値から 1 ステップ先を予測し，その結果を次の入力として次々に先の時刻を推定する方法である．この方式は 1 つのモデルで複数時間先を推定できる点で効率的だが，予測誤差が累積しやすく，長期予測では精度が低下する傾向がある．

c）予測対象時間分を一括予測出力する方式（多ステップ同時予測）

一度の推論で複数時刻の値をまとめて出力する方法である．長期の動向を一貫して捉えやすく，誤差の伝播を防げる利点があるが，全期間のパターンを同時に学習するため汎化性能の高いモデルを構築するためには多量の学習データが必要となる．

本検討では予測対象時間を 24 時間後までに設定したため，予測精度を重視した方式 a)を採用することとした．

(2)　DNN モデルのハイブリッド化

DNN モデルは全結合型（Fully-Connected：FC）の 4 層構成とし，DNN モデルへ入力する説明変数に RRI モデルによる主要地点の流量計算値を追加することでハイブリッド構成を実現した（図-2.13）．具体的な RRI 計算値の入力条件は次項で示す．また以降の検討の学習条件には，事前試行において安定した収束を確認した表-2.5 の設定値を共通で用いた．収束性能の安定化のため，本検討の Optimizer には Adam に Nesterov の補正項を導入した Nadam[48)]を用いた．

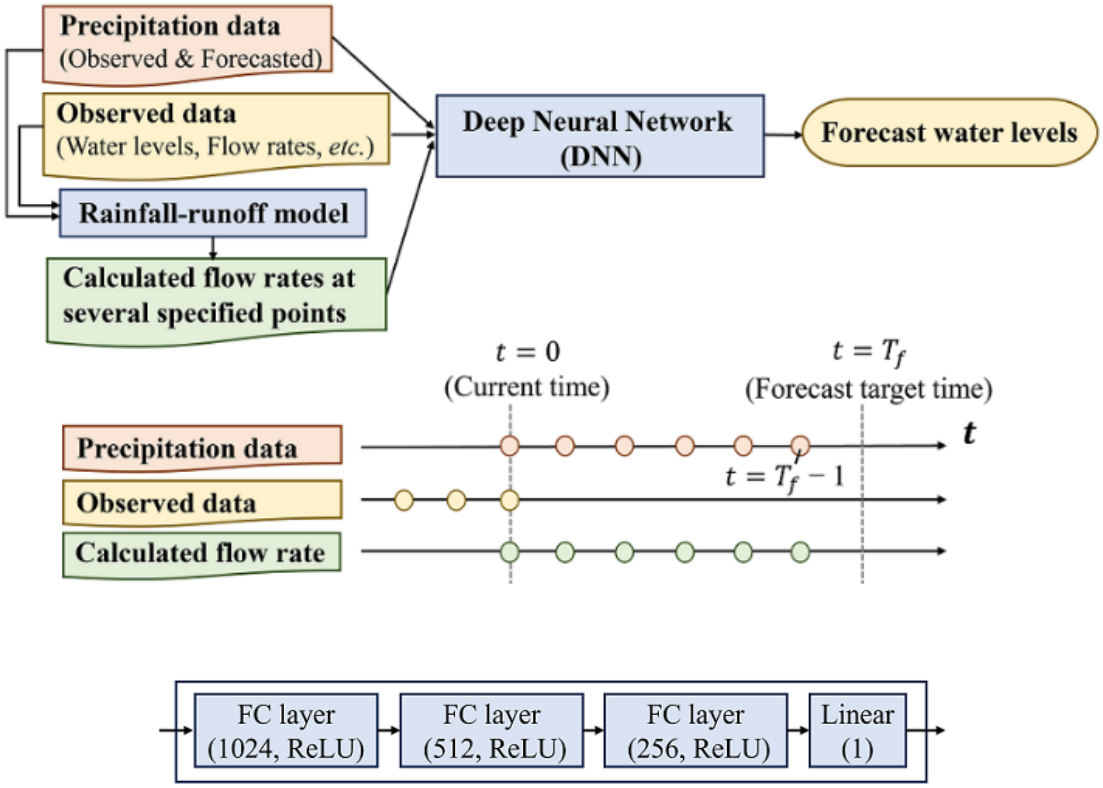

図-2.13　　ハイブリッド DNN の入出力構成

表-2.5　共通の学習条件

Parameter	Value
Loss function	Mean Squared Error
Optimization algorithm	Nadam
Learning rate	0.001 (Decreased by 1/5 times every 10 epochs.)
Batch size	16
Learning epochs	30

2.6　ハイブリッドモデルの効果的な構築方法の検討

2.6.1　効果的な計算流量連携地点の検討

(1)　検証設定

本ハイブリッド構成における重要な自由度の一つである，DNN モデルへ連携入力する物理モデルの計算流量地点選択に関する知見を得るため，連携入力地点に関するケーススタディを実施した．

各ケースの入力変数の組み合わせを表-2.6 に示す．各ケースで共通となる入力変数は，樋渡地点の観測水位と各水位観測所(５地点)における観測水位変化量であり，これに加えて，各ケースで対象地点とする RRI 計算流量が入力対象となる．RRI 計算流量は観測/予測降雨量から流出過程を考慮して抽出された特徴量と考えられるため，同等の情報となる観測/予測降雨量はここでは入力対象としない．Case1 は予測対象となる樋渡地点における計算流量のみを追加入力するケースであり，これは物理モデルで計算した流量から水位に変換する HQ 換算式を DNN モデルで近似する構成[30]と非常に近い条件設定である．Case2 は水位観測所 5 地点（図-2.14 中の赤三角）における計算流量を入力対象としており，これは主流部の流量状況のみを追加入力する条件設定である．Case3 と Case4 は支流を含む上流部を入力するケースであり，入力地点は河道セルの集水面積を基準に設定した．先行研究[1]では雨量観測所地点 14 か所が入力対象に設定されていたため，入力地点数が同等程度となる集水面積 24km^2 以上の上端地点を Case3 の入力対象地点とし（図-2.14 中の紺菱形），Case4 は Case3 の 1/2 となる集水面積 12km^2 以上の上端地点を入力地点に設定した(図-2.14 中の赤丸)．また，ハイブリッド化の効果を確認するために RRI 計算流量を入力しない DNN 構成（単純な AI モデル）を Case5 とした．

予測精度の評価には，DNN の初期重みや学習プロセスに対する疑似乱数の影響を低減するため、異なる乱数シードを用いて独立に学習した 10 モデルの予測平均値を用いた．

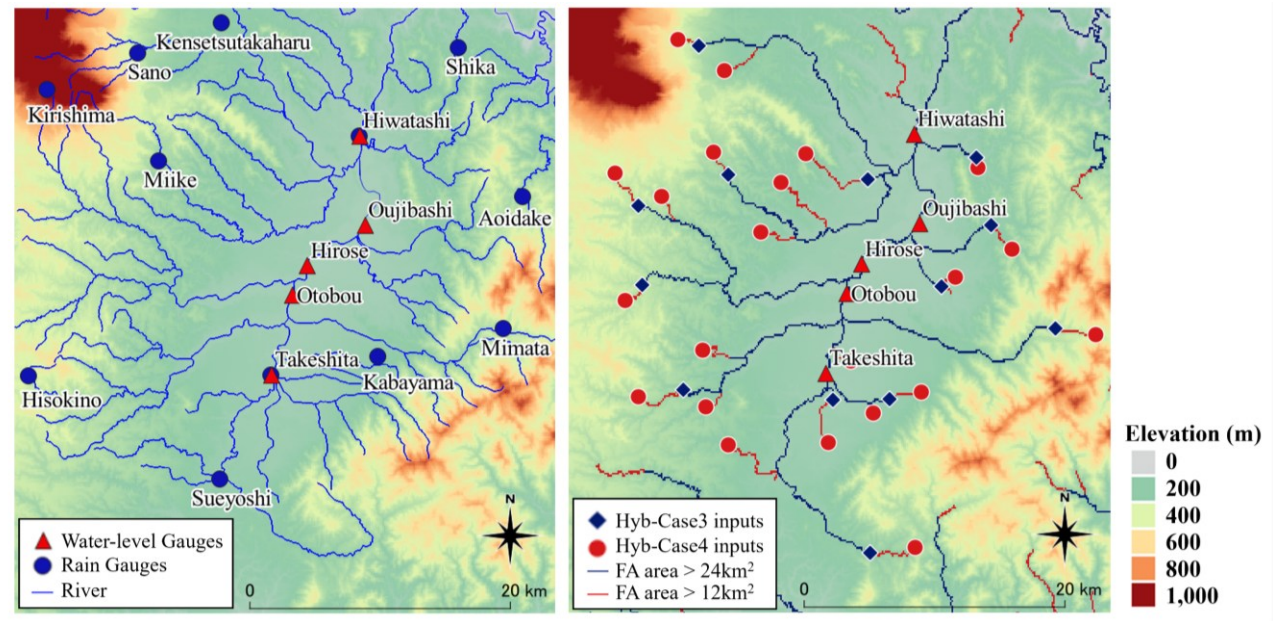

図-2.14　　RRI モデル計算流量の DNN 連携入力地点

表-2.6　各比較ケースの入出力条件設定

Case	入力変数 ($t=0$：予測実行時の現時刻，T_f：予測リードタイム(h))	入力数	出力
各ケースの 共通入力変数	- 樋渡地点の観測水位 ($t=0,-1$) - 各水位観測所(5 地点)の観測水位変化量($t=-2$ to 0)	17	-
Hybrid-Case1 (予測対象地点のみ)	- 共通入力変数 (上記参照) - RRI 計算流量（樋渡地点） (*1)	22–28	T_f後の 樋渡地点 予測水位
Hybrid-Case2 (主流地点)	- 共通入力変数 (上記参照) - RRI 計算流量（主流部の水位観測所 5 地点）(*1)	42–72	
Hybrid-Case3 (上流地点)	- 共通入力変数 (上記参照) - RRI 計算流量（図-2.14 に紺菱形で示した 13 地点） (*1)	82–160	
Hybrid-Case4 (最上流地点)	- 共通入力変数(上記参照) - RRI 計算流量（図-2.14 に赤丸で示した 22 地点） (*1)	127–259	
Hybrid-Case 1–4	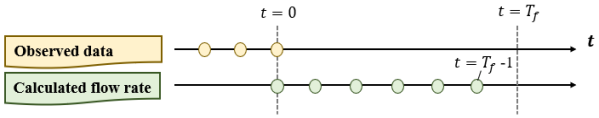		
Simple DNN (Case5) (Not hybrid)	- 共通入力変数 (上記参照) - 雨量観測所(14 地点)の観測/予測降雨量 (*2)	87–339	
Simple DNN	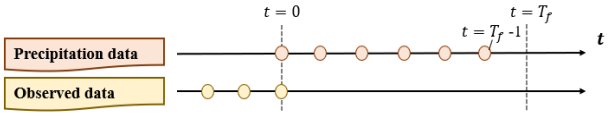		

(*1) $t = \boldsymbol{T_f}-6$ to $\boldsymbol{T_f}-1$ for $\boldsymbol{T_f} < 6$, 0 to $\boldsymbol{T_f}-1$ for $6 \le \boldsymbol{T_f} < 12$, $\boldsymbol{T_f}-12$ to $\boldsymbol{T_f}-1$ for $12 \le \boldsymbol{T_f}$

(*2) $t = \boldsymbol{T_f}-6$ to $\boldsymbol{T_f}-1$ for $\boldsymbol{T_f} < 6$, 0 to $\boldsymbol{T_f}-1$ for $6 \le \boldsymbol{T_f}$

（2） 検証結果

表-2.7 と図-2.15 に，各検証ケースの予測リードタイム（LT）：24 時間までの RMSE を，図-2.16 に LT 別の実際の水位予測波形を示す．ハイブリッドモデルケース（Case1–Case4）と DNN 単モデルケース（Case5）はいずれも，表-2.4 に示した RRI モデルよりも優れた予測精度を示している．ハイブリッドケースの予測精度は高い方から順に，Case3（上流地点），Case4（最上流地点），Case2（主流地点）≈Case1（予測対象地点）の順となっている．また，Case1 と Case2 の精度は検証出水ごとのバラつきが大きく，未学習出水に対する汎化性能が不安定であることが分かる．これより，予測対象地点に近い地点の計算流入量よりも，上流地点の計算流入量を選択することがハイブリッドモデルの予測性能向上への寄与が大きいと推察される．

次に入力地点数と入力地点の集水面積に対する平均 RMSE の依存性を図-2.17 に示す．図より，本流域におけるハイブリッド構成では，入力地点数が 10–15 程度，入力地点集水面積は主流部観測地点の上流端（岳下：集水面積 160km^2）よりも小さく，予測対象地点（樋渡：集水面積 861km^2)の 2%より大きい範囲（20–100km^2）が適切な計算入力地点選定の目安となっている．図-2.14 の位置関係が示す通り，本流域におけるこの条件は支流を含む上流地点をバランスよく選択することに該当している．また，適切な入力地点数は雨量観測所の配置数(=14)が示す通り，流域内の降雨分布特徴を捉えるために必要な独立

表-2.7　検証洪水に対する予測リードタイム（LT）別の平均 RMSE（m）

（※LT 別に最高精度のケースを太字で表示）

Case	LT=1	LT=3	LT=6	LT=12	LT=18	LT=24	全 LT 平均
Case1	**0.12**	0.41	0.66	0.71	0.69	0.77	0.65
Case2	0.13	0.39	0.65	0.71	0.81	0.78	0.68
Case3	0.18	**0.23**	**0.38**	0.44	**0.43**	**0.44**	**0.39**
Case4	0.21	0.32	0.42	0.54	0.59	0.56	0.50
Case5	0.14	0.26	0.43	**0.42**	**0.43**	0.48	0.40

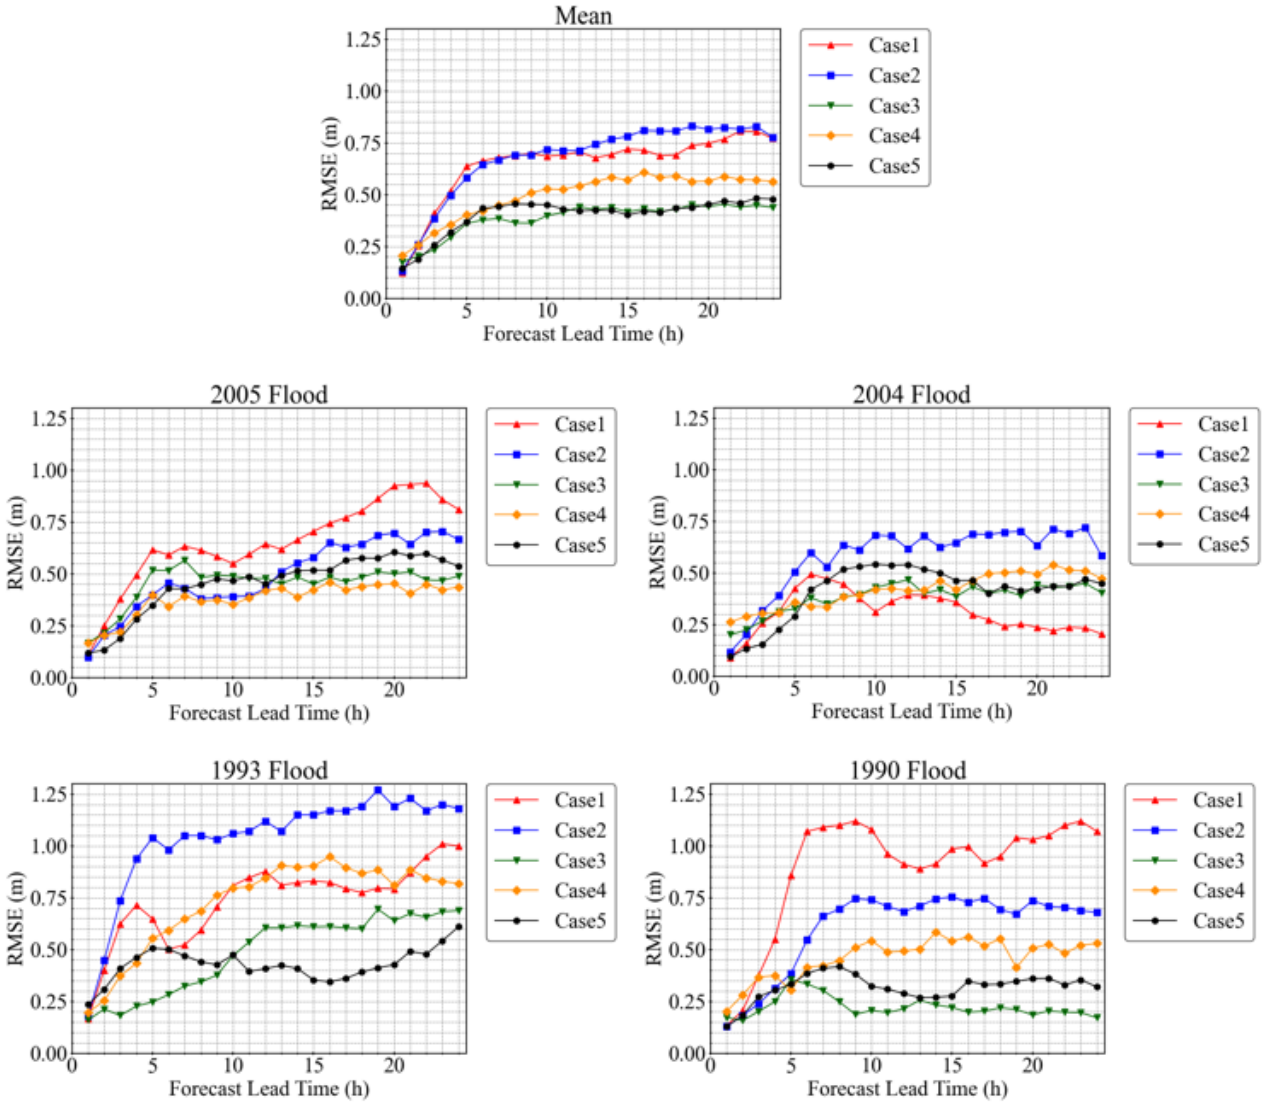

図-2.15　　予測リードタイム（LT）別の RMSE

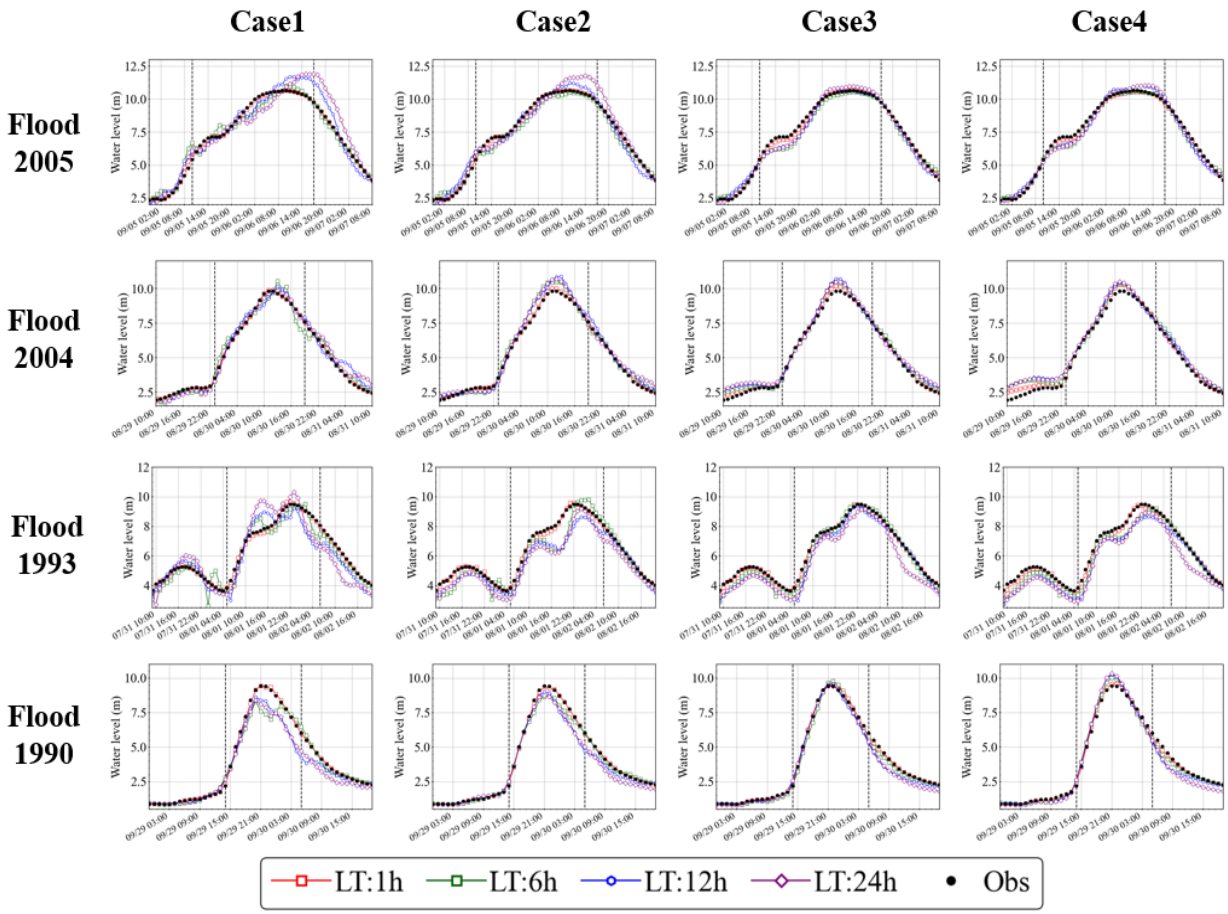

図-2.16　検証洪水に対する各ハイブリッドケースの予測水位．黒点線は精度評価期間を示す．（※Case5：DNN 単独モデルの予測波形は後の DNN 構造検討の項に記載）

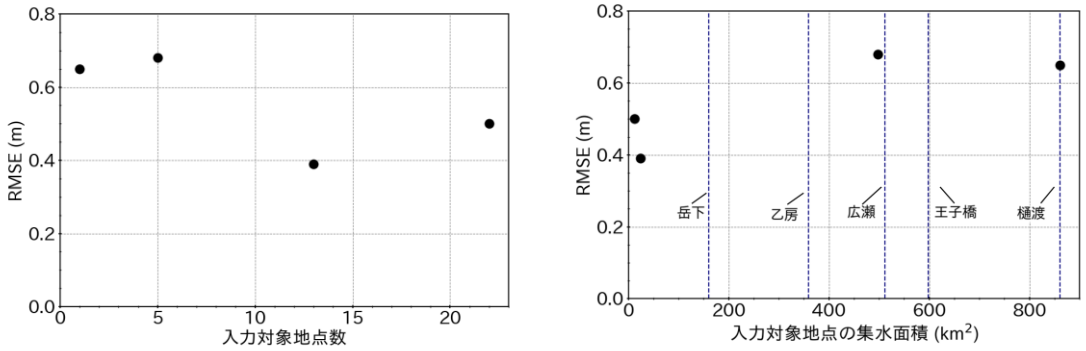

図-2.17　左：入力対象地点数と RMSE，右：入力対象地点の集水面積と RMSE

変数が 10–15 程度であると考えられ，これ以上の細分化した情報は冗長入力となって精度劣化をもたらしている可能性が高い．

以上より，適切な入力地点選定では，支流を含む上流部の入力が効果的であるが，降雨分布がほぼ等しい地点に対する細分化は逆効果となる可能性が高く，降雨分布の特徴を表す独立した情報量に対応する入力点数とすることが望ましいと推察される．なお，最良精度の Case3 では，いくつかの予測リードタイムで DNN 単モデル（Case5）の予測精度を上回っているものの，平均的にはほぼ同程度であり，RRI 計算値を単純に DNN へ追加する構造では，ハイブリッド化の効果は限定的であることが示唆される．

2.6.2 物理モデルの予測精度が与える影響の分析

(1) 検証設定

物理モデルの予測精度がハイブリッドモデルに与える影響を分析するため，RRI モデルパラメータを変更したケースの検証を実施した．具体的には，SCE-UA 法による最適化対象洪水について，検証対象 4 洪水を除いて樋渡地点のピーク水位が最大の洪水（2010/07/03：9.16m，前項までの採用ケース），中央値の洪水（2007/07/14：7.11m），最小の洪水（1999/08/17：6.03m）をそれぞれキャリブレーション対象としたパラメータセットを用意し，比較検討を行った（表-2.8）．

各ケースについて，検証対象出水に対する RRI モデル自体の再現計算結果を図-2.18 と表-2.9 に示す．水位波形全体の精度を示す RMSE の他，ピーク水位や立ち上がり時刻の時間位相も各ケースで差異があるため，本ケース比較を通してこれらの影響を考察する．

表-2.8 比較対象としたモデルパラメータ一覧 ※ケース内の()はキャリブレーション利用洪水

パラメータ	記号	Case1 (2010/07/03)	Case2 (2007/07/14)	Case3 (1999/08/17)	単位
河道の粗度係数	n_r	0.025	0.052	0.038	$m^{-1/3}$・s
斜面の粗度係数 (等価粗度)	n_s	0.57	0.28	0.35	$m^{-1/3}$・s
土層厚	D	0.81	1.27	1.03	m
空隙率	γ_a	0.32	0.28	0.27	-
鉛直方向の飽和透水係数	k_v	0.0	0.0	0.0	m/s
湿潤前面における吸引圧	S_f	- (inactive)	- (inactive)	- (inactive)	m
側方の飽和透水係数	k_a	0.49	0.28	0.45	m/s
空隙率（不飽和層）	γ_m	0.018	0.025	0.014	-
定数 β	β	12.0	8.9	9.0	-
河道設定集水セル数閾値	r_{thresh}	111	149	108	-
レジーム則：河道幅係数	C_W	3.4	2.5	3.6	m
レジーム則：河道幅指数	S_w	0.48	0.62	0.54	-
レジーム則：河道深さ係数	C_D	0.33	0.47	0.31	m
レジーム則：河道深さ指数	S_D	0.52	0.58	0.70	-
差分時間間隔（斜面）	dt	600	600	600	s
差分時間間隔（河道）	ddt	60	60	60	s

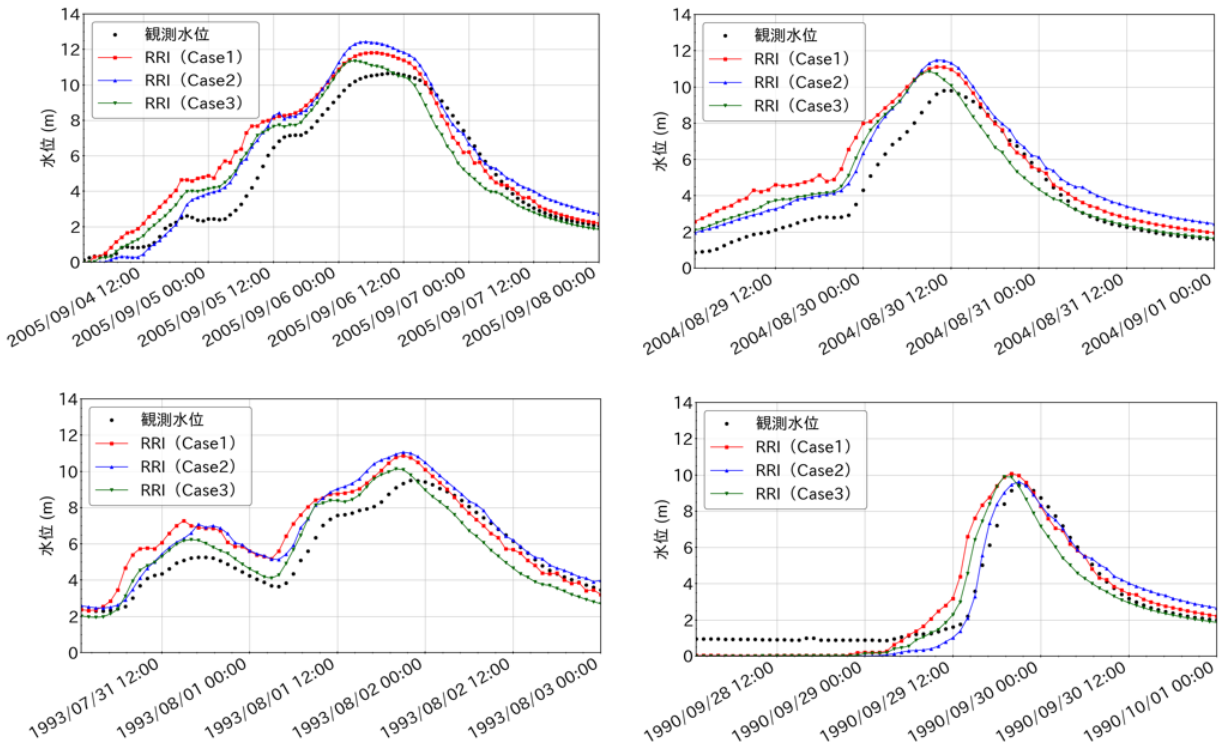

図-2.18　検証 4 洪水に対する再現計算結果

表-2.9　各ケースの検証洪水に対する RMSE（m）　※()内はピーク水位誤差（m）

対象洪水	1990/09/29	1993/08/01	2004/08/30	2005/09/06
Case1	1.03 (+0.65)	1.13 (+1.36)	1.40 (+1.31)	1.30 (+1.17)
Case2	0.81 (+0.19)	0.97 (+1.55)	1.05 (+1.69)	1.06 (+1.78)
Case3	0.96 (+0.46)	0.85 (+0.64)	1.05 (+1.06)	1.07 (+0.71)

(2)　検証結果

表-2.10 と図-2.19 に，各検証ケースの予測リードタイム（LT）：24 時間までの RMSE を，図-2.20 に LT 別の実際の水位予測波形を示す．図表が示す通り，対象とする検証洪水ごとに予測精度のバラつきは出るものの，未学習出水に対する平均的な汎化性能には各ケースでほとんど差が無いことが確認できる．実際，図-2.21 に示すように，RRI モデルの各予測精度指標とハイブリッドモデルの平均 RMSE 間には特徴的な相関関係は見られない．これは，RRI モデル自体の予測における系統バイアス（予測傾向）は，DNN が学習過程において内部的に補正調整可能であり，最終出力に直結しないためと推察される．

以上より，本ハイブリッド構成においては，ある程度の再現性が確認できる範囲であれば，物理モデルの詳細なパラメータチューニングの重要性は低いことが分かった．物理モデルの詳細なパラメータチューニングは一般に工数を要する工程となるため，本特性は実務利用において有用な特性である．

表-2.10 検証洪水に対する予測リードタイム（LT）別の平均 RMSE (m)

（※LT 別に最高精度のケースを太字で表示）

Case	LT=1	LT=3	LT=6	LT=12	LT=18	LT=24	全 LT 平均
Case1	0.18	**0.23**	**0.38**	0.44	**0.43**	**0.44**	**0.39**
Case2	**0.16**	0.27	0.43	0.44	0.47	0.50	0.42
Case3	0.19	**0.23**	0.40	**0.42**	0.44	0.45	0.40

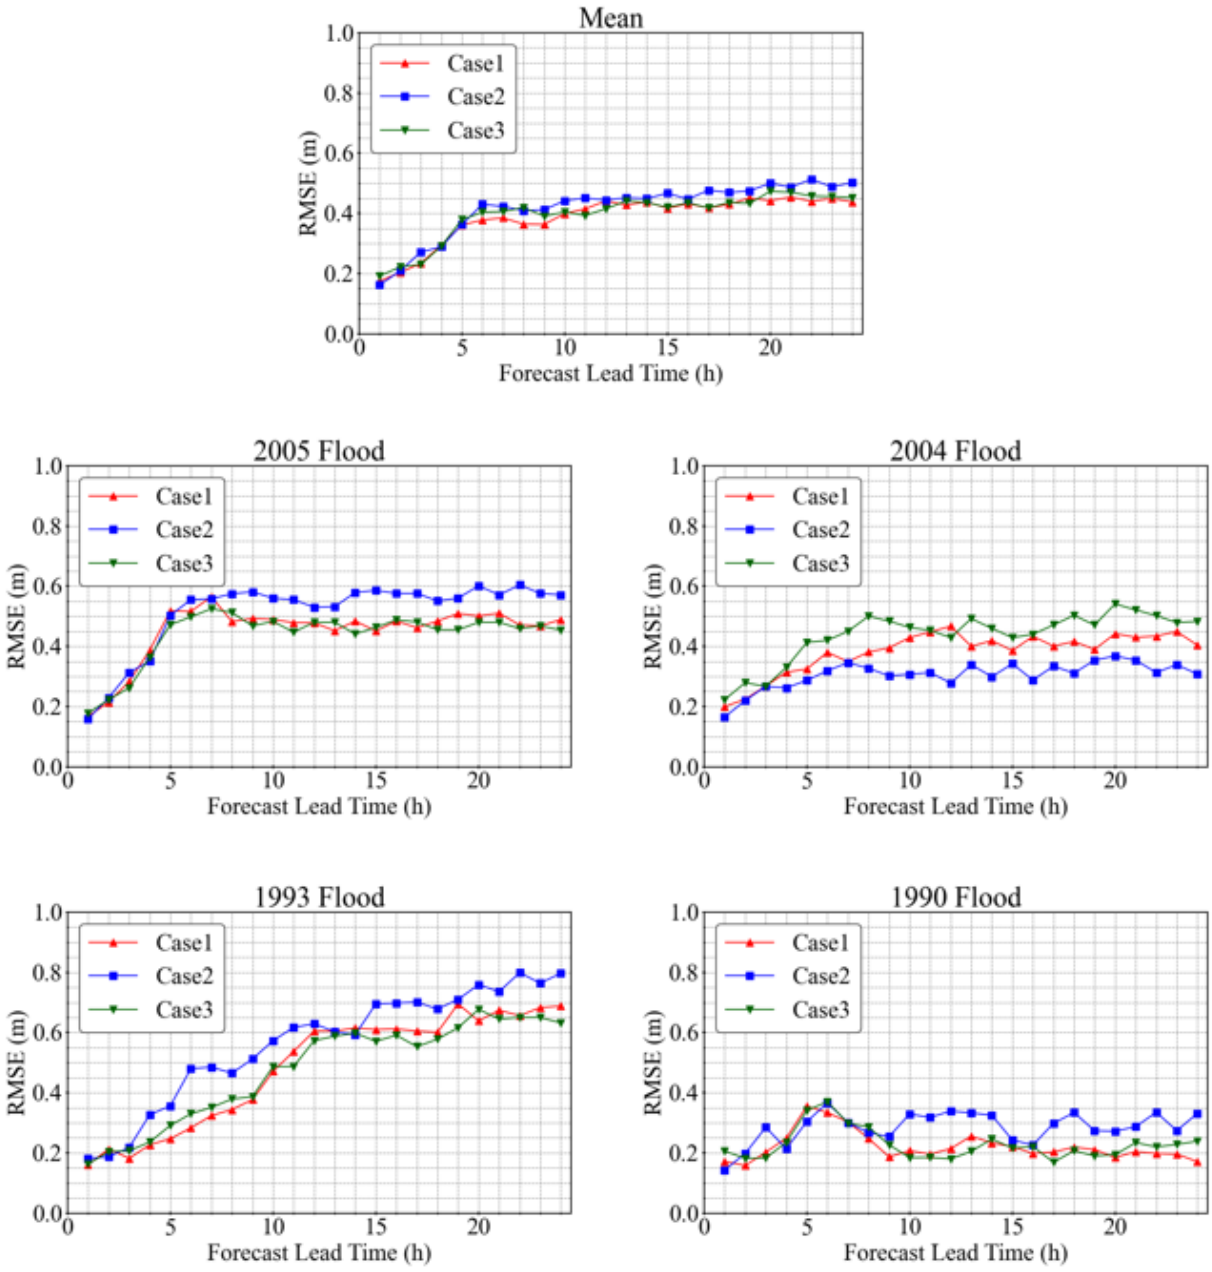

図-2.19　　予測リードタイム（LT）別の RMSE

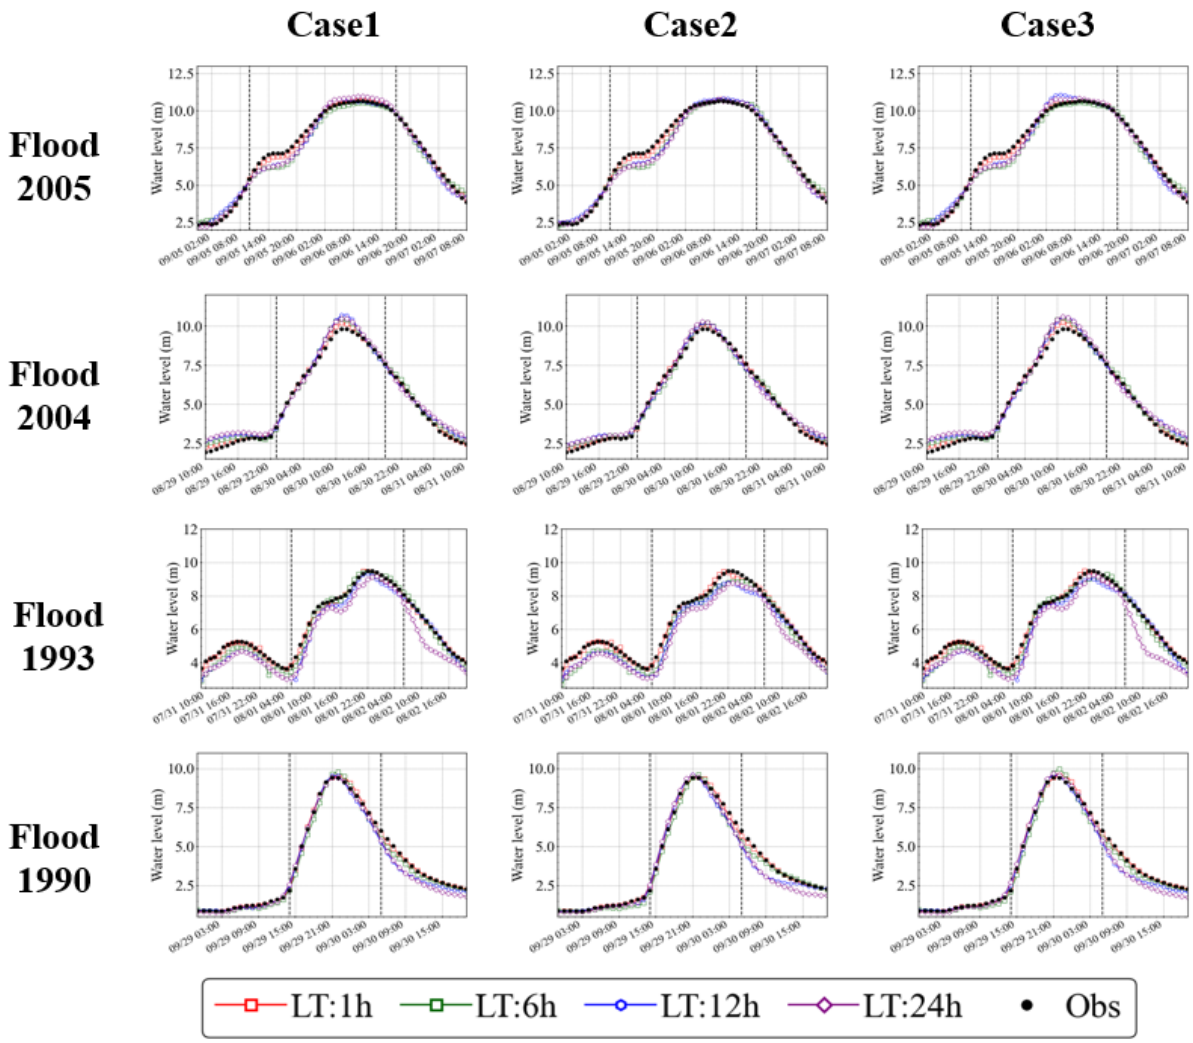

図-2.20　検証洪水に対する各ケースの予測水位．黒点線は精度評価期間を示す．

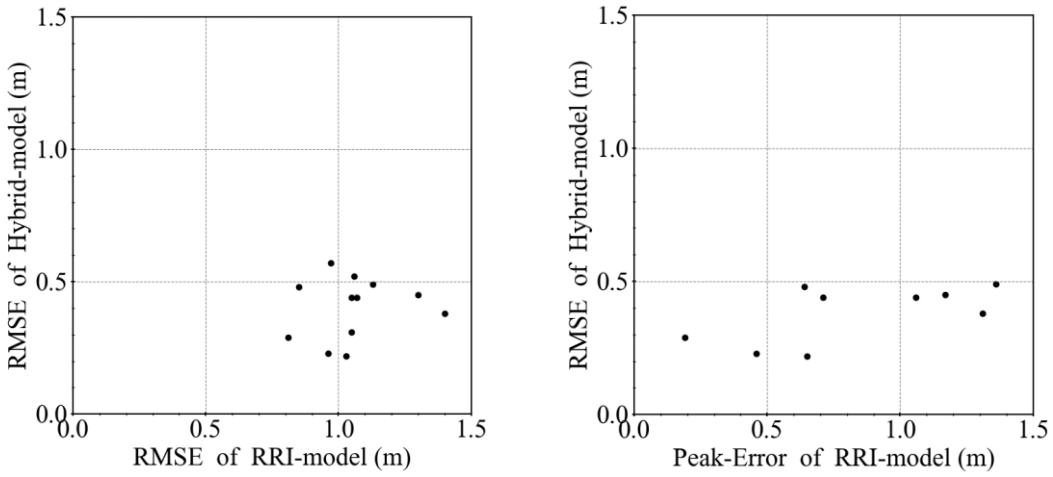

図-2.21　ハイブリッドモデル精度と入力元の RRI モデル精度の散布図
（左：RRI モデルの RMSE との比較，右：RRI モデルのピーク誤差との比較）

2.7 ハイブリッド入力に適した DNN 構造の検討

2.7.1 ハイブリッド DNN 構造の設計

前節までに示した RRI 計算流量を単純に DNN へ追加するハイブリッド構造では，物理モデルを利用しない AI 単独モデルに対して必ずしも上位互換とはならず，対象洪水によっては AI 単独モデルの方が高精度となるケースも存在することが分かった．本ハイブリッドモデル構成では，AI 単独時には入力されていない降雨流出モデルによる計算流量が追加入力されているため，この追加入力が精度向上に寄与しないケースではこれを内部的に無視することで，原理的には AI 単独モデルの完全上位互換が実現できると期待される．本手法は水位，降雨量，計算流量といった異なる種類の入力情報を DNN モデルが統合するため，この観点からこれらの入力変数をより効率的に統合・処理できる DNN 構造を探索した．

異なる種類の入力情報を効果的に統合する DNN 構造として，本研究では，一般に DNN モデルの精度を向上させることが多いアンサンブル構造 [49]，残差補正構造 [50]，入力特徴埋め込み [51]の DNN 構造を基本とし，最適な組み合わせを模索した．

アンサンブル構造とは，複数の独立したモデルを組み合わせることで予測性能を向上させる手法である．個々のモデルは異なる誤差特性を持つため，それらを統合することで単一モデルの弱点を補い，一般に単独モデルよりも安定した出力が得られる．代表的な方法には，モデルの予測を平均化する「バギング」，弱点を補うようにモデルを順次追加して統合する「ブースティング」，異なる構造のモデル出力を統合する上位モデル（メタモデル）を用いる「スタッキング」などがある．アンサンブルの利点は，過学習の抑制と汎化性能の向上であり，大規模データセットでも効果を発揮する．ただし，計算コストやメモリ使用量が増加する点には注意が必要である．

残差補正構造とは，ベースとなるモデルの出力と正解との誤差（残差）を別のモデルで学習し，元のベース予測結果を改善する構造である．これにより，ベースモデルで大域的な挙動を再現し，詳細な挙動は補正モデルが学習する等の役割分担を可能とし，全体の精度改善が図られる．Residual Network（ResNet）[49]を始めとして広く採用されている DNN 構造であり，複雑な入出力関係の学習を分散・軽減できる点に強みがある．

入力特徴埋め込み層（Embedding layer）は，カテゴリ変数や高次元／低次元の入力特徴を，学習に適した次元の連続ベクトルに変換する層構造である．埋め込み層はニューラルネットワークで構成される層に限らず，PCA（主成分分析）変換やフーリエ変換など，特定アルゴリズムを用いた前処理が層として組み込まれているケースも多い．自然言語処理の単語埋め込みが代表例だが [51]，時系列予測に対する DNN 適用等にも活用されている [52]．入力特徴埋め込みにより，例えば冗長な高次元入力に対しては次層以降に伝える情報量を適切に削減できるため，学習の効率化や精度向上に寄与することが期待される．

これらの DNN 構造の例を図-2.22 に示す．(a)はすべての情報（降水量の直接入力を含む）を DNN に単純に入力する基本構造（前節までの採用構造），(b)は降水量に基づいて予測を行う DNN と RRI 計算流量に基づいて予測を行う DNN を組み合わせたバギング型のアンサンブル構造，(c)は降水量に基づく DNN 予測に対し，RRI 計算流量を入力に持つ別の DNN を用いて補正する残差補正構造，(d)は(b)の構造をベースに RRI 計算流量の入力特徴埋め込み層を追加した構造である．

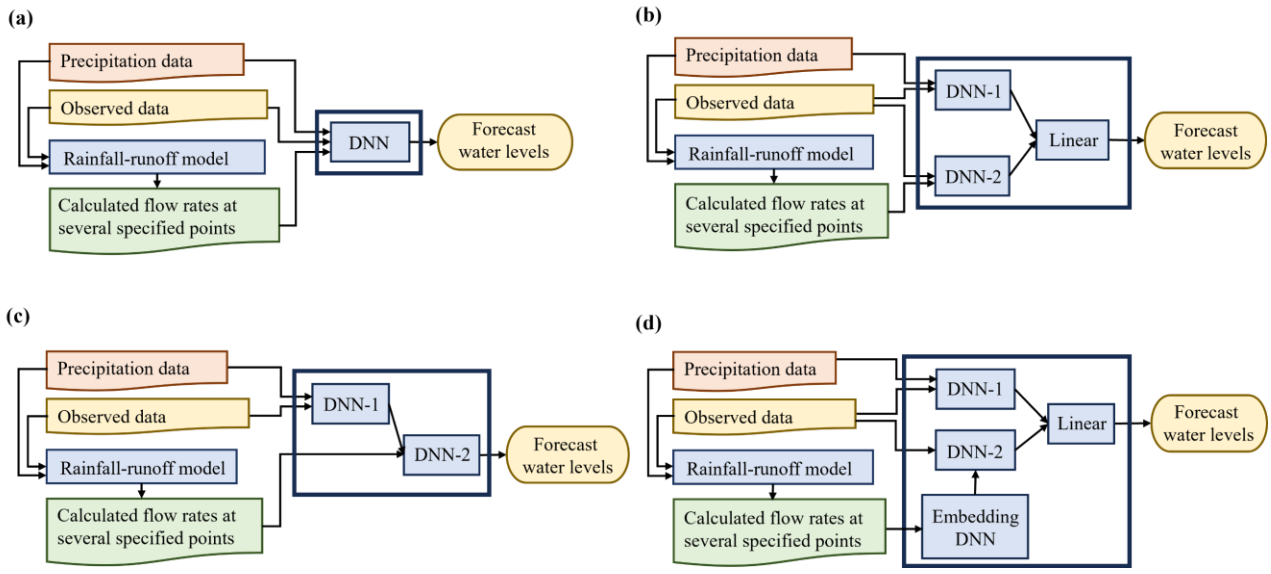

図-2.22　　構造設計の基本としたハイブリッド DNN 構造

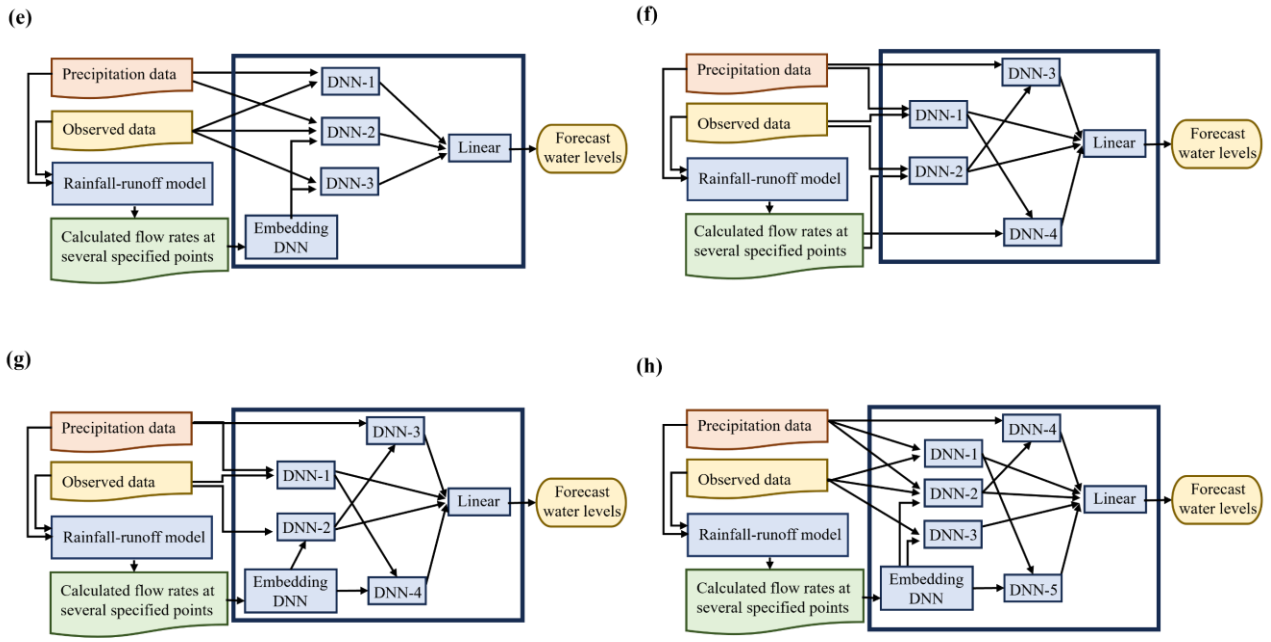

図-2.23　　候補構造として追加した DNN 構造

2.7.2 候補構造の比較評価

(1) 検証設定

基本となる（a）–（d）の構造（図-2.22）の他，これらを組み合わせた図-2.23 に示す各構造も候補構造に追加し，モデル学習並びに予測精度の比較評価を実施した．(e)は(d)に 3 種類の入力変数（降雨量，観測流量/水位，RRI 計算流量）を一度に入力する DNN を加えた構造，(f)は(c)の構造を降雨量と RRI 計算流量に関して対称化し，各 DNN を線形結合層で接続した構造，(g)は(f)に RRI 埋め込み層を追加した構造，(h)は(g)に 3 種類の入力変数を一度に入力する DNN を加えた構造である．

DNN-n として示した基本単位となる DNN 構造には，前節までと同様に 4 層 の全結合型 DNN を共通で用いた．

(2) 検証結果

表-2.11 に各検証ケースの予測リードタイム（LT）：24 時間までの RMSE を示す．表より，アンサンブル構造，残差補正構造，入力埋め込み構造のすべてを有する構造(g)と(h)が，24 時間リードタイム(LT)までの平均 RMSE で最も高精度となることが確認できる．(g)と(h)の精度差は小さいことから，以降ではより軽量な構成である(g)の DNN 構造を最終的な選定構造として，より詳細な検証を行うこととした．

なお，本検討では水位，降雨量，計算流量の 3 種別のデータを前提とした際の効果的なデータ統合構造の探索に焦点を当てた比較を実施している．このため，今後，基本単位とした全結合型 DNN の上位互換モデルが提案された場合にも，提案構造中の基本単位モデルを単に置き換えることにより，ハイブリッド入力データの統合処理に対する有効性は保持できると考えられる．

表-2.11 検証洪水に対する予測リードタイム（LT）別の平均 RMSE (m)
（※LT 別に最高精度のケースを太字で表示）

Case	LT=1	LT=3	LT=6	LT=12	LT=18	LT=24	全 LT 平均
(a)	0.18	0.23	0.38	0.44	0.43	0.44	0.39
(b)	0.23	0.30	0.39	0.40	0.46	0.49	0.41
(c)	0.16	0.25	0.35	0.38	0.42	0.48	0.38
(d)	**0.08**	0.21	0.40	0.39	0.37	0.47	0.36
(e)	0.09	0.22	0.41	0.37	0.37	0.45	0.36
(f)	0.17	0.24	**0.31**	0.40	0.40	0.46	0.37
(g)	0.09	**0.20**	0.33	**0.34**	**0.35**	**0.41**	**0.32**
(h)	0.11	0.23	0.33	**0.34**	0.39	0.46	0.33

2.7.3　選定構造の性能検証

(1)　選定構造の概要

前節の比較検証で最も優れた性能を示した DNN 構造を Hybrid-input Ensemble Neural Network（図-2.24)として提案し, より詳細な検証を実施した. 以下では本構造におけるデータ処理の流れを詳述する.

提案 DNN 構造では，降雨量と RRI の計算流量を同等の情報を持つ特徴量として扱い，まずサブネットワーク DNN-1 と DNN-2 を用いて予測を生成する．この際，RRI モデルの計算流量はサブネットワークに入力する前に, RRI モデルの系統的バイアスの補正，ならびに計算流量時系列を学習に有効な特徴ベクトルに変換する目的で，埋め込み層（DNN）を適用した．これらの処理は以下の式で表現される.

$$O_{eDNN}(T_f) = g_{Emb}(Q_{calc}(T_f - 1), Q_{calc}(T_f - 2), \dots, Q_{calc}(T_f - k)) \tag{2.34}$$

$$H_{DNN-1}(T_f) = g_1(r_{obs}, r_{forecast}, h_{obs}) \tag{2.35}$$

$$H_{DNN-2}(T_f) = g_2(O_{eDNN}(T_f), h_{obs}) \tag{2.36}$$

ここで，$Q_{calc}(t)$は各入力対象地点における時刻tの RRI 計算流量，r_{obs}は観測降雨時系列，$r_{forecast}$は予測降雨時系列，h_{obs}は観測水位時系列を表し，kは RRI 計算流量の参照時刻範囲を決める定数パラメータである．また，g_{Emb}は RRI モデルの計算流量の特徴埋め込み DNN（Embedding DNN; 図-2.24）を表し，$O_{eDNN}(T_f)$は予測時刻T_fに対する出力を表す．同様に，g_nと $H_{DNN-n}(T_f)$ は，それぞれのサブネットワークと予測時刻 T_fに対するその出力を表す．事前試行の結果から，埋め込み層g_{Emb}には中間層 2 層の全結合型 DNN を採用している.

次に，サブネットワーク DNN-3 と DNN-4 は，それぞれ DNN-1 と DNN-2 の予測結果に対し，各サブネットワークに入力されていないもう一方の特徴量（降雨量 or RRI 計算流量）を用いた残差補正により予測を生成する.

$$H_{DNN-3}(T_f) = g_3(r_{obs}, r_{forecast}, H_{DNN-2}(T_f)) \tag{2.37}$$

$$H_{DNN-4}(T_f) = g_4(O_{eDNN}(T_f), H_{DNN-1}(T_f)) \tag{2.38}$$

最後に，それぞれの予測結果を線形結合して最終予測を出力する.

$$H'_{forecast}(T_f) = \sum_{n=1}^{4} a_n * H_{DNN-n}(T_f) + b \tag{2.39}$$

ここで，a_n と b は，学習により決定される重みパラメータである.

本構造はアンサンブル構造，残差補正構造，特徴埋め込み層の組み合わせで構成されており，類似性が高い情報と考えられる降雨量と RRI 計算流量に対して，埋め込み層を除いて対称な構造となっている.

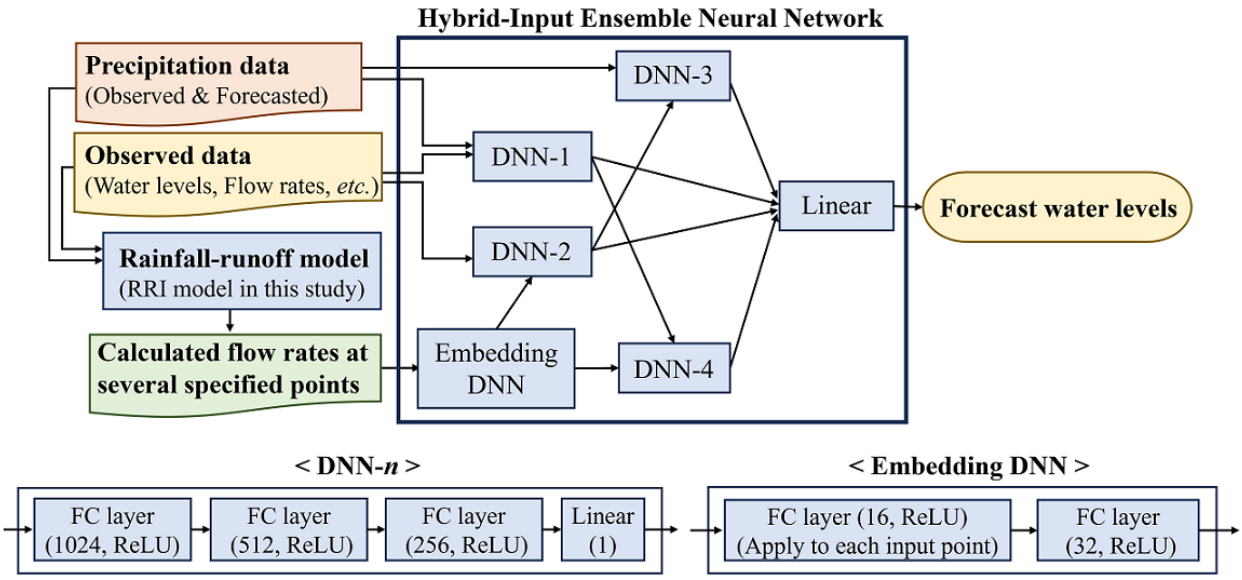

図-2.24　　選定 DNN 構造（Hybrid-input Ensemble Neural Network）

(2)　各単独モデルとの予測精度比較

選定構造の性能に関する検証のため，RRI 計算流量を入力しない DNN 単独モデル（Simple-DNN），RRI モデル（RRI），RRI 計算流量を単純に DNN へ追加するハイブリッドモデル（H-DNN(a)；図-2.22 中の構造(a)），2 モデル(Simple-DNN と H-DNN(a))の加重平均出力を予測値とする単純なアンサンブルモデル（Simple-Ensemble）との比較を行った．RRI モデルの予測時系列は，予測実行時点の観測水位と計算水位の残差をゼロとするように予測時系列全体を定数補正するスライド補正を適用し，予測リードタイム別の予測値を評価した．

表-2.12 と図-2.25 に RMSE による予測精度の比較結果を示す．ハイブリッドモデルと DNN 単独モデルはどちらもスライド補正した RRI モデルよりも優れた予測精度を示しており，これは一言・桜庭.(2017）が分布型流出モデルに対して報告した結果と一致している．また，対象出水によるばらつきは存在するが，提案ハイブリッド DNN は，平均的な予測精度において，ほぼすべての予測リードタイムで他のモデルよりも優れた性能を示していることが確認できる．これは，提案 DNN 構造が，単純なハイブリッド入力（H-DNN（a））や，個々の学習後モデルを用いた単純なアンサンブル処理（Simple-Ensemble）よりも，入力情報をより効果的に統合処理できることを示している．24 時間までの予測リードタイムにおける平均 RMSE は，DNN 単独モデルが 0.40，提案ハイブリッド DNN は 0.32 であるため， DNN 単独モデルとの比較では，提案ハイブリッド DNN により平均 RMSE が 20%改善されている．

次に，検証対象出水に対する予測水位波形の比較を図-2.26 に示す．DNN 単独モデルと比較して，提案ハイブリッド DNN はピーク水位誤差や予測水位時系列の擾乱が少なく，より正確で安定した予測水位波形を出力していることが確認できる．なお，RRI モデルはスライド補正の影響により，直近 1 時間の予測精度は比較的良好であるが，予測リードタイムとともに誤差が大きく増大している様子が確認できる．物理モデルのチューニング後の精度やデータ同化手法により程度の差はあるが，これは物理モデル出力を直近観測値のみに適合するよう補正した場合に，しばしば見られる挙動である．

表-2.12 検証洪水に対する予測リードタイム（LT）別の平均 RMSE (m)

Case	LT=1	LT=3	LT=6	LT=12	LT=18	LT=24	全 LT 平均
Proposed H-DNN	**0.09**	**0.20**	**0.33**	**0.34**	**0.35**	**0.41**	**0.32**
H-DNN (a)	0.18	0.23	0.38	0.44	0.43	0.44	0.39
Simple-Ensemble	0.16	0.23	0.32	0.38	0.40	0.46	0.36
Simple-DNN	0.14	0.26	0.43	0.42	0.43	0.48	0.40
RRI (slide-correction)	0.25	0.68	1.10	1.33	1.36	1.38	1.18

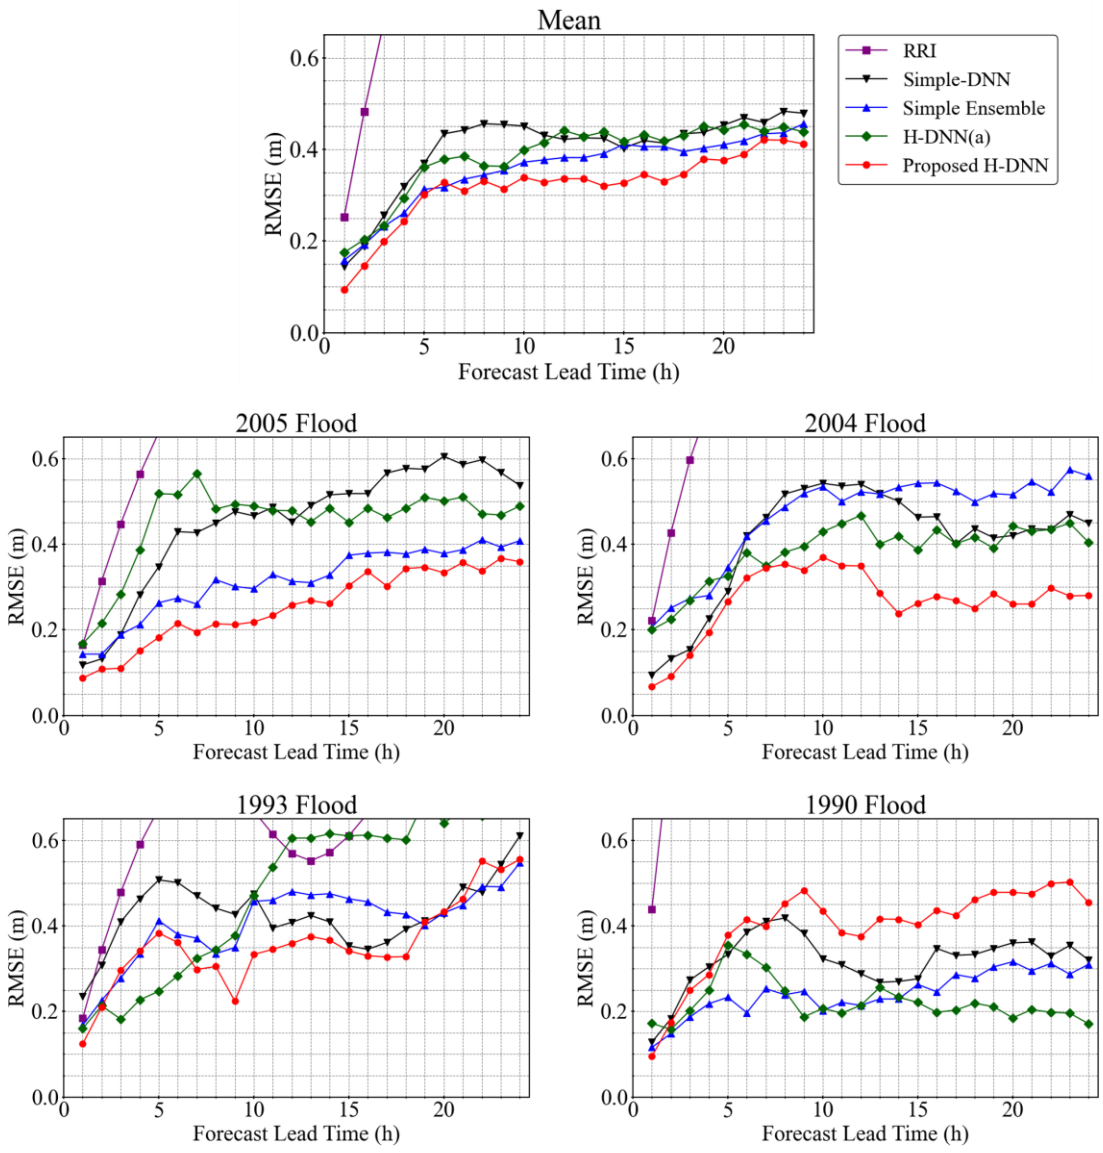

図-2.25 予測リードタイム（LT）別の RMSE

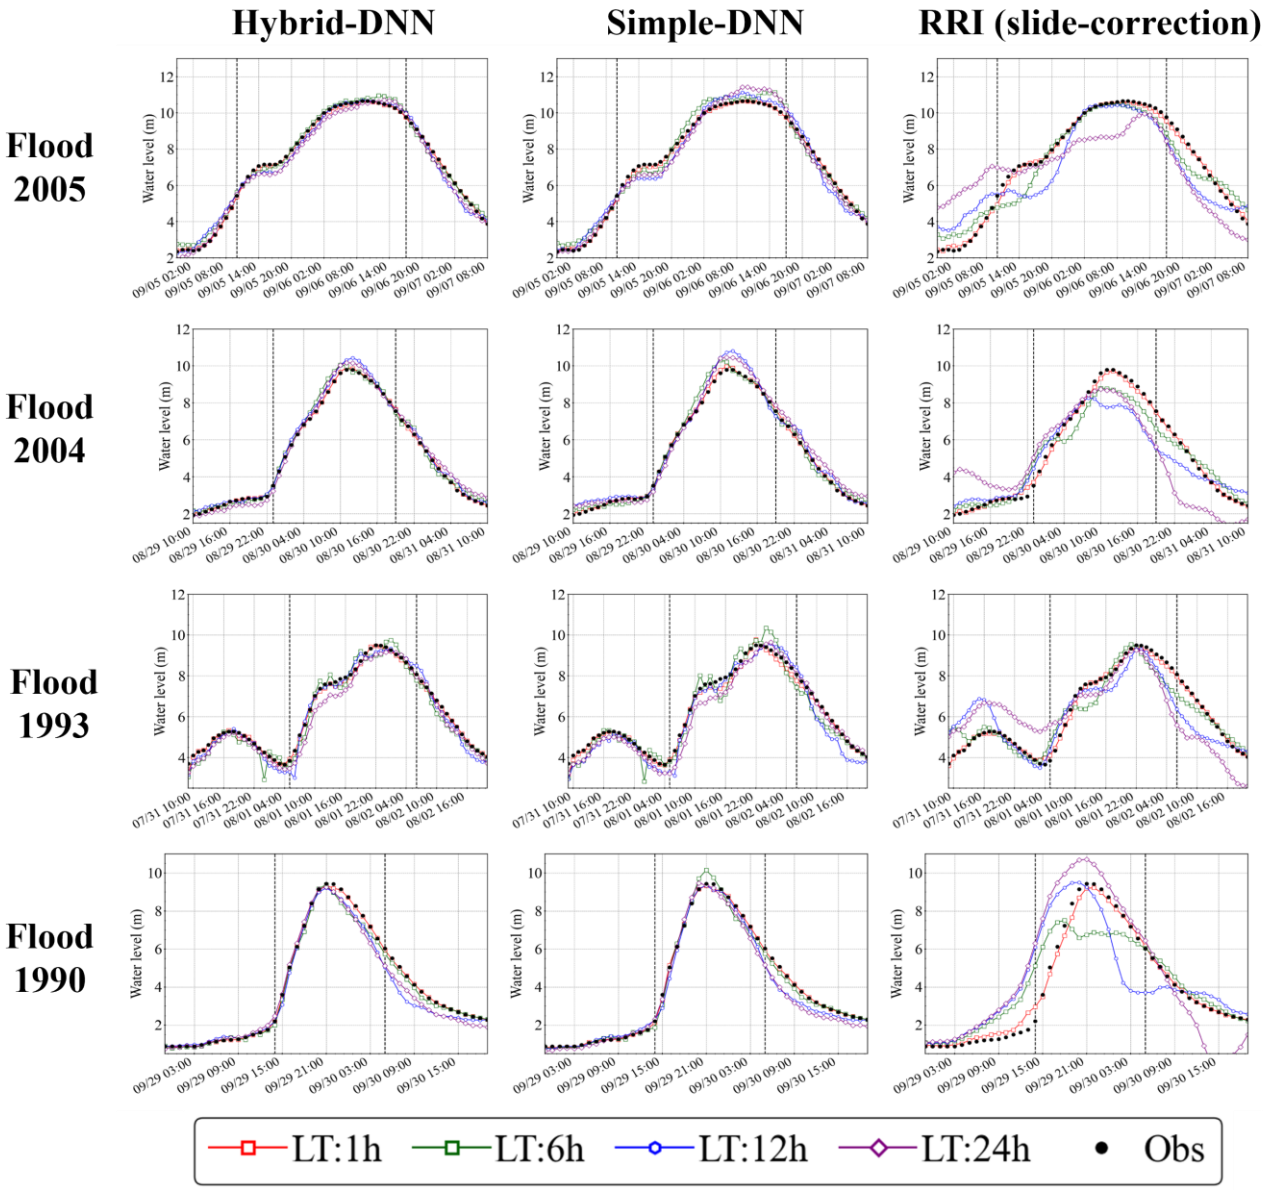

図-2.26　検証洪水に対する各ケースの予測水位．黒点線は精度評価期間を示す．

(3) 学習データセットに対する感度分析

学習対象とする洪水データセットのデータ数と出水規模が予測精度に与える影響を確認するため，表-2.13 に示すように，学習対象を 10 洪水（10-A，10-B）と 5 洪水（5-A，5-B）に限定したケースの検証を行った．未経験規模出水に対する予測精度を確認するため，検証対象とした 4 洪水を Leave-one-out 交差検証法に用いる場合（10-A，5-A：検証洪水と同規模の洪水データが学習データセットに含まれるケースに該当）と用いない場合（10-B，5-B：検証洪水と同規模の洪水データが学習データセットに含まれない場合に該当）の 2 つのシナリオをテストした．限定ケースの対象洪水は近年から順に選択した．

図-2.27 と表-2.14 に，学習データセットごとの RMSE を提案ハイブリッド DNN と DNN 単独モデルで比較した結果を示す．また，図-2.28 には各予測リードタイム（LT：1/6/12/24 時間）における予測水位時系列の比較を示す．

表-2.13 検証対象洪水の組み合わせ

Flood Case	Max Water Level at Hiwatashi (m)	Test	Full (train)	10-A (train)	10-B (train)	5-A (train)	5-B (train)
1990/09/19	7.47		(*1)	(*1)	(*1)	(*1)	(*1)
1990/09/29	9.44	○	○ (*2)	○ (*2)		○ (*2)	
1993/08/01	9.50	○	○ (*2)	○ (*2)		○ (*2)	
1993/08/10	8.04		○				
1993/09/03	6.99		○				
1995/06/25	6.90		○				
1996/07/18	6.84		○				
1999/07/27	6.72		○				
1999/08/17	6.03		○		○		
1999/09/14	8.26		○		○		
2000/06/03	6.53		○		○		
2003/08/08	6.79		○	○	○		
2004/08/30	9.80	○	○ (*2)	○ (*2)		○ (*2)	
2004/10/20	7.70		○	○	○		
2005/09/06	10.65	○	○ (*2)	○ (*2)		○ (*2)	
2007/07/14	7.11		○	○	○		○
2010/06/20	6.30		○	○	○		○
2010/07/03	9.16		○	○	○		○
2014/07/31	6.61		○	○	○	○	○
2014/08/09	6.08		○	○	○	○	○

(*1) were used as the validation data. (*2) were used for cross-validation.

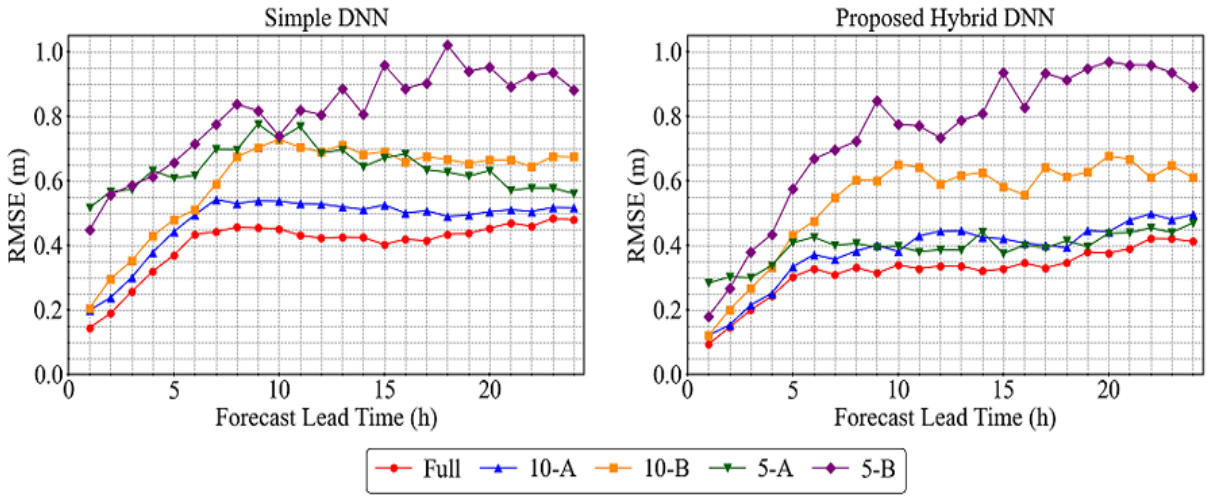

図-2.27　　学習データセットに対する予測精度の依存性

表-2.14　検証洪水に対する予測リードタイム（LT）別の平均 RMSE（m）

Case		LT=1	LT=3	LT=6	LT=12	LT=18	LT=24	全 LT 平均
Full	Simple DNN	0.14	0.26	0.43	0.42	0.43	0.48	0.40
	Hybrid DNN	0.09	0.20	0.33	0.34	0.35	0.41	0.32
10-A	Simple DNN	0.52	0.57	0.62	0.69	0.63	0.56	0.64
	Hybrid DNN	0.12	0.22	0.37	0.44	0.39	0.50	0.38
10-B	Simple DNN	0.21	0.35	0.51	0.69	0.67	0.67	0.60
	Hybrid DNN	0.12	0.27	0.48	0.59	0.61	0.61	0.54
5-A	Simple DNN	0.52	0.57	0.62	0.69	0.63	0.56	0.64
	Hybrid DNN	0.28	0.30	0.43	0.39	0.41	0.47	0.39
5-B	Simple DNN	0.45	0.59	0.71	0.81	1.02	0.88	0.81
	Hybrid DNN	0.18	0.38	0.67	0.73	0.91	0.89	0.75

提案ハイブリッド DNN では，学習データ量が少ないケースでも DNN 単独モデルよりも総じて高精度を示している．ただし，シナリオ A とシナリオ B の結果比較から，学習サンプル数が同じであっても，予測精度は学習サンプルの質に大きく依存していることが確認できる．学習データに検証洪水と同規模の洪水が含まれているシナリオ A（10-A，5-A）では，提案ハイブリッド DNN は全予測 LT において高精度を示し，少数データからの効率的な学習が可能であることを示唆している．しかしながら，学習洪水規模が検証洪水よりも小さいシナリオ B（10-B，5-B）では，DNN 単独モデルに対する有意な精度改善は予測 LT：6 時間程度までの範囲にとどまっており，長期の予測 LT では同程度の精度となっていることが確認できる．

以上の結果から，提案ハイブリッド DNN は，学習データセットと同等程度の洪水規模（データセットの内挿領域）においては，学習データ量が少ない場合にも優れた予測性能を発揮できると推察される．一方で，学習データセットに含まれない規模の外挿領域（未経験規模の大洪水）に対する予測性能の向上効果は限定的であるため，この領域での予測精度の確保に向けては，DNN 単独モデルと同様，仮想大規模洪水データに対する物理モデル計算結果の追加学習等による対処が必要であると考えられる．

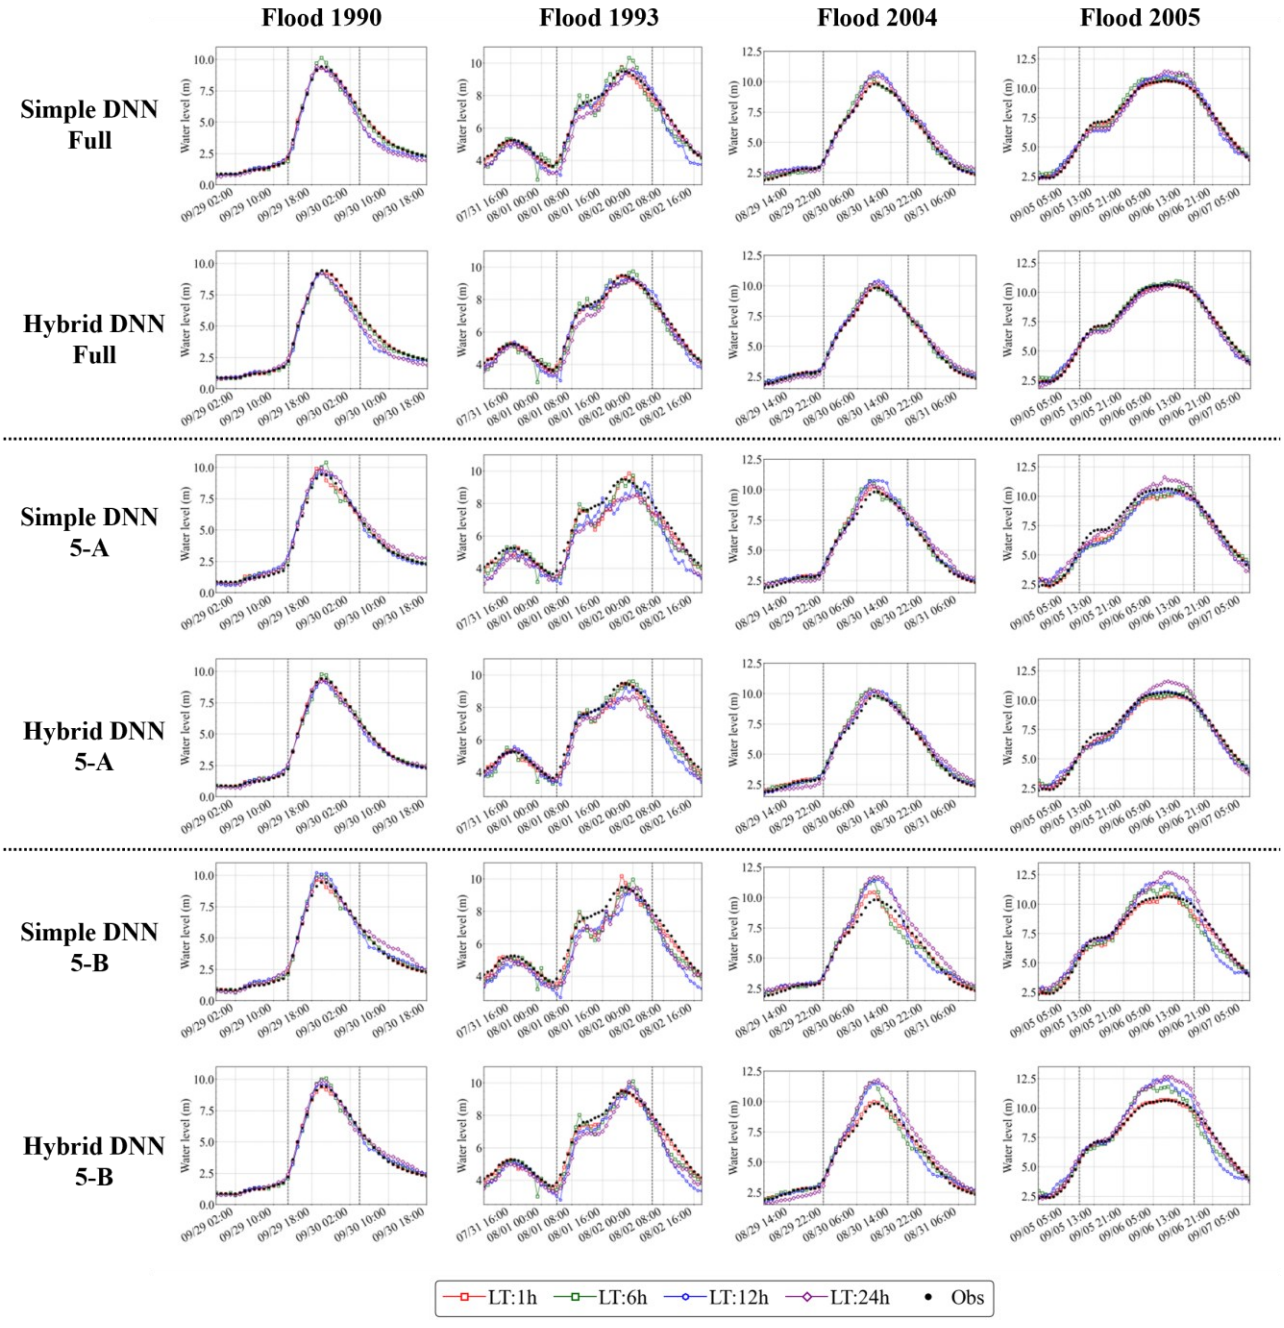

図-2.28　　予測水位波形の比較（Full, 5-A, 5-B）

2.8 まとめ

本章では，降雨流出予測モデルの性能向上を目的として，分布型流出解析モデル（RRI モデル）と深層学習モデルを組み合わせたハイブリッド予測手法の改良について検討を行った．ハイブリッドモデル構築における自由度，ならびにハイブリッド入力を処理する DNN（Deep Neural Network）構造の改良について試行した結果として，本章で得られた知見を以下に示す．

- DNN へ入力する RRI 計算流量地点は，予測対象地点や主流部よりも，支川を含む上流地点の方がハイブリッド DNN の予測精度を向上させる上で効果的な入力となることが示された．ただし，降雨分布がほぼ等しい地点に対する過剰な細分化は逆効果となる可能性が高く，降雨分布の特徴を表す独立した情報量に対応する程度の入力点数となるように調整することが望ましいと推察される．

- RRI モデル自体の予測精度とハイブリッドモデルの予測精度には特徴的な相関関係は見られないことが分かった．これは，RRI モデル自体の予測における系統バイアス（予測傾向）は，DNN が学習過程において内部的に補正調整可能であり，最終出力に直結しないためと推察される．これより，本ハイブリッド構成においては，ある程度の再現性が確認できる範囲であれば，物理モデルの詳細なパラメータチューニングの重要性は低いと考えられる．物理モデルの詳細なパラメータチューニングは一般に工数を要する工程となるため，本特性は実務利用において有用な特性である．

- アンサンブル構造，残差補正構造，特徴埋め込み構造を組み合わせた提案ハイブリッド DNN 構造（Hybrid-input Ensemble Neural Network）は，24 時間までの予測リードタイム範囲において，DNN 単独モデルや，単純なハイブリッド入力構造，個々の学習後モデルによる単純なアンサンブル処理と比較して，より高い予測精度を示すことが確認でき，今回の検討においては，DNN 単独モデルと比較して平均 RMSE が 20%向上した．これより，本 DNN 構造を用いることで，これらのモデルよりもハイブリッド入力情報をより効果的に統合処理できることが示された．

- 提案ハイブリッド DNN は，学習データセットと同等程度の洪水規模（データセットの内挿領域）において，学習データ量が少ない場合にも優れた予測性能を発揮できることが分かった．このため，提案モデルは既往観測データが限られている場合も有効に適用可能であると考えられる．一方で，学習データセットに含まれない規模の外挿領域（未経験規模の大洪水）に対する予測性能の向上効果は限定的であり，この領域での予測精度の確保に向けては，DNN 単独モデルと同様，仮想大規模洪水データに対する物理モデル計算結果の追加学習等による対処が必要であると推察される．

なお，本検討は比較的大きな流域面積（流域面積 = 861 km^2）を持つ大淀川水系を対象に実施している．このため，本結果の汎用性や適用限界を精査する上では，今後，中小規模流域や潮位影響が大きい河口域など，より多様な流域での比較検証が必要である．

参考文献（第 2 章）

1) 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, doi: 10.2208/jscejhe.73.22.
2) 木村俊晃: 貯留関数法. 河鍋書店, 1975.
3) M. Sugawara: Automatic calibration of the tank model, *Hydrological Sciences Journal*, Vol. 24, No. 3, pp. 375–388, 1979.
4) 椿涼太, 小林健一郎, 内藤正彦, 谷口丞：洪水予測技術の現状と課題について, 河川技術論文集, Vol. 19, pp. 1–6, 2013, doi: 10.11532/river.19.0_1.
5) Q. Duan, S. Sorooshian, V. Gupta: Effective and efficient global optimization for conceptual rainfall-runoff models, *Water Resources Research*, Vol. 28, No. 4, pp. 1015 – 1031, 1992, doi: 10.1029/91WR02985.
6) 杉原成満, 朝位孝二, 倉本和正, 荒木義則, 古川浩平：SCE-UA 法を用いたタンクモデルの最適構造構築に関する一考察, 土木学会論文集 F3（土木情報学）, Vol. 70, No. 1, pp. 12–17, 2014, doi: 10.2208/jscejcei.70.12.
7) 山地秀幸, 土屋修一, 川﨑将生：C バンド MP レーダ雨量計と XRAIN による高精度広域雨量観測, 土木技術資料, Vol. 58-7, 2016. Available: https://www.pwrc.or.jp/thesis_shouroku/thesis_pdf/1607-P026-029_yamaji.pdf
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, doi: 10.11532/river.30.0_531.
9) 菅原快斗, 佐山敬洋, 山田真史, 山本浩大：広域かつ高速な降雨流出氾濫計算のためのマクロスケール RRI モデルの開発, 土木学会論文集, Vol. 80, No. 16, 2024, doi: 10.2208/jscejj.23-16125.
10) 立川康人, 永谷言, 寶馨：飽和・不飽和流れの機構を導入した流量流積関係式の開発, 水工学論文集, Vol. 48, pp. 7–12, 2004, doi: 10.2208/prohe.48.7.
11) 安陪和雄, 大八木豊, 辻倉裕喜, 安田佳哉：分布型流出モデルの広域的適用, 水工学論文集, Vol. 46, pp. 247–252, 2002, doi: 10.2208/prohe.46.247.
12) T. Sayama: Rainfall-Runoff-Inundation (RRI) Model Technical Manual, Technical Note of PWRI, No.4277, 2014.
13) 国立研究開発法人土木研究所：降雨流出氾濫（RRI）解析モデルについて, 2022 年度土研新技術セミナー講演資料, 2022. Available: https://www.pwri.go.jp/jpn/results/tec-info/siryou/seminar/R4/pdf/2022seminar_1555.pdf
14) 立川康人, 須藤純一, 椎葉充晴, 萬和明,キムスンミン：粒子フィルタを用いた河川水位の実時間予測手法の開発, 土木学会論文集 B1(水工学), Vol. 67, No. 4, I_511-I_516, 2011, doi: 10.2208/jscejhe.67.I_511.
15) 中村要介, 小池俊雄, 阿部紫織, 中村和幸, 佐山敬洋, 池内幸司：粒子フィルタを適用した RRI モデルによる河川水位予測技術の開発, 土木学会論文集 B1(水工学), Vol. 74, No. 5, I_1381-I_1386, 2018,

doi: 10.2208/jscejhe.74.5_I_1381.
16）藤村健介，小槻峻司，山田真史，塩尻大也，渡部哲史：降雨流出氾濫モデルのアンサンブルデータ同化安定化に関する研究，土木学会論文集 B1(水工学)，Vol. 78，No. 2，I_409-I_414，2022，doi: 10.2208/jscejhe.78.2_I_409.
17）F.-J. Chang, K. Hsu, and L.-C. Chang: *Flood Forecasting Using Machine Learning Methods,* Basel, Switzerland: MDPI, 2019. Available: https://www.mdpi.com/books/reprint/1151-flood-forecasting-using-machine-learning-methods
18）一言正之，櫻庭雅明，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），Vol. 72, No. 4, I_187-I_192, 2016, doi: 10.2208/jscejhe.72.I_187.
19）守谷将史，辻倉裕喜，三浦心，山脇正嗣，金子拓史：長時間水位予測への深層学習の適用，河川技術論文集, Vol. 25, pp. 303–308, 2019, doi: 10.11532/river.25.0_303.
20）C. Subramaniyam，高木桃子，天口英雄，今村能之, Bi-LSTM を用いた都市中小河川の洪水流出予測，河川技術論文集, Vol. 30, pp. 471–476, 2024, doi: 10.11532/river.30.0_471.
21）岡崎亮太，中津川誠，小林洋介：ランダムフォレスト法による洪水時の水位予測手法の提案，土木学会論文集 B1(水工学)，Vol. 74, No. 4, I_1459-I_1464, 2018, doi: 10.2208/jscejhe.74.I_1459.
22）S. Okuno, K. Ikeuchi, K. Aihara：Practical Data-Driven Flood Forecasting Based on Dynamical Systems Theory, *Water Resources Research*, Vol. 57, No. 3, e2020WR028427, 2021, doi: 10.1029/2020WR028427.
23）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－，土木学会論文集 B1（水工学），Vol. 74, No. 5, p. I_1327-I_1332, 2018, doi: 10.2208/jscejhe.74.5_I_1327.
24）坂本莉子，小林洋介，中津川誠：異常洪水時のダム貯水位予測に用いる機械学習手法の比較，土木学会論文集 B1(水工学)，Vol. 75, No. 2, I_85-I_90, 2019, doi: 10.2208/jscejhe.75.2_I_85.
25）蟹江盛仁，辻倉裕喜，武田英祐，佐々木海人，長谷川敦，金子拓史，高木晃人，川部らら：深層学習を用いたダム流入量予測と低頻度・未経験洪水への対応機能の実装，土木学会論文集 B1（水工学），Vol. 78, No. 2, I_163-I_168, 2022, doi: 10.2208/jscejhe.78.2_I_163.
26）木村延明,皆川裕樹,福重雄大,木村匡臣,馬場大地：深層学習モデルに物理モデルを融合させた排水機場水位予測への転移学習の適用，土木学会論文集 B1(水工学)，Vol. 77, No. 2, I_319-I_324, 2021, doi: 10.2208/jscejhe.77.2_I_319.
27）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，I_175-I_180，2022，doi: 10.2208/jscejhe.78.2_I_175.
28）G. Konapala, S.-C. Kao, S. L. Painter and D. Lu: Machine learning assisted hybrid models can improve streamflow simulation in diverse catchments across the conterminous US, *Environ. Res. Lett.*, Vol. 15, No. 10, p. 104022, 2020, doi: 10.1088/1748-9326/aba927.
29）D. Lu, G. Konapala, S. L. Painter, S.-C. Kao and S. Gangrade: Streamflow Simulation in Data-Scarce Basins Using Bayesian and Physics-Informed Machine Learning Models, *Journal of Hydrometeorology*, Vol. 22, No. 6, pp. 1421–1438, 2021, doi: 10.1175/JHM-D-20-0082.1.

30）中村要介，小池俊雄，阿部紫織，中村和幸，佐山敬洋，池内幸司：粒子フィルタを適用した RRI モデルによる河川水位予測技術の開発，土木学会論文集 B1(水工学), Vol. 74, No. 5, I_1381-I_1386, 2018, doi: 10.2208/jscejhe.74.5_I_1381.
31）T. Ito, J. Kashiwada, N. Harayama, R. Kaneko, T. Kataoka, S. Onomura, M. Nakayoshi, Y. Nihei: Nowcast and Forecast Modeling of Water-Level Profiles in Rivers Based on Improved Diex-Flood and Deep Learning, *Journal of JSCE*, Vol. 10, No. 1, pp. 307–314, 2022, doi: 10.2208/journalofjsce.10.1_307.
32）J. M. Frame, F. Kratzert, D. Klotz, M. Gauch, G. Shalev, O. Gilon, L.M. Qualls, H.V. Gupta, G.S. Nearing: Deep learning rainfall–runoff predictions of extreme events, *Hydrology and Earth System Sciences*, Vol. 26, No. 13, pp. 3377–3392, 2022, doi: 10.5194/hess-26-3377-2022.
33）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, Vol. 32, No. 6, pp. 287–300, 2019, doi: 10.3178/jjshwr.32.287.
34）G. Cybenko: Approximation by superpositions of a sigmoidal function, *Mathematics of Control, Signals, and Systems*, vol. 2, no. 4, pp. 303–314, 1989.
35）K. Hornik, M. Stinchcombe, and H. White: Multilayer feedforward networks are universal approximators, *Neural Networks*, vol. 2, no. 5, pp. 359–366, 1989.
36）K. Hornik: Approximation capabilities of multilayer feedforward networks, *Neural Networks*, Vol. 4, No. 2, pp. 251–257, 1991.
37）M. Tan and Q. V. Le: EfficientNet: Rethinking model scaling for convolutional neural networks, in *Proc. Int. Conf. Machine Learning (ICML)*, 2019, pp. 6105–6114.
38）A. Krizhevsky, I. Sutskever, and G. E. Hinton: ImageNet classification with deep convolutional neural networks, in *Proc. Advances in Neural Information Processing Systems (NeurIPS)* ,2012, pp. 1097–1105.
39）S. Hochreiter and J. Schmidhuber: Long short-term memory, *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
40）K. Cho, B. van Merriënboer, C. Gulcehre, et al.: Learning phrase representations using RNN encoder–decoder for statistical machine translation, in *Proc. Empirical Methods in Natural Language Processing (EMNLP)*, 2014, pp. 1724–1734.
41）A. Vaswani, N. Shazeer, N. Parmar, et al.; Attention is all you need, in *Proc. Advances in Neural Information Processing Systems (NeurIPS)*, 2017, pp. 5998–6008.
42）J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova: BERT: Pre-training of deep bidirectional transformers for language understanding, in *Proc. North American Chapter of the Association for Computational Linguistics (NAACL)*, 2019, pp. 4171–4186.
43）D. P. Kingma and J. Ba: Adam: A method for stochastic optimization, in *Proc. Int. Conf. Learn. Representations (ICLR)*, 2015.
44）L. Bottou: Stochastic gradient descent tricks, in *Neural Networks: Tricks of the Trade*, Springer, 2012, pp. 421–436.
45）国土交通省: 水文水質データベース, Available: https://www1.river.go.jp/

46) D. Yamazaki, S. Togashi, A. Takeshima, T. Sayama: High-resolution flow direction map of Japan, *Journal of Japan Society of Civil Engineers Ser. B1 (Hydraulic Engineering)*, 74: I_163–I_168, 2018. (in Japanese with English abstract). doi: 10.2208/journalofjsce.8.1_234.
47) 国土交通省: 国土数値情報 土地利用細分メッシュデータ（L03-b-2021），Available: https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-L03-b-2021.html
48) T. Dozat: Incorporating Nesterov momentum into Adam, in *Proc. Int. Conf. Learn. Representations (ICLR) Workshop*, 2016.
49) L. Liu, W. Wei, K.H. Chow, M. Loper, E. Gursoy, S. Truex, Y. Wu: Deep neural network ensembles against deception: Ensemble diversity, accuracy and robustness. *Presented at the 2019 IEEE 16th International Conference on Mobile Ad Hoc and Sensor Systems (MASS) November 4–7, 2019 Monterey, CA, USA,* 274–282, 2019, doi: 10.1109/MASS.2019.00040.
50) K. He, X. Zhang, S. Ren, J. Sun: Deep residual learning for image recognition, *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) June 27–30, 2016 Las Vegas, NV, USA,* 770–778, 2016, doi: 10.1109/CVPR.2016.90.
51) T. Mikolov, K. Chen, G. Corrado, and J. Dean: Efficient estimation of word representations in vector space, in *Proc. Int. Conf. Learn. Representations (ICLR)*, 2013.
52) G. Zerveas, S. Jayaraman, D. Patel, A. Bhamidipaty, C. Eickhoff: A Transformer-based Framework for Multivariate Time Series Representation Learning, *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, KDD '21. Association for Computing Machinery, New York, NY, USA*, 2114–2124, 2021, doi:10.1145/3447548.3467401.

第３章　リアルタイム予測に向けた実用性向上に関する検討

3.1　はじめに

前章では，分布型流出モデルである RRI モデル [1]と深層学習モデルを組み合わせたハイブリッド型流出予測モデルを対象として，効果的な構築方法の検討と高性能な深層ニューラルネットワーク（DNN）構造の探索を行い，実務への適用に資するモデル構造と学習方法を提案するとともに，DNN 単独モデルや RRI 単独モデル単純と比較して，予測性能が向上可能であることを確認した．

しかしながら，前章の検討を始め，ハイブリッドモデル等の先行研究の多くは，流域内の「単一観測点」を対象とした流出予測性能の検証にとどまっている [2-4]．実際の洪水時の防災対応では，流域の上流から下流まで連続する複数地点の水位情報を同時に把握し，それらの時系列関係や空間分布から洪水リスクを判断する必要がある．このような実際の河川管理・防災現場で求められる「複数地点を同時に高精度で予測する」という課題に対し，現在のモデル構成では各観測地点に対して個々に独立したモデルを構築し，システム上で統合することが前提となる．しかし，観測地点ごとの個別構築では，モデル構築工数や計算負荷，保守対応コストなどが予測対象地点数の増加に対して線形に増大していく．今後さらに空間的に密な予測情報が求められる状況においてこの問題を回避するためには，1 モデルで同流域内の複数地点予測をカバーできることが望ましい．このため，多地点同時予測にモデルを拡張した際の予測精度や安定性の確保は，実用において重要な研究課題である．多点同時予測のためには，個々の地点の特性だけでなく，上下流の水理的影響，流域の広域的な降雨分布，水文応答の空間的連続性をモデルが適切に扱えることが求められるため，これらの点に関するハイブリッドモデルの性能や，その性能に影響を与える要因を把握することが重要となるが，現時点ではこれらに関する情報は非常に限られている [5]．

さらに，実際の観測システムの運用時には，通信障害，センサーの故障，定期的な保守作業などにより，観測水位データが部分的に欠損する状況が発生する [6-9]．特に洪水時には流木等の漂流物が物理的に接触して計測機器が故障するなど，計測データが欠損する状況が発生しやすい．データ欠損は流況に起因した数分・数時間といった短期的なものから，計器故障に起因して長期間に渡り計測不可となるケースまで様々である．またデータ欠損は単地点とは限らず，洪水時には複数観測地点で同時に欠損が発生するケースも珍しくない．したがって，予測モデルがこのような不完全な観測データの状況下でも安定して動作し，信頼できる予測値を継続的に提供できることは実際のシステム運用における重要な要件となる．しかし，ハイブリッド手法等に対して観測データの欠損が予測精度に与える影響はあまり検討されておらず [7]，データ欠損量と予測性能劣化の関係や，欠損パターンによる予測精度への影響の差異といった，実際の運用で重要となる点については未解明である．

これらの課題点に対し，本章では前章で検討した RRI モデルと深層学習モデルを組み合わせたハイブリッド型流出予測モデルを対象に，ハイブリッド手法の実用性向上に向けた検討を行った．具体的には，適用範囲を単一地点から多点同時水位予測へと拡張し，その予測精度や有効性を検討した．また，実際の運用で発生しうる観測水位の欠損状況を想定し，欠損の有無・欠損率・欠損パターンを変化させた複数の条件下で数値実験を実施し，観測データ欠損がモデル精度に与える影響を多角的に分析し，リアルタイムでの実運用を見据えてデータ欠損がモデル予測精度へ与える悪影響を低減する方法を検討した．

3.2　多地点同時予測方式によるモデルの軽量化

3.2.1　　多地点同時予測方式へのモデル拡張

前章で検討したハイブリッド DNN 構造（Hybrid-Input Ensemble Neural Network）[10]に対し，出力層を単一セルから複数セルに拡張することにより，1 モデルで多地点同時予測を行うモデルへと拡張した（図-3.1）．本モデルの予測対象は同一流域内の複数地点を想定しているため，モデルへの予測雨量等の入力情報は共通としており，複数地点予測にあたって変更するモデル要素は出力層のみと簡便である．このため，本構成の運用時には，予測対象地点の追加や削除等の変更に伴う保守工数の低減が期待できる．

本構成では，各予測対象地点に対する予測出力の元となる中間特徴量が共有化される．一般に中間重みの共有化は，正則化効果によって学習効率が改善するメリットがある一方で，各予測対象に特化した特徴量を抽出しづらくなるデメリットが存在する [11]．このため，学習データが少ない場合には前者のメリットが強調されやすく，学習データが十分に存在する場合には後者のデメリットが強調されやすい．洪水予測用途においては学習データが限られるケースが多いため，後者のデメリットが顕在化する可能性は低いと考えられるが，単独出力時との精度比較は検証要素の 1 つである．また，各予測対象地点における予測精度の差異も重要な検証要素であり，出力対象地点ごとに予測精度に大きなばらつきが見られる場合には，各出力に対する残差損失項の重み調整等が必要と考えられる．

次節ではこれらの事項を念頭に，多地点同時水位予測へと拡張した際のハイブリッドモデルの有効性に関する検証を実施した．

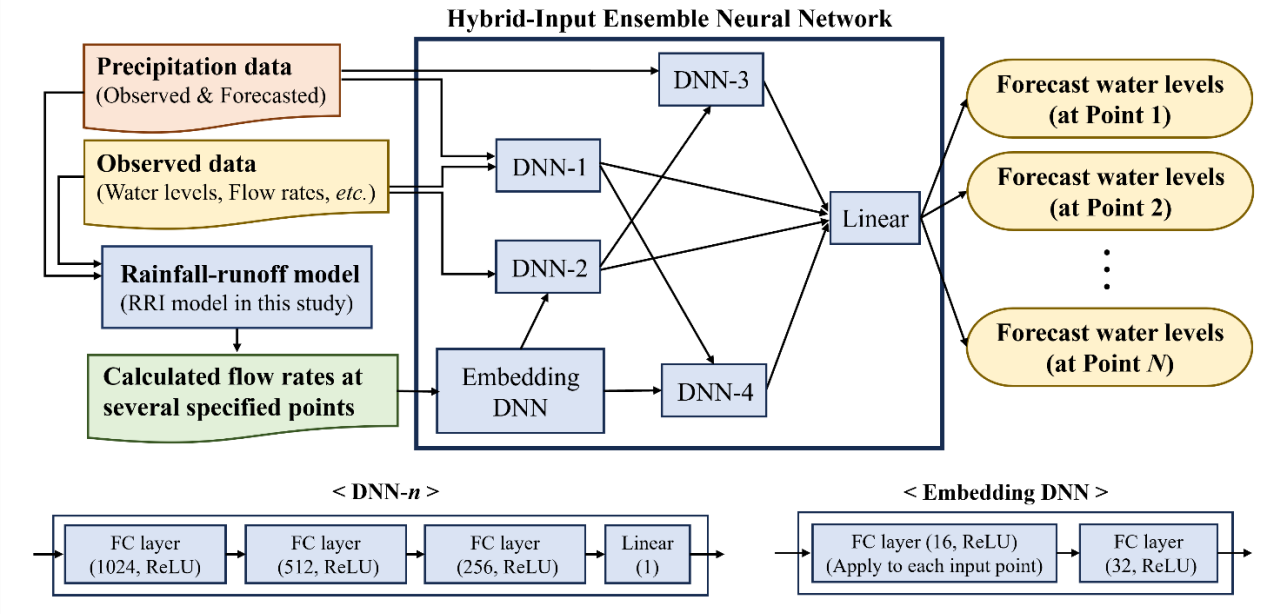

図-3.1　　多地点同時予測方式に拡張したハイブリッドモデルの構成

3.2.2　検証設定

ハイブリッドモデルを多点同時水位予測に適用した場合の有効性を評価するために，前章で検証した大淀川流域の 5 つの水位観測所（St.1～St.5）を予測対象地点に選定した（図-3.2，図-3.3，表-3.1）．モデルの出力は 5 地点の予測水位であり，1 時間から 24 時間までの各予測リードタイムについて個別にモデルを構築した．予測リードタイム 6 時間までの入力データ設定は，先行研究 [2]と同様であり，7 時間から 24 時間の予測リードタイムについては，降雨予測および計算流量の入力時間ウィンドウを予測リードタイムに応じて拡張した（表-3.2）．比較のために，ハイブリッド構成ではない DNN 単独モデル（Simple-DNN; 図-3.1 のサブネットワークと同じ 4 層構成）も学習・評価を実施した．モデルは Nadam（初期学習率 ＝0.001, 10 エポックごとに 1/5 ずつ減少）を使用して学習し，平均二乗誤差を損失関数に採用した．疑似乱数で決定されるモデルの初期重みと学習プロセスの影響を減らすため，異なる疑似乱数で独立に学習した 5 つのモデルの予測出力を平均し，予測精度を評価した．RRI モデルは，J-FlwDir[12]によって提供された地形データを使用して構築し，パラメータは，SCE-UA 法 [13]を使用して，2010/07/03 洪水時の樋渡地点の水位（検証に使用された 4 つの洪水を除いて，樋渡観測所で最高水位を記録した洪水）に対するパラメータキャリブレーションを行った．

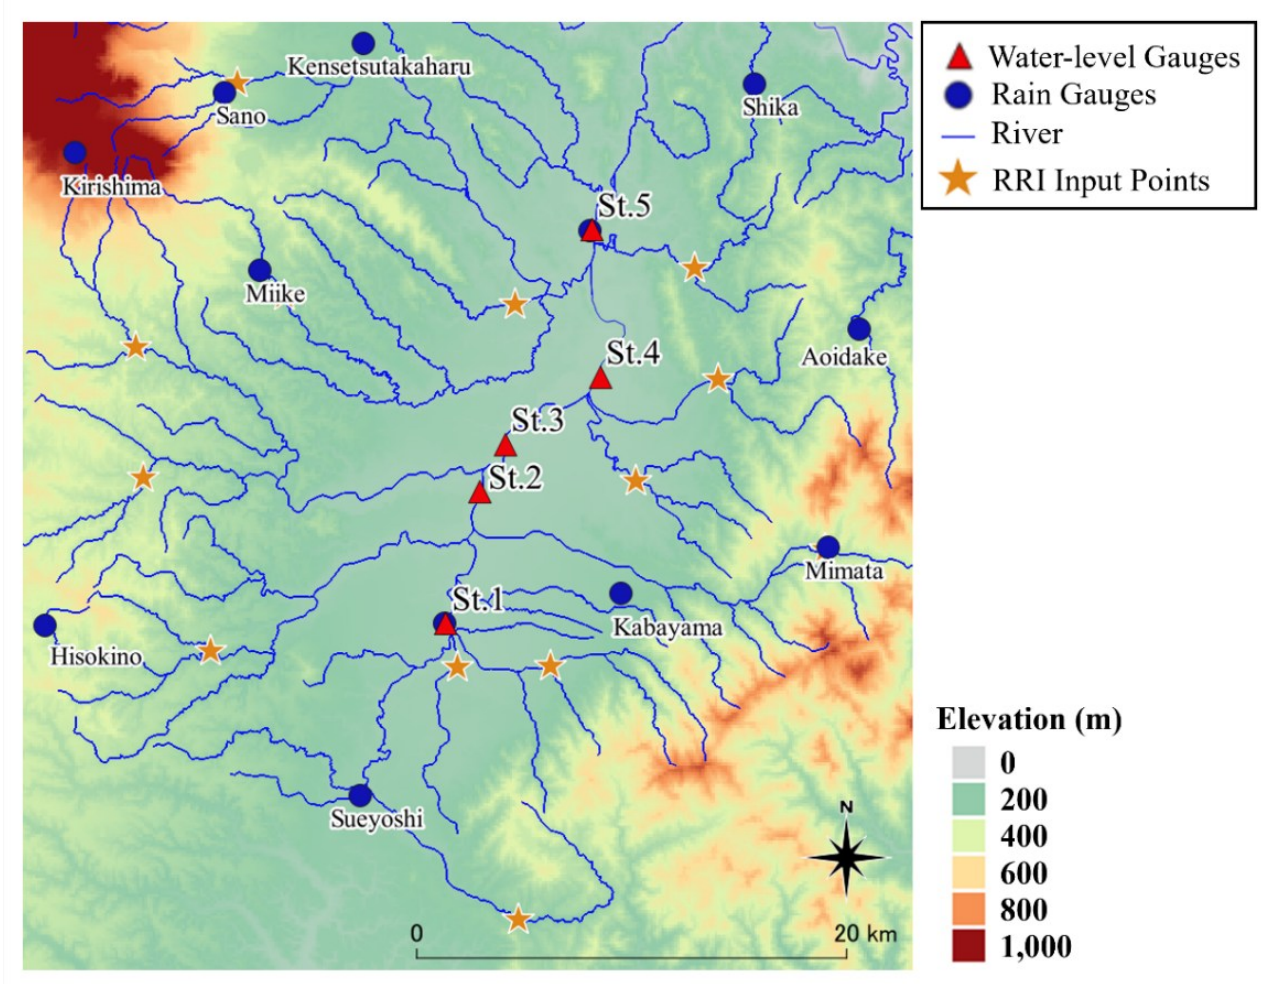

図-3.2　　予測対象地点（5 地点）と DNN に入力する RRI 計算流量地点

表-3.1　検証対象洪水と各観測所におけるピーク水位．St.1，St.2，St.3，St.4，St.5 のゼロ点基準高は，それぞれ T.P. 135.0m，128.5m，127.0m，121.4m，118.0m である．

Flood Date	Peak W.L. (m) at St.1 (Takeshita)	Peak W.L. (m) at St.2 (Otobou)	Peak W.L. (m) at St.3 (Hirose)	Peak W.L. (m) at St.4 (Oujibashi)	Peak W.L. (m) at St.5 (Hiwatashi)
1990/09/29	4.91	7.49	6.60	8.47	9.44
1993/08/01	3.97	6.55	6.12	7.94	9.50
2004/08/30	5.08	7.43	6.64	8.89	9.80
2005/09/06	4.90	7.45	6.82	9.32	10.65

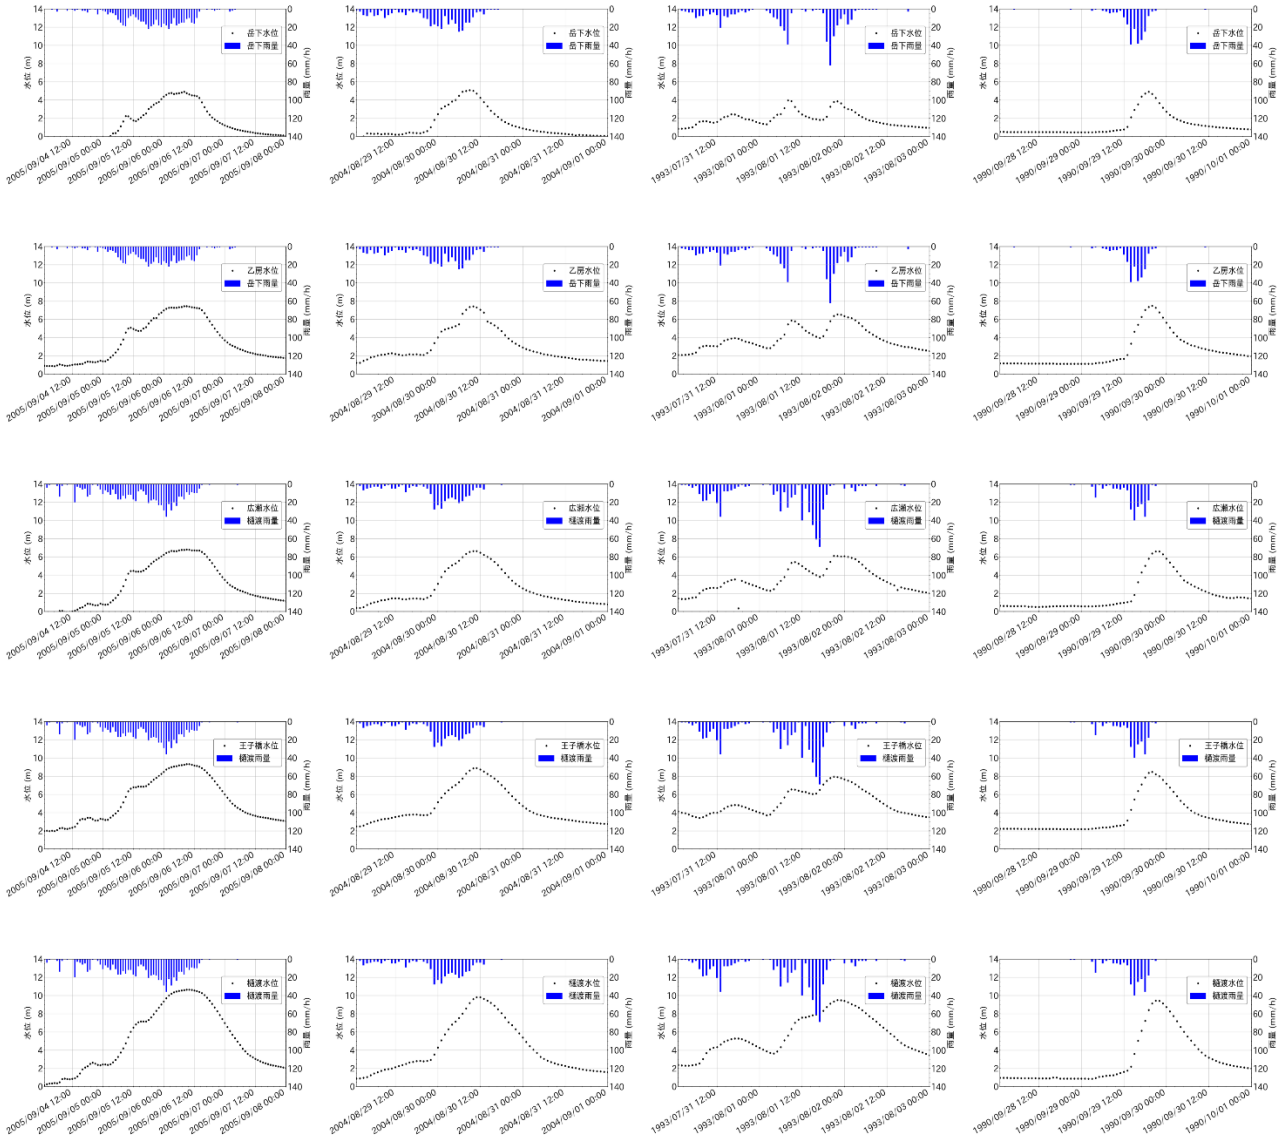

図-3.3　　各観測地点における検証出水波形

（左から，2005 出水，2004 出水，1993 出水，1990 出水．上から，St.1，St.2，St.3，St.4，St.5.）

表-3.2　各モデルの入力変数と出力変数

(t = 0 は現在の時刻を表し、T_f は予測までのリードタイムを示す).

Model	[Input] Observed water level (5 points, t =0, −1)	[Input] Observed hourly change in water level (5 points, t =−2 to 0)	[Input] Observed/Forecasted rainfall (14 gauging stations, *1)	[Input] RRI calculated flow rate (13 points, *2)	[Output] Forecasted water level (5 points, $t = T_f$)
Hybrid-DNN	○	○	○	○	○
Simple-DNN	○	○	○	-	○

*1) $t = T_f-6$ to T_f-1 for $T_f < 6$, 0 to T_f-1 for $6 \leq T_f$

*2) $t = T_f-6$ to T_f-1 for $T_f < 6$, 0 to T_f-1 for $6 \leq T_f < 12$, T_f-12 to T_f-1 for $12 \leq T_f$

3.2.3　検証結果

表-3.3 と図-3.4 に 3 つのモデル（Hybrid-DNN，Simple-DNN，RRI モデル）の RMSE における予測精度比較を示す．RRI モデルの予測時系列は，予測計算を行った時点での観測値と計算値の差を用いて一律にスライド補正を適用し，予測リードタイム別の精度評価を行っている．

まず分布型流出モデルである RRI 単独時との比較では，最大 24 時間の予測リードタイム範囲において，5 地点全てでハイブリッドモデルと DNN 単独モデルの予測精度がスライド補正を適用した RRI モデルの精度を大きく上回っており，出力対象を多地点に拡張したモデル構成においても，前章で示した単地点予測時と同様の傾向となることが全予測対象地点に対して確認できる．樋渡地点（St.5）における単地点予測方式時との比較（図-3.5）では，予測リードタイムが 10 時間より長い場合において単地点予測方式の予測精度が若干上回っているが，多地点予測方式へ拡張した場合にも顕著な精度劣化は見られず，同等程度の予測精度が実現されていることが確認できる．また，多地点予測方式のハイブリッドモデルの予測精度は，全予測リードタイムで単地点予測方式の DNN 単独モデル精度を上回っていることが確認できる．

次に，Hybrid-DNN と Simple-DNN を比較すると，最上流に位置する St.1 ではほとんど差が見られないが，上流から下流に進むにつれてハイブリッド化による精度向上の効果が明確となっている（図-3.6．縦軸の改善率は，$(\mathrm{RMSE}_{\mathrm{Simple-DNN}} - \mathrm{RMSE}_{\mathrm{Hybrid-DNN}}) * 100/\mathrm{RMSE}_{\mathrm{Simple-DNN}}$により算出）．最下流に位置する St.5 では，24 時間までの全予測リードタイムにおける RMSE の平均は 0.34 m となり，Simple-DNN の RMSE の平均 0.42 m と比べて 10%以上の改善が見られた．この結果は，対象流域が大きいほど，すなわち降雨流出過程が複数小流域からの支川合流等によって複雑化するほど，ハイブリッド化の効果が大きくなる可能性を示唆している．また，樋渡地点の平均 RMSE は 0.34 となっており，前章で検討した単一出力構成時の精度（0.32）と比較すると，6%程度の精度劣化が発生していることが分かる．

表-3.3　検証洪水に対する予測リードタイム（LT）別の平均 RMSE (m)

Case		LT=1	LT=3	LT=6	LT=12	LT=18	LT=24	全 LT 平均
St.1 (岳下)	Hybrid-DNN	0.11	0.20	0.27	0.37	0.40	0.46	0.33
	Simple-DNN	0.12	0.21	0.28	0.34	0.42	0.49	0.34
St.2 (乙房)	Hybrid-DNN	0.14	0.22	0.29	0.37	0.41	0.44	0.34
	Simple-DNN	0.15	0.23	0.30	0.41	0.45	0.51	0.38
St.3 (広瀬)	Hybrid-DNN	0.13	0.23	0.31	0.40	0.41	0.43	0.36
	Simple-DNN	0.13	0.26	0.39	0.47	0.48	0.53	0.43
St.4 (王子橋)	Hybrid-DNN	0.16	0.29	0.30	0.34	0.33	0.40	0.32
	Simple-DNN	0.16	0.28	0.32	0.39	0.38	0.46	0.36
St.5 (樋渡)	Hybrid-DNN	0.14	0.23	0.27	0.37	0.40	0.46	0.34
	Simple-DNN	0.15	0.23	0.32	0.48	0.48	0.55	0.42

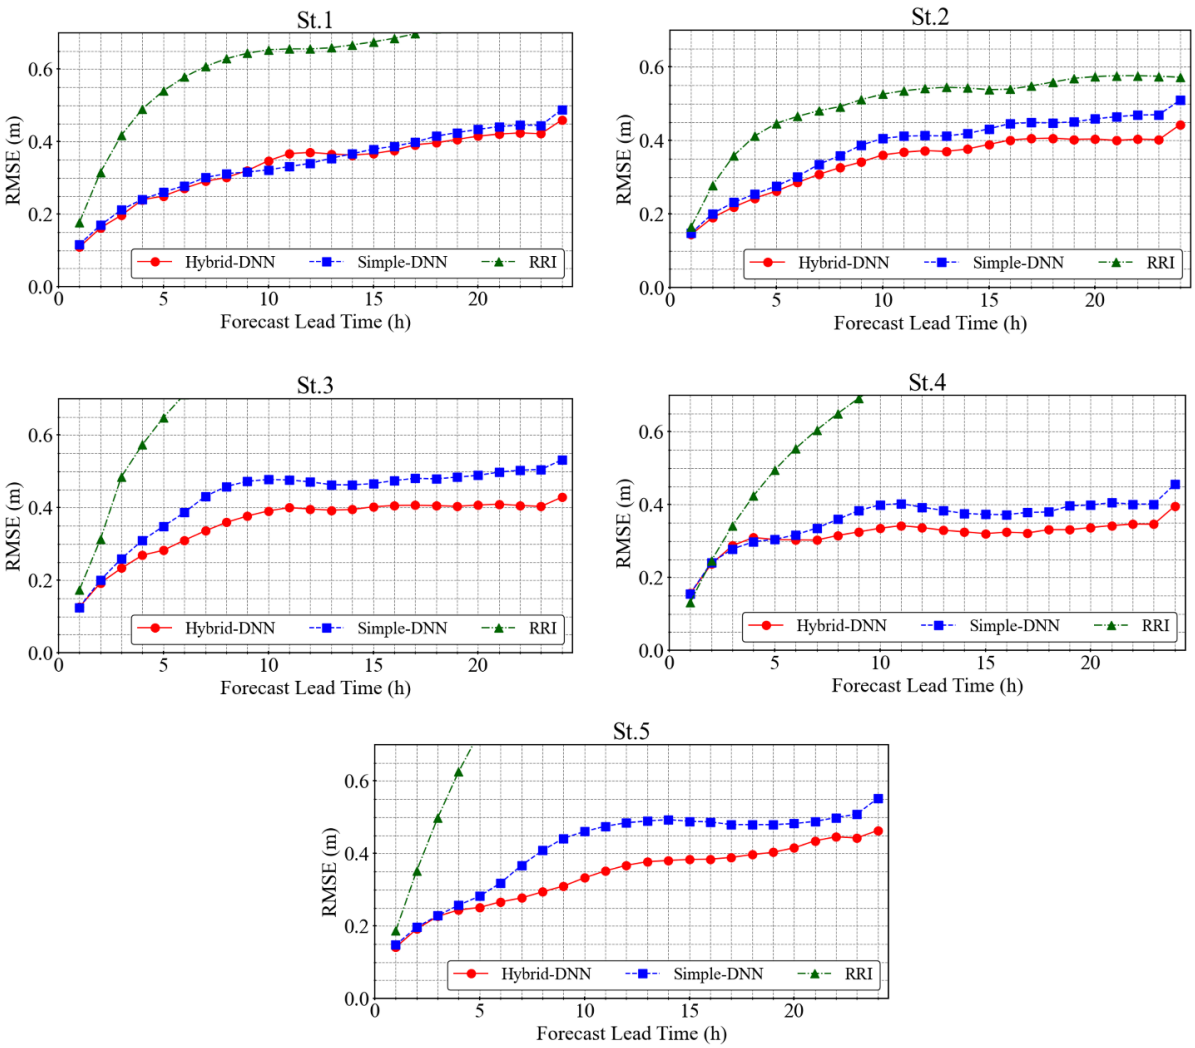

図-3.4　　各予測対象地点の予測リードタイム（LT）別 RMSE の比較

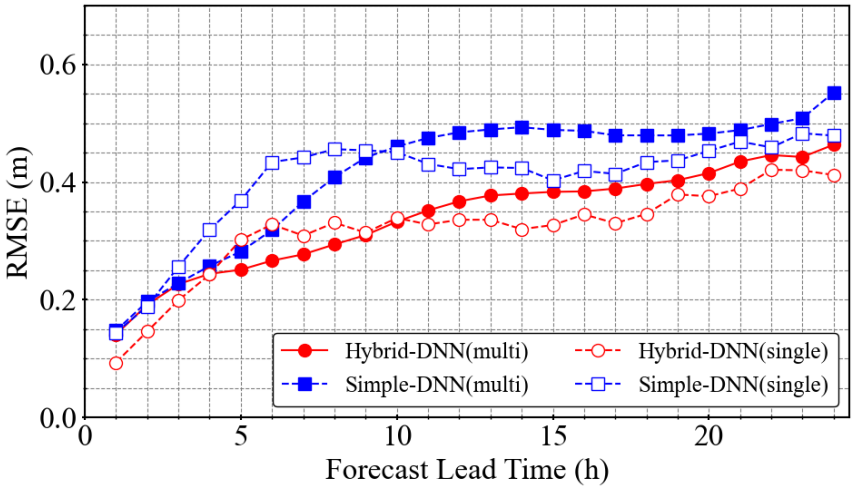

図-3.5　　樋渡地点(St.5)における多地点同時予測方式(multi)と単地点予測方式(single)の RMSE 比較

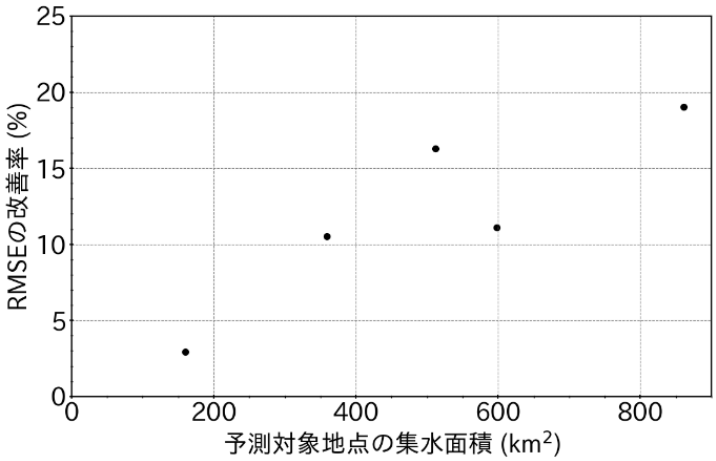

図-3.6　　予測対象地点の集水面積とハイブリッド化による予測精度（RMSE）改善率の関係

次に，予測リードタイムによる RMSE の違いに着目すると，予測リードタイム 1～3 時間ではハイブリッド化による精度向上は小さいものの，予測リードタイム 4 時間程度以降ではハイブリッド化による精度向上が顕著となっている．これは，直近 3 時間程度までは降雨量（および観測水位）と予測対象水位との相関が比較的明確であるために付加情報（RRI 計算流量）の価値が低く，4 時間程度以降は RRI モデルを用いた複雑な降雨流出過程を考慮した抽出特徴量が有効に機能するためと考えられる．

最後に，図-3.7 に 2005 年洪水の各地点における予測水位時系列の比較（予測リードタイム 6 時間）を示す．この結果図からも，最上流の St. 1 では RMSE 比較結果が示す通り，予測波形にはほとんど差がないのに対し，下流地点では特にピーク水位付近の予測精度が向上していることが確認できる．

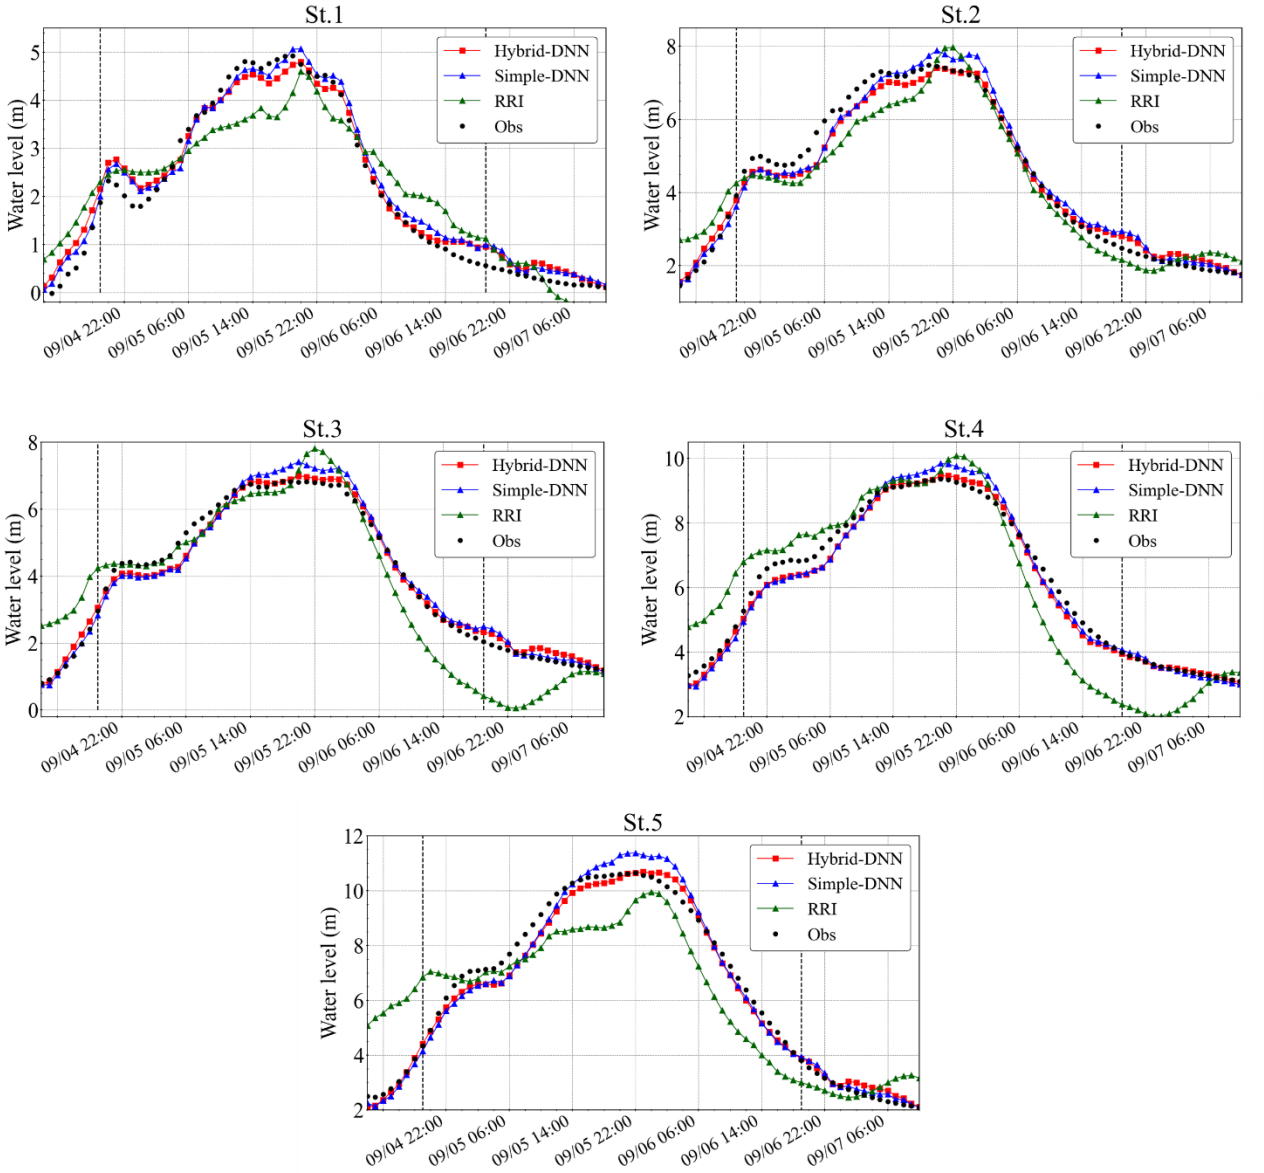

図-3.7　　2005 年洪水（最大規模出水）における各地点の水位予測時系列の比較
（縦の黒点線は RMSE 評価期間）

3.3 入力データ欠損影響の軽減

3.3.1 検討の概要と目的

洪水時には観測機器の故障や通信網の負荷に起因して，水位データが欠損しやすいという課題がある．まず物理的要因として，観測局の水没・漂流物の衝突・濁水や浮遊物の付着などによりセンサー計測が不安定化し，異常値や測定不能が発生する．特に圧力式・超音波式センサーでは高水位時の流速増大や乱流の影響を受けやすく，ピーク付近で連続的な欠損が生じることが多い．また，観測機器を設置している堤防や橋梁部が浸水すると電源障害が起こり，長時間の欠測につながる．通信面では，洪水時に携帯回線や専用線が輻輳・断線・停電の影響を受け，データ送信が不安定になる．特にリアルタイムテレメータでは，短時間の通信途絶が連続欠損として表れる [10]．

欠損パターンとしては，洪水ピーク前後で連続して欠測するパターン，通信不安定によりランダムに欠損が生じるパターン，電源障害などで長期間データが途絶するパターンなどが挙げられる．これらの水位データ欠損は，水位データ入力を前提としている DNN モデル構成に対しては予測精度を大きく左右する要因となるため，データ欠損状況が予測精度に与える影響の把握や，精度劣化の低減手法について検討することが重要となる．

3.3.2 検証設定

観測水位データの欠損が予測精度に与える影響を評価するため，異なる水位欠損パターンを想定した 4 ケースに対するケーススタディを実施した (図-3.8，表-3.4)．ケース 1 と 2 は，特定の観測所が完全に利用不可となる場合を仮定したケースである．ケース 1 は，上流観測所 St. 1 (岳下) のデータが利用不可となるケースであり，ケース 2 は，St. 1 (岳下) と中間観測所 St. 3 (広瀬) の複数観測地点のデータが利用不可となるケースである．次に，ケース 3 と 4 は，時系列観測データが部分的に欠損していると仮定したケースである．ケース 3 では全水位観測所の時系列データの 10% がランダムに欠損したケースであり，ケース 4 は 30% が欠損したケースである．

各ケースに対する検証対象モデルとして，欠損データのないデータ（以下,「マスクなしデータセット」と呼ぶ）のみで事前学習したモデルに加えて，データ欠損の状況を模擬し，ランダムに 全体の 10% と 30% をマスクした (水位値を -1.0 に置き換えた) 観測水位時系列データ（以下,「マスク付きデータセット」と呼ぶ）で事前学習したモデルの比較を行った．

評価検証時には，ケース 1 と 2 では，欠損データの値は -1.0 に設定した．ケース 3 および 4 では，欠損データの値について，欠損データなしのデータセットで学習したモデルは前後の値から線形補間した値に設定し，マスクデータありで学習したモデルには-1.0 に置換して入力した．データ欠損状況は疑似乱数に依存するため，精度評価は疑似乱数の異なる 3 回の独立した試行の平均値で評価した．

表-3.4　検証対象とした上流地点水位の欠損ケース設定

Case No	Data missing type	Description
Case 1	Specific gauging stations are entirely unavailable	St.1 (Takeshita) is assumed to be entirely unavailable.
Case 2	Specific gauging stations are entirely unavailable	St.1 (Takeshita) and St.3 (Hirose) are assumed to be entirely unavailable.
Case 3	Randomly missing in time series data	Randomly missing 10% of the time series data (St.1, St.2, St.3, St.4, and St.5)
Case 4	Randomly missing in time series data	Randomly missing 30% of the time series data (St.1, St.2, St.3, St.4, and St.5)

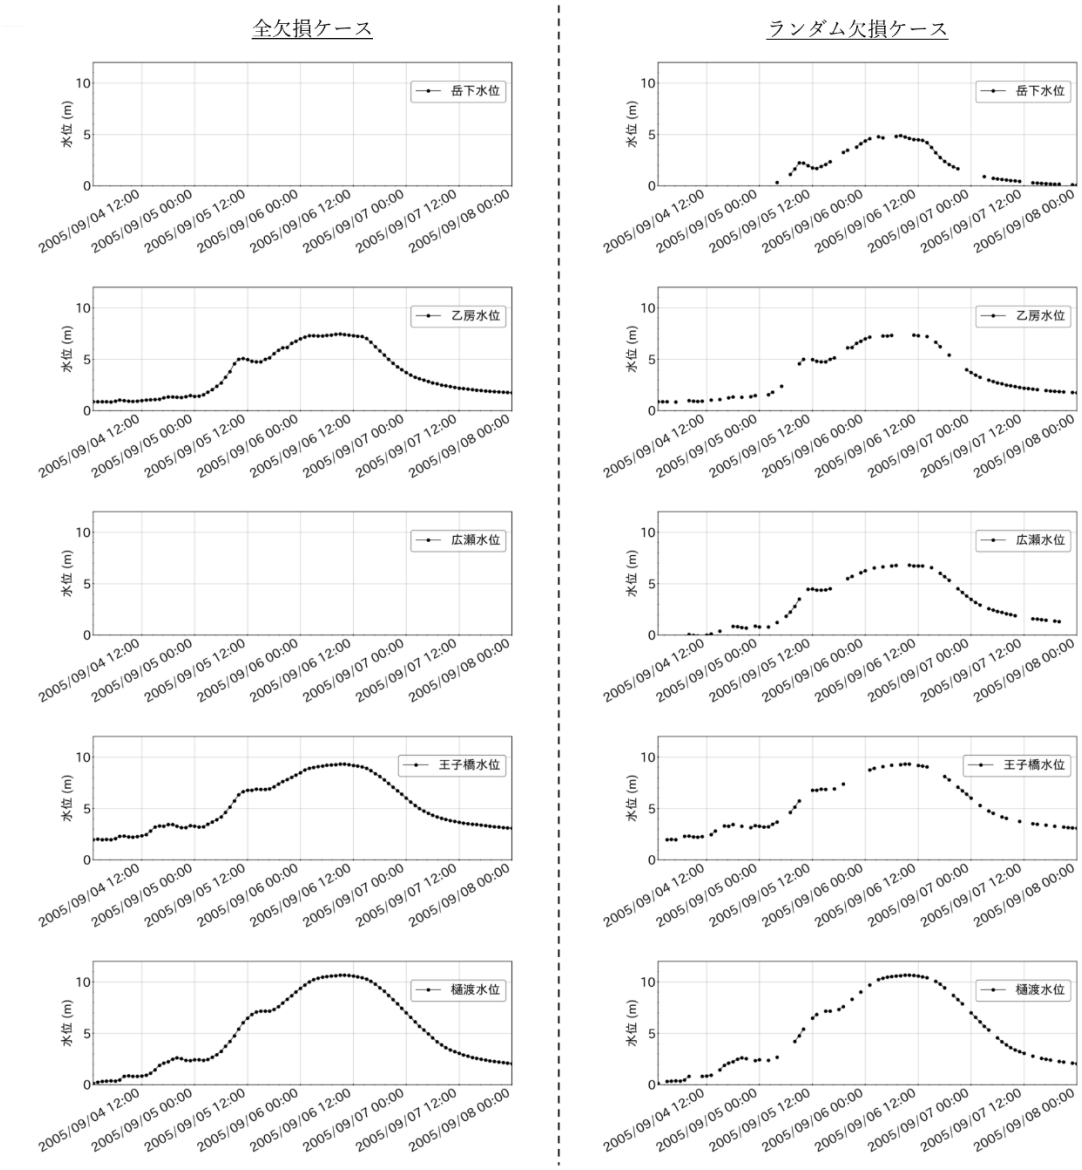

図-3.8　　水位データ欠損ケースの概要
（左：一部観測所データが利用不可，右：時系列的なランダム欠損（図は 30%））

3.3.3　検証結果

図-3.9 に，24 時間先までの全予測リードタイムに対する平均 RMSE をケースごとに比較した結果を示す．図では，Hybrid-DNN と Simple-DNN のそれぞれに対し，1) マスクなしデータセット，2) 10%マスク付きデータセット，3) 30%マスク付きデータセット，をそれぞれ事前学習させたモデル（計 6 モデル）について，欠損状況の異なる各検証ケースでの予測精度を比較している．ケース 1 と 2 は一部の水位観測所データが全欠損するケースとなるが，比較対象モデルは上述の通り，マスクなしデータセットを学習したモデルと，マスク付きデータセット（10%および 30%のマスク）を学習したモデルであり，全欠損ケースを事前学習したモデルは検証対象に含まれないことに留意されたい．

まず，マスクなしデータセットで学習させた一般的な学習ケース（「Hybrid」と「Simple」）に焦点を当てると，いずれのケースでもハイブリッドモデルの精度が優れており，ハイブリッド化によって欠損データ発生時の予測結果の安定性が向上していることがわかる．ハイブリッドモデルでは，RRI によって算出された流量が予測のための特徴量として追加入力されるため，観測水位が予測結果に与える影響が相対的に小さくなることにより，観測水位の欠損に対するモデルの頑健性が向上していると考えられる．

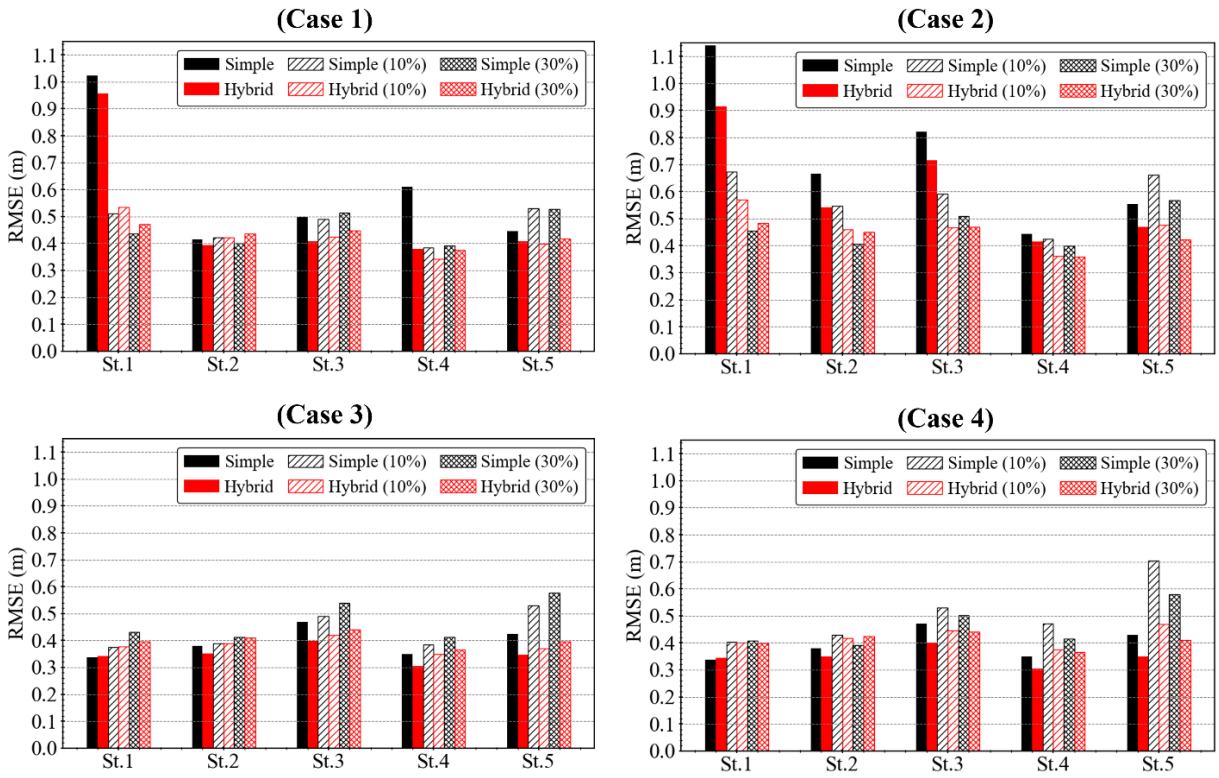

図-3.9　　各データ欠損ケースにおける RMSE の比較
（Hybrid-DNN と Simple-DNN に対し，1) マスクなしのデータセット，2) 10%マスク付きデータセット，3) 30%マスク付きデータセット，でそれぞれ事前学習したモデル(計 6 モデル)を対象として，欠損条件の異なる各検証ケースで予測精度を比較）

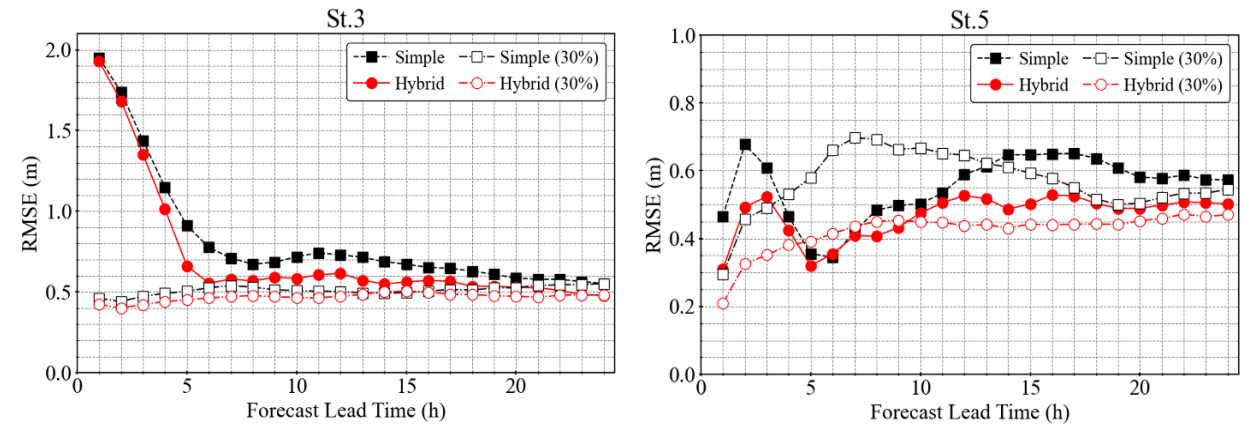

図-3.10　　予測リードタイム別の上流水位データ欠損に対する精度影響

次に，マスクなしデータセットで学習させたモデルとマスク付きデータセットで学習させたモデルを比較する．特定の観測所が完全に利用不可となるケース 1 とケース 2 では，マスク付きデータセットで学習したモデルは，マスクなしデータセットで学習したモデルよりも各地点で高い予測精度を示している．特に観測水位データが全く利用できない観測所（ケース 1 では St. 1，ケース 2 では St. 1 と St. 3）での予測精度向上は顕著である．一方，時系列データがランダムに欠損しているケース 3 とケース 4 では，マスクなしデータセットで学習したモデル（ケース 3 とケース 4 の欠損値には線形補間値を入力）は，マスク付きデータセットで学習したモデルよりも高い予測精度を示している．

欠損率を 30%からさらに増加させていくことを仮定すると，欠損率が 100%になった際にはケース 1 やケース 2 と同様の状況となることから，マスク付きデータセットで学習したモデルとマスクなしデータセットで学習したモデルのどちらがより良い予測精度を示すかは，線形補間などを用いて妥当な観測水位を推定可能かどうかに依存すると推察される．ただし，マスク付きデータセットで学習したハイブリッド DNN の場合，欠損データによる予測精度の低下は，全ケースと地点に対して平均した RMSE で，6.9%（0.394 から 0.421）に収まることが分かった．マスクなしデータセットで学習したハイブリッドモデルの精度低下は，RMSE で 30.4%（0.349 から 0.455）であったことから，マスク付きデータセットで学習したモデルは，データ欠損の有無に関わらず安定した予測が可能となることが分かる．またこの結果は，10%がマスクされたデータセットと 30%がマスクされたデータセットで学習した場合に有意な差が見られないことから，予測精度は学習時のマスク率にはあまり依存しないことが示唆される．

最後に，ケース 2（St.1 と St.3 の観測データが完全に利用不可）における RMSE の予測リードタイムへの依存性を図-3.10 に示す．RMSE が示した通り，マスクデータを学習したモデルでは，データ欠損による精度低下影響があまり見られないことが確認できる．一方でマスクされていないデータセットで学習したモデルについて，観測水位データが完全に利用できない St.3 では，予測リードタイムが 5 時間までの範囲に対して，データ欠損による精度低下の影響が顕著である．一方で下流に位置する St.5 では，マスクされていないデータセットで学習したモデルの精度低下は，予測リードタイムが 2 時間から 5 時間までの間で顕著だが，1 時間後の水位予測への影響は比較的小さい．これは，1 時間後の予測において，St.3 地点の予測では St.3 の観測水位は直近水位変動を示すため，予測への寄与が大きいのに対し，St.5 地点の予測では，St.1～St.3（データ欠損地点）の観測水位が影響するのは，これらの地点から St.5 まで洪水が流下した後となるためである．これより，特定地点のデータ欠損により精度低下が発生する期間は流

下時間から推定可能であると推察され，全リードタイムで悪影響を及ぼすわけではないと考えられる．

以上の結果から，観測水位欠損が予測水位に影響を与えるのはデータ欠損地点から対象地点までの流下時間以降の数時間であり，それ以降の予測リードタイムではデータ欠損による予測精度低下への影響は軽微であると推察される．なお，本結果は予測リードタイム別にモデルを個別に構成した場合の結果であり，前時間の予測結果を引き継いで逐次的に予測を行うモデル構成では，1 時間後等の早い予測リードタイムにおける予測誤差の影響が，その後の予測結果に影響する点に留意が必要である．

3.4 まとめ

本章では，降雨流出氾濫（RRI）モデルと深層学習モデルを用いたハイブリッドモデルに対し，同時多点水位予測にモデルを拡張した場合の予測精度，ならびに上流地点水位のデータ欠損が予測精度に与える影響を評価した．得られた知見を以下に示す．

- 多地点同時予測方式に拡張した場合，予測リードタイムが長い場合は単地点予測方式の予測精度が若干上回るものの，顕著な予測精度の劣化は見られないことを確認した．また，ハイブリッド化による予測精度の向上効果は，単地点予測方式時と同様に有意であることが示された．

- 上流から下流に向かうにつれてハイブリッド化による予測精度向上効果が大きく，DNN 単独モデルと比較して二乗平均平方根誤差（RMSE）が最大 10%以上改善されることがわかった．この結果は，対象流域が大きいほど，すなわち降雨流出過程が複雑であるほど，ハイブリッド化の効果が大きいことを示唆している．

- ハイブリッドモデルは，一部の水位観測所データが全く利用できない場合や，時系列的にランダムにデータが欠損している場合でも，DNN 単独モデルより安定した予測精度を示すことが分かった．ハイブリッドモデルでは，RRI によって算出された流量が予測のための特徴量として追加入力されるため，観測水位が予測結果に与える影響が相対的に小さくなることにより，観測水位の欠損に対するモデルの頑健性が向上していると考えられる．

- 水位データ欠損を模擬したマスクデータで学習させた結果，水位データ欠損による予測精度の低下は RMSE で 6.9%に抑えられた．一方で，部分的な時系列欠損に対して前後データからの線形補間を行った場合，マスクデータで学習させていないモデルの方が高精度を示すことが分かった．このため，実運用ではデータ欠損の程度に応じて，これらのモデルを切り替えて運用することが望ましいと考えられる．

以上の結果より，本ハイブリッドモデルは単独モデルと比較して，複数地点の効率的な同時予測が可能であること，水位データ欠損時の予測結果の安定性が向上することから，多地点での安定した予測が求められる実際のリアルタイム予測システムへの適正が高いことが示唆された．

参考文献（第 3 章）

1) T. Sayama, G. Ozawa, T. Kawakami, S. Nabesaka, K. Fukami: Rainfall–runoff–inundation analysis of the 2010 Pakistan flood in the Kabul River basin, *Hydrological Sciences Journal* 57: 298–312, 2012, doi: 10.1080/02626667.2011.644245
2) M. Hitokoto and M. Sakuraba: Hybrid Deep Neural Network and Distributed Rainfall-Runoff Model for Real-Time River-Stage Prediction, *Journal of JSCE*, Vol. 8, No. 1, pp. 46−58, 2020, doi: 10.2208/journalofjsce.8.1_46.
3) G. Konapala, S.-C. Kao, S. L. Painter, D. Lu: Machine learning assisted hybrid models can improve streamflow simulation in diverse catchments across the conterminous US, *Environ. Res. Lett.*, Vol. 15, No. 10, p.104022, 2020, doi: 10.1088/1748-9326/aba927.
4) 中村要介, 関本大晟, 阿部紫織, 新井章珣：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, I_313-I_318, 2021, doi: 10.2208/jscejhe.77.2_I_313.
5) 福丸大智, 赤松良久, 新谷哲也, 藤井晴香: 深層学習を用いた流域内多地点における河川水位・流量予測モデルの開発，土木学会論文集 B1(水工学), Vol. 77, No. 2, I_1231-I_1236, 2021, doi: 10.2208/jscejhe.77.2_I_1231.
6) 石井陽子, 脇本政行, 福本教朗：テレメータ欠測の対応について, 四国地方整備局管内技術・業務研究発表会, 2018. Available: https://www.skr.mlit.go.jp/kikaku/kenkyu/h30/ronbun/II-97.pdf
7) 佐久間駿, 中安正晃, 鴨下由男：精度監視による異常値対応について,令和 5 年度 河川情報シンポジウム講演資料, 一般財団法人河川情報センター, 2023.
Available: https://www.river.or.jp/01kenshuu/sympo/r05/img/report_04.pdf
8) 小髙茂治：近畿地方整備局における河川情報の監視と水文観測データの品質照査について, 平成 25 年度近畿地方整備局 研究発表会論文集, 2013.
9) 児島利治, Weilisi, 大橋慶介：深層学習による流量欠測値の補完方法の検討, 河川技術論文集, Vol. 26, pp. 137−142, 2020, doi: 10.11532/river.26.0_137.
10) K. Watanabe, M. Irie, M. Iguchi: Hybrid-input ensemble neural network for improving flood-forecasting performance, *Hydrological Research Letters*, Vol. 19, No. 1, pp. 22−29, 2025, doi: 10.3178/hrl.24-00015.
11) I. Goodfellow, Y. Bengio, and A. Courville: *Deep Learning*, Cambridge, MA, USA: MIT Press, 2016.
12) D. Yamazaki, S. Togashi, A. Takeshima, T. Sayama: High-resolution flow direction map of Japan, *Journal of Japan Society of Civil Engineers Ser. B1 (Hydraulic Engineering)*, 74: I_163–I_168, 2018. (in Japanese with English abstract). doi: 10.2208/journalofjsce.8.1_234.
13) Q. Duan, S. Sorooshian, V. Gupta: Effective and efficient global optimization for conceptual rainfall-runoff models, *Water Resources Research*, Vol. 28, No. 4, pp. 1015−1031, 1992, doi: 10.1029/91WR02985.

第 4 章　縦断予測とデータ同化に向けた PINNs 河道モデルの検討

4.1　はじめに

河川水位予測では, 降雨情報をもとにした流域から河道への流出解析と, その流出量を入力とした河川流解析を組み合わせることで, 時空間的に連続した縦断的な河川水位予測を行うことが一般的である. このような解析モデルは, 多数のパラメータや初期条件, 境界条件を含んでおり, それらには不確実性が内在している. そのため, 観測情報を活用してこれらの不確実なパラメータや状態量を推定・補正するデータ同化技術は, 予測精度の向上において極めて重要な役割を担っている.

近年では, 洪水時に特化した危機管理型水位計の整備が全国的に進展しており, 従来よりも高頻度かつ高密度な観測データが得られる状況にある. これにより, 河川の縦断方向における水位変化を詳細に把握することが可能となり, 複数地点の観測情報を同時に活用することで, モデルの不確実性をより効果的に低減できる可能性が広がっている. このため, これらの多地点観測データを効率的かつ自動的に解析モデルへ反映し, リアルタイムで水位予測を更新できるようなデータ同化技術の発展が期待されている.

河川水位予測におけるデータ同化手法として, 逐次型データ同化手法である粒子フィルタが広く普及しているが, 多地点水位データ同化を行う場合には計算負荷が問題となりやすく, 逐次同化のため推定パラメータの時間変動は物理的に解釈しづらい結果となりやすい. 非逐次型データ同化手法であるアジョイント法は, 同化期間内で一貫した合理的な推定値が得られる一方で, アジョイントコード実装の労力が大きく, 順解析と推定値の修正を繰り返す収束計算の特性上, リアルタイム予測に向けた並列計算による高速化が容易ではない等の課題がある.

このような従来手法に対し, 近年提案された支配方程式の情報を考慮可能な深層学習モデルである PINNs (Physics-Informed Neural Networks)を用いたデータ同化は, 同化対象データを柔軟かつ簡便に設定できる, 同化対象地点数による計算量への影響が小さい, 境界条件の事前学習により大幅な高速化が期待できる, 等の利点を有する有望な手法である. PINNs は学習データが必須である従来の深層学習モデルとは異なり, 支配方程式に基づいて初期条件と境界条件のみから推論が可能であるという特長を持つ. 一方で, 適用する問題によっては学習過程で誤った解 (Failure Modes) に収束しやすい課題が知られている他, 実河川を想定した一次元不定流解析(Saint-Venant Equations) への適用報告は現時点で少なく, 水深と河積が線形関係となる矩形断面かつ横流入が存在しない簡易的な条件に対する検証に留まっており, 粗度係数等を対象としたデータ同化に関する報告例も存在しない.

本章では, 横流入を含む一般河道断面の一次元不定流解析へ PINNs を適用する方法を検討し, 実河川を対象とした多地点水位データ同化の性能を検証する. 具体的には, 一般的な計算条件である横流入を含む一般河道断面の一次元不定流解析に対し, PINNs による順解析を安定して正しい解へ収束させる方法を検討する. さらに, 実河川を対象とした多地点水位データ同化に関して, 区間別の粗度係数を同化対象としたケーススタディを行い, 本手法のデータ同化に対する有効性を検証する.

4.2 河道水理モデルの概要

4.2.1 河川における洪水流計算手法

河川における洪水流の計算（水理解析）では，特定の河道形状，河床粗度，植生分布などの物理的特性を持つ河道モデルを設定し，これに対して上流端・下流端の境界条件（流量または水位）を与えることで，対象河川における流況，すなわち水位・流量・流速などの水理量の空間分布および時間変化を計算する．

解析手法は，流れの時間的変動および空間的変化の扱い方に応じて，等流計算・不等流計算・不定流計算の三つに大別される．まず，等流計算は流れが時間的にも空間的にも変化しない定常状態を仮定し，水面勾配が河床勾配と等しい状況を解析するものである．主にマニング式などの経験式を用い，平常時の流況評価や水理構造物設計に適用される．次に，不等流計算は時間的には定常であるが，空間的には水面が変化する流れを対象とする．ダムや堰，橋梁，河床勾配の変化などによって局所的に流況が変動する場合に用いられ，エネルギー方程式または運動方程式を基礎として水面形を逐次的に求める．背水区間評価や限界水深の解析など，水面形の空間分布評価に有効である．不定流計算は時間的にも空間的にも流況が変化する非定常流を扱う．洪水流やダム放流など，短時間に流量・水位が大きく変動する現象を表現するため，連続式および運動方程式から水理量の時間発展を求める手法である．この計算は洪水予測，氾濫解析，リアルタイム流況シミュレーションなどで広く利用されている．これらの解析手法はさらに，空間次元によっても分類される．一次元解析は河道の主流方向の流れを主として扱うもので，二次元解析は平面方向の広がりを考慮し，三次元解析では鉛直方向の流速分布まで含めて詳細に解析する．用途に応じて適切な解析手法は異なるが [1]，リアルタイム河川水位予測においては，対象が非定常流であること，広範な河川区間を対象とした迅速な計算が求められること，また避難判断などで重視されるのは水位・流量といったスカラーの水理量であることから，一次元不定流解析を用いるのが一般的である．以下では，本研究の対象となる一次元不定流解析の概要について述べる．

4.2.2 一次元不定流解析モデルの概要

(1) 基礎方程式

河川や開水路における非定常流（不定流）を表す一次元不定流計算の基礎方程式は，一次元浅水流方程式，あるいは Saint-Venant（サン・ヴナン）方程式とも呼ばれ，連続の式（質量保存則）と運動方程式（運動量保存則）から構成される。連続式と運動方程式は次のように表される。

$$\frac{\partial A}{\partial t}+\frac{\partial Q}{\partial x}=q_l \tag{4.1}$$

$$\frac{\partial Q}{\partial t}+\frac{\partial vQ}{\partial x}+gA\frac{\partial H}{\partial x}+\frac{S\tau_b}{\rho}=q_l(u_l-u) \tag{4.2}$$

ここで，x: 流線方向の位置，t: 時間，v: 流速，A: 河積，Q: 流量，H: 水位，ρ: 水の密度，S: 潤辺，τ_b: 河床近傍の掃流力，g: 重力加速度，q_l: 単位長さあたりの横流入量，u_l: 流入流速である．連続式は，河道内の流出入のバランスを示しており，運動方程式の左辺第 1 項は運動量の時間変化，第 2 項は運動量

の移流の効果，第 3 項は静水圧と河床勾配による重力の効果，第 4 項は摩擦損失の効果，右辺は流入速度と主流速度を近付ける効果を表す．河床近傍の掃流力はマニング式を用いて以下の式で評価される．

$$\frac{S\tau_b}{\rho} = SgRI_f = gAI_f = \frac{Sgn^2v^2}{R^{\frac{1}{3}}} = \frac{Sgn^2Q}{R^{\frac{1}{3}}A^2}Q = \frac{gn^2Q}{R^{\frac{4}{3}}A}Q \tag{4.3}$$

ここで，n: マニングの粗度係数，R: 径深，I_f: エネルギー勾配を表す．

(2) 一般河道断面を対象とした有限差分法による計算スキーム

有限差分法（Finite Difference Method，以降 FDM）を用いた一次元不定流の計算フローを以下に示す．以下では簡単のため横流入が無いケースを示すが，横流入を考慮する場合も定数項の違いを除いて計算フローは同様である．なお，本計算フローは一般断面の不等流・不定流・河床変動を計算する iRIC ソフトウェアソルバー「Nays1D+」[2)]の計算フローに準拠している．

不定流流れの運動方程式（式（4.2））は，エネルギー勾配I_fを用いると次のようになる．

$$\frac{\partial Q}{\partial t} + \frac{\partial vQ}{\partial x} + gA\frac{\partial H}{\partial x} + gAI_f = 0 \tag{4.4}$$

ここで，一般断面を複数の領域に分割することを考える（図-4.1）．分割された領域は，鉛直方向に長方形断面を有する領域であると仮定する．一般断面を N 個の領域に分割し，第 j 番目の計算領域の面積は以下の式で表される．

$$a_j = h_j \cdot \Delta y_j \tag{4.5}$$

第 j 番目の計算領域の流速をu_jとすると，第 j 番目の計算領域のΔt時間の流量変化Δq_jは以下となる．

$$\Delta q_j = u_j \cdot a_j = u_j h_j \Delta y_j \tag{4.6}$$

第 j 番目の計算領域の流速u_jは，マニングの抵抗則を用いて以下のようになる．

$$u_j = \frac{1}{n_j} r_j^{\frac{2}{3}} i_e^{\frac{1}{2}} \tag{4.7}$$

r_j: 第 j 番目の計算領域の径深で，以下のように第 j 番目の計算領域の水深h_jから

$$r_j \approx h_j \left(\because r_j \approx \frac{\Delta a_j}{\Delta y_j} = h_j \right) \tag{4.8}$$

以上より式(4.6)と流量Qは以下のようになる．

$$\Delta q_j = \frac{1}{n_j} h_j^{\frac{2}{3}} i_e^{\frac{1}{2}} \cdot h_j \Delta y_j \tag{4.9}$$

$$Q = \sum_{j=1}^{N} \Delta q_j = \sum_{j=1}^{N} \left(\frac{1}{n_j} h_j^{\frac{5}{3}} \Delta y_j \right) \cdot i_e^{\frac{1}{2}} \tag{4.10}$$

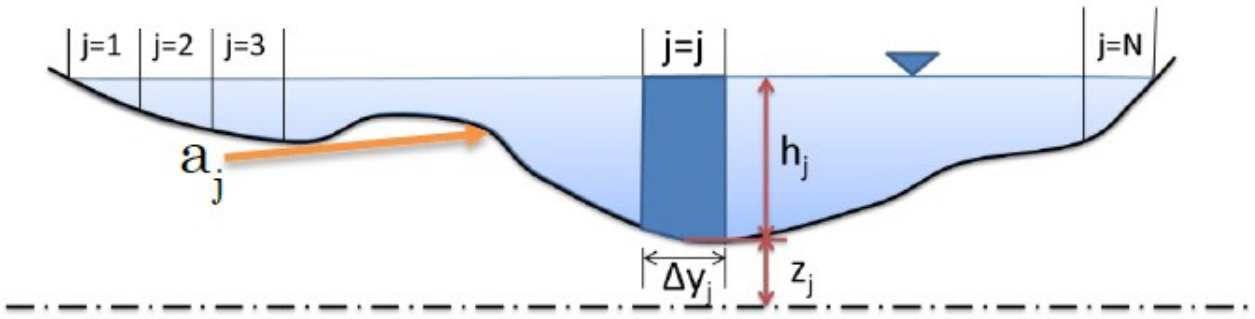

図-4.1　　一般断面の分割（出典：文献[2]）

一般的に，エネルギー勾配は横断方向に一様であり以下のようになる．

$$i_e = \frac{Q^2}{\left(\sum_{j=1}^{N} \frac{1}{n_j} h_j^{\frac{5}{3}} \Delta y_j\right)^2} \tag{4.11}$$

したがって，式(4.4)の一般断面における運動方程式を分割したブロックの総和として表現するとき，エネルギー勾配I_fは横断方向に一定と仮定されるため，以下のようになる．

$$\sum_{j=1}^{N} \frac{\partial u_j a_j}{\partial t} + \sum_{j=1}^{N} \frac{\partial u_j^2 a_j}{\partial x} + \sum_{j=1}^{N} g a_j \frac{\partial H}{\partial x} + \sum_{j=1}^{N} g a_j I_f = 0 \tag{4.12}$$

断面面積の総和を$\left(\sum_{j=1}^{N} a_j = A\right)$として，以下のように書き換えられる．

$$\frac{\partial \sum_{j=1}^{N} u_j a_j}{\partial t} + \frac{\partial \sum_{j=1}^{N} u_j^2 a_j}{\partial x} + gA \frac{\partial H}{\partial x} + gAI_f = 0 \tag{4.13}$$

断面における全流量は，次式により求める．

$$\sum_{j=1}^{N} a_j u_j = Q \tag{4.14}$$

断面平均流速は，以下のようになる．

$$v = \frac{Q}{A} = \frac{\sum_{j=1}^{N} a_j u_j}{A} = \frac{\sum_{j=1}^{N} a_j u_j}{\sum_{j=1}^{N} a_j} \tag{4.15}$$

運動量補正係数βは，以下のように定義される．

$$\sum_{j=1}^{N} u_j^2 a_j = \beta v^2 A \tag{4.16}$$

$$\beta = \frac{\sum_{j=1}^{N} u_j^2 a_j}{v^2 A} = \frac{\sum_{j=1}^{N} \left(\frac{1}{n_j} h_j^{\frac{2}{3}} I_f^{\frac{1}{2}} \right)^2 h_j \Delta y_j}{\left(\frac{\sum_{j=1}^{N} a_j u_j}{A} \right)^2 A} = \frac{A \sum_{j=1}^{N} \left(\frac{1}{n_j} h_j^{\frac{2}{3}} I_f^{\frac{1}{2}} \right)^2 h_j \Delta y_j}{\left(\sum_{j=1}^{N} a_j u_j \right)^2} \tag{4.17}$$

$$\beta = \cdots = \frac{A \sum_{j=1}^{N} \left(\frac{1}{n_j} h_j^{\frac{2}{3}} I_f^{\frac{1}{2}} \right)^2 h_j \Delta y_j}{\left(\sum_{j=1}^{N} h_j \Delta y_j \frac{1}{n_j} h_j^{\frac{2}{3}} I_f^{\frac{1}{2}} \right)^2} = \frac{A \sum_{j=1}^{N} \frac{1}{n_j^2} h_j^{\frac{7}{3}} I_f \Delta y_j}{\left(\sum_{j=1}^{N} \frac{1}{n_j} h_j^{\frac{5}{3}} I_f \Delta y_j \right)^2} = \frac{A \sum_{j=1}^{N} \frac{1}{n_j^2} h_j^{\frac{7}{3}} \Delta y_j}{\left(\sum_{j=1}^{N} \frac{1}{n_j} h_j^{\frac{5}{3}} \Delta y_j \right)^2} \tag{4.18}$$

エネルギー勾配I_fは式(4.11)と同様に求めて，下記のようになる．

$$I_f = \frac{Q^2}{\left(\sum_{j=1}^{N} \frac{1}{n_j} h_j^{\frac{5}{3}} \Delta y_j \right)^2} \tag{4.19}$$

支配方程式は，以下の手順で計算する．

（STEP1）初期条件の設定をする．

— 流量を与える．

— 不等流計算により初期水位を求める．

— 水位を用い，断面面積総和 A，断面平均流速 v，第 j 番目の計算格子の水深h_jを求める．

（STEP2）運動量補正係数，エネルギー勾配を式(4.18)，(4.19)より求める．

（STEP3）運動方程式の計算を行う．

$$\frac{Q_i^{n+1} - Q_i^n}{\Delta t} + F_{V_i}^n + F_{S_i}^n + F_{f_i}^n Q_i^{n+1} = 0 \tag{4.20}$$

各変数は以下により計算される．

$$F_{V_i}^n = \left. \frac{\partial \beta v Q}{\partial x} \right|_i^n = \frac{\beta_{i+1/2} v_{i+1/2} Q_d - \beta_{i-1/2} v_{i-1/2} Q_u}{\Delta x_i} \tag{4.21}$$

$$v_{i+1/2} = \frac{v_{i+1}^n + v_i^n}{2}, v_{i-1/2} = \frac{v_i^n + v_{i-1}^n}{2} \tag{4.22}$$

$$Q_d = \begin{cases} Q_i^n \ if \ v_{i+1/2} \geq 0. \\ Q_{i+1}^n \ if \ v_{i+1/2} < 0. \end{cases}, Q_u = \begin{cases} Q_{i-1}^n \ if \ v_{i-1/2} \geq 0. \\ Q_i^n \ if \ v_{i-1/2} < 0. \end{cases} \tag{4.23}$$

$$F_{S_i}^n = gA\frac{\partial H}{\partial x}\Big|_i^n = gA_i^n\left(\frac{H_{i+1/2}-H_{i-1/2}}{\Delta x_i}\right), H_{i+1/2} = Z_{b,i+1/2} + h_{i+1/2} \tag{4.24}$$

$$F_{f_i}^n = \frac{gA_iI_{f_i}}{Q_i} = gA_i\lambda_{f_i}Q_i, \qquad \lambda_f = \frac{1}{\left\{\sum_{j=1}^{N}\frac{1}{n_j}h_j^{\frac{5}{3}}\Delta y_j\right\}^2} \tag{4.25}$$

（STEP4）流量 Q を更新する

$$Q_i^{n+1} = \frac{Q_i^n - \left(F_{V_i}^n + F_{S_i}^n\right)\Delta t}{1 + F_{f_i}^n\Delta t} \tag{4.26}$$

（STEP5）連続式(4.1)より，断面面積の総和A_iを更新する．ここで，空間差分には中央差分，時間積分には Euler 法を用いている．

$$A_{i+1/2}^{n+1} = A_{i+1/2}^n + \Delta t\left(-\frac{\partial Q}{\partial x}\right)_{i+1/2} = A_i^n - \Delta t\frac{Q_{i+1}-Q_i}{\Delta x_{i+1/2}} \tag{4.27}$$

（STEP6）図-4.2 の計算フローに従い，各断面の水位H_iを更新する．

（STEP7）断面ごとに第 j 番目の計算格子の水深h_jを以下の式から求める．

$$h_j = \max\left[H - z_{bj}, 0\right] \tag{4.28}$$

計算終了時間まで（STEP2）から（STEP7）を繰り返すことで，一次元不定流を計算する．

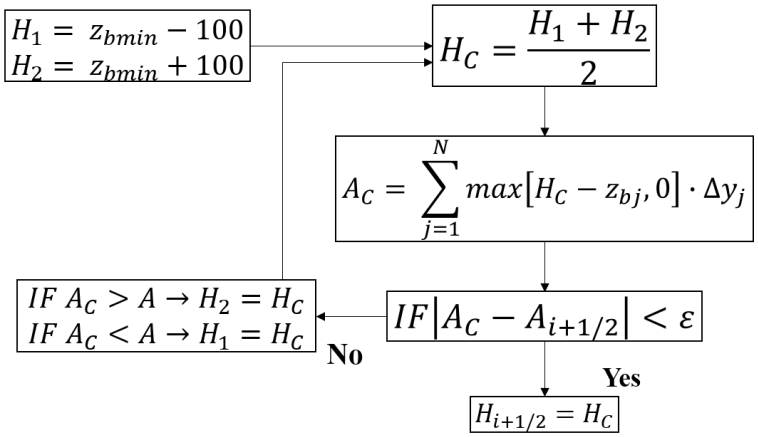

図-4.2　　H_iの更新の模式図

4.2.3　河川水位予測におけるデータ同化手法

河川水位予測のデータ同化は，物理モデル（流出‐河道流の結合など）がもつ初期条件・境界条件・粗度等のパラメータ（状態）における不確実性を，逐次または一定期間ごとの観測情報（水位・流量・雨量など）により補正し，モデルの予測精度を向上させる枠組みである．現在の日本におけるリアルタイム洪水予測システムでは，非線形モデルや非ガウス分布にも適用が可能で，実装も比較的容易である粒子フィルタ（Particle Filter：PF）の適用例が多い[3–6]．

PF は逐次ベイズ推定に基づく手法であり，状態分布を多数の粒子で表し，観測情報に対する各粒子の尤度を用いた状態推定，ならびに粒子のリサンプリングにより状態分布を修正する．RRI モデルに PF を適用した事例として，中村ら[3]は，2017 年 7 月九州北部豪雨時の花月川を対象に、RRI モデルの斜面水深を状態量として粒子フィルタで水位観測値を逐次同化することにより，3 時間先までの水位予測誤差が改善されたことを報告している．また，芦川を対象とした検討では，RRI の斜面水深と河床変動量を同時推定しつつ 6 時間先までを予測し，河床変動を考慮することで長いリードタイムでも水位予測精度を維持できることを示している[4]．柿沼ら[5]は，急激な水位上昇が起こりやすい中小河川を対象として粒子フィルタにより観測水位を RRI モデルへ同化する検証を複数河川で行い，中小河川の予測リードタイムの延伸を検討している．

アンサンブルカルマンフィルタ（EnKF）は，カルマンフィルタを非線形・大規模モデルへ拡張した確率的同化手法であり，状態の確率分布をモデルのサンプル集合（アンサンブルメンバー）で近似する点は粒子フィルタと同様である．ただし EnKF における状態更新はカルマンフィルタと同様に平均と共分散を用いた線形ガウス近似に基づくため，非ガウス性が強い状態分布には不向きな一方で，アンサンブルメンバー数は相対的に少なく済むことから計算コストに利点があり，大規模系でも扱いやすい．藤村ら[7]は RRI への適用において，降雨入力への摂動付加などにより，観測点・非観測点ともに水位予測精度を改善できることを報告している．また，Lingzhong ら[8]は 1 次元不定流式に対して流れの擾乱（境界条件誤差など）と水位を同時に推定する joint EnKF を提案しており，擾乱の不確実性を取り込むことで水位予測の頑健性が向上することを示している．Chen ら[9]は，1 次元不定流式を基礎とする河道網水理モデルに EnKF を組み込み、分岐を含む河川ネットワークの水位シミュレーションにおける水位予測誤差の低減を図っている．

アジョイント法（変分データ同化；4DVar）は，観測値に対する計算誤差等で定義されたコスト関数の最小化を通して，同化対象（初期条件・境界条件・パラメータ）の最適化を行う手法である．コスト関数の最小化には勾配法を用いるが，アジョイント法では変分法より導出されるアジョイント方程式により，同化対象の修正勾配が効率的に計算可能であることが基礎となっている．逐次型データ同化手法に分類される粒子フィルタやアンサンブルカルマンフィルタと異なり，時間的に一貫した合理的な推定値が得られる点が強みである．吉田ら[10,11]は，一次元不定流モデルを対象にマニング粗度係数の時系列変化をアジョイント法で逆推定し，観測情報の違いが推定精度に及ぼす影響を双子実験で系統的に評価している．西口ら[12]は，同様の一次元不定流モデルを対象としたアジョイント法により，境界流量の推定や流下能力を最大化する最適河道形状の推定に対する有効性を示している．分布型流出モデルへの適用に対しては，入江ら[13]が河道粗度を含む多種別パラメータの同時最適化に対する検証結果を報告している．

その他の手法として，運動方程式に追加した付加項を介してデータ同化を行う力学的内外挿法も提案

されているが[14, 15]，現時点では報告事例が少なく，今後の動向が注目される．

これら既往のデータ同化手法に関して，逐次型データ同化手法である粒子フィルタや EnKF は，逐次同化のため推定パラメータの時間変動が一貫せず，物理的に解釈しづらい結果となりやすい課題がある．また，妥当な状態分布評価のためには粒子数やアンサンブルメンバーを多く確保する必要があり，逐次同化過程で分布が適切に表現できなくなる粒子縮退や Filter Divergence といった特有の問題が知られている．これに関連して，例えば粒子フィルタでは粒子数が 50 程度以上に設定されることが多いが[16]，多地点水位データ同化を行う場合には計算負荷が問題となる．特に現在の国土交通省の標準手法では，粒子フィルタを用いて同化対象地点ごとに上流側から計算区間を一部重複させながら順次データ同化を行うカスケード同化方式であるため[17]，今後想定される観測用センサ機器の拡充により同化対象地点が増加した際には，計算負荷がそれに比例して増大する課題がある．

一方，非逐次型データ同化手法であるアジョイント法は，同化期間内で一貫した合理的な推定値が得られる利点があるが，アジョイントコード実装の労力が大きいため，プログラム改修等の保守コストが大きくなる課題がある．また，順解析と推定値の修正を繰り返す収束計算の特性上，粒子フィルタのように単純な並列計算による高速化が困難であり，リアルタイム予測に向けた高速化には工夫が必要となる．この他，非線形性の強いモデル計算時や目的関数が複雑な場合，複数のパラメータセットで同じ観測結果を再現できる非同定性がある場合などには，アジョイント法の勾配が局所最適解に陥りやすく，推定結果が不安定になりやすい課題がある．

本研究では，これら既存のデータ同化手法の課題を解決しうる新たなデータ同化手法として，近年提案された支配方程式の情報を考慮可能な深層学習モデルである PINNs (Physics-Informed Neural Networks)の一次元不定流解析への適用について検討した．PINNs は従来の深層学習モデルと異なり，支配方程式に基づいて初期条件と境界条件のみから推論が可能であり，データ同化においては，同化対象データを柔軟かつ簡便に設定できる，同化対象地点数による計算量への影響が小さい，境界条件の事前学習により大幅な高速化が期待できる，等の利点を有する有望な手法である．以降では，PINNs による河道モデルの定式化とデータ同化・逆解析の問題設定について詳述する．

4.3 PINNs を用いた河道モデルの定式化

4.3.1 PINNs の概要

PINNs (Physics-Informed Neural Networks)は，物理法則（主に偏微分方程式 Partial Differential Equation: PDE／常微分方程式 Ordinary Differential Equation: ODE）をニューラルネットワークの学習過程に直接組み込むことで，データ駆動型手法と物理モデル型手法の両立を目指した手法である[18–20]．従来の深層学習モデルで一般的な教師あり学習では，モデル出力値と真値の残差（L_{data}）を最小化するようにモデルの最適化が行われるが，PINNs ではこの残差損失に加えて，計算対象の時空間領域内で選択された点における支配方程式の誤差（L_{PDE}），初期条件に対する誤差（L_{IC}），および境界条件に対する誤差（L_{BC}）といった物理的制約が損失関数に追加項として組み込まれる．PINNs における損失関数の形式は下記となる．

$$L_{\mathrm{total}} = w_{\mathrm{data}}L_{\mathrm{data}} + w_{\mathrm{PDE}}L_{\mathrm{PDE}} + w_{\mathrm{IC}}L_{\mathrm{IC}} + w_{\mathrm{BC}}L_{\mathrm{BC}} \tag{4.29}$$

ここで，L_{data} は観測値との二乗誤差等で表され，L_{PDE}は対象式を$f(x,t)=0$として，$L_{\mathrm{PDE}}=\frac{1}{N}\sum|f(x_i,t_i)|^2$ 等で表される．Nはサンプリング点数である．L_{IC}とL_{BC}は設定条件に応じて，このいずれかの形式で表現される．wは各項の重み係数である．これらの追加された物理制約はソフト制約として機能し，ニューラルネットワークがこれらの条件を満たすように「観測データ誤差＋物理法則誤差」を同時に最小化する．このため，PINNs では学習データ（観測データ）が存在しない場合にも，物理モデルと同様に初期条件と境界条件のみから求解（順解析）することが可能である．

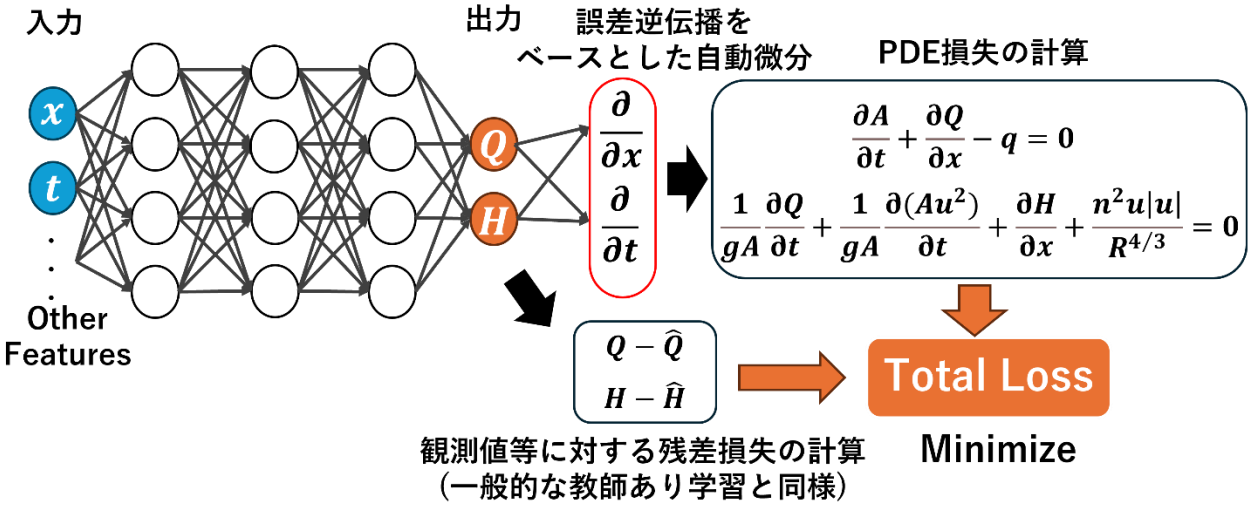

図-4.3　　PINNs の概要

PINNs では誤差逆伝播法を基礎とした深層学習フレームワークの自動微分機能（Automatic Differentiation: AD）により，支配方程式の偏微分項を効率的に計算可能であることを活用している．このため，PINNs ではモデルの入力に偏微分を行う変数を含む必要があり，出力には偏微分対象の変数を含む必要がある．すなわち，ネットワークは入力として時空間座標 x,tとその他の付加情報を受け取り，状態変数 $u(x,t)$を出力するように構成される（図-4.3）．

PINNs は，従来の数値シミュレーション手法やデータ駆動型機械学習モデルと比較して，次に示す利点が存在する．

a) 順問題および逆問題への統一的アプローチ

PINNs は，順問題（既知の物理法則と初期・境界条件から挙動を予測）と逆問題（観測データから未知の物理パラメータや支配方程式を推定）の両方を，同じ最適化フレームワーク内で実行可能である．従来の数値ソルバーでは，逆問題の解決は前述のデータ同化手法の実装等が別途必要となり，順解析プログラムの改変時には逆解析プログラムをそれに合わせて修正した上でパラメータ調整が必要となるなど，両者の互換性を常に考慮する必要が生じる．PINNs では両者を統一的に扱えるため，プログラム拡張や保守改修コストを低く抑えることができ，逆解析や最適制御といった問題への応用が容易である．

b) 物理的一貫性と汎化性能の向上

物理法則を学習プロセスに直接組み込むことにより，PINNs では既知の物理法則を満足するような解を再現するように学習が進む．これによる PINNs の大きな利点として，観測データが少ない場合や学習データセットの範囲外のデータに対しても，物理方程式による制約を通じて解の整合性を保ちやすい点

が挙げられる．従来のデータ駆動型モデルでは，データが少ないケースでは過学習の問題が顕著となりやすく，学習データセット範囲外のデータに対するモデル挙動は不透明であったが，PINNs ではこれらの条件下でも物理的に一貫性のある妥当な解を学習可能である．

c) 物理法則と観測データ間の柔軟なバランス調整

PINNs が物理法則を損失関数内の「ソフト制約」として扱う設計は，既知の物理法則に対する整合性と，現実世界の観測データに存在するノイズや不完全性との間で，柔軟なバランス調整を可能にしている．従来の数値手法が物理法則を「ハード制約」として厳密に適用し，モデルが物理法則を完全に満たすことを前提とするのに対し，PINNs は学習プロセスにおいて物理法則からのずれや観測データからのずれを許容しつつ，両者の整合性を両立しようと努める．水文モデルや河道水理モデルにおいては，地形情報や初期条件等を定めるための観測データが時空間的に充足していることは稀であり，物理法則も特定条件下での近似式や経験式となるため，設定した物理式を完全に満たすことが必ずしも現実を反映しているとは限らない．一方で観測データも，特にリアルタイム運用においてはノイズや異常値等の誤差が避けられないことから，どちらかに過度に依存することなく，両者を両立する妥当な解を探索できる柔軟性は，PINNs の利点の 1 つである．

d) メッシュフリー特性と複雑な形状への対応

従来の数値手法では，計算ドメインを離散的なメッシュに分割することを必要とし，複雑な形状や高次元の問題ではメッシュ生成が困難かつ工夫を要するプロセスとなる．PINNs はメッシュ生成の代わりに空間-時間座標を入力としてニューラルネットワークに直接与えるため，複雑な幾何学的形状や高次元の問題を柔軟に扱うことができる．これにより，特に高次元問題においては計算負荷が削減される可能性が指摘されている [20]．

一方で課題点として，実用面では学習の不安定性と収束の困難さが知られており，特に非線形性の強い方程式や高次元 PDE では損失 landscape が複雑になり，勾配が消失・爆発して最適化が進まない Failure modes が起こりやすい [21, 22]．また，PDE 由来の残差項はスケールが観測データとは異なるため，損失の重み付け（loss balancing）が難しい点も指摘されており [23]，PINNs の最適化アルゴリズム改善や理論的収束保証が最新研究の焦点となっている．

4.3.2 一次元不定流式に対する PINNs の定式化

一次元不定流解析における支配方程式（Saint-Venant Equations）は，式（4.1），式（4.2）の連続式と運動方程式より構成される．掃流力として式（4.3）を採用し，簡単のため横流入箇所における流入速度と主流速度は等しいと仮定すると，対象となる基礎方程式は下記のように書き直せる．

$$\frac{\partial A}{\partial t}+\frac{\partial Q}{\partial x}-q_l=0 \tag{4.30}$$

$$\frac{1}{gA}\frac{\partial Q}{\partial t}+\frac{1}{gA}\frac{\partial (Au^2)}{\partial x}+\frac{\partial H}{\partial x}+\frac{n^2u|u|}{R^{3/4}}=0 \tag{4.31}$$

ここで，A: 河積，Q: 流量，u: 流速，H: 水位，R: 径深，n: マニングの粗度係数，g: 重力加速度，q_l: 単位長さあたりの横流入量である．

既往研究[24–26]では，より簡略化した条件設定である $q_l = 0$，$A = Bh$（B：川幅 ※定数，h：水深）を前提とした横流入の無い矩形断面を対象とした検討がなされている．この条件下では，式(4.30)，式(4.31)は下記のように簡略化される．

$$\frac{\partial h}{\partial t} + \frac{\partial (uh)}{\partial x} = 0 \tag{4.32}$$

$$\frac{\partial u}{\partial t} + u\frac{\partial u}{\partial x} + g\frac{\partial (h + z_b)}{\partial x} + g\frac{n^2 u|u|}{R^{3/4}} = 0 \tag{4.33}$$

$$R = \frac{Bh}{(2h + B)} \tag{4.34}$$

ここで，z_b: 河床高であり，$H = h + z_b$である．簡略化した条件下においては，偏微分対象変数が $u,\ h$ のみであり，河床高の定義も明瞭であるため，既往研究[24–26]では $u,\ h$ を PINNs の出力対象とした検討がなされている．本検討では実用化に向けて，より一般的な条件式である式（4.30），式（4.31）に対して PDE 残差損失を定義する．この場合，互いに換算関係が存在するA, Q, H, u, h が PINNs 出力変数の候補となるが，以下では Q, H を出力変数とする．この点に関しては後の 4.4 項で詳述する．

PINNs 最適化対象の損失関数は下記のように書ける．

$$J(\theta) = w_f J_f(\theta) + \sum_j w_j J_j(\theta) \tag{4.35}$$

ここで，θは Deep Neural Network（DNN） のパラメータベクトル，$J(\theta)$は総損失，$J_f(\theta)$はサンプリング対象点で算出した PDE 残差損失，右辺第二項の添え字jは初期条件に対する損失($J_{INIT}(\theta)$)，境界条件に対する損失($J_{BC}(\theta)$)，観測値に対する損失($J_{OBS}(\theta)$)を表す．w_f, w_j は各損失項の重み係数であり，各項を無次元化する次元を持つ．

一般的な条件式である式（4.30），(4.31)の残差r_f^a, r_f^bと，その重み係数w_f^a, w_f^bにより，式（4.35）の PDE 損失項（右辺第 1 項）は式（4.36）で定義される．x^i, t^iは PDE 損失を計算するサンプリング点を，N_fはサンプリング点数を表す．

$$w_f J_f(\theta) = \frac{1}{N_f}\sum_{i=1}^{N_f}\sum_{\alpha \in \{a,b\}} w_f^\alpha \left| r_f^\alpha\left(x^i, t^i, \theta\right)\right|^2 \tag{4.36}$$

本検討では，初期条件/境界条件/観測値に対する損失は，いずれも式（4.37）の平均二乗誤差により定義した．このため，境界条件はディリクレ条件を指定していることになるが，PINNs ではノイマン条件による境界設定も可能である．ϕは流量 or 水位であり，$\hat{\phi}$が DNN 出力値，ϕが真値，N_jはサンプリング点数であり，初期条件は有限差分法と同様に，初期時刻の境界条件を元にした不等流計算や助走計算から与えられる．

$$J_j(\theta) = \frac{1}{N_j}\sum_{i=1}^{N_j}\left| \hat{\phi}_j\left(x^i, t^i, \theta\right) - \phi_j\left(x^i, t^i\right)\right|^2 \tag{4.37}$$

PINNs による一次元不定流解析の計算設定例を図-4.4 に示す. 本手法は上述の損失関数により, 式(4.38)の関数fを近似する DNN の最適パラメータベクトルθ を求める問題として定式化される.

$$(Q(x,t),H(x,t)) = f(x,t,\theta) \tag{4.38}$$

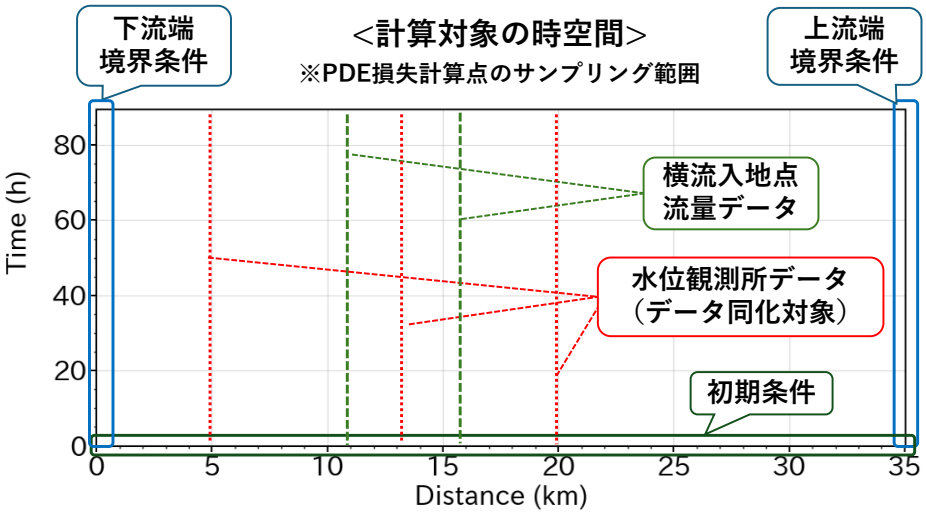

図-4.4　　PINNs による 1 次元不定流計算設定

θには DNN を構成する重みパラメータの他，粗度係数等の同化対象パラメータも含まれる．同化対象パラメータを定数として与えた場合は順解析，変数として最適化対象に含めた場合は順解析と逆解析（データ同化推定）を並行して行う問題設定となる．

データ同化に関して，PINNs はアジョイント法（変分法）に近い性質を有するが，PINNs では同化対象パラメータのみでなく，流量や水位を近似出力する DNN 自体の最適化も並行して行われるため，通常のアジョイント法が支配方程式を完全に満たす強拘束条件（ハード制約）で適用されることが多い（ただし，弱拘束条件によるアジョイント法も存在する）のに対し，観測誤差等との兼ね合いで支配方程式の誤差を許容する弱拘束条件（ソフト制約）のデータ同化手法となる．また，式（4.35）が示す通り，PINNs のデータ同化においては同化対象データの残差項($J_{OBS}(\theta)$)を損失関数に加えるのみで良く，同化対象の設定変更は非常に簡便である．

なお，本論文では，観測データの追加入力により，縦断水位や粗度係数パラメータといった状態量推定値の改善・逆推定を行う問題設定を PINNs によるデータ同化と表現しており，PINNs に関する研究論文ではこのような問題設定をデータ同化と表現することが一般的である．ただし，PINNs では損失関数の中で支配方程式の残差損失と観測値の残差損失が対等に扱われるため，従来のデータ同化手法(EnKF やアジョイント法など)のように，システムモデルと観測モデルで定義される状態空間モデルに対して，観測データを同化する，というアプローチとは異なる手法である点には留意が必要である．

4.3.3 本問題設定に関連した既往研究と課題点

河川流や洪水解析の分野において，PINNs は特に観測データが限られた状況や複雑な地形条件下における新たな解析アプローチとして近年注目を集めているが，現時点での先行研究の多くは仮想データを用いた扱いやすい条件下における浅水流方程式等を対象としており，実際の流域や河川を対象とした地形条件等へ適用した報告は多くない．

本検討と関連の深い 2 次元浅水流方程式への適用に関しては，阿部らが洪水時の外水氾濫再現を対象として，実地形条件で 2 次元浅水流方程式に PINNs を適用している[27]．この研究では，複雑地形を扱うために Positional Encoding を導入しており，複雑地形においても良好な浸水状況の再現が可能であることや，最長 2 日かかっていた従来計算を数分にまで短縮可能であることを示している．Yongfu ら[28]は地形起伏と降雨条件を反映した 2 次元浅水流方程式において，変数型と保存型の浅水流方程式を比較し，結果として両者のハイブリッド構成が最も PINNs モデル精度を向上させたことを報告している．Qi ら[29]は 2 次元浅水流方程式に適用する PINNs 構成として全結合型ニューラルネットワークと畳み込みニューラルネットワークの比較を行っている．実際の河川流域への適用結果として，いずれのネットワーク構成でも有限体積法と同等の計算精度を実現可能であることが確認され，計算時間と計算精度のトレードオフを考慮した場合には畳み込みニューラルネットワークの方が優位であることを示している．大原ら[30]は，2 次元浅水流方程式への PINNs 適用により，交互砂州上の流れに対する PINNs の適用性を評価しており，PINNs による推定値が数値計算の結果と高波数を除き一致したことを報告している．

本検討の主題となる実河川を対象とした一次元不定流解析（Saint-Venant Equations: SVE）への適用についても，現時点での報告事例は限られる．Feng ら[24]は、大規模河川モデルのサブグリッド・ダウンスケーリングを目的として 1 次元 SVE へ PINNs を適用し，少数の観測データから河川の縦断的な水深分布を高精度に推定可能であったことを報告している．木村ら[25]は 1 次元 SVE へ PINNs を適用する同様の問題設定において，低平農地の直線排水路を対象とした検証により，従来の教師あり学習による DNN と比較して，学習データの無い区間での PINNs 予測の優位性を示す一方で，急激な時間変化を伴うケースでは予測精度が劣化することを示した．Mahesh ら[26]は，SVE 損失を組み込んだ PINN モデルに河床勾配と粗度係数も入力変数として加える条件設定で合成洪水データによる学習・評価を行い，従来の DNN よりも水深の予測精度が向上したことを報告している．

しかしながら，これらの 1 次元 SVE への PINNs 適用に対する先行事例はいずれも水深と河積が線形関係となる矩形断面かつ横流入が存在しない簡易的な条件に対する検証に留まっており，実務利用に際しては一般断面への適用に向けた手法拡張が必須である．また，応用として重要である粗度係数等を対象としたデータ同化・逆解析に関する適用報告は存在せず，様々なデータ同化ケースにおける検証事例の蓄積が待たれる．

以上の先行研究状況を踏まえ，本検討では一般的な計算条件である横流入を含む一般河道断面の一次元不定流解析へ PINNs を適用可能なように計算手法を拡張するとともに，安定して正しい解へ収束させる方法を検討した．また，実河川を対象とした多地点水位データ同化に関して，粗度係数を同化対象としたケーススタディを行い，本手法のデータ同化に対する有効性を検証した．

4.4　一般的な河道条件での順解析に関する開発と検証

4.4.1　計算手法の開発と改良

横流入を含む一般河道断面の一次元不定流解析へ PINNs を適用可能とするため，計算手法の拡張開発を行った．また前述の通り，PINNs では問題設定によっては学習過程で誤った解に収束しやすい課題（Failure Modes; 図-4.5 の上段は 1 次元移流方程式の求解に際して，初期条件が時間方向(横軸方向)に正しく伝播していかない例，下段は 1 次元反応拡散方程式の求解に完全に失敗している例を示している）が知られており [22]，本問題設定においてもシンプルな適用では正しい解に安定して収束しないことが判明したため，計算手法の改良を実施した．実施した開発・改良項目は以下の 5 点である．

(1)　一般河道断面への PINNs 適用に向けた計算手法の拡張開発
(2)　横流入ケースの適用へ向けた適切な PINNs 計算設定の検討
(3)　収束性改善に向けた PINNs 初期化過程の導入
(4)　収束性改善に向けた Stan 活性化関数の適用
(5)　高周波モードの再現性向上に向けた入力変数へのフーリエ特徴埋め込みの適用

以下ではそれぞれの開発・改良点に関する詳細を示す．また，シンプルな適用での収束が難しい様子と改良効果の具体的な比較は，次項の順解析における比較検証において示す．

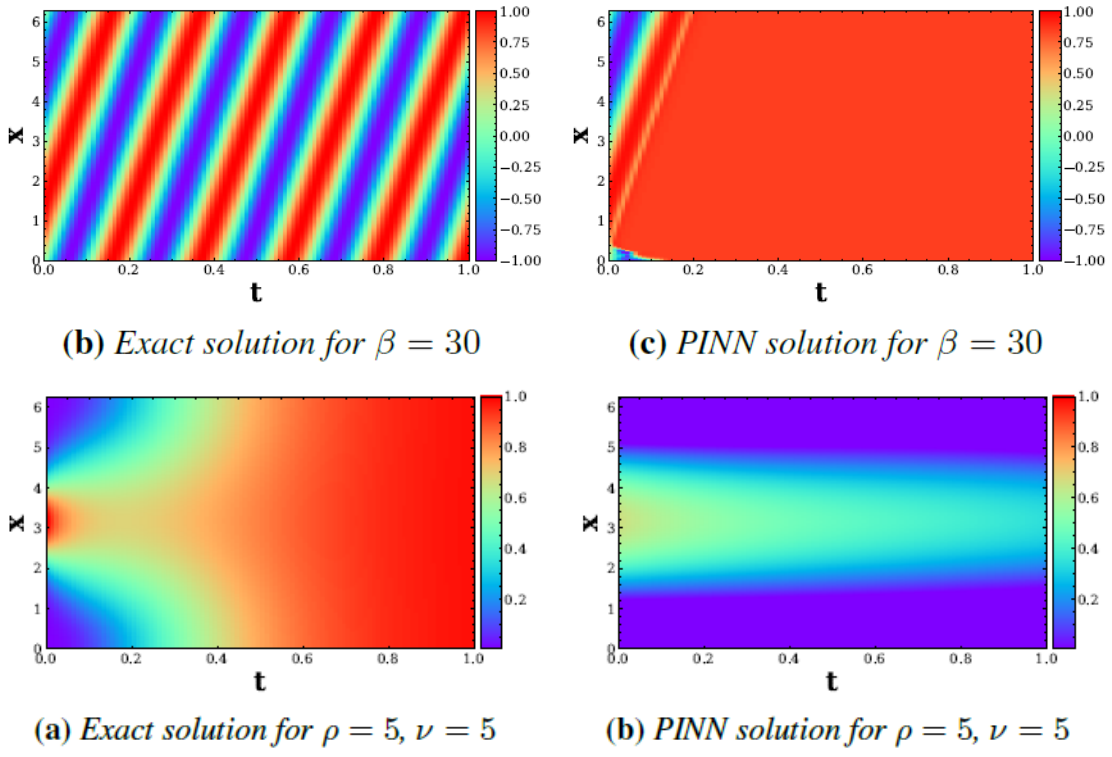

図-4.5　　PINNs 学習における Failure Mode の例（出典：文献 [22]）

(1) 一般河道断面への適用に向けた計算手法の拡張

一般河道断面を想定して式（4.30），式（4.31）に対して PDE 残差損失を定義する場合，互いに換算関係が存在するA, Q, H, h, u が PINNs 出力変数の候補となる．PINNs ではこれらすべてを出力変数として構成することも可能であるが，連続式と運動方程式を連立して解いていること，各変数の換算関係を厳密に満足させることを考えると，PINNs の出力変数は 2 つとするのが自然である．矩形断面を対象とした先行研究[24–26]では，川幅をB として河積Aは，$A = Bh$ の比例関係で表現でき，水位Hは水深hと，各河床断面に対して明瞭に定義できる河床高z_bにより $H = h + z_b$と表現できるため，式（4.32），式（4.33）の表式から最も自然な流速uと水深hが PINNs の出力対象に設定されている．また，2 次元浅水流式への PINNs 適用においても，多くがこの 2 変数の組み合わせとなっている．

しかし，一般河道断面においては図-4.1 のように河床高は一定でなく，低水敷と高水敷の境界の決め方によって平均河床高は変動する．また，日本国内の実務における河道断面データの測量ピッチは 100m～200m 程度であることが多く，隣接する河道断面形状が非連続的となるケースも少なくない．これらのことから，断面平均流速uと水深hは河道断面ごとに大きく変動しうるが，PINNs（DNN）では偏微分方程式の空間微分を自動微分により計算するため，出力対象とする変数の解は，空間的に連続的で滑らかな分布であることが望ましい．実際，事前試行において断面平均流速uと水深hを出力対象とした構成では学習がうまく収束しないことを確認した．このため，出力変数には一般河道断面においても解が空間的に連続的で滑らかな振る舞いとなることが期待される流量 Q と水位 H を採用した．この場合，河積Aは$A = g(H)$と河道断面ごとに水位の関数として求められ，断面平均流速uは，$u = Q/A$より求めることができる．また，式（4.31）より，PDE 損失計算では水深hと河床高z_bを個別に求める必要は無いため，上述の河床高の定義が難しい問題も回避することができる．

河積Aは河道断面ごとに$A(t) = g(H(t))$と表現できるため，時間に対する偏微分は微分の連鎖率を用いて，次のように水位 H の偏微分により計算可能である．

$$\frac{\partial A}{\partial t} = \frac{\partial A}{\partial H}\frac{\partial H}{\partial t} \tag{4.39}$$

深層学習フレームワークによる自動微分と誤差逆伝搬による勾配計算を阻害しないよう，$A = g(H)$の換算関係は河道断面ごとに数値的に事前計算してテーブルとして保持し，$g(H)$はこの換算テーブルを用いたHに対する内挿補間により算出した．これを用いて，$\partial A/\partial H$ は次の 4 次精度中心差分式により評価することとした．本検討では水位の差分幅 Δh は 10cm とした．

$$\frac{\partial A}{\partial H} = \frac{-g(H + 2\Delta h) + 8g(H + \Delta h) - 8g(H - \Delta h) + g(H - 2\Delta h)}{12\Delta h} \tag{4.40}$$

次に$\partial A/\partial x$の計算では，連鎖率を適用するためには $A(H(x))$ のx依存性を考慮する必要が生じる．これにより，$\partial A/\partial H$の計算は隣接河道断面の内挿計算等を含むことになるが，前述の通り隣接河道断面は非連続的となることも多く，収束計算が安定しないことが分かった．このため，$\partial A/\partial x$は単に隣接断面で換算テーブルから算出したAの空間風上差分により評価することとし，空間差分幅Δx は隣接断面間隔とした．地点xにおける$g(H)$を$g_x(H)$と表記すると，次式のようになる．

$$\frac{\partial A}{\partial x} = \frac{g_{_}x(H) - g_{_}(x-\Delta x)(H)}{\Delta x} \tag{4.41}$$

河道断面データが存在しない区間に対する PDE 残差の計算時は，隣接河道断面データを用いた空間内挿により評価を行った．

(2) 横流入に対する適切な PINNs 計算設定の検討

式（4.30）の横流入q_lに関して，単純に PDE 損失のサンプリング間隔を全区間で一様に設定して適用した場合，流入箇所の急激な流入変化に対して流入箇所付近のサンプリング点数が少ないためか，横流入量が十分に反映されず，実際の流量よりも過小評価される傾向が見られた．これを改善するため，横流入箇所に対する損失評価点のサンプリング間隔をより密に設定することを検討した．

ケーススタディの結果，本検討では横流入箇所の前後 50m (横流入幅 100m)に対してサンプリング間隔を 1m に設定することで流量の過小評価傾向が改善されることが分かったため，これを標準設定として採用することとした．具体的な比較結果については次節の順解析検証において示す．

(3) PINNs 初期化過程の導入

PINNs の学習過程において，PDE 残差を直接最適化する標準手法では，ネットワークが初期段階で誤った局所最適状態に収束しやすく，学習結果が安定しないことが多い．これに対する有力な対処法の 1 つとして，カリキュラム学習の導入が挙げられる [31, 32]．カリキュラム学習は，容易なタスクから徐々に難易度の高いタスクへ移行させる学習方法であり，PINNs では PDE が定義される領域・時間・周波数を段階的に増加させる等によって実現される．また，損失関数における重み付けを段階的に変化させる方法もあり，PDE 残差の大きさに応じて学習の重点を変更する適応サンプリング手法も提案されている [33, 34]．

本研究では学習の安定化を図るカリキュラム学習の考え方を踏まえて，PDE 損失を学習させる前段階に，教師あり学習による PINNs の初期化過程を導入した．具体的には，境界条件である上流端流量$Q(x = 0, t)$と，これを用いて等流計算により求めた計算対象領域全体の水位の近似解 $\hat{H}(x, t)$を初期推定値とし，教師あり学習により学習させた．等流計算式は下記で表される．

$$Q = \frac{1}{n} A R^{2/3} I^{1/2} \tag{4.42}$$

ここで，n: マニングの粗度係数，A: 河積，R: 径深，I: 河床勾配である．各河道断面形状に対して，河積・径深と水位は換算可能であるため，式（4.42）を満たす $\hat{H}$ を数値的に求めて初期近似値とする．

本アプローチでは，簡便な数値解法による近似解を教師信号とすることにより，ネットワークにあらかじめ解の基本構造を学習させることが可能であるため，ネットワークは解のスケールや大域的形状といった重要な特徴を獲得した状態から，高次微分を伴う PDE 残差の最適化へ移行できる．これにより，PDE 残差学習において頻出する局所解への誤収束を防ぎ，安定した収束が実現可能と期待される．

これらの事前学習やカリキュラム学習は，PINNs が抱える非線形・多スケール・高周波性といった本質的な学習の難しさを軽減し，安定した学習プロセスを提供するための実践的な技術である．このため，対象とする問題に応じた適切な学習プロセスの確立は，実務での PINNs 活用に向けて非常に重要である．

(4) Stan 活性化関数の適用

PINNs では偏微分式に対するパラメータ勾配を求める際に 2 階以上の高階微分を計算する必要があるため，DNN の活性化関数には通常，C^{∞}級の関数である tanh 等が用いられる．しかし，tanh は勾配消失問題により深い DNN への適用が困難であり，複雑な問題へ PINNs を適用する際の課題の 1 つとなっている．この問題を解消するC^{∞}級の活性化関数として，Stan (Self-scalable tanh)が近年提案されている [35].

Stan 活性化関数は PINNs の学習効率と汎化性能を改善するために提案された活性化関数であり，従来の tanh が抱える飽和による勾配消失とスケール適応性の欠如の改善を目指している．標準の tanh は滑らかで高次微分との相性が良い一方，入力値が大きくなると飽和領域に入り勾配が急減するため，PDE 残差が適切に伝搬せず収束が著しく遅くなる．また，PINNs では解のスケールや振幅が事前に既知とは限らず，tanh の出力範囲（±1）が最適な表現を阻害するケースも存在する．Stan 活性化関数は，これらの問題を解消するために tanh に自己スケーリング項を付加し，さらに学習可能なパラメータを導入することで入力スケールへの柔軟な適応性を持たせている．Stan の表式は式(4.43)の通りであり，右辺第二項が自己スケーリング機構として機能する（図-4.6）.

$$\sigma(x) = \tanh(x) + \beta x \tanh(x) \tag{4.43}$$

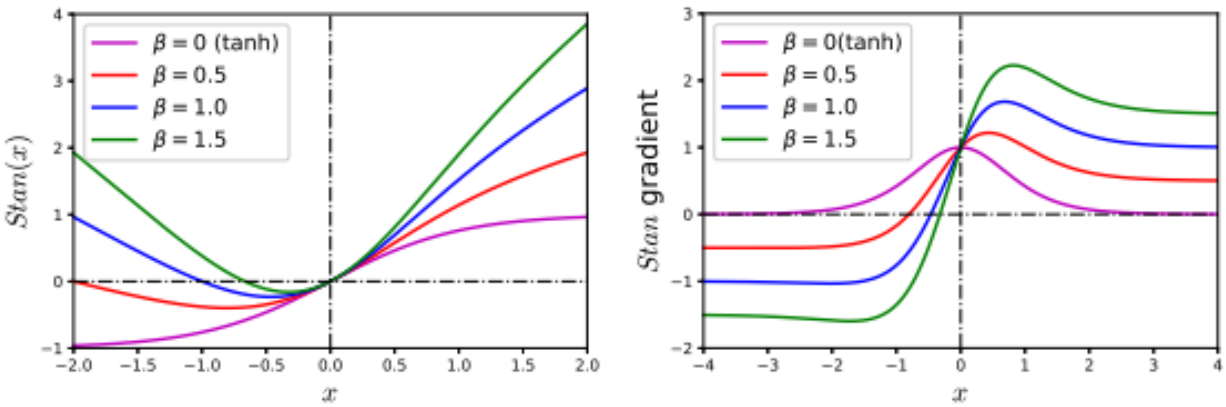

(a) Stan activation function　　(b) Stan activation function gradient

図-4.6　　Stan 活性化関数の関数形（出典：文献 [35]）

ここで βはユニットセル毎あるいは層毎に導入される学習可能なパラメータであり，これがゼロであれば Stan は通常の tanh に一致する．提案論文では Stan が非飽和性（non-saturating）を持つことが理論的に示されており，入力値が大きな値を取る場合でも勾配が消失しにくいという利点を主張している．さらに、滑らかな関数形と高次微分の扱いやすさは tanh と同様に保たれるため，PINNs の自動微分による PDE 残差計算との整合性も確保される．

本検討でも標準的な tanh の適用では学習収束が安定しないことを確認したため，Stan 活性化関数の適用により収束性能の改善を試みた．βは一般化の上では対象層と対象ユニットセルに応じた最適化対象パラメータ(0.25～1.5 程度)とされているが，本検討では簡単のため，$\beta = 1.0$を用いた．

(5) 入力変数へのフーリエ特徴埋め込みの適用

PINNs（Physics-Informed Neural Networks）における入力変数の特徴埋め込みとは，空間座標や時刻といった低次元の入力に対して，多様な周波数成分をもつ三角関数を適用することで高次元の特徴空間へ写像する手法であり，Fourier feature embedding あるいは Positional encoding として知られている．全結合型 DNN はスペクトルバイアスと呼ばれる特性を有し，高周波成分よりも低周波成分を優先的に学習する傾向がある．PINNs が対象とする偏微分方程式の解には，境界層の急峻な変化や波動の細かな振動といった多くの高周波構造が含まれることが普通であるため，この特性は学習の遅延や精度不足を引き起こしやすく，入力位置の特徴埋め込みはこの問題を緩和するために導入される．

先行研究 [24, 27]でも言及されている通り，本検討においても入力となる時空間位置情報の x, t を直接 DNN への入力とした場合には，低周波モードの学習が優先されて水位波形が時間的に鈍る傾向が確認された．このため，水位波形における高周波モードの学習が適切に進むように，入力位置のフーリエ特徴埋め込み（Positional Encoding：式(4.44)，(4.45) [27]）を適用した．

$$PE(pos, 2i) = \sin(\alpha * \frac{pos}{10000^{2i/N}}) \tag{4.44}$$

$$PE(pos, 2i+1) = \cos(\alpha * \frac{pos}{10000^{2i/N}}) \tag{4.45}$$

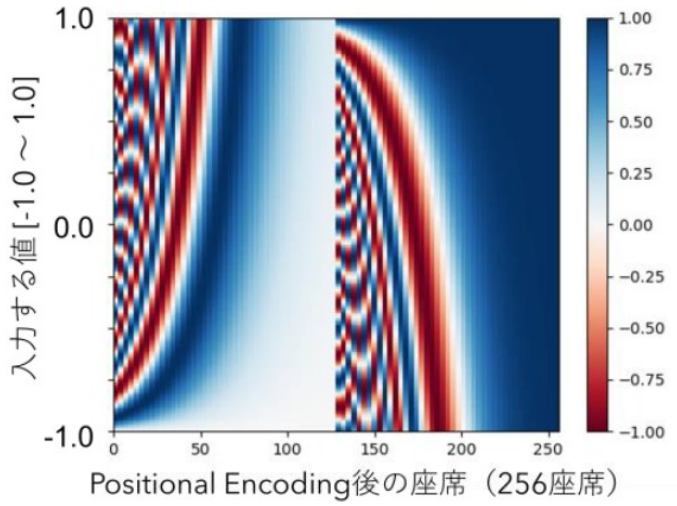

図-4.7　　入力位置変数の特徴埋め込み例（出典：文献 [27]）

posは x or tを表し，埋め込み後の特徴量次元が$N(i = 1, 2, \ldots, N)$，αは定数パラメータである．試行の結果，本研究における以降の検討では，$\alpha = 100.0$，$N = 256$ を採用した．

このような非線形かつ多周波数への変換により，元のスカラー情報は相対関係を保持した多様な表現空間へと展開される（図-4.7）．これにより，DNN は単純な重み学習によっても高周波の挙動を捉えやすくなり，PDE 残差の計算に必要な高次微分がより精度よく学習される．また，異なる周波数が解の異なるスケール構造を担当することが可能となるため，多スケール性を有する問題にも有効に作用すると期待される．

4.4.2　実河川の既往出水データを用いた適用検証

(1)　対象流域と計算条件

実河川における適用性を検証するため，兵庫県加古川の既往 2 出水（H29 年 10 月 21 日 0 時～10 月 25 日 0 時，H30 年 7 月 5 日 0 時～7 月 10 日 0 時）を対象として以降の検証を実施した（図-4.8，図-4.9）．加古川は兵庫県の南西に位置し，幹川流路延長 96 km，流域面積 1730 km^2 の一級河川である．

対象河川に対する主な計算条件を表-4.1 に示す．計算対象区間は 1.4k～36.4k までの 35km 区間であり，上流端流量を板波（37.6k）の観測流量，下流端水位を藍屋（1.4k）の観測水位で与える設定とした．また，この区間内には，東条川（25.4k），万願寺川（21.4k），美嚢川（15.8k）の 3 か所に横流入が存在するため，流入箇所付近の観測所における観測流量を横流入量として与えた．本区間内の水位観測所は，大門(27.8k)，大島（20.0k），国包（14.2k）の 3 地点であり，これらの地点における観測水位を再現精度評価の対象とした．いずれの観測値も計測時間間隔は 1 時間である．縦断方向の河道断面データ間隔は概ね 200m であり，計算対象区間内に存在する 176 個の河道断面を入力情報として利用した．粗度係数は既往検討 [36]の値を推定真値として採用した．粗度係数の設定区画は 6 区画存在し，上流から下流にかけて粗度係数の値が徐々に小さくなる設定となっている．

出水時の水位波形を見ると，H29 出水は一山形状の比較的シンプルな水位波形である一方，H30 出水は二山かつ微小な変動を有する複雑な水位波形となっている．また加古川の 0.0k～3.85k は感潮域であるため，下流端水位として設定する藍屋（1.4k）のみ，潮位変動に起因した水位変動が確認できる．



図-4.8　　検証対象の加古川流域

表-4.1　共通の計算条件設定

項目	設定値
対象区間	1.4k－36.4k (35km 区間)
河道断面設定幅	約 200m (計：176 断面)
境界条件	上流端：板波観測流量 下流端：藍屋観測水位
横流入条件	東条川（25.4k）：古川第二観測流量 万願寺川（21.4k）：万願寺観測流量 美嚢川（15.8k）：別所橋観測流量
粗度係数	(Section.1)　30.0k ~ 36.4k：0.040 (Section.2)　21.8k ~ 30.0k：0.039 (Section.3)　16.0k ~ 21.8k：0.035 (Section.4)　9.0k ~ 16.0k：0.030 (Section.5)　2.0k ~ 9.0k：0.029 (Section.6)　1.4k ~ 2.0k：0.028

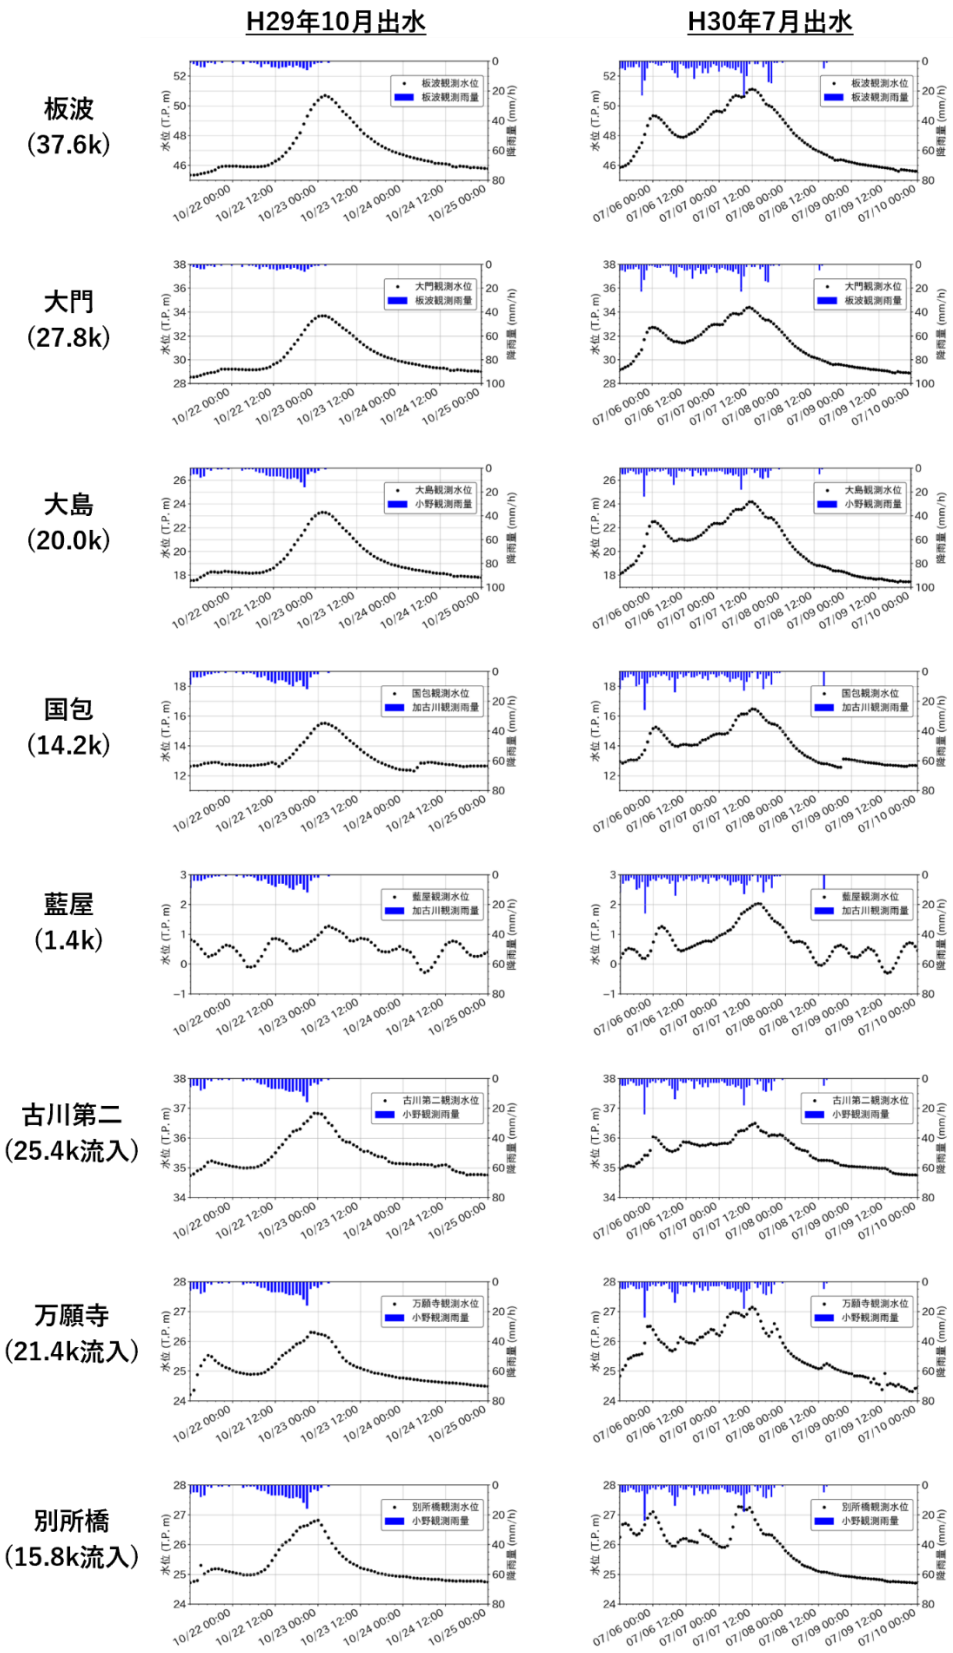

図-4.9　　各観測地点における観測水位
（降雨は最寄りの地上観測地点における観測値）

(2) 検証設定

PINNs による順解析結果の妥当性を確認するため，4.2.2 に示した一般的な有限差分法による不定流解析との比較を行った． PINNs の学習設定を表-4.2 に示す．各損失項の重み係数は，各損失項が同程度のオーダーとなるよう事前試行により設定した．また，前節で述べた各手法改良の効果を確認するため，各改良を適用しないケースとの比較を実施した．比較検証ケースの一覧を表-4.3 に示す．Case1 が全ての改良を適用したケースであり，Case2～Case5 は，いずれかの改良を適用しないケースである．

精度評価では同解析条件の有限差分法による計算水位波形の再現を目安とし，計算対象区間内の観測所（3 地点）の観測水位に対する RMSE（Root Mean Squared Error：二乗平均平方根誤差）を評価した．

表-4.2 PINNs 学習設定

項目	設定値
PDE 損失計算点のサンプリング間隔	空間 (x軸)：100m 間隔 時間 (t軸)： 10 分間隔
初期条件・境界条件のサンプリング間隔	同上 (※境界条件は上下流端，初期条件は$t = 0$のみ)
横流入箇所の PDE 損失計算サンプリング間隔	空間 (x軸)： 1m 間隔 (※流入地点前後 50m 範囲) 時間 (t軸)：10 分間隔
各損失項の重み係数	w_f^a：1×10^4，w_f^b：1×10^{-1} (w_jは下記で共通) 残差算出の対象が流量(m^3/s)の項：1×10^{-3} 残差算出の対象が水位(m)の項：1×10^2
DNN 構成	全結合型 (1024 セル ×4 層)
Optimizer	Adam

表-4.3 比較検証ケースの一覧

計算ケース	説明
有限差分法	4.2.2 に示した差分法による計算（※比較用）
PINNs-Case1	4.4.1 に示したすべての改良を適用したケース
PINNs-Case2	初期化学習過程を非適用
PINNs-Case3	横流入サンプリング間隔：100m （※横流入箇所を密にサンプリングしない設定）
PINNs-Case4	入力変数へのフーリエ特徴埋込を非適用
PINNs-Case5	Stan 活性化関数を非適用 ※tanh 適用

(3) 検証結果

各ケースの観測水位に対する RMSE 比較結果を表-4.4 に，有限差分法と Case1 の比較結果を図-4.10 と図-4.11 に，各改良を適用しないケースとの比較結果を図-4.12 と図-4.13 に示す．図が示す通り，改良後の PINNs では，各出水において有限差分法と同等の順解析結果が得られていることを確認できる．特に H30 出水は 2 山の比較的複雑な水位波形であるが，水位の立ち上がり箇所などの非線形性が強い部分も含めて問題なく再現ができている．また図より，水位・流量と比較して断面平均流速・河積は空間方向の非線形性が強い様子が確認でき，座標変数に対して滑らかな変化（低周波数）を学習しやすい PINNs の出力変数としては水位と流量が適していることが改めて確認できる．

次に図-4.12 より，本検証で対象としたいずれかの PINNs 手法改良を適用しない場合には，適切な解へ収束できていない様子が確認でき，本検討で適用した各改良のそれぞれが，適切な順解析に重要な役割を果たしていることが分かる．特に初期化学習過程の追加は本質的に重要であり，適用されない場合には部分的に水位等がゼロに張り付いてしまうなど，妥当な学習が進まない挙動が確認された．特に縦断水位波形（図-4.13）で見た場合には，初期化学習過程を適用しない Case2 とフーリエ特徴埋め込みを適用しない Case4 において，正しい縦断水位からの逸脱が顕著である．Case5 の tanh 活性化関数適用時は，収束先が逸脱するような振る舞いこそ確認できないが，ピーク部やふた山の高周波部への学習はうまく進んでいない様子が確認できる．Case3 の横流入サンプリング間隔については他のケースと比較して影響が小さいが，ピーク付近の流量等で過小評価が発生している様子が見られる．この点に関しては次節の感度分析で詳細を述べる．なお，国包地点については T.P.12.5m 以下で乖離が見られるが，これは 12.0k 地点に存在する加古川大堰のゲート操作の影響である．加古川大堰では平常時は T.P.12.5m の水位を確保し，洪水時にはゲートを全開にする操作が行われている．本検討は洪水時を主眼としているため，加古川大堰の平常時ゲート操作はモデル化していないことから，T.P.12.5m 以下は観測値よりも低い水位結果となっている．ただし，平常時水位が重要なケースでは，加古川大堰（12.0k）を支配断面として計算領域を分割し，境界条件にゲート操作規則を適用することにより PINNs による計算は問題なく可能である．

以上の通り，一般断面への PINNs 計算手法拡張と手法改良の適用により，一般的な河道条件に対して PINNs による妥当な順解析が可能となることが確認できた．PINNs によるデータ同化のためには妥当な順解析が前提となるため，本改良開発を通して，一般的な一次元不定流計算条件に対する PINNs によるデータ同化・逆解析への応用に向けた検討が可能となった．

表-4.4　検証出水の観測水位に対する RMSE (m)

計算ケース	国包　(14.2k)		大島　(20.0k)		大門　(27.8k)	
	H29 出水	H30 出水	H29 出水	H30 出水	H29 出水	H30 出水
有限差分法	0.89	0.67	0.37	0.49	0.18	0.23
PINNs-Case1	1.03	0.77	0.38	0.38	0.24	0.27
PINNs-Case2	10.42	1.60	15.47	0.94	16.44	19.18
PINNs-Case3	1.10	0.91	0.28	0.27	0.21	0.33
PINNs-Case4	1.10	13.81	1.95	11.19	0.64	3.51
PINNs-Case5	1.50	1.55	1.31	1.06	1.23	1.34

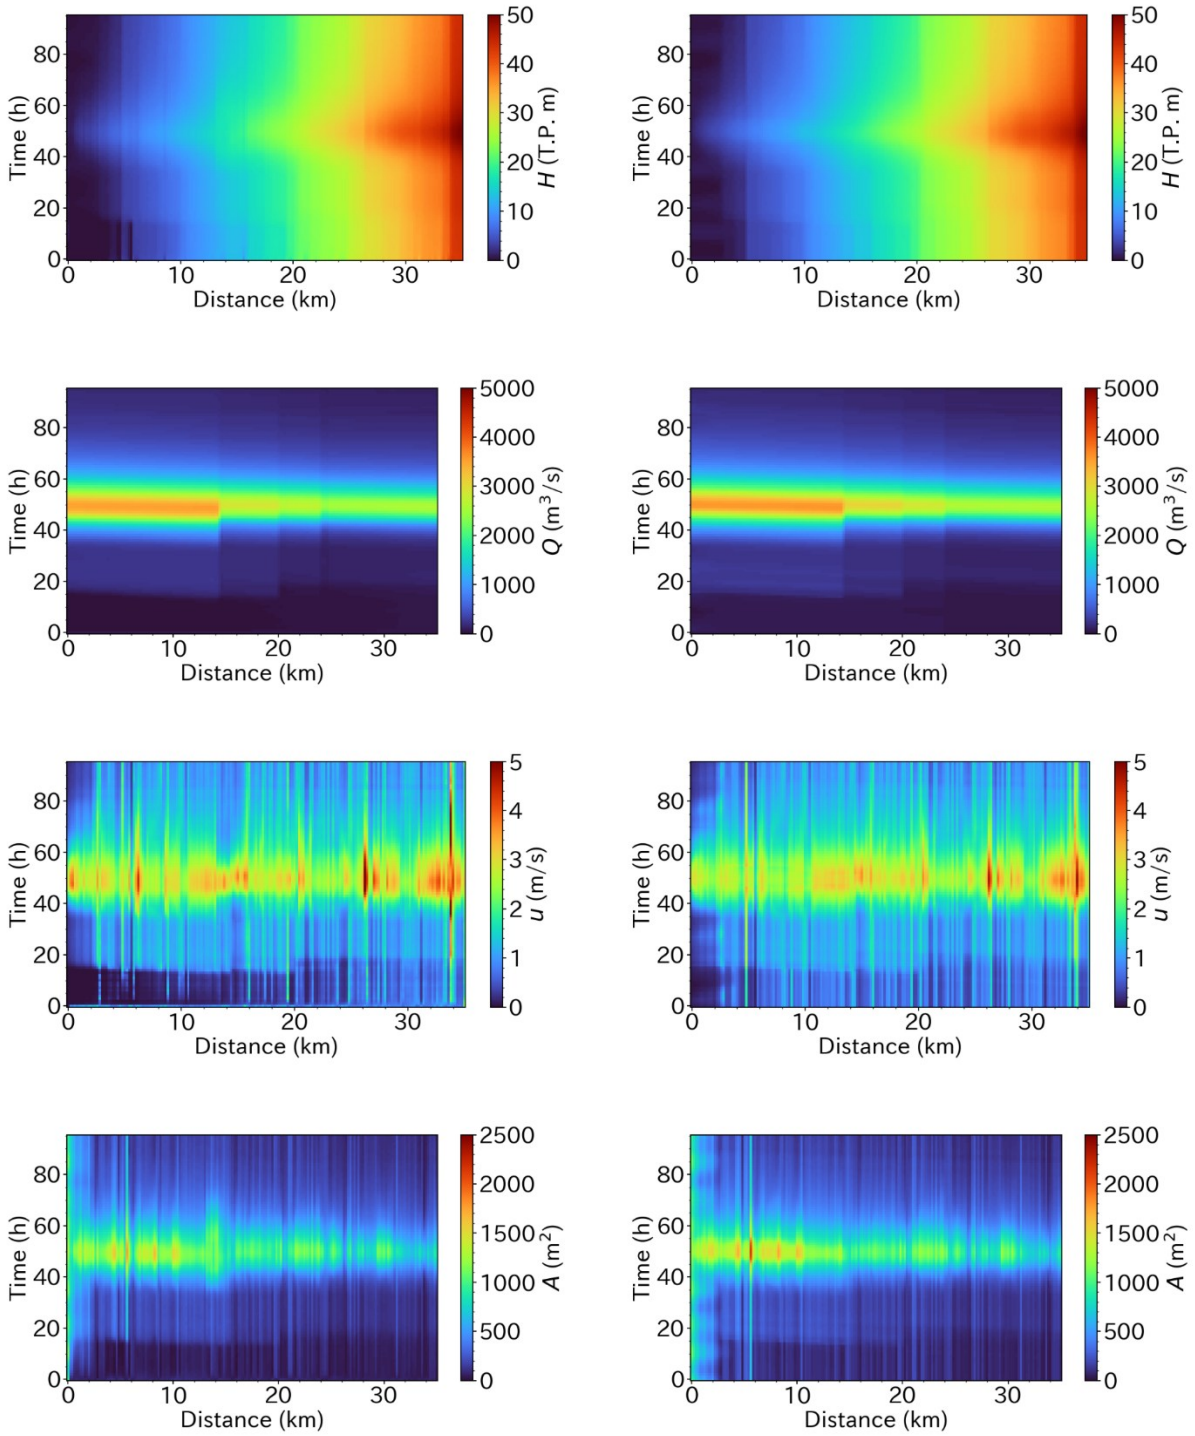

図-4.10　　H29 出水の再現比較
（左：PINNs-Case1，右：有限差分法．上から水位，流量，断面平均流速，河積）

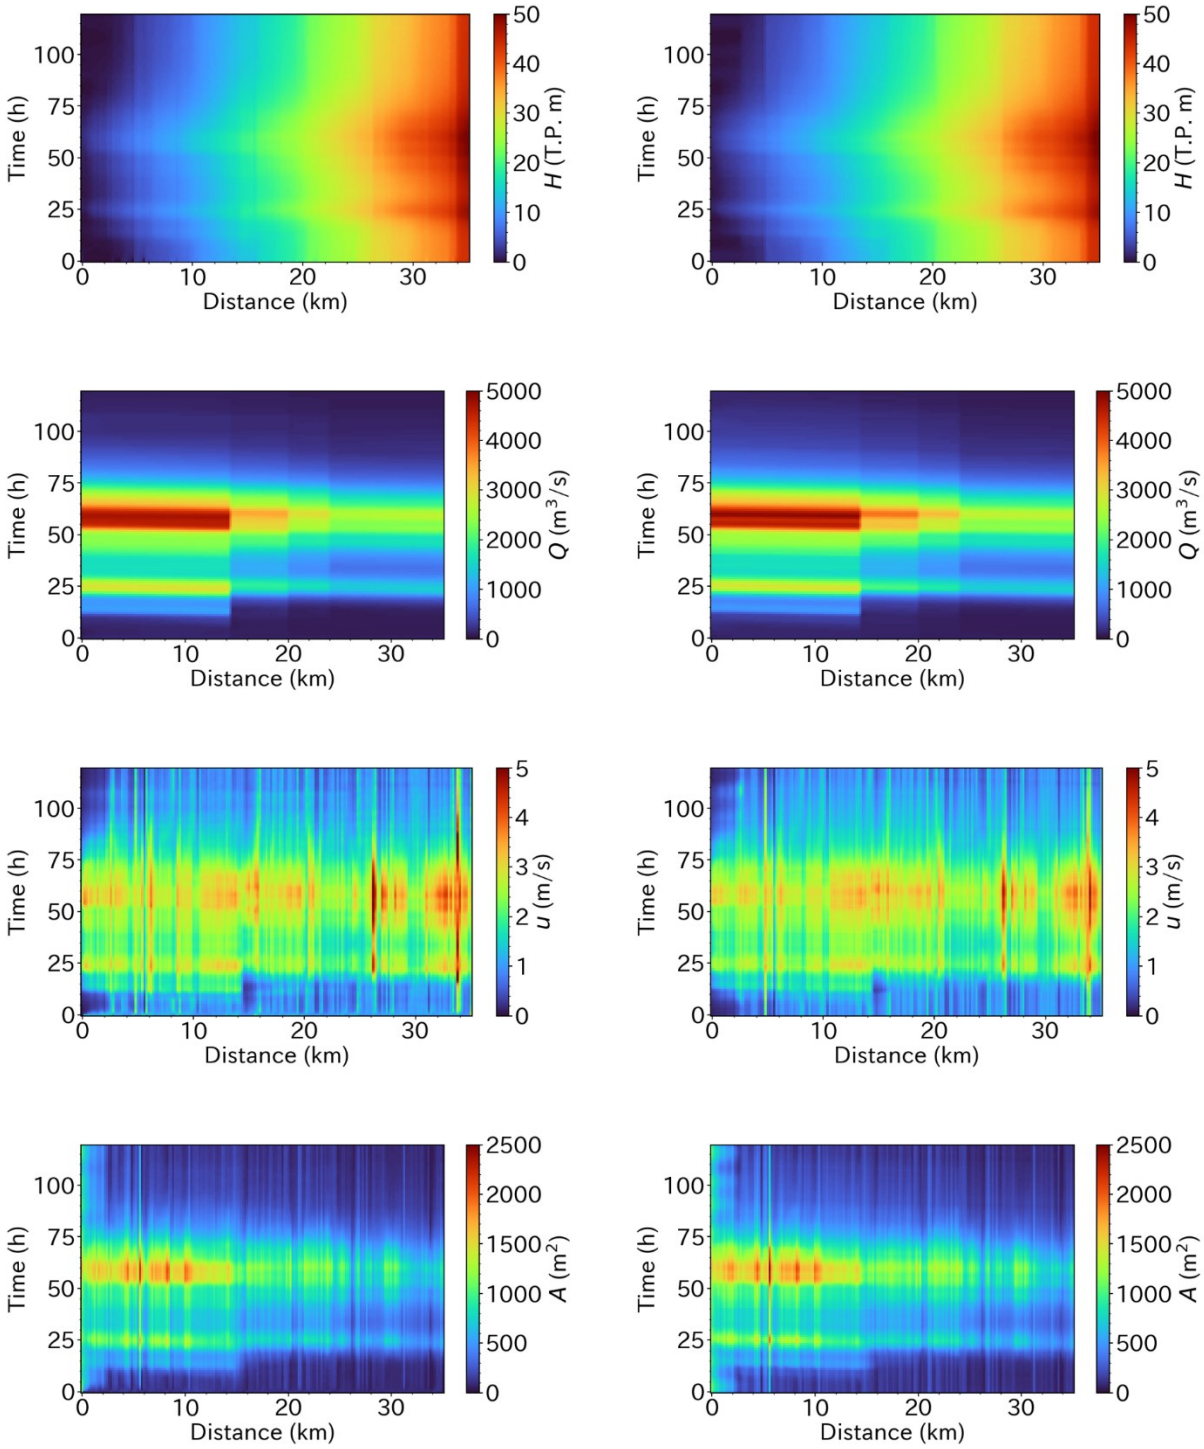

図-4.11　　H30 出水の再現比較
（左：PINNs-Case1，右：有限差分法．上から水位，流量，断面平均流速，河積）

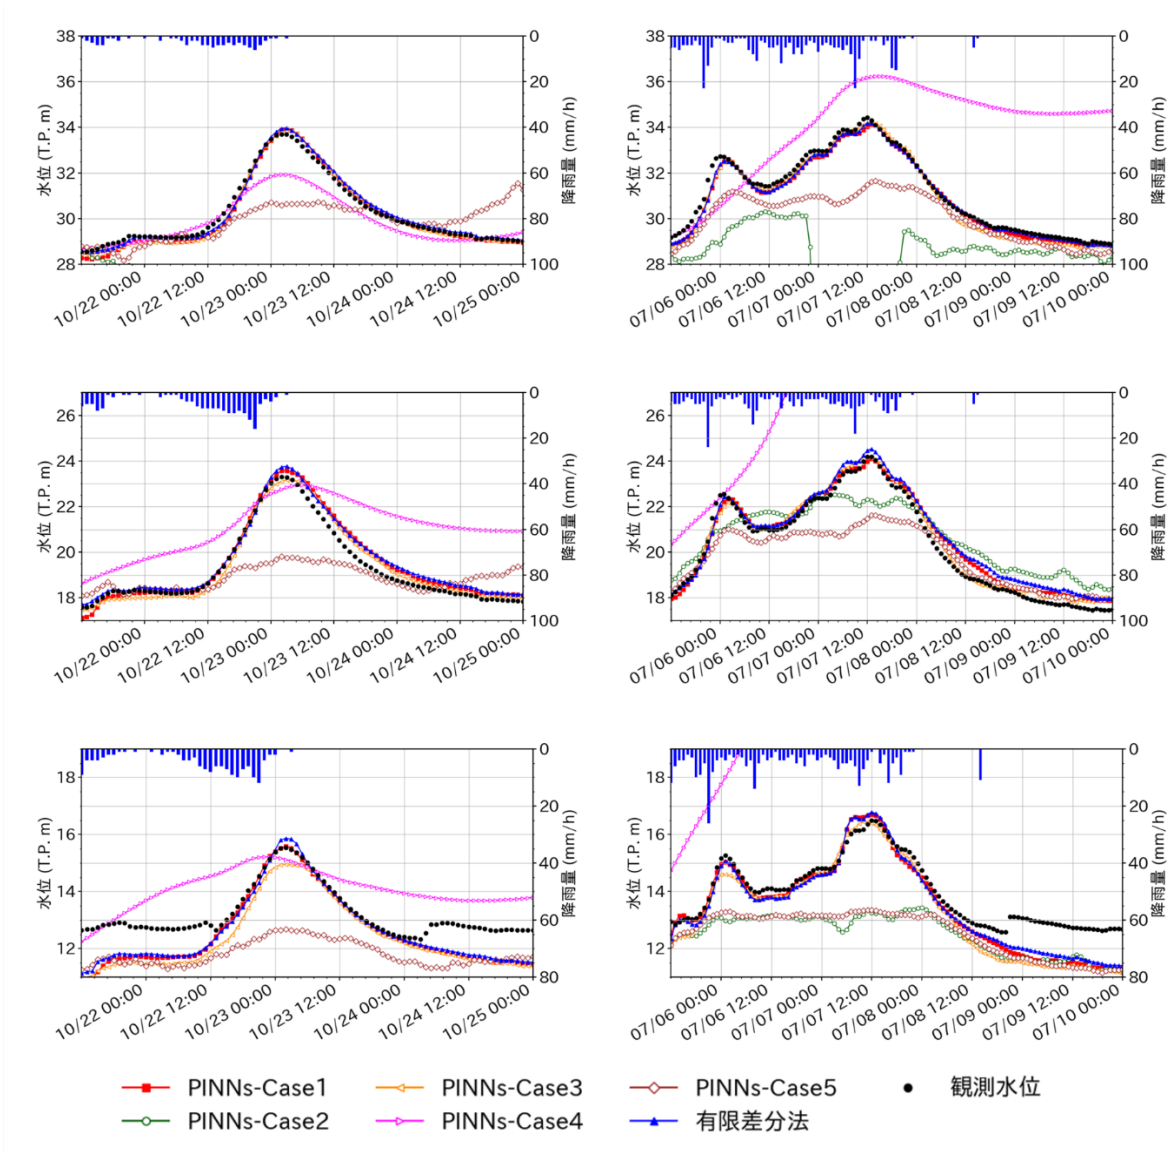

図-4.12　　観測地点（3 地点）における順解析水位の比較
（左：H29 出水，右：H30 出水．上から大門，大島，国包．）

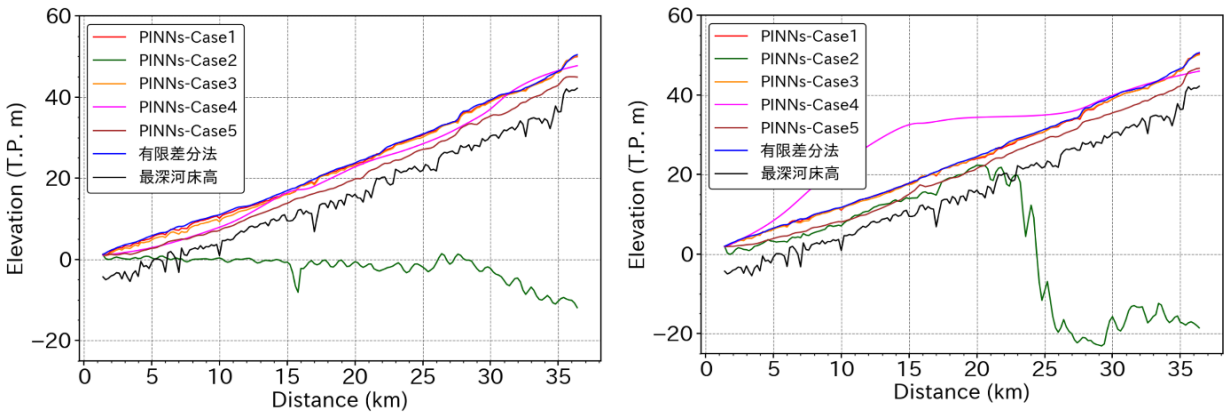

図-4.13　　国包ピーク水位時刻における水位縦断図の比較（左：H29 出水、右：H30 出水）

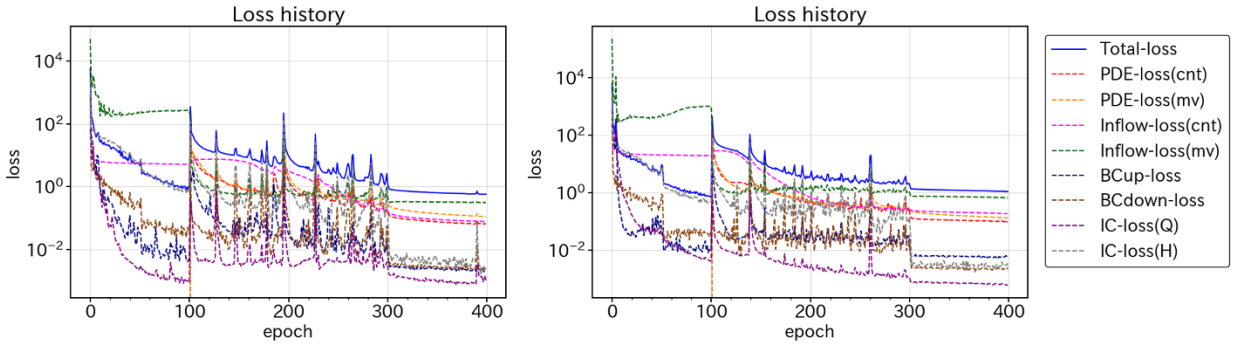

図-4.14　学習曲線の比較 (左：H29 出水，右：H30 出水)

表-4.5　学習後の各損失項の値

損失項	H29 出水	H30 出水	重み係数設定値
Total	5.8×10^{-1}	1.1×10^{0}	-
PDE（連続式）	6.5×10^{-2}	1.0×10^{-1}	1×10^{4}
PDE（運動方程式）	1.1×10^{-1}	1.3×10^{-1}	1×10^{-1}
横流入箇所 PDE（連続式）	7.7×10^{-2}	1.9×10^{-1}	1×10^{0}
横流入箇所 PDE（運動方程式）	3.1×10^{-1}	6.8×10^{-1}	1×10^{0}
上流端境界条件（流量）	2.3×10^{-3}	5.7×10^{-3}	1×10^{-3}
下流端境界条件（水位）	2.6×10^{-3}	2.5×10^{-3}	1×10^{2}
初期条件（流量）	1.0×10^{-3}	6.3×10^{-4}	1×10^{-3}
初期条件（水位）	2.5×10^{-3}	3.7×10^{-3}	1×10^{2}

図-4.14 と表-4.5 に学習曲線と学習後の各損失項の値を示す．学習初期時点で同程度の大きさになるように重み係数を設定したにも関わらず，各項の収束速度と収束値には差異が見受けられる．これは，損失項自体が大きい値であっても，その項に関しては局所解に収束している等で DNN 重みパラメータの損失勾配が小さい場合，その項に対しては改善が進まないためと考えられる．

また，PDE 項の損失評価では最低でも 2 階以上の微分となるためか，1 階微分で済む境界条件等の具体数値に対する残差損失よりも収束しづらい傾向が見受けられ，同程度の損失オーダーに重み係数で調整した場合も観測損失への適合が優先的に進む傾向となっている．このような挙動への対応としては，各損失項の重みを動的に調整する PINNs 学習手法などが提案されており，本問題設定においても PINNs の収束効率改善に向けて有効である可能性がある．なお，100epoch までは等流計算結果に対する初期化学習のため、損失関数の定義が切り替わる 100epoch で学習曲線の挙動が変化している．

4.4.3 PINNs 学習設定に関する感度分析

前節で確認した一般河道の不定流計算に対する PINNs 順解析について，収束挙動の詳細を把握するため，計算設定値に対する感度分析を実施した．対象としたのは，既往研究の中で報告事例が希薄である横流入に対する PINNs 計算設定と，計算速度と再現精度のトレードオフが発生することから実利用において適切な設定が重要となる PDE サンプリング間隔である．

(1) 横流入の PINNs 計算設定に関する感度分析

前節の結果（Case-3）より，式（4.30）の横流入q_lに関して，単純に PDE 損失のサンプリング間隔を全区間で一様に設定して適用した場合，流入箇所の急激な流入変化に対して流入箇所付近のサンプリング点数が少ないためか，横流入量が十分に反映されず，実際の流量よりも過小評価される傾向が見られた．この点に関して，適切な流量反映にあたってどのような横流入設定が必要かを確認するため，表-4.6 に示した検証ケースに対する学習計算を試行した．各ケース間で差異を設けた感度分析項目は，連続式における横流入量を決める横流入幅（単位幅）と，横流入幅の区間における PDE 損失のサンプリング間隔である．

表-4.6 Case 設定の一覧

計算ケース	横流入幅 (m)	横流入 PDE 損失のサンプリング間隔 (m)
Case1	100	1
Case2	100	10
Case3	100	100
Case4	10	1

各ケースについて，有限差分法（FDM）による流量計算結果と比較した際の RMSE を表-4.7 に，計算対象時空間領域における比較結果を図-4.15 に示す．比較ケースの中では Case1 が最も FDM 計算流量に近い結果を示しており，平均流量値に対する誤差は H29 出水で 10.3%，H30 出水で 6.7%である．図-4.15 より， FDM と比較してやや流量を過小評価する傾向があるが，時間位相の差異はほとんど見受けられないことが分かる．PDE 損失計算点のサンプリング幅を Case1 よりも粗くした Case2 と Case3 では，いずれも FDM との流量差異が拡がっている．このことから，横流入地点のように非線形変化が大きい箇所では，PDE 損失計算点のサンプリングを密に取ることが精度を確保する上で重要であり，本検証で対象とした加古川のような一級河川規模に対しては，1m ピッチよりも密なサンプリング間隔を設定することが必要であると考えられる．次に，横流入幅を狭く変更した Case4 との比較を見ると，流量差異が大幅に増大しており，妥当な学習計算が実行できなくなっていることが確認できる．横流入幅を狭めた場合，連続式における単位幅あたりの流量q_lは大きく設定されることになるが，特に美嚢川との合流地点では実際の横流入幅が 100m 程度あることから，単位幅あたりの流入量が大きくなり過ぎることで学習計算が不安定化するものと考えられる．このため，連続式中に現れるq_lが極端に大きな値とならないように，合流地点における実際の横流入幅程度を設定する必要があると考えられる．

表-4.7　有限差分法（FDM）による計算流量に対する RMSE (m^3/s)

計算ケース	H29 出水 （FDM 平均流量：663.1m^3/s）	H30 出水 （FDM 平均流量：1166.7m^3/s）
Case1	68.2	77.9
Case2	77.9	117.6
Case3	144.2	110.0
Case4	604.3	2245.3

表-4.8　検証出水の観測水位に対する RMSE (m)

計算ケース	国包　(14.2k)		大島　(20.0k)		大門　(27.8k)	
	H29 出水	H30 出水	H29 出水	H30 出水	H29 出水	H30 出水
Case1	1.03	0.77	0.38	0.38	0.24	0.27
Case2	0.99	0.84	0.33	0.38	0.26	0.25
Case3	1.16	0.85	0.32	0.37	0.23	0.26
Case4	1.51	2.34	1.11	4.46	0.44	0.84

次に計算水位について，観測地点における観測値との比較結果を表-4.8 と図-4.16 に，国包地点のピーク水位時刻における縦断水位の比較結果を図-4.17 に示す．水位比較結果では，Case1～Case3 には流量ほど大きな差異が見られないことが分かる．ただし，横流入量が大きい美嚢川合流後の国包地点では，流量の過小評価を反映して水位も観測値より過小評価傾向が目立つ結果となっている．また，Case4 については流量と同様に妥当な学習計算ができていない様子が確認できる．

以上より，横流入箇所のサンプリング間隔を密に設定すること，横流入幅を実際の状況に即した値に設定することが，精度の良い学習計算を実現する上で重要となることが分かった．

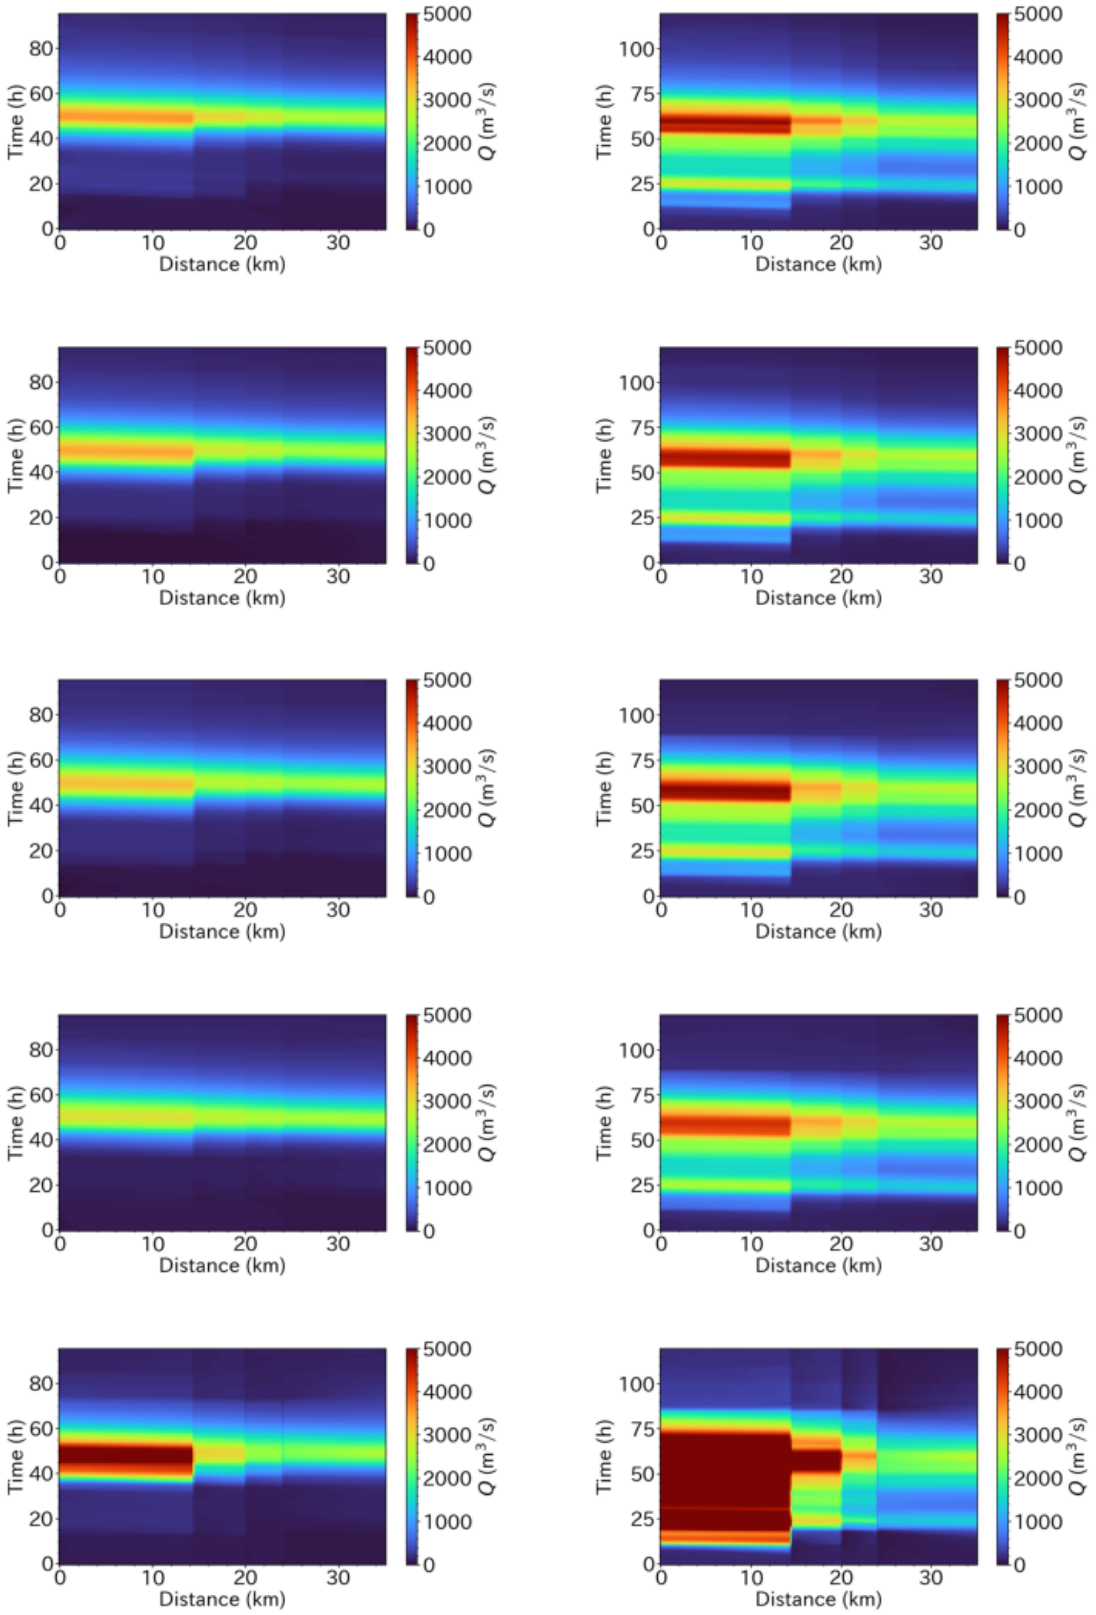

図-4.15　　計算流量の比較

（左：H29 出水，右：H30 出水．上から，有限差分法，Case1，Case2，Case3，Case4，Case5）

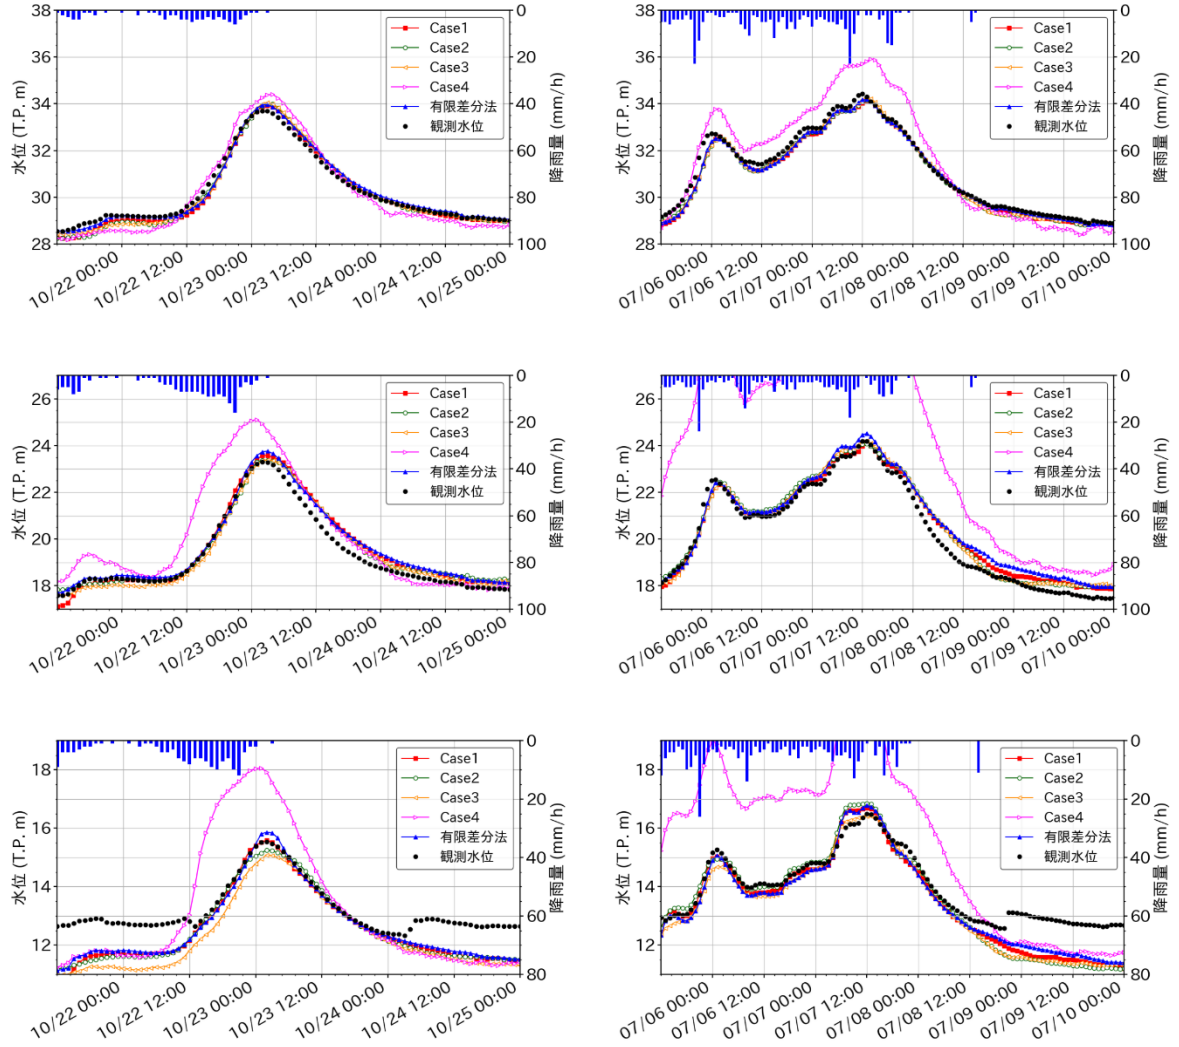

図-4.16　　観測地点（3 地点）における順解析水位の比較
（左：H29 出水，右：H30 出水．上から大門，大島，国包.）

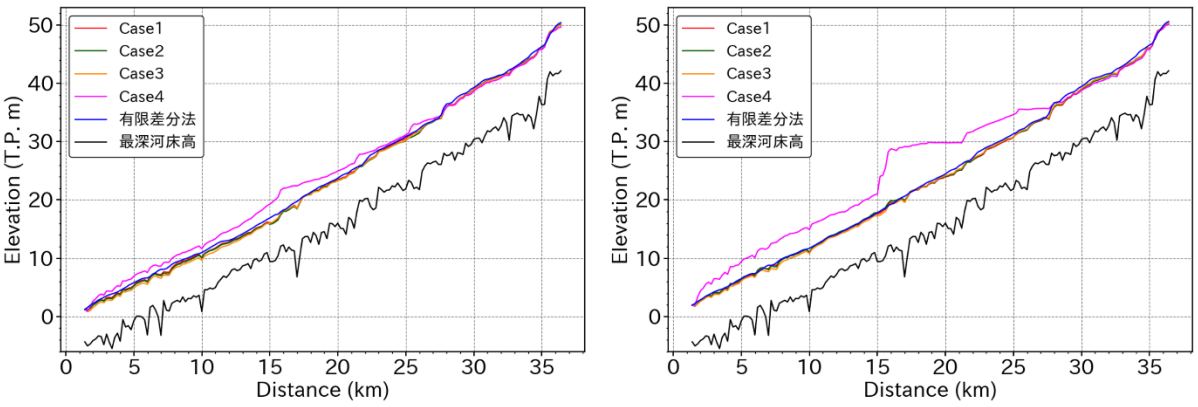

図-4.17　　国包ピーク水位時刻における水位縦断図の比較（左：H29 出水、右：H30 出水）

（2） PDE 損失計算点のサンプリング幅に対する感度分析

横流入幅における感度分析で示した通り，妥当な学習計算には PDE 損失計算点を密に設定することが重要である．一方で，PDE 損失計算点の数は計算時間に直結するため，計算負荷の観点からはなるべく少ない点数設定が望ましい．このように PDE 損失計算点のサンプリング間隔は，再現精度と計算速度のトレードオフの観点から実利用において適切な設定が重要となるため，感度分析を実施した．

対象ケースを表-4.9 に示す．入力対象の河道断面形状を反映する必要があることから，空間サンプリング間隔は河道断面データ間隔より小さい 100m で固定とし，時間方向のサンプリング間隔について，10 分/30 分/1 時間の 3 ケースを試行した．PDE 損失計算対象点数は Case1 と Case3 で 6 倍異なり，この差は計算時間に直結することが期待される．各ケースの観測水位との比較結果を表-4.10 と図-4.18 に，縦断水位の比較結果を図-4.19 に，計算時間の比較結果を表-4.11 に示す．時間方向のサンプリング間隔を粗くするにつれて，精度が悪化しており，特にピーク水位付近と下流部での過小評価傾向が顕著である．一方で上流部である大門においては，それほど精度に差がないことが分かる．次に計算時間を見ると，Case1 よりも Case3 の方が約 6 倍高速であり，これは PDE 損失計算点数にほぼ比例している．

以上より，PDE 損失計算点の配置は一定間隔に設定するよりも，上流は疎に設定し，下流部にかけてサンプリング幅を密に設定するような非均一な配置の方が効率的である可能性が高いと考えられる．対象河川に応じた適切な非均一サンプリング点の設定手法は，今後の検討課題である．

表-4.9　Case 設定の一覧

計算ケース	PDE 損失計算点の時間方向のサンプリング間隔 (s)	PDE 損失計算点の空間方向のサンプリング間隔 (m)	PDE 損失計算対象点数（H29 出水/H30 出水）
Case1	600	100	197566 / 247390
Case2	1800	100	66086 / 82694
Case3	3600	100	33216 / 41520

表-4.10　検証出水の観測水位に対する RMSE (m)

計算ケース	国包　(14.2k)		大島　(20.0k)		大門　(27.8k)	
	H29 出水	H30 出水	H29 出水	H30 出水	H29 出水	H30 出水
Case1	1.03	0.77	0.38	0.38	0.24	0.27
Case2	1.25	1.01	0.26	0.41	0.27	0.30
Case3	1.23	1.26	0.29	0.57	0.14	0.32

表-4.11　学習計算時間の比較 (※Intel Xeon w3-2423 / NVIDIA RTX A4000 を利用)

計算ケース	H29 出水 (sec / epoch)	H30 出水 (sec / epoch)
Case1	63.7	80.4
Case2	21.6	27.1
Case3	10.6	12.9

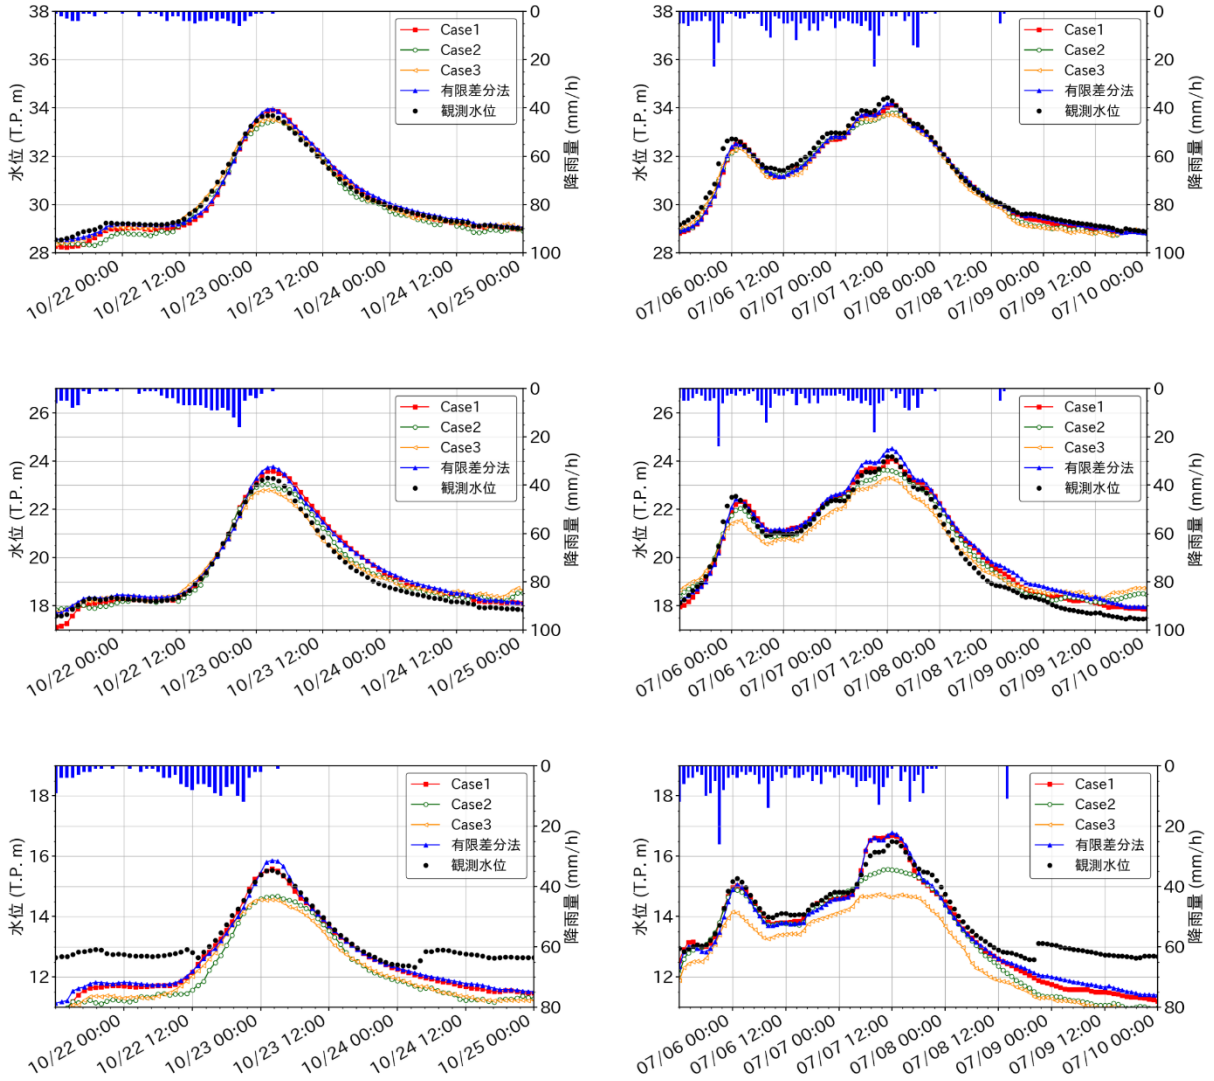

図-4.18　　観測地点（3 地点）における順解析水位の比較
（左：H29 出水，右：H30 出水．上から大門，大島，国包．）

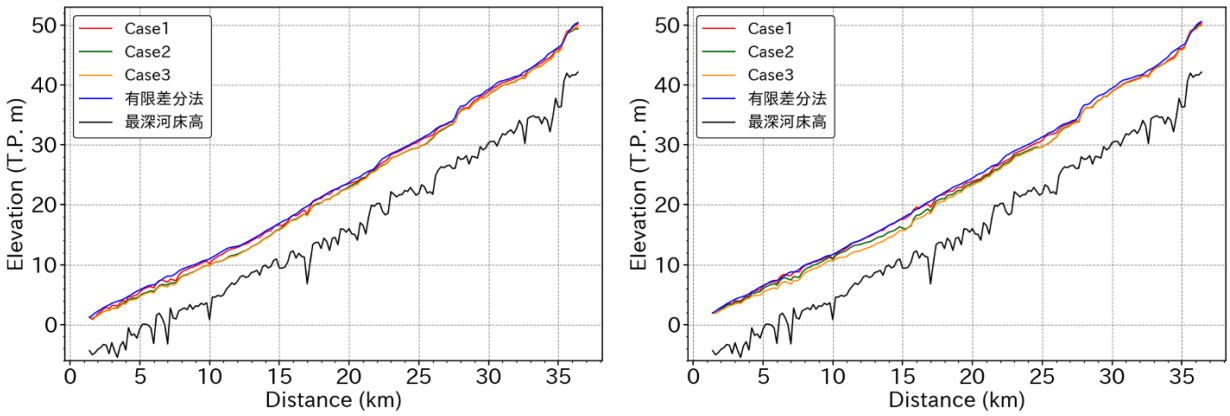

図-4.19　　国包ピーク水位時刻における水位縦断図の比較（左：H29 出水、右：H30 出水）

4.5 データ同化・逆解析に関する開発と検証

前節では種々の手法改良により，一般的な河道計算条件において妥当な PINNs 順解析が可能となったことを確認した．本節では縦断水位予測において重要な応用となる，河床粗度係数と縦断水面形を対象とした多地点水位データ同化に関する検証を実施する．

4.5.1 多地点観測水位データ同化の問題設定

多地点観測水位データ同化の問題設定として，同化対象とするパラメータや同化対象時間には多様な選択肢がある．本検討では最も基本的な問題設定として，複数の区間でそれぞれ設定された河床粗度係数を修正対象パラメータとみなし，空間上で離散的に得られる多地点の観測水位のデータ同化により，これらの粗度係数の最適化を図る問題を対象に検討を実施した．

4.5.2 粗度係数の逆推定に関する検証

(1) 検証設定

PINNs による多地点水位データ同化の基本的な性能を検証するため，表-4.1 に示した 6 区間の各粗度係数を推定対象（仮想真値）とした適用検証を実施した．仮想真値を設定した条件下で有限差分法により計算した水位を，時空間的に密な仮想水位観測値として与えた理想的なケース（Case1：双子実験）と，時空間的に疎である実観測水位を与えた現実的なケース（Case2）について比較を行った（表-4.12，図-4.20）．Case1 における仮想観測水位の空間間隔は PDE サンプリング幅と同じ 100m とし，時間間隔は両ケースともに，実際の水位観測値として得られることが多い 1 時間間隔を設定した（図-4.24）．同化対象データ数は Case1 と Case2 で 100 倍程度の違いがあり，よりスパースなデータ間隔である Case2 の方がより真値推定が困難な条件設定となる．推定対象である粗度係数の初期推定値には，いずれの推定真値よりも 2 倍以上大きい値となる 0.1 を一律で設定した．なお，Case1 と Case2 の双方で粗度係数の推定真値には表-4.1 に示した値を用いるが，Case2 では実際の観測水位を同化するため，既往の再現計算結果から推定されている表-4.1 の粗度係数（推定真値）が必ずしも最適解とは限らない点には留意が必要である．

また，本検証はデータ同化・逆解析機能に対する基礎検証として，出水期間中の全観測水位データを同化対象とし，各区間の粗度係数を推定する問題設定とした．

表-4.12 各ケースのデータ同化設定

項目	Case1	Case2
データ同化対象	計算水位（双子実験）	観測水位
同化対象の空間間隔	100m	離散的な 3 地点 (大門/大島/国包)
同化対象の時間間隔	1 時間	1 時間
同化対象点数 (H29 出水/H30 出水)	33,600 / 42,000	288 / 360

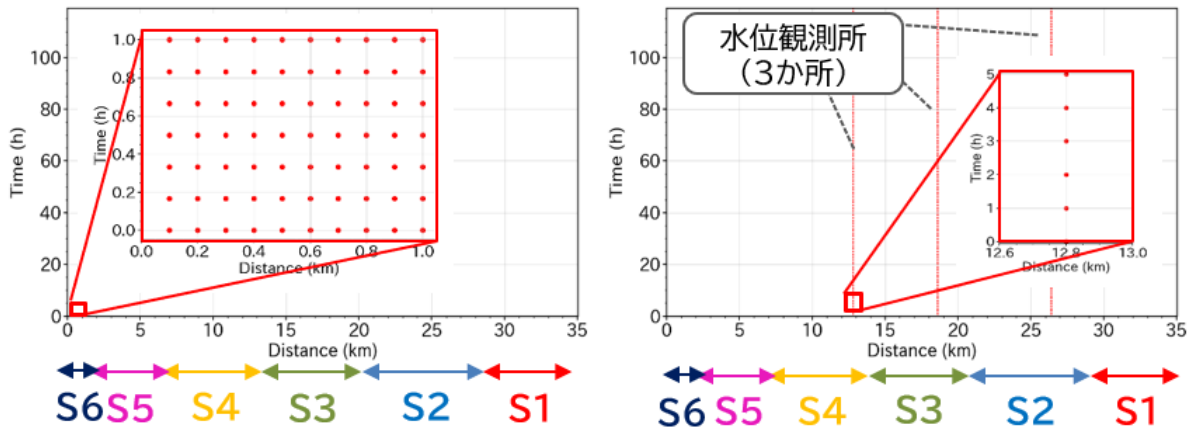

図-4.20　検証ケース設定の概要（左：Case1，右：Case2）

表-4.13　各区間の粗度係数推定精度(推定値と誤差率)

対象区間 (推定真値)	Case1		Case2	
	H29 出水	H30 出水	H29 出水	H30 出水
Sec.1 (0.040)	0.040 (0.0%)	0.040 (0.0%)	0.038 (5.0%)	0.038 (5.0%)
Sec.2 (0.039)	0.038 (2.6%)	0.038 (2.6%)	0.035 (10.3%)	0.042 (7.6%)
Sec.3 (0.035)	0.034 (2.9%)	0.032 (8.6%)	0.036 (2.9%)	0.038 (8.6%)
Sec.4 (0.030)	0.029 (3.3%)	0.029 (3.3%)	0.039 (30.0%)	0.042 (40.0%)
Sec.5 (0.029)	0.029 (0.0%)	0.030 (3.4%)	0.036 (24.1%)	0.040 (37.9%)
Sec.6 (0.028)	0.026 (7.1%)	0.027 (3.6%)	0.029 (3.6%)	0.035 (25.0%)

（2） 検証結果

結果を表-4.13，図-4.21，図-4.22 に示す．いずれのケースでも推定真値へ向けた収束が見られ，特に理想的な条件の Case1 では，各河道粗度係数に対して±0.0～8.6%の良好な精度で推定されることが確認できた．また，現実的な条件である Case2 においても，データ同化対象の観測値を含む区間（Sec.1～Sec.3）では，推定真値に対して±2.9～10.3%の妥当な精度で推定されている．一方で区間中の上流端付近に観測値を有する Sec.4 や観測値を含まない Sec.5~6 では，同化影響が小さいためか，推定粗度係数は Sec.1～Sec.3 の推定値と同程度の値となるなど，推定真値に対しては過大評価傾向となった．

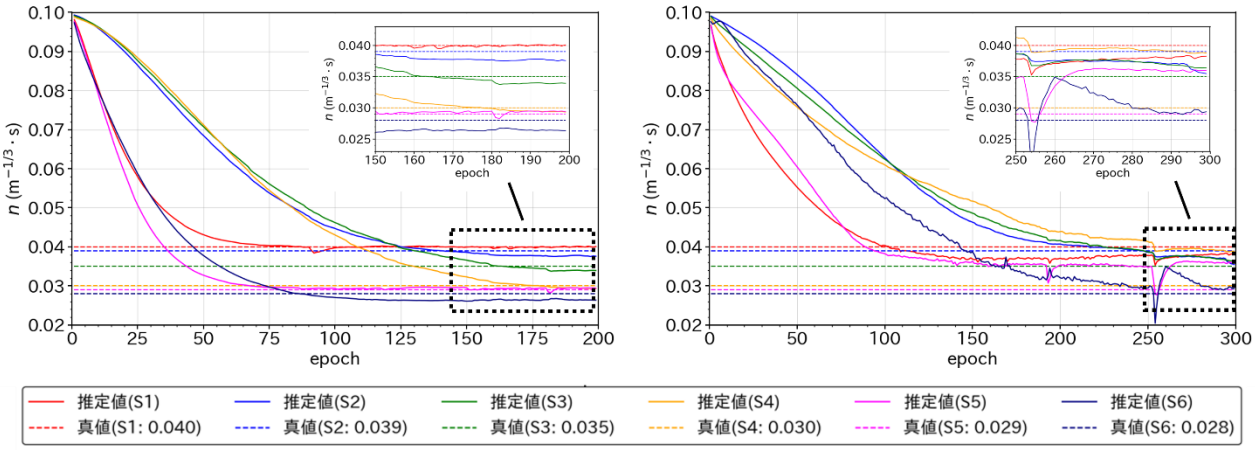

図-4.21　H29 出水に対する多地点水位データ同化による区間別粗度係数の推定結果
（左：Case1，右：Case2）

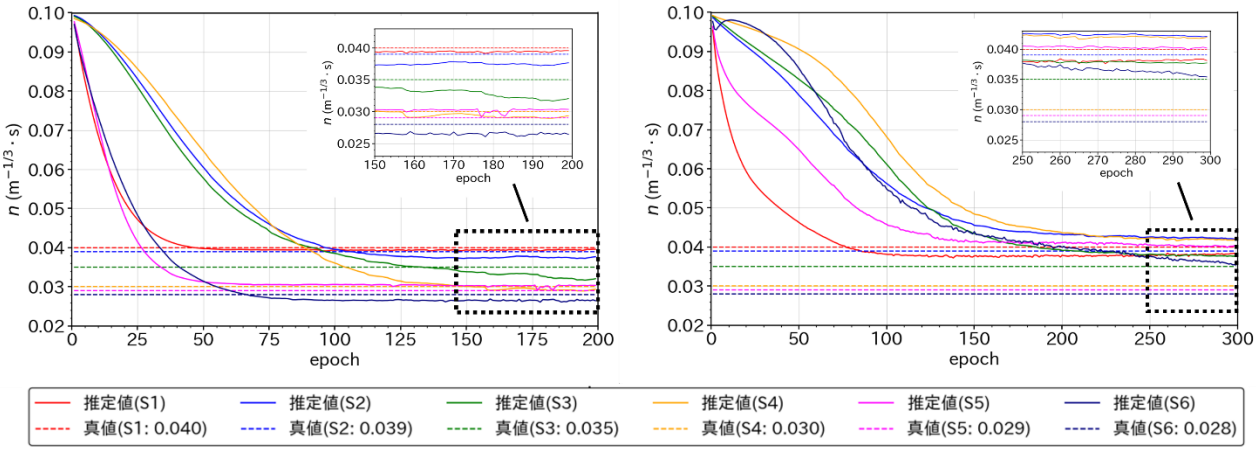

図-4.22　H30 出水に対する多地点水位データ同化による区間別粗度係数の推定結果
（左：Case1，右：Case2）

Case1 と Case2 の比較では，最終的な推定精度の他に収束速度と収束過程の安定性にも差が見られ，同化対象点が十分にある Case1 の方がより収束が速く，収束過程も安定していることが確認できる．また収束順序に目を向けると，上流端の Sec.1 と下流端の Sec.5 と Sec.6 が最初に収束し，その後に中流部のパラメータが調整されていく様子が見られる．これは，上下流端の境界条件の制約により，上下流端付近の調整方向が中流部よりも分かりやすく（損失勾配が明瞭に現れやすく），パラメータ調整が優先的に進むためと考えられる．H29 出水と H30 出水の比較では，水位波形が 2 山となってより複雑である H30 出水の方が，特に情報が不足する Case2 において，より収束過程が安定する傾向が見られた．

以上より，本問題設定において，PINNs を用いたデータ同化が有効に機能することが確認できた．特に同化対象点が十分な双子実験ケースでは，収束値が各区間の粗度係数の大小関係を再現し，推定精度も概ね推定真値の 5%以下に収まる結果となった．スパースな現実の観測値を用いた場合にも，観測地点への影響が大きい区間の粗度係数は推定真値の 10%程度以下の妥当な値に収束することが確認できたが，収束過程は双子実験ケースと比較して不安定さが目立つ結果となり，安定したデータ同化推定に向けては，より密な観測地点間隔が必要であることが示唆された．

（3） 初期推定値に対する感度分析

データ同化・逆解析による粗度係数の収束値に関して，初期推定値に対する最終的な収束推定値の感度を確認するため，初期推定値の異なるケースに対して検証を行った（表-4.14）．対象としたのは，全区間の粗度係数の仮想真値から大きく外れたケース（Case1），仮想真値のすべてを上回るケース（Case2），仮想真値のすべてを下回るケース（Case3）の 3 ケースである．また各ケースについて，計算水位データを同化する双子実験条件（前節の Case1）と観測水位データを同化する現実条件（前節の Case2）で検証を実施した．

表-4.14 Case 設定の一覧

（各ケースについて計算水位データ同化（双子実験条件）と観測水位データ同化（現実条件）を試行）

計算ケース	粗度係数の初期推定値
Case1	0.100
Case2	0.050
Case3	0.025

図-4.23 と図-4.24 に，計算水位データ同化時と観測水位データ同化時それぞれに関して，各区間の粗度係数推定における収束挙動を各ケースで比較した結果を示す．また，図-4.25，図-4.26 と，表-4.15，表-4.16 には，同様に計算水位データ同化時と観測水位データ同化時それぞれに関して，各ケースにおける最終推定値の精度評価結果を示す．まずデータ同化対象数が十分な双子実験ケースを見ると，H29 出水と H30 出水のいずれにおいても，全区間で初期推定値によらず，ほぼ同一の値に安定して収束する様子が確認でき，各河道粗度係数に対して±0.0～8.6%の良好な精度で推定されている．実河川では粗度係数は 0.03 前後となることが多いため，リアルタイム運用において想定される変動範囲においては，大小方向に関係なく妥当な値へ収束可能であると考えられる．また，推定真値と大きく異なる Case1 と比較して，Case2 と Case3 は最終推定値付近への収束がほとんどの区間で 2 倍以上速い結果となっている．このため，初期推定値を想定真値付近に設定することは，計算時間を短縮する上で重要である．パラメータ調整順序については前節で示した結果と同様に，いずれのケースも上下流端が最初に収束し，中流部が最後に調整される順序となっている．

次にデータ同化対象数が不足気味である観測水位データの同化ケースを見ると，双子実験ケースと比較して収束過程が不安定化するものの，各ケース間の収束速度の関係や，区間ごとの収束順序の傾向は双子実験ケースと同様である．データ同化対象の観測値を含む区間（Sec.1～Sec.3）に対し，H30 出水では推定真値に対して±0.0～8.6%の良好な精度で推定された一方で，H29 出水では推定真値に対して±0.0～20.0%とやや推定精度が劣化する傾向となった．これは，H29 が一山の単純な波形であるために粗度係数に対する損失勾配が小さく，推定真値付近から始めた場合には局所最適解で安定しやすかった可能性が考えられる．また区間中の上流端付近に観測値を有する Sec.4 や観測値を含まない Sec.5~6 では，やはり同化影響が小さいためか，一貫した傾向は見受けられないが，Sec.4 に対しては推定真値に近い初期推定値を設定した Case2 や Case3 の方が，Case1 よりも推定精度が良い結果となっている．また，Sec.4～6 については，Case1 では一山の単純波形である H29 出水同化時の方が H30 出水同化時よりも推定精度が良い一方で，Case2 と Case3 では H30 出水同化時の方が H29 出水同化時よりも推定精度が良くなる結果を

示している．これより，対象区間内に直接的に寄与する同化対象データを有さない場合においては，推定真値から遠い初期推定値では全体的な調整方向が分かりやすい単純な一山波形が収束に有利となり，推定真値に近い初期推定値ではより詳細な調整に向けて，二山等により情報が多い波形の方が収束に有利となる可能性が考えられる．

以上より，データ同化対象数が十分なケースでは初期推定値によらず推定真値へ安定して収束することが確認できたが，推定真値に近い初期推定値を設定した場合の方が最終推定値付近への収束は 2 倍以上速いことから，妥当な初期推定値を設定することの重要性が示唆された．ただし，データ同化対象数が不十分なケースでは，出水波形によっては推定真値付近から始めることで逆に局所解で安定化してしまい，推定精度が劣化するケースも存在することが示された．

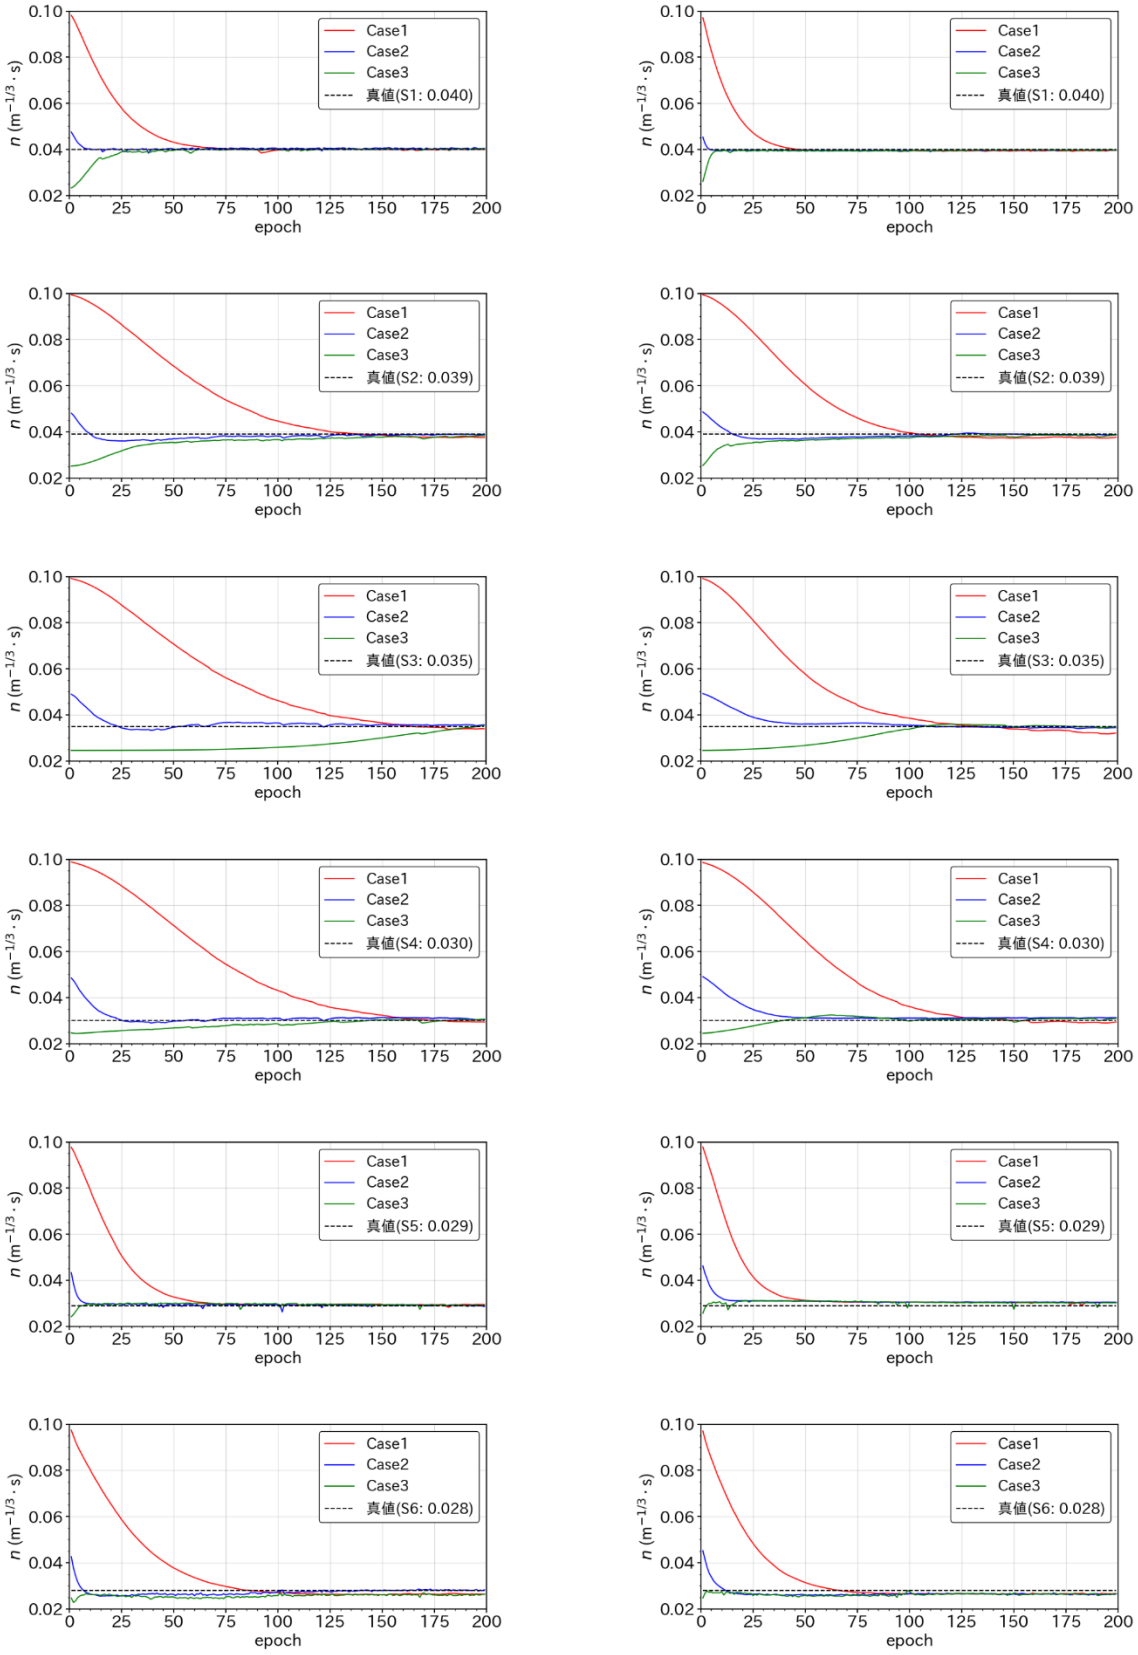

図-4.23　　計算水位データ同化条件時における粗度推定の初期値依存性
（左：H29 出水，右：H30 出水．上から順に S1～S6 の粗度係数が異なる各区間に対する推定結果）

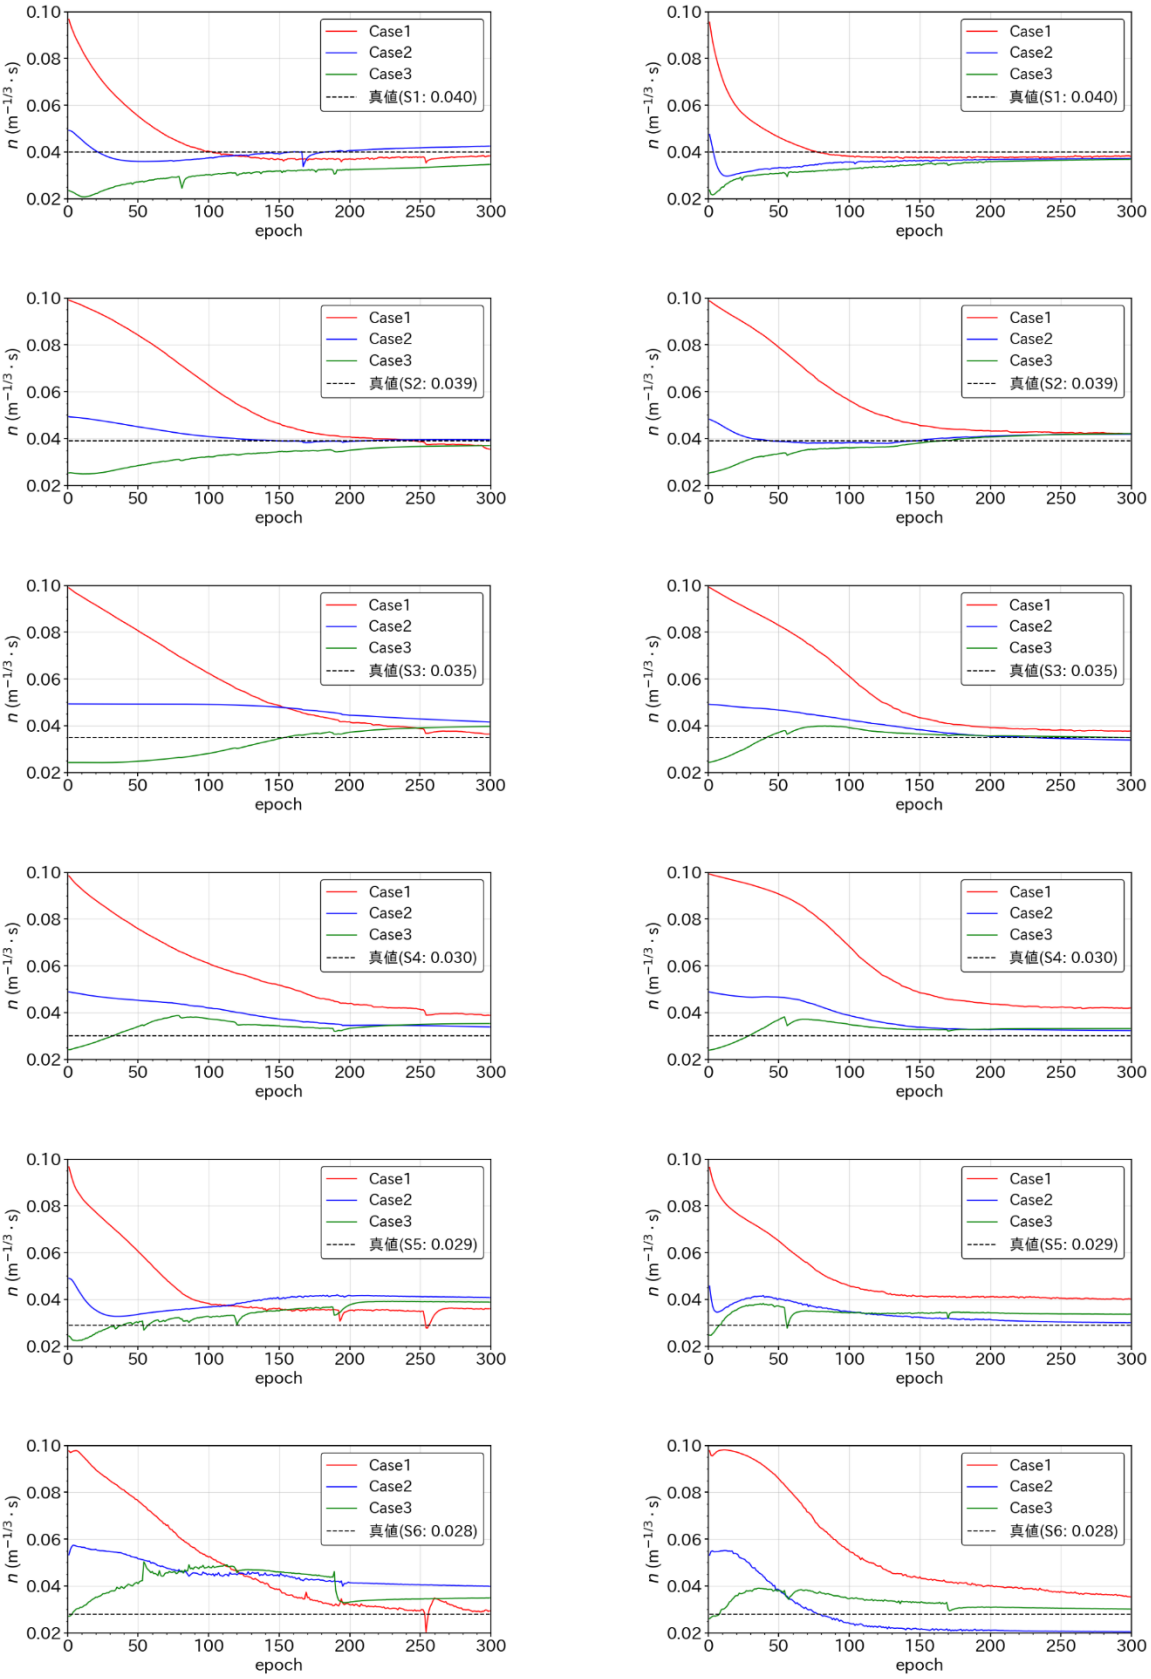

図-4.24　　観測水位データ同化条件時における粗度推定の初期値依存性
（左：H29 出水，右：H30 出水．上から順に S1～S6 の粗度係数が異なる各区間に対する推定結果）

表-4.15 計算水位データ同化条件時における各区間の粗度係数推定精度(推定値と誤差率)

対象区間 (推定真値)	Case1		Case2		Case3	
	H29 出水	H30 出水	H29 出水	H30 出水	H29 出水	H30 出水
Sec.1 (0.040)	0.040 (0.0%)	0.040 (0.0%)	0.040 (0.0%)	0.040 (0.0%)	0.040 (0.0%)	0.040 (0.0%)
Sec.2 (0.039)	0.038 (2.6%)	0.038 (2.6%)	0.039 (0.0%)	0.039 (0.0%)	0.038 (2.6%)	0.039 (0.0%)
Sec.3 (0.035)	0.034 (2.9%)	0.032 (8.6%)	0.036 (2.9%)	0.034 (2.9%)	0.035 (0.0%)	0.035 (0.0%)
Sec.4 (0.030)	0.029 (3.3%)	0.029 (3.3%)	0.030 (0.0%)	0.031 (3.3%)	0.031 (3.3%)	0.031 (3.3%)
Sec.5 (0.029)	0.029 (0.0%)	0.030 (3.4%)	0.029 (0.0%)	0.031 (6.9%)	0.029 (0.0%)	0.030 (3.4%)
Sec.6 (0.028)	0.026 (7.1%)	0.027 (3.6%)	0.028 (0.0%)	0.026 (7.1%)	0.026 (7.1%)	0.026 (7.1%)

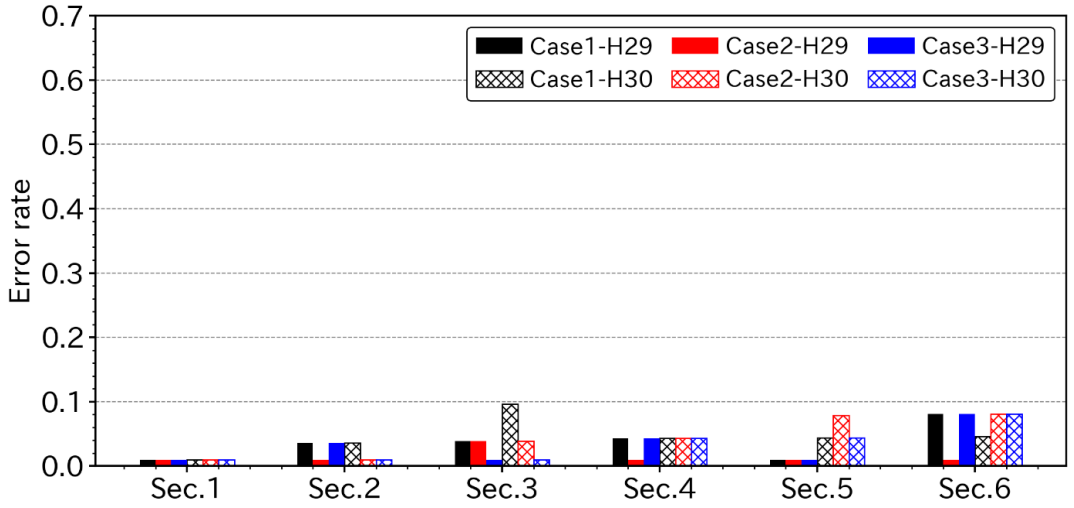

図-4.25 計算水位データ同化条件時における各区間の粗度係数推定精度の比較（誤差率）

表-4.16 観測水位データ同化条件時における各区間の粗度係数推定精度(推定値と誤差率)

対象区間 (推定真値)	Case1		Case2		Case3	
	H29 出水	H30 出水	H29 出水	H30 出水	H29 出水	H30 出水
Sec.1 (0.040)	0.038 (5.0%)	0.038 (5.0%)	0.042 (5.0%)	0.037 (7.5%)	0.035 (12.5%)	0.037 (7.5%)
Sec.2 (0.039)	0.035 (10.3%)	0.042 (7.6%)	0.039 (0.0%)	0.042 (7.6%)	0.037 (5.1%)	0.042 (7.6%)
Sec.3 (0.035)	0.036 (2.9%)	0.038 (8.6%)	0.042 (20.0%)	0.034 (2.9%)	0.040 (14.3%)	0.035 (0.0%)
Sec.4 (0.030)	0.039 (30.0%)	0.042 (40.0%)	0.034 (13.3%)	0.032 (6.7%)	0.035 (16.7%)	0.033 (10.0%)
Sec.5 (0.029)	0.036 (24.1%)	0.040 (37.9%)	0.041 (41.4%)	0.030 (3.4%)	0.039 (34.5%)	0.034 (17.2%)
Sec.6 (0.028)	0.029 (3.6%)	0.035 (25.0%)	0.040 (42.9%)	0.021 (25.0%)	0.035 (25.0%)	0.030 (7.1%)

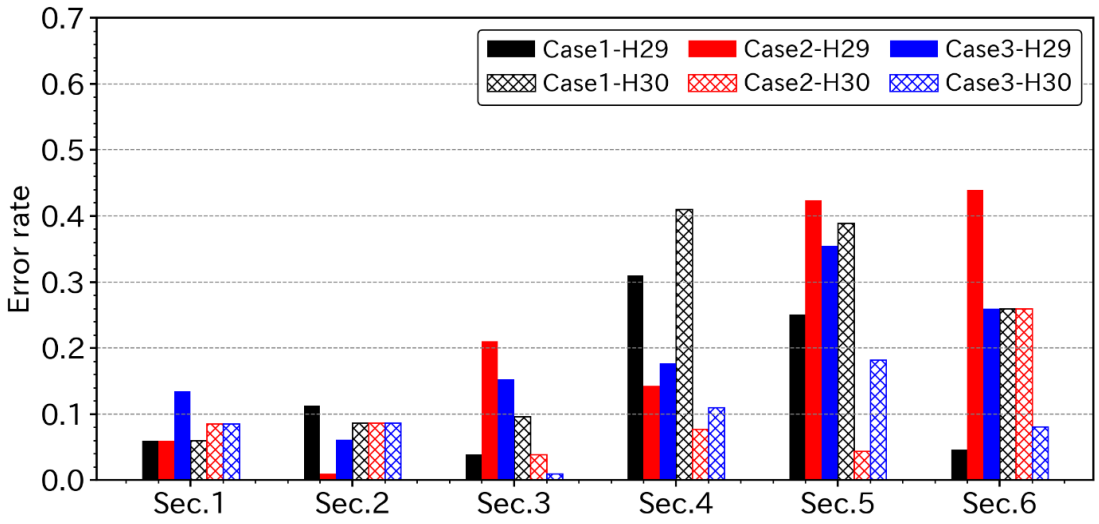

図-4.26 観測水位データ同化条件時における各区間の粗度係数推定精度の比較（誤差率）

（4） 同化対象データ数による推定精度に関する感度分析

データ同化・逆解析による粗度係数の推定値に関して，同化対象データ数による推定精度の感度を確認するため，同化対象データ数の異なるケースに対して検証を行った（表-4.17）．対象としたのは，計算水位を同化対象として，同化対象の空間間隔を 100m（Case1），1km（Case2），5km（Case3）とした双子実験 3 ケースと，観測水位を同化対象としたケース（Case4）の 4 ケースである．粗度係数の初期推定値は，全区間共通で 0.05 を設定した．

結果を表-4.18 と図-4.27，図-4.28 に示す．100m ピッチで同化対象点を設定している Case1 において良好な推定が可能であるのは，前項で確認した通りである．Case2～Case4 の収束に向けた挙動は H29 出水と H30 出水で大きく異なり，H30 出水では総じて推定精度が良く，Case2～Case4 で顕著な差異は見受けられない．一方で H29 出水においては，Case2，Case3 は Sec.4～Sec.6 に同化対象点を有するため，概ね同化対象点数が多いほど精度が良化する傾向となっている．各区間の推定精度を見ると，Case2 では最大でも 25%，ほとんどが 20%以下の誤差に収まっていることから，理想的には 1km ピッチ程度で水位観測データを取得できれば安定した粗度係数の推定が可能であると考えられる．Sec.4 の結果などから，各区間で同化対象が 1 点程度となる 5km ピッチ（Case3）では若干データ量が不足していると考えられ，データ同化の観点から水位観測地点を設置する目安としては，推定対象区間あたりに 2 地点以上が効果的であると推察される．

次に，各ケースの計算時間の比較結果を表-4.19 に示す．各ケースともに計算時間にはほとんど差が無く，対象地点数に応じて計算時間が増える傾向も見受けられない．これは，PINNs では PDE 損失計算処理が計算フロー上律速となるため，現実的に想定される 100m ピッチよりも疎な同化対象地点数の範囲では，観測誤差損失の計算処理が計算時間全体へ及ぼす影響が軽微であるためと考えられる．これより，PINNs では同化対象地点の変更が損失関数中の残差項の定義変更のみと非常に容易に対応できる特性と合わせて，今後予想されるセンサ機器のさらなる拡充に対し，効率的なデータ同化利用への適性は高いと考えられる．

表-4.17 各ケースのデータ同化設定 （初期推定値は一律で 0.05）

項目	Case1	Case2	Case3	Case4
データ同化対象	計算水位 （双子実験）	計算水位 （双子実験）	計算水位 （双子実験）	観測水位
同化対象の空間間隔	100m	1km	5km	離散的な 3 地点 (大門/大島/国包)
同化対象の時間間隔	1 時間	1 時間	1 時間	1 時間
同化対象点数 (H29 出水/H30 出水)	33,600 / 42,000	3,360 / 4,200	672 / 840	288 / 360

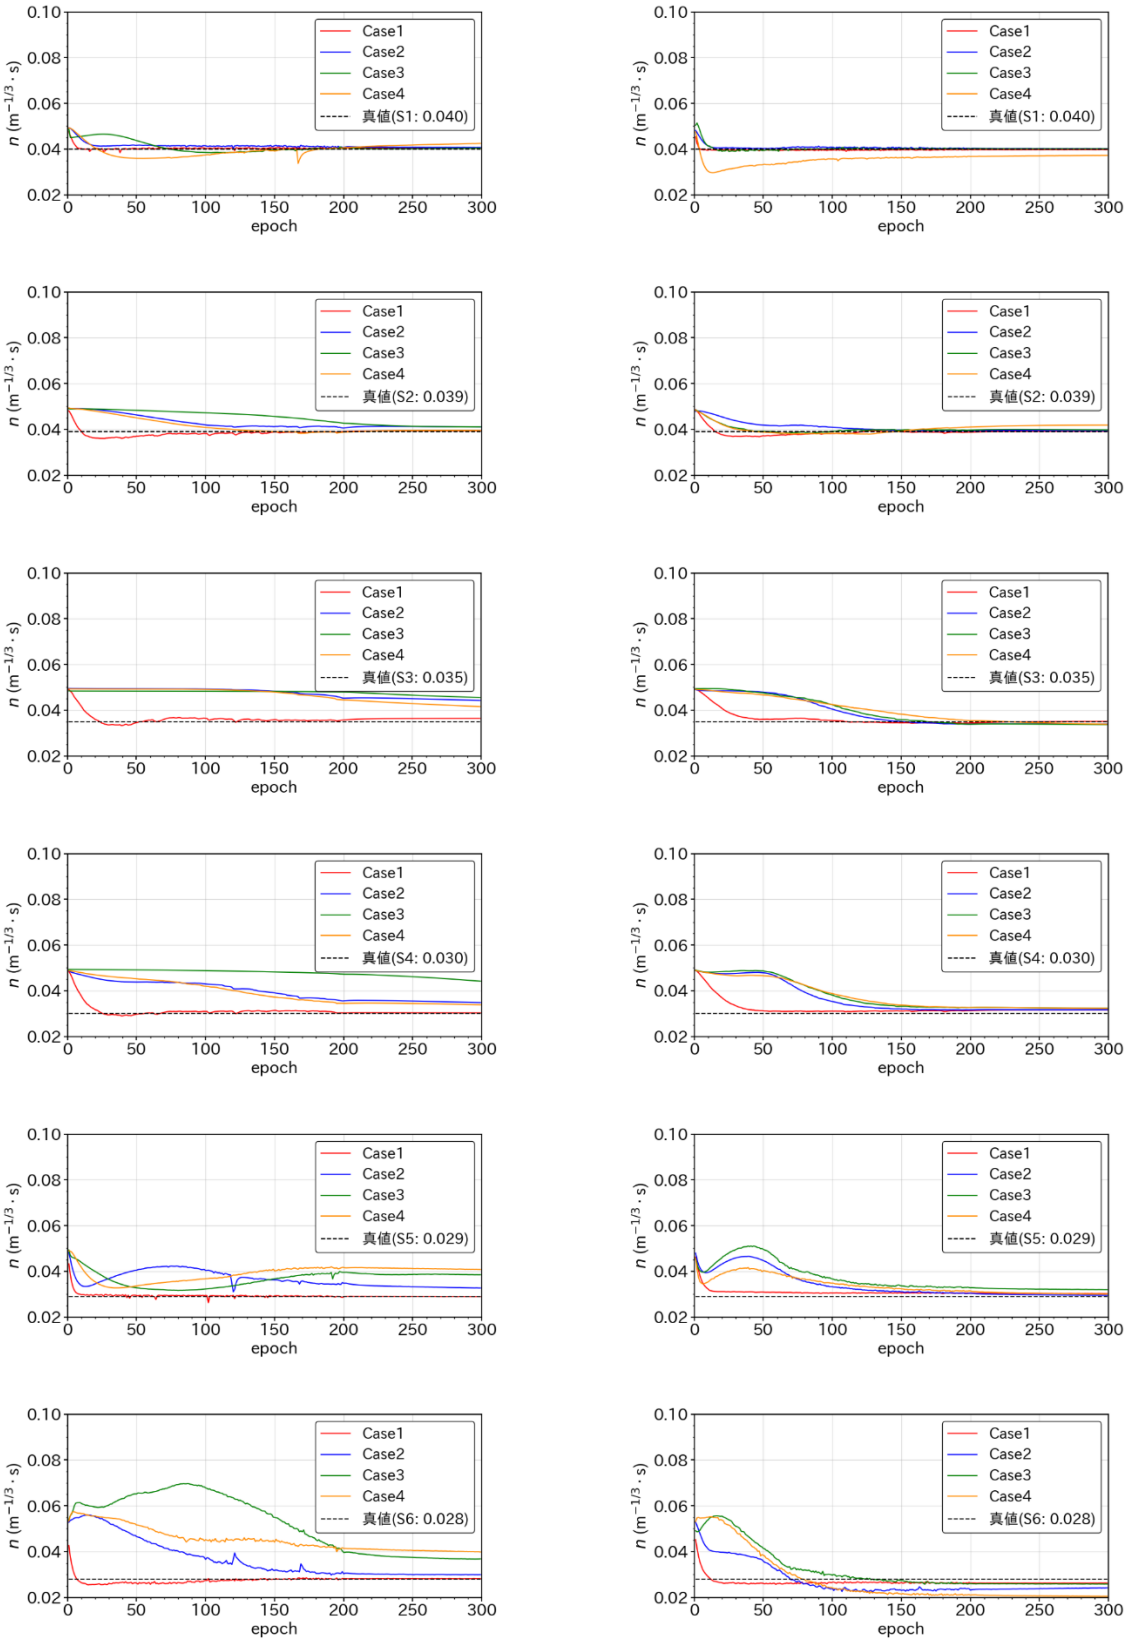

図-4.27　　粗度推定の同化対象データ数依存性

（左：H29 出水，右：H30 出水．上から順に S1～S6 の粗度係数が異なる各区間に対する結果）

表-4.18 各区間の粗度係数推定精度(推定値と誤差率)

対象区間 (推定真値)	Case1		Case2		Case3		Case4	
	H29	H30	H29	H30	H29	H30	H29	H30
Sec.1 (0.040)	0.040 (0.0%)	0.040 (0.0%)	0.041 (2.5%)	0.040 (0.0%)	0.040 (0.0%)	0.040 (0.0%)	0.042 (5.0%)	0.037 (7.5%)
Sec.2 (0.039)	0.039 (0.0%)	0.039 (0.0%)	0.041 (5.1%)	0.039 (0.0%)	0.041 (5.1%)	0.040 (2.6%)	0.039 (0.0%)	0.042 (7.6%)
Sec.3 (0.035)	0.036 (2.9%)	0.035 (0.0%)	0.044 (25.7%)	0.034 (2.9%)	0.045 (28.6%)	0.034 (2.9%)	0.042 (20.0%)	0.034 (2.9%)
Sec.4 (0.030)	0.030 (0.0%)	0.032 (6.7%)	0.035 (16.7%)	0.032 (6.7%)	0.044 (46.7%)	0.032 (6.7%)	0.034 (13.3%)	0.032 (6.7%)
Sec.5 (0.029)	0.029 (0.0%)	0.030 (3.4%)	0.033 (13.8%)	0.029 (0.0%)	0.038 (31.0%)	0.030 (10.3%)	0.041 (41.4%)	0.030 (3.4%)
Sec.6 (0.028)	0.028 (0.0%)	0.026 (7.1%)	0.030 (7.1%)	0.024 (14.3%)	0.037 (32.1%)	0.021 (7.1%)	0.040 (42.9%)	0.021 (25.0%)

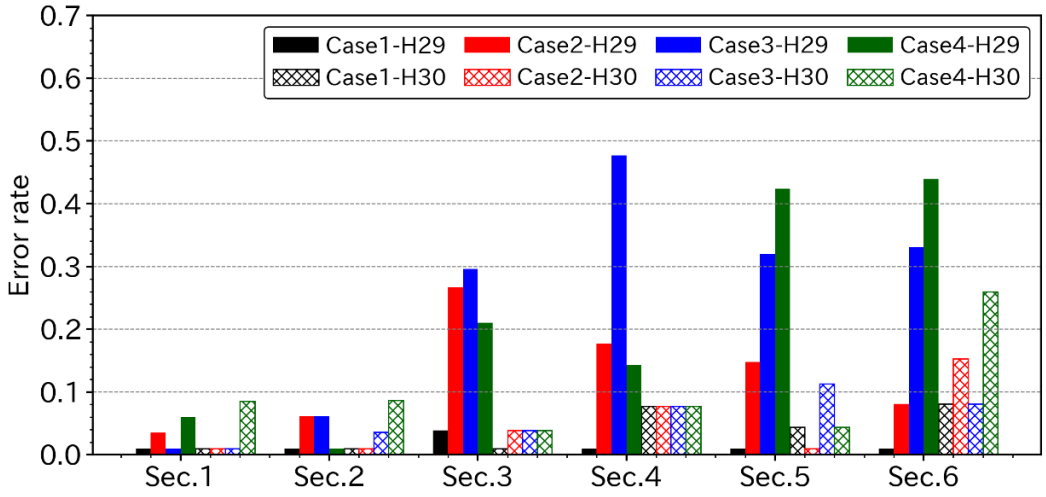

図-4.28 各区間の粗度係数推定精度の比較（誤差率）

表-4.19 学習計算時間の比較（※Intel Xeon w3-2423 / NVIDIA RTX A4000 を利用）

計算ケース	H29 出水 (sec / epoch)	H30 出水 (sec / epoch)
Case1	67.2	82.4
Case2	66.1	84.1
Case3	64.9	81.9
Case4	66.1	82.4

4.5.3　データ同化による縦断水位補正挙動の分析

多地点観測水位のデータ同化による縦断水位の補正挙動を確認するため，前節(4)の粗度係数推定ケースのうち，Case 2（データ同化対象：1km ピッチの計算水位）と Case4（データ同化対象：3 地点の観測水位）で PINNs により同時に最適化された縦断水面形と，各ケースで推定された粗度係数を設定値として有限差分法（FDM）で再計算した縦断水面形の比較を行った．

比較結果を図-4.29～図-4.31 と表-4.20 に示す．図-4.30 が示す通り，PINNs は支配方程式に対して弱拘束のデータ同化手法となるため，Case4 では直接の同化対象となっている観測水位に対し，データ同化後の推定水位が観測水位とほぼ完全に合致する振る舞いとなっている．また，推定された粗度係数を用いた FDM による再計算結果は，H29 出水では総じてピーク部分が過大評価となっている一方，PINNs では観測水位に近い水位に抑えられていることが分かる．さらに H30 出水においては，いずれのケースにおいても，データ同化前と比較して，データ同化により妥当な水位へ補正されている様子が確認できる．

図-4.29 の PINNs と PINNs 推定粗度による FDM 計算結果の水位差分を見ると，特に Case4 の観測値を直接同化するケース（左から 2 列目）において，国包（図-4.29 の横軸 12.6km の箇所）付近のピーク時刻付近を除く範囲での差異が顕著となっている．これは，今回モデル化していない加古川大堰のゲート操作による平常時の水位上昇(T.P. 12.5m に保つ)がデータ同化を通して水位に反映されているためである．一般的な強拘束条件によるデータ同化では，このようにモデル化されていない要因が存在した場合，無理に適合させようとして実情から離れた状態値が推定されてしまい，悪影響が広範囲に及んでしまうことも多い．その点 PINNs では，このような観測値とモデル計算が明らかに整合しない状況に際しては，観測地点付近の水位出力だけを観測値に擦り付けて回避するような挙動となっており，広範囲へ影響する粗度係数推定への悪影響は限定的となることが確認できる．

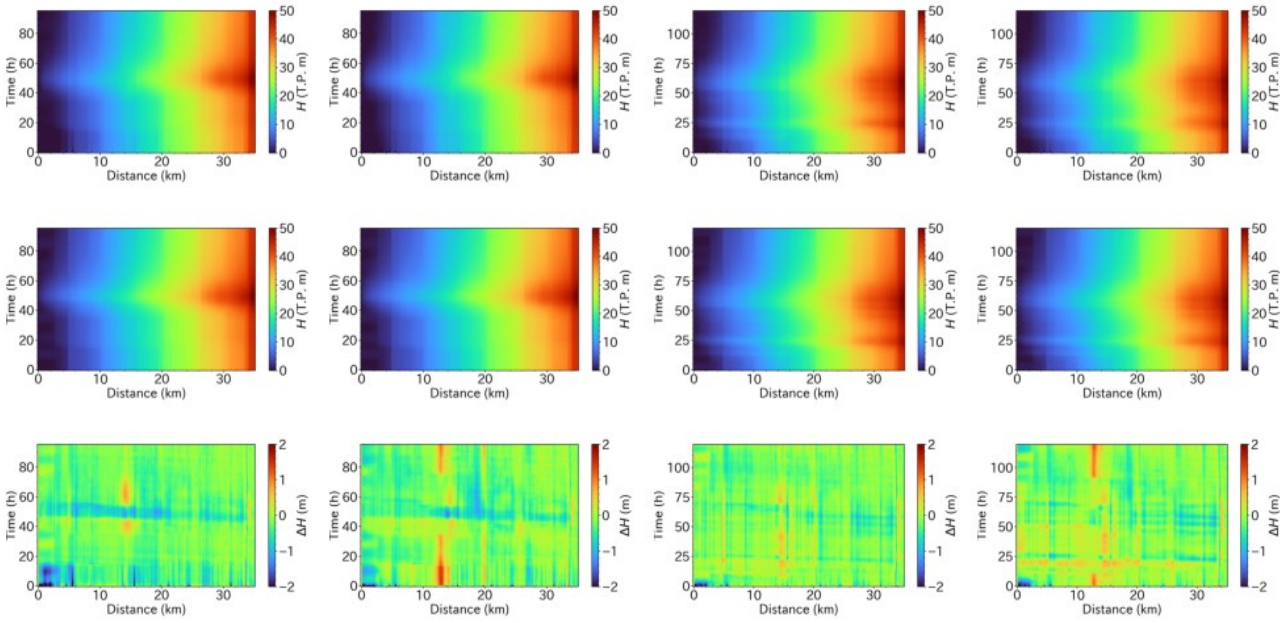

図-4.29　　データ同化後の水位の比較
（上：PINNs，中：PINNs 推定粗度による FDM 計算（PINNs-FDM），下：PINNs と PINNs-FDM の差分．
左から，H29-Case2，H29-Case4，H30-Case2，H30-Case4）

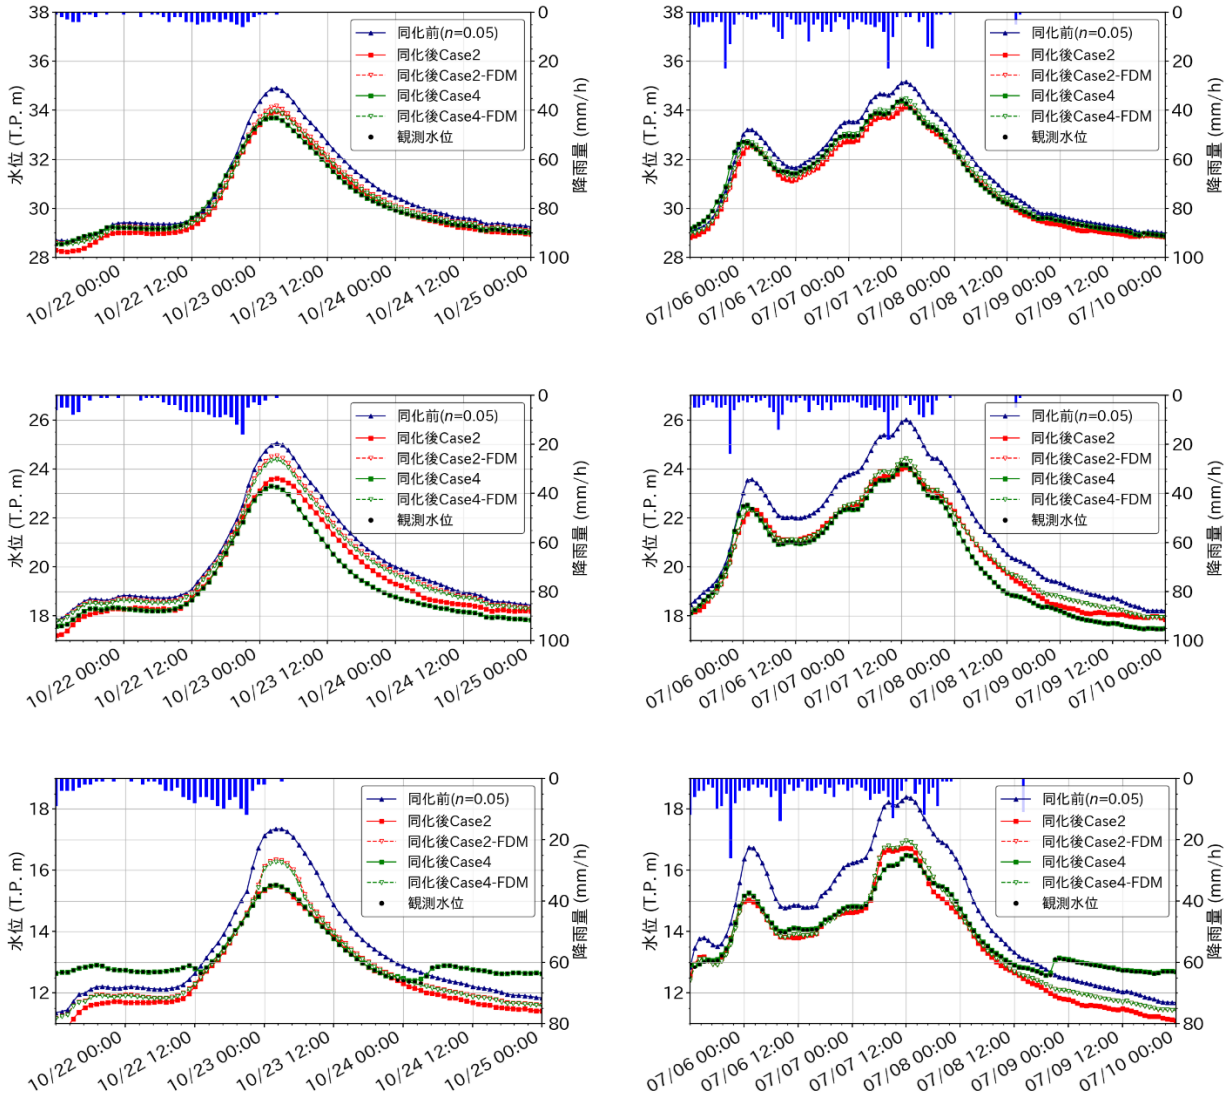

図-4.30　　観測地点（3 地点）におけるデータ同化前後水位の比較
（左：H29 出水，右：H30 出水．上から大門，大島，国包.）

この際，同化対象ではない地点に関しては連続的な水面形となるように同化地点の修正に合わせて少しずつ修正される挙動となっている．今回の検証設定では，水位擦り付け修正の影響範囲は同化対象地点の前後 100～200m 区間程度となっていた．このため逆に水理学的な観点から見た場合，これらの区間では支配方程式を厳密に満していない水面形が出力されていると思われる．弱拘束条件と強拘束条件のどちらが望ましいかはケースバイケースであるが，PINNs では重み係数の調整により，強拘束条件と弱拘束条件のバランスを柔軟に調整することが可能であると期待される．本検証では，観測データ地点がそれぞれ 5km 以上離れていることから，モデル計算値と実測値の本質的な乖離が生じた際に，PINNs データ同化による水面形の局所的な修正が有効に作用するかどうかの検証が難しい．このため，今後はより空間的に密な観測データを有する河川での検証が必要である．

表-4.20 各ケースの観測水位に対する RMSE (m)

計算ケース	国包　(14.2k)		大島　(20.0k)		大門　(27.8k)	
	H29 出水	H30 出水	H29 出水	H30 出水	H29 出水	H30 出水
同化前（$n = 0.05$）	0.97	1.06	0.99	1.23	0.52	0.44
Case2	1.03	0.78	0.40	0.37	0.25	0.27
Case2-FDM	0.85	0.65	0.74	0.45	0.22	0.23
Case4	0.13	0.08	0.02	0.02	0.02	0.01
Case4-FDM	0.85	0.65	0.66	0.45	0.18	0.18

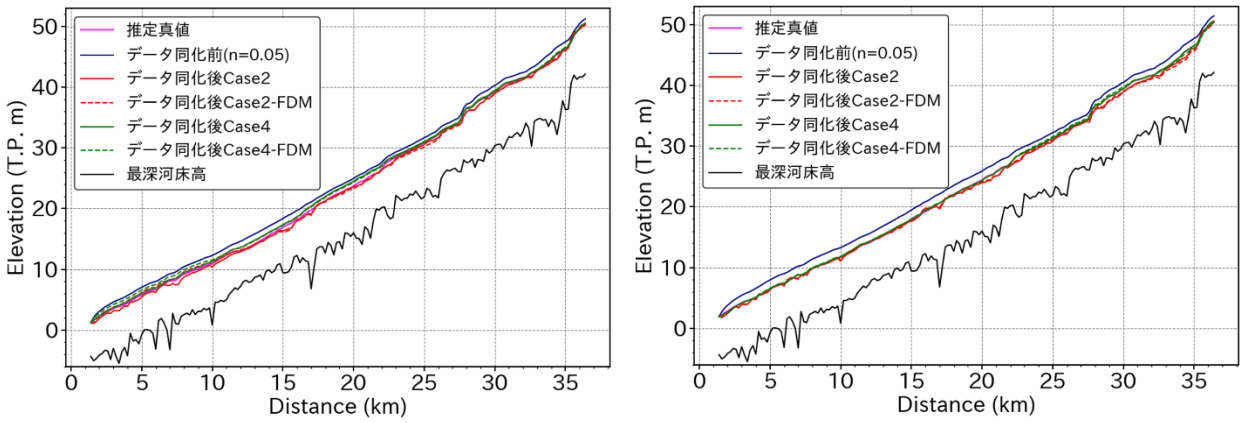

図-4.31　国包ピーク水位時刻における水位縦断図の比較（左：H29 出水、右：H30 出水）

最後に，各ケースの学習曲線と最終 epoch（学習後）の各損失項の値をそれぞれ図-4.32 と表-4.21 に示す．いずれの損失項も学習 epoch とともになだらかに最適化が進んでおり，順解析時と学習曲線の挙動は同様である．なお，200epoch のタイミングで学習率を下げる学習スケジューリングを行っているため，200epoch のタイミングで 1 段階損失が下がるような挙動となっている．

損失項の最終的な大小関係や数値オーダーは各ケースで同様である．PDE 残差と観測誤差項に着目すると，同じ水位観測条件に対する損失にも関わらず，下流端水位や初期条件水位に対する損失項が 10^{-2}~10^{-3} となっているのに対し，観測水位の損失項はオーダーが 10^{-1} と 1 桁大きく，PDE 損失項と同じオーダーとなっている．これは，初期条件や境界条件は PDE 残差と矛盾なく最適化することが可能な一方で，観測誤差と PDE 誤差間にはトレードオフが生じ，同時最適化を目指す際に両者の損失がバランスするためであると考えられる．この結果からも PINNs では重み係数調整により，観測値の信頼性が高い場合とモデルの信頼性が高い場合に応じて，強拘束条件と弱拘束条件の間を柔軟かつ簡便に調整可能であると考えられ，この特性の有効活用に向けた検討は今後の課題である．

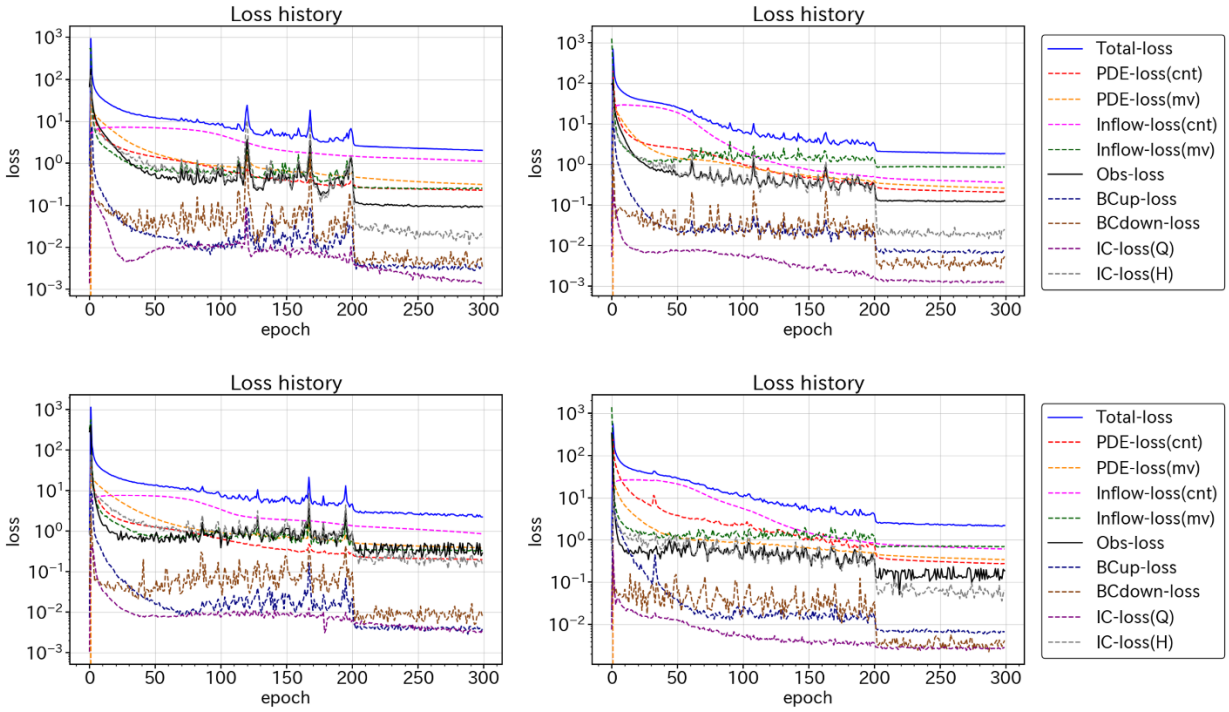

図-4.32　学習曲線の比較（左：H29 出水，右：H30 出水．上：Case2，下：Case4）

表-4.21　学習後の各損失項の値

損失項	Case2		Case4		重み係数設定値
	H29 出水	H30 出水	H29 出水	H30 出水	
Total	2.0×10^{0}	1.8×10^{0}	2.2×10^{0}	2.2×10^{0}	-
PDE（連続式）	2.3×10^{-1}	2.0×10^{-1}	1.9×10^{-1}	2.8×10^{-1}	1×10^{4}
PDE（運動方程式）	3.1×10^{-1}	2.6×10^{-1}	3.8×10^{-1}	3.4×10^{-1}	1×10^{-1}
横流入箇所 PDE（連続式）	1.1×10^{0}	3.6×10^{-1}	8.4×10^{-1}	6.1×10^{-1}	1×10^{0}
横流入箇所 PDE（運動方程式）	2.6×10^{-1}	8.5×10^{-1}	3.2×10^{-1}	7.0×10^{-1}	1×10^{0}
観測値（水位）	9.2×10^{-2}	1.3×10^{-1}	2.8×10^{-1}	1.9×10^{-1}	1×10^{2}
上流端境界条件（流量）	3.3×10^{-3}	8.1×10^{-3}	3.8×10^{-3}	6.7×10^{-3}	1×10^{-3}
下流端境界条件（水位）	3.4×10^{-3}	5.3×10^{-3}	7.9×10^{-3}	4.2×10^{-3}	1×10^{2}
初期条件（流量）	1.6×10^{-3}	1.2×10^{-3}	3.5×10^{-3}	2.8×10^{-3}	1×10^{-3}
初期条件（水位）	1.7×10^{-2}	2.5×10^{-2}	1.5×10^{-1}	6.5×10^{-2}	1×10^{2}

4.6 まとめ

本章では，横流入を含む一般河道断面の一次元不定流解析へ PINNs を適用する方法を検討し，実河川を対象とした多地点水位データ同化の性能を検証した．得られた知見を以下に示す．

- 初期化学習過程の追加等により，横流入を含む一般河道断面の一次元不定流解析に対して，有限差分法と同等の PINNs 順解析が可能となった．これにより，一般的な一次元不定流計算条件に対して PINNs によるデータ同化・逆解析の適用が可能となった．

- 多地点水位データ同化に関して，時空間的に密な計算水位を仮想水位観測値として与えた双子実験ケースでは，設定した各河道粗度係数に対して±0.0〜8.6%の精度で推定可能であった．また，時空間的に疎な実観測水位を対象としたケースでは，観測地点を含む区間では推定真値に対して±2.9〜11.4%の推定精度となった．

- 適切なデータ同化推定に際しては，粗度係数の推定対象とする区間ごとに 2 地点以上の観測地点を有するのが望ましいことが示唆された．

- PINNs による多地点水位データ同化において，データ同化対象地点数による計算量への影響は小さく，データ同化対象地点の変更も損失関数で対象となる残差項を変更するのみと簡便であるため，今後予想される観測態勢の拡充や観測地点の統廃合に対して，効率的なデータ活用が可能である．

- 一般的な強拘束条件によるデータ同化では，モデル化されていない要因に起因して観測値との不整合が生じている場合，無理に適合させようとして実情から離れた状態値が推定されてしまい，悪影響が広範囲に及んでしまうことも多い．この点について PINNs では，観測値とモデル計算が明らかに整合しない状況に際しては，観測地点付近の水位出力だけを観測値に擦り付けて回避するような挙動となり，広範囲へ影響する粗度係数推定への悪影響は限定的となることが確認できた．

今後の課題として，本研究では出水の全期間を用いた PINNs によるデータ同化(逆解析)の基礎的な検証に留まるため，リアルタイム水位予測への適用に向けて，より短い期間の同化ウインドウに対する検証が必要である．また河道粗度係数だけでなく，境界条件の上流端流量や横流入量の誤差推定への応用も重要である．アジョイント法との差別化においては，初期条件と境界条件の事前学習による高速化が PINNs (深層学習モデル) 特有の大きな強みになりうると考えられ，今後の主要な研究課題である．また，学習計算の効率化や，強拘束条件と弱拘束条件の柔軟な調整を可能とするために，各損失項の重み係数の動的な調整手法や最適化設定手法の検討も重要である．

参考文献（第 4 章）

1) 国土交通省：河川砂防技術基準（調査編），
Available: https://www.mlit.go.jp/river/shishin_guideline/gijutsu/gijutsukijunn/chousa/pdf/05.pdf (accessed Dec. 13, 2025).
2) iRIC Software Project: Nays1D+ ソルバーマニュアル,
Available: https://i-ric.org/solvers/nays1dplus/ (accessed Dec. 13, 2025).
3) 中村要介,小池俊雄,阿部紫織,中村和幸,佐山敬洋,池内幸司：粒子フィルタを適用した RRI モデルによる河川水位予測技術の開発, 土木学会論文集 B1(水工学), Vol. 74, No. 5, I_1381-I_1386, 2018, doi: 10.2208/jscejhe.74.5_I_1381.
4) 中村要介,江頭進治,池内幸司,柿沼太貴：RRI モデルと河床変動予測モデルを組み込んだ粒子フィルタによる河川水位予測, 土木学会論文集 B1(水工学), Vol. 76, No. 2, I_859-I_864, 2020, doi: 10.2208/jscejhe.76.2_I_859.
5) 柿沼太貴, 沼田慎吾, 望月貴文, 久保田啓二朗, 中村要介, 小池俊雄, 池内幸司：降雨流出応答特性を考慮した洪水予測のための粒子フィルタ適用手法の検討, 土木学会論文集 B1(水工学), Vol. 78, No. 2, I_403-I_408, 2022, doi: 10.2208/jscejhe.78.2_I_403.
6) 立川康人,藤田翔子,田中裕士,萬和明,市川温：粒子フィルタを用いた実時間流出予測システムの開発と異なる状態量を持つ流出予測システムの精度比較：, 土木学会論文集 B1(水工学), Vol. 74, No. 2, pp. 32–43, 2018, doi: 10.2208/jscejhe.74.32.
7) 藤村健介, 小槻峻司, 山田真史, 塩尻大也と渡部哲史：降雨流出氾濫モデルのアンサンブルデータ同化安定化に関する研究, 土木学会論文集 B1(水工学), Vol. 78, No. 2, I_409-I_414, 2022, doi: 10.2208/jscejhe.78.2_I_409.
8) L. Kong, R. Chen, H. Tang, S. Yuan, Q. Yang, and Q. Ji: Ensemble data assimilation for open channel water level forecasting under flow disturbances: A synthetic data study, *Journal of Hydrology*, Vol. 625, Art. no. 130116, 2023, doi: 10.1016/j.jhydrol.2023.130116.
9) Y. Chen, F. Cao, X. Meng, and W. Cheng: Water level simulation in river network by data assimilation using ensemble Kalman filter, *Applied Sciences*, Vol. 13, No. 5, Art. no. 3043, 2023. doi: 10.3390/app13053043
10) 吉田圭介：浅水流 adjoint モデルによる河床粗度の時間変化の逆推定法に関する基礎的検討, 土木学会論文集 A2(応用力学), Vol. 67, No. 2, I_533-I_540, 2011, doi: 10.2208/jscejam.67.I_533.
11) 吉田圭介：浅水流 adjoint モデルによる複断面河道の河床粗度の逆推定法に関する基礎的検討, 土木学会論文集 B1(水工学), Vol. 67, No. 4, I_1009-I_1014, 2011, doi: 10.2208/jscejhe.67.I_1009.
12) 西口亮太, 田方俊輔, 陰山建太郎, 泉典洋, 関根正人：河川流の逆解析・データ同化に関する基礎的研究, 土木学会論文集 B1(水工学), Vol. 76, No. 1, pp. 30-41, 2020.
13) Irie M, Toi H, Ishizuka M, Tanaka K, Nishida S. 2019. Parameter estimation of a distributed hydrological model using the adjoint method: A case study in the Ibo river watershed, Japan. Presented at the 38th IAHR World Congress September 1–6, 2019 Panama City, Panama; 4692–4701. DOI: 10.3850/38WC092019-1775.
14) 柏田仁, 二瓶泰雄：一次元不定流解析のための新たな水位データ同化手法の開発, 土木学会論文集 B1(水工学), Vol. 73, No. 4, I_595-I_600, 2017, doi: 10.2208/jscejhe.73.I_595.

15) 伊藤毅彦, 柏田仁, 原山和, 金子凌, 片岡智哉, 小野村史穂, 仲吉信人, 二瓶泰雄：改良版 DIEX-Flood と深層学習に基づく河川水位縦断分布の現況再現･将来予測手法の提案, 土木学会論文集 B1(水工学), Vol. 75, No.2, I_217-I_222, 2019.
16) 国立研究開発法人土木研究所 水災害・リスクマネジメント国際センター（ICHARM）：中小河川洪水予測モデル構築マニュアル（Ver. 1）, 2023,
Available: https://www.pwri.go.jp/icharm/research/articles/project-prism_download_j.html
17) 気象庁：防災気象情報のあり方に関する検討会 資料 3-1_3, 2024.
Available: https://www.jma.go.jp/jma/kishou/shingikai/kentoukai/arikata/part3/siryou3-1_3.pdf
18) Raissi, M., Perdikaris, P. and Karniadakis, G. E.: Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, Vol. 378, pp. 686-707, 2019.
19) Hennigh, O., Narasimhan, S., Nabian, M.A., Subramaniam, A., Tangsali, K., Fang, Z., Rietmann, M., Byeon, W., Choudhry, S.: NVIDIA SimNet: An AI-Accelerated Multi-Physics Simulation Framework, In *International Conference on Computational Science*, pp. 447–461. Springer, 2021.
20) G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang and L. Yang: Physics-informed machine learning, *Nat Rev Phys*, Vol. 3, No. 6, pp. 422–440, 2021, doi: 10.1038/s42254-021-00314-5.
21) S. Wang, Y. Teng と P. Perdikaris: Understanding and Mitigating Gradient Flow Pathologies in Physics-Informed Neural Networks, *SIAM Journal on Scientific Computing*, Vol. 43, No. 5, pp. A3055−A3081, 2021, doi: 10.1137/20M1318043.
22) Krishnapriyan, A. , Gholami, A., Zhe, S. , Kirby, R. and Mahoney, M. W. : Characterizing possible failure modes in physics-informed neural networks, *Advances in Neural Information Processing Systems*, 34:26548–26560, 2021.
23) Y. Liu, L. Cai, Y. Chen, B. Wang, Y. Liu, L. Cai, Y. Chen, B. Wang: Physics-informed neural networks based on adaptive weighted loss functions for Hamilton-Jacobi equations, *Mathematical Biosciences and Engineering*, Vol. 19, No. 12, pp. 12866−12896, 2022, doi: 10.3934/mbe.2022601.
24) Feng, D., Tan, Z. and He, Q.: Physics-informed neural networks of the Saint-Venant equations for downscaling a large-scale river model, *Water Resour. Res.*, Vol. 59, e2022WR033168, 2023.
25) 木村延明, 皆川裕樹, 木村匡臣, 福重雄大, 吉永育生: 1 次元非定常流計算を導入した Physics-informed neural networks(PINN)の開水路流れへの適用, 土木学会論文集, Vol. 81, No. 16, 2025.
26) Mahesh, R.B., Leandro, J., Lin, Q.: Physics informed neural network for spatial-temporal flood forecasting, In: Kolathayar, S., Mondal, A., Chian, S.C. (eds) *Climate change and water security*. Lecture notes in civil engineering, Vol. 178, Springer, Singapore, 2022.
27) 阿部真己, 平松裕基, 大石哲也：洪水時の外水氾濫を対象とした Physics-Informed Neural Networks による浸水把握の試み, AI・データサイエンス論文集, Vol. 4, No. 3, pp. 638–645, 2023.
28) Y. Tian, S. Ding, L. Huang, G. Su, and J. Chen: Physics-informed neural networks for solving the two-dimensional shallow water equations with terrain topography and rainfall source terms, *Water Resources Research*, Vol. 61, No. 9, e2025WR040052, 2025. doi: 10.1029/2025WR040052.
29) X. Qi, G. A. M. de Almeida, and S. Maldonado: Physics-informed neural networks for solving flow problems

modeled by the 2D shallow water equations without labeled data, *Journal of Hydrology*, Vol. 636, Art. no. 131263, 2024, doi: 10.1016/j.jhydrol.2024.131263.

30) 大原由暉, 茂木大知, 村松正吾, 早坂圭司, 安田浩保：交互砂州上の平面二次元流れにおける支配方程式を制約とした深層学習の適用性, 土木学会論文集, Vol. 81, No. 16, 2025, doi: 10.2208/jscejj.24-16171.

31) Y. W. Bekele: Physics-informed neural networks with curriculum training for poroelastic flow and deformation processes, 2024, arXiv: arXiv:2404.13909. doi: 10.48550/arXiv.2404.13909.

32) Y. Guo et.al.: Long-term simulation of physical and mechanical behaviors using curriculum-transfer-learning based physics-informed neural networks, 2025, arXiv: arXiv:2502.07325. doi: 10.48550/arXiv.2502.07325.

33) M. A. Nabian, R. J. Gladstone and H. Meidani: Efficient training of physics-informed neural networks via importance sampling, *Computer-Aided Civil and Infrastructure Engineering*, Vol. 36, No. 8, pp. 962−977, 2021, doi: 10.1111/mice.12685.

34) L. D. McClenny and U. M. Braga-Neto: Self-adaptive physics-informed neural networks, *Journal of Computational Physics*, Vol. 474, p. 111722, 2023, doi: 10.1016/j.jcp.2022.111722.

35) Gnanasambandam, R., Shen, B., Chung, J., Yue, X., and Kong, Z.: Self-scalable tanh (stan): Multi-scale solutions for physics-informed neural networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45.12, 15588-15603, 2023.

36) 国土交通省 近畿地方整備局 姫路河川国道事務所：参考資料-1：瀬と淵の変遷整理と河床変動予測, 第 3 回加古川河道整備検討会，2005.

第５章　結論

本研究では，河川水位予測を対象とした洪水予測技術の高度化を目指し，AI モデルと水理モデルを統合したハイブリッド予測手法に関する改良と開発を実施した．本研究で得られた主たる結論は以下の通りである．

第１章では，序論として本研究の背景，目的，および論文の構成を述べた．

第２章では，特定地点の河川水位予測（流出予測）の性能向上に向けて，AI モデルと水理モデルを併用した主要なハイブリッド手法について整理し，分布型流出モデルである RRI モデルで算出した主要地点流量を深層学習モデルの入力として活用するハイブリッド手法の改良を検討した．

効果的なモデル構築方法とハイブリッド入力に対する DNN 構造の改良を主題として検討した結果，ハイブリッドモデルの構築に際しては，予測対象地点近傍の計算流量よりも，支川を含む上流地点の計算流量を DNN モデルへ追加入力する構成の方が良好な予測精度を示すことが分かった．これより，上流側の各小流域に対する流出量を早期に DNN へ伝えることが本ハイブリッド構成の予測精度向上において本質的に重要であると考えられる．また，RRI モデル自体の予測精度は最終的なハイブリッドモデル出力の予測精度に直接的な影響は少ないことが分かり，RRI モデルの計算結果に内在する系統バイアスなどは，DNN が内部的に補正した上で最終予測出力に利用されている可能性が高いことが示唆された．RRI モデルのパラメータキャリブレーションに要する工数を抑えられることから，これは実務利用において有用な特性である．

DNN 構造に関しては，残差補正構造とアンサンブル構造を両立した DNN 構造を用いることにより，単独利用時や単純なアンサンブル構成に対して，上位互換の予測性能を示すことが確認された．特に同程度の出水規模が学習データに含まれる場合は少量の学習データでも高い予測精度を示すことが確認でき，AI モデル単独利用時に見られる限界がハイブリッド活用により改善可能であることが示唆された．一方で，学習データセットと出水規模が大きく異なる洪水や小規模流域に対しては AI モデル単独利用時から有意な改善効果が見られないことも分かり，本ハイブリッド手法の有効範囲に関する知見が得られた．

本検討で得られたこれらの知見は，RRI モデル固有の特性に依存するものではないため，他のあるいは既存の流出解析モデル資産を活用する場合においても，本ハイブリッド予測モデル構成の採用と展開が期待できるものである．

第 3 章では，上記のハイブリッド流出予測技術をリアルタイム予測システムで活用するための改良について検討した．具体的には，多地点同時予測方式によるモデルの軽量化と，出水時に想定される観測水位データ欠損の悪影響を低減する方法について検討を行った．

その結果，多地点同時予測方式に拡張した場合にも，単地点予測方式時と比較して顕著な予測精度の劣化は発生しないこと，ならびにハイブリッド化による予測精度の向上効果が有意であることを確認した．ただし，ハイブリッド化による精度向上効果は，集水面積が大きく流出経路が複雑となる下流域でより明瞭であり，集水面積の小さい上流域では効果が小さいことが示唆された．観測水位データ欠損に対して

は，AI 単独モデル利用時よりもハイブリッド構成の方が頑健であることが示され，欠損データを模擬してマスクされた学習データを学習することにより，データ欠損時の精度低下影響を抑制可能であることが明らかとなった．ただし，データ欠損が無い場合にはマスクの無い通常データで学習したモデルの方が高精度を示したため，実利用においては欠損状況に応じて両モデルを切り替える運用が望まれる．

第 4 章では，縦断的な予測水位の計算に必要となる河道モデルに対して，簡便且つ効率的な多地点水位データ同化の実現に向け，物理法則を組み込んだ深層学習手法である PINNs の適用を検討した．

河道モデルとして広く用いられている一次元不定流式を対象に，現状で先行事例が存在しない一般的な条件下での順解析への適用を試行した結果，適切な予測結果へ安定して収束させるためには，初期化過程の導入，入力変数のフーリエ特徴量埋め込み，および Stan 活性化関数の適用が必要となることが分かった．さらに横流入量を適切に反映させるためには，横流入箇所の PDE サンプリング点を本川の流下方向に密に取る必要があることが分かった．これらの工夫を適用することで，既往出水波形に対して既存の FDM と同等の計算精度が得られることが示された．

次に，粗度係数と縦断水面形の推定・補正を目的とした多地点水位データ同化・逆解析機能に対する検討を実施した．実河川の既往出水事例を用いた双子実験の結果，同化対象の観測点が十分に密であれば，区間別に設定された粗度係数を約 5%以下の精度で逆解析可能であることが分かり，観測点が疎なケースにおいても，観測データが直接影響する区間においては約 10%以下の精度で逆解析が可能であることが示された．本手法は支配方程式に対して弱拘束型の同化手法となり，同化対象地点においては PDE 損失よりも観測水位データへの適合性が優先された水位補正の振る舞いが見られるが，PDE 損失を犠牲とした水位補正影響は対象地点前後の 100m 程度の区間に限定されることが示された．また，4〜5 日程度の全出水期間を対象としたデータ同化において，計算時間は同化対象地点数の影響をほとんど受けないことが明らかとなり，PINNs ではデータ同化対象地点の変更が損失関数の残差損失項の修正のみと簡便である特性と合わせて，今後予想される観測態勢の拡充や観測地点の統廃合に対し，縦断水位予測への効率的なデータ活用が期待できることが示された．

最後に，本研究で扱うことができなかった今後の課題と展開について述べる．

ハイブリッド流出予測について，本研究は予測降雨の誤差を考慮しない完全予測降雨条件下での検討に留まるため，実利用に向けては予測雨量誤差の影響軽減手法，あるいはアンサンブル予測降雨を用いた不確かさ評価手法の検討は重要課題の 1 つである．また，本検討では既存の流出解析モデルを AI 予測モデルで活用するハイブリッド構成を検討したが，AI モデルも含めた複数の流出予測モデル結果を人間的な視点から統合判断するメタ AI モデルも有望と考えられ，今後の研究対象である．

河道 PINNs モデルについては，本研究では先行研究が限定的であることから基礎的な検討が主となった．そのため，実用化に向けた改良検討の余地が多く残されている．具体的には，予測運用に向けた同化ウインドウの感度分析，事前学習による計算速度の向上，損失重みの動的制御による計算の効率化・安定化，などが挙げられる．

洪水予測システムとしての実用化の観点からは，両モデルを連動した予測システムとしての適用検証や，河川水位予測のみでなく浸水予測技術との連携が今後の重要課題である．

謝辞

本研究を実施するにあたり，数多くの方々のご支援を頂きました．

大阪大学大学院工学研究科 入江政安教授には，民間企業に勤務しながら研究を遂行する著者の立場をご理解頂いた上で，研究内容だけでなく，研究活動に対する考え方や取り組み方など，多大なご助言とご指導を賜りました．また研究室生活において常に暖かなお心遣いを頂きました．ここに深甚なる感謝の意を表します．

大阪大学大学院 中谷祐介准教授には，本研究の副査をして頂くとともに，ゼミ等で数多くの有益なご助言を頂きました．また，折に触れて拝聴した指導学生の興味深い研究内容を通して，研究活動の楽しさを改めて勉強させて頂きました．ここに深く感謝の意を表します．

大阪大学大学院 荒木進歩教授には，本研究の副査をして頂き，研究内容について数多くの貴重なご助言を頂きました．また筆者の研究活動に際し，折に触れて暖かなお心遣いとご支援を賜りました．ここに深く感謝の意を表します．

大阪大学大学院 土井健司教授，飯田克弘准教授，貝戸清之准教授，葉健人助教，佐々木勇弥助教には，社会システム学ゼミ等において研究に関する有益なご助言を数多く賜りました．ここに深く感謝の意を表します．

大阪大学大学院みず工学領域の研究室の学生の皆様には，社会人学生として研究室へ顔を出す機会が少なかった著者に終始暖かく接して頂きました．特に永野さん，鹿島さん，Afiqah さん，崔さん，中原さんには，研究室に関連して様々なご支援を頂きました．ここに深く感謝の意を表します．

株式会社ハイドロ総合技術研究所 長谷川誠社長には，大学院博士後期課程で学ぶ機会を与えて頂くとともに，在学期間中の研究に対し，格別のご配慮を賜りました．ここに深甚なる感謝の意を表します．同社 井口真生子取締役には，本研究の遂行に際して格別のご配慮を賜るとともに，本研究内容に関する数多くのご助言を頂きました．ここに深く感謝の意を表します．また職場の同僚の皆様には，著者が社会人博士として働く上で様々なご支援を頂きました．ここに深く感謝の意を表します．

最後に，著者の研究生活を温かく見守り支えてくれた妻と家族に心より感謝の意を表します．