

ICT浚渫工におけるマルチビーム測深データを対象とした 深層学習によるノイズ処理の検討

辰巳大介*・小川雅史**

要 旨

少子高齢化による将来的な労働力不足に備え、建設工事の生産性向上が喫緊の課題となっている。港湾分野における生産性向上の取り組みの一つとしては、浚渫工へマルチビーム測深の導入が進められて来た。マルチビーム測深は、従来のシングルビーム測深に比べて多量の点群データを短時間に取得可能であり、面的な計測が行える。一方で、取得する点群データが多いため、マルチビーム測深ではノイズ処理に要する時間が長くなる。ノイズ処理の大半は時間と手間を要する手動処理であり、マルチビーム測深による更なる生産性向上のためには、ノイズ処理時間の短縮が重要である。

本研究では、機械学習の一つである深層学習を応用し、過去のデータから学習して効率的なノイズ処理プログラムを作成する手法を開発した。さらに、実際の浚渫工のマルチビーム測深データを利用して、開発したノイズ処理プログラムの学習プロセス及び推論プロセスの精度検証を実施した。精度検証の結果から、深層学習によって作成されたノイズ処理プログラムは、比較的短い時間で一定の精度においてノイズ処理ができることを確かめた。また、教師データの作成方法及び学習プロセスのパラメータ設定について感度分析を行い、学習を効率的に実行するための要点をとりまとめた。

キーワード：ICT浚渫工，マルチビーム測深，ノイズ処理，深層学習，i-Construction

* 港湾研究部 港湾施工システム・保全研究室 室長

** 前 港湾研究部 港湾施工システム・保全研究室 主任研究官（現 中国地方整備局 港湾空港部）

目 次

| | |
|---------------------------|----|
| 1. はじめに | 1 |
| 1.1 背景と目的 | 1 |
| 1.2 既往研究 | 1 |
| 2. 深層学習によるノイズ処理プログラムの開発 | 2 |
| 2.1 プログラムの全体構成 | 2 |
| 2.2 データの前処理 | 4 |
| 2.3 学習プロセス | 5 |
| 2.4 推論プロセス | 6 |
| 3. 開発したノイズ処理プログラムの精度検証 | 6 |
| 3.1 使用した教師データと精度検証用テストデータ | 6 |
| 3.2 精度検証の結果 | 8 |
| 3.3 考察 | 17 |
| 4. おわりに | 19 |
| 4.1 主要な結論 | 19 |
| 4.2 今後の課題 | 19 |
| 謝辞 | 19 |
| 参考文献 | 19 |

1. はじめに

1.1 背景と目的

少子高齢化に伴う労働力不足においても持続的な経済成長を実現するため、国土交通省では、2016年度より生産性向上の取り組みを進めている。その中でも、建設分野における生産性向上の取り組みは i-Construction と呼ばれ、ICT 施工の工種拡大、施工時期の平準化、BIM/CIM の導入、新技術・新工法・新材料の利活用等が実施されて来た。

港湾分野における i-Construction の取り組みの一例として、マルチビーム測深が 2017 年度から浚渫工へ導入された。また、2021 年度からは、海上地盤改良工（床掘工・置換工）にもマルチビーム測深が導入されている¹⁾。

マルチビーム測深は、測量船の左右方向に指向性の高い音響ビームを照射し、船の進行とともに一括で多数点の水深値を計測する測深技術である。従来のシングルビーム測深が送受波器直下の水深情報を線で測深しているのに対し、マルチビーム測深は面的に詳細な海底地形を測深できる。

一方で、シングルビーム測深やマルチビーム測深等の音響測深技術は、海中の気泡等の浮遊物や魚群等の影響で、実際の海底の水深とは異なる値であるノイズも計測してしまう。マルチビーム測深は、面的計測を短時間で可能にする一方で、取得する点群データが膨大となるため、ノイズ処理に要する時間が長くなる。

図-1 は、2018 年度に実施中又は実施済みの ICT 浚渫工試行工事の受注者を対象とした、アンケート調査の結果である²⁾。ICT 方式（マルチビーム測深）と従来方式（同工事においてシングルビーム測深をした場合の想定）の二者において、作業内容ごとに所要時間を比較したもの

である。

④計測時間は、従来方式の 10.8 時間に対し ICT 方式は 7.3 時間となり、マルチビーム測深の導入により平均 3 時間以上、計測時間が短縮している。一方、⑥データ解析時間は、従来方式の 30.6 時間に対し ICT 方式は 36.1 時間と増加しており、これはマルチビーム測深のノイズ処理の増大によるものと考えられる。また、⑥データ解析時間は、①測量船への機材機装から⑩検査・報告用資料の作成（水路測量）までの 11 の作業の中で 2 番目に多くの時間を要している。

以上のことから、マルチビーム測深による更なる生産性向上を図るためには、ノイズ処理を中心とするデータ解析時間の短縮が重要であると考えられる。そこで本研究は、マルチビーム測深データのノイズ処理時間を短縮するため、深層学習による自動的なノイズ処理プログラムの開発を目的とする。マルチビーム測深データのノイズ処理は、技術者の手動・目視で行われている部分が多いため、自動的なノイズ処理プログラムを開発できれば、データ解析時間の短縮が期待される。

1.2 既往研究

深層学習による自動的なノイズ処理プログラムの開発にあたり、マルチビーム測深データのノイズ処理に関する既往研究を調査した。

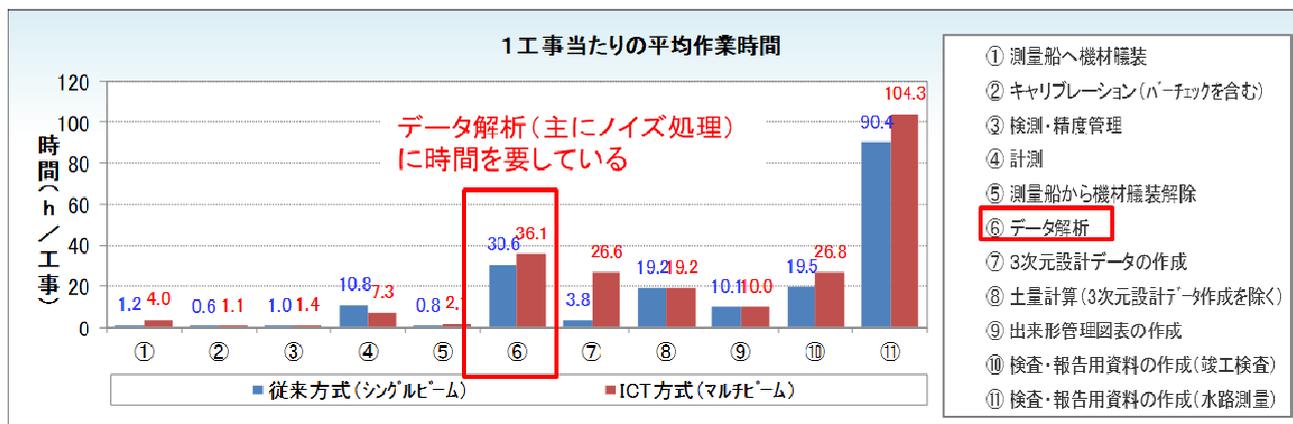


図-1 浚渫工における ICT 方式と従来方式の作業時間の比較²⁾

楠³⁾は、着目する水深値の隣接8地点の水深値の平均値及び標準偏差を計算し、着目する水深値の平均値からのズレの大きさと隣接8地点の標準偏差の比較から、着目した水深値が適正か判断するプログラムを開発した。また、巻ら⁴⁾は、船舶の動揺がノイズ発生の一つの要因であることに着目し、より高精度な動揺補正法を開発した。さらに、住吉ら⁵⁾及び長田ら⁶⁾は、米国で開発されたCUBE処理について調査を行った。なおCUBE処理とは、マルチビーム測深の特性である、装置直下と斜め下方向の取得データの品質の違いを考慮した統計的アルゴリズムである。

上記の研究のノイズ処理は、人がノイズ処理プログラムの計算方法を予め決定し、その上で過去のデータに基づき、ノイズ処理プログラムの閾値・パラメータ等を試行錯誤して同定したものと見なすことができる。これに対し、機械学習によるノイズ処理とは、ノイズ処理プログラムの計算方法及び閾値・パラメータ等を、過去のデータから学習して自動的に作成するものである。

マルチビーム測深データのノイズ処理に機械学習を適用した既往研究としては、例えば Le Deunf ら⁷⁾と Stephens ら⁸⁾が挙げられる。Le Deunf らは、機械学習を含むノイズ処理方法全般のレビューを行った。Stephens らは、マルチビーム測深データを3次元の離散データとして取り扱い、機械学習の1つである深層学習によるノイズ処理プログラムを開発した。

以上のとおり、マルチビーム測深データのノイズ処理については、機械学習を利用しない手法、利用する手法のどちらについても先行的な研究が行われている。しかし、ノイズ処理を完全に自動化するプログラムは開発されておらず、手動・目視によるノイズ処理結果の確認は不可欠である。また、機械学習を利用して、ノイズ処理プログラムの計算方法及び閾値・パラメータ等を、自動的に作成・最適化する試みは未だ少ない状況である。

2. 深層学習によるノイズ処理プログラムの開発

2.1 プログラムの全体構成

(1) マルチビーム測深データの現行のノイズ処理手法

深層学習によるノイズ処理プログラムの位置付けを明確にするため、まず、現行のノイズ処理手法について説明する。

図-2は、マルチビーム測深データの現行のノイズ処理の手順を示したものである。現地作業では、水深値に加えて、潮位、ヘディング（船首の方向）、船舶の動揺、音速度のデータも観測・記録される。これらの計測結果は、マルチビームソナー機器の固有のフォーマットで記録される。

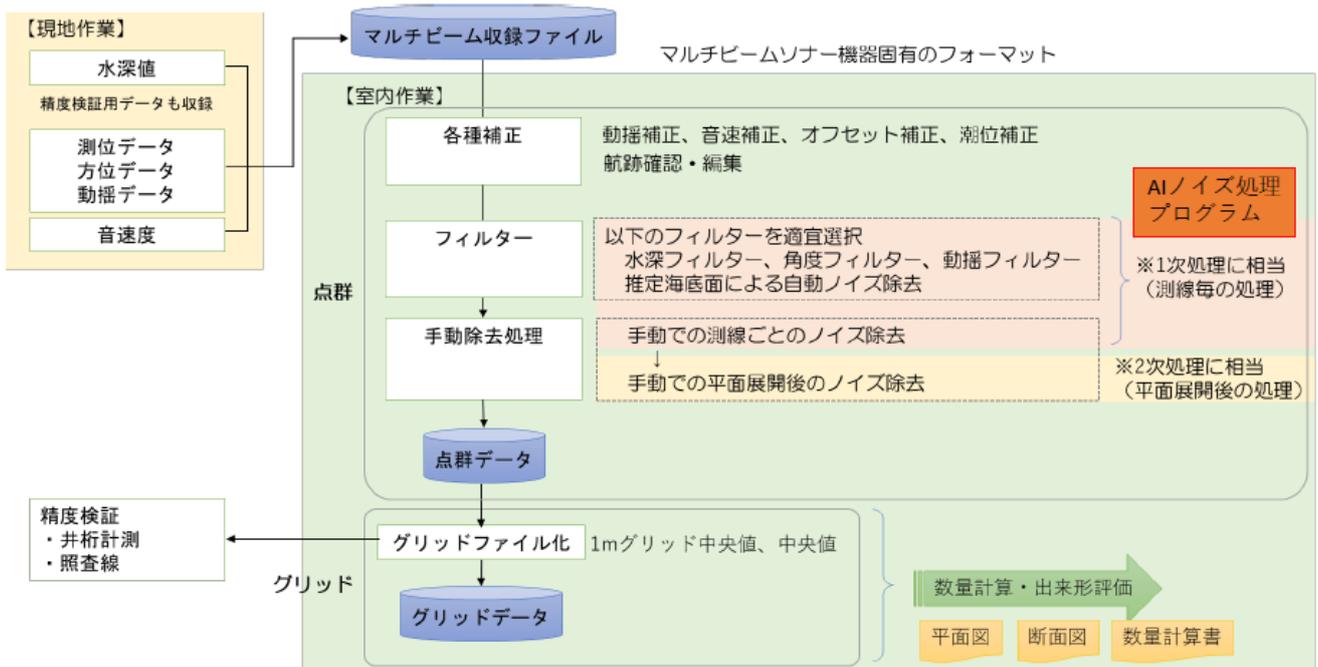


図-2 マルチビーム測深データの現行のノイズ処理手法

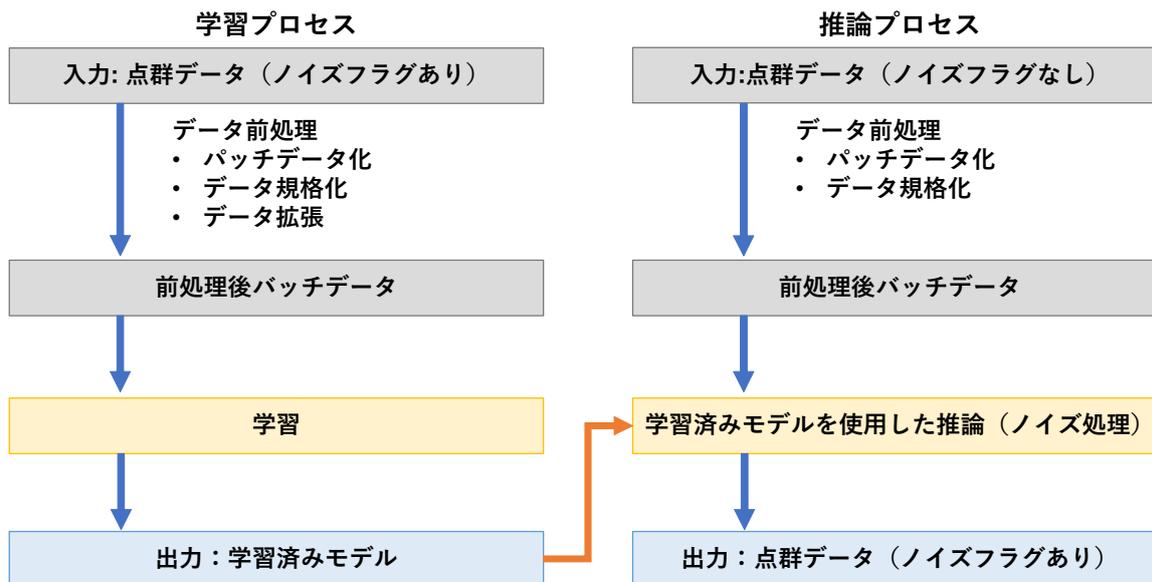


図-3 本研究で開発したノイズ処理プログラムの全体構成

ノイズ処理は、始めに動揺補正、音速補正、オフセット補正、潮位補正等を行い、次にフィルター処理を行う。フィルター処理をした後でも、海中の気泡等の浮遊物や魚群等の影響で実際の海底の水深と異なる値を計測した結果は、ノイズとして残っている。このため、測線単位で測深データのプロファイルを図化し、技術者が手動でノイズを判別・除去する。さらに、測線単位のプロファイルではノイズかどうか迷う場合もあり、そのような場合は、複数の測線のプロファイルを比較表示（平面展開）して総合的に判断することになる。すなわち、測線ごとのプロファイル表示と平面展開を交互に繰り返しながらノイズ処理が手動で行われる。

(2) 深層学習によるノイズ処理プログラムの全体構成

本研究で開発したノイズ処理プログラムは、機械学習の1つである深層学習を利用して、図-2の「フィルター処理」と「測線ごとのノイズ除去」を自動的に実行するものである。なお、「平面展開後のノイズ除去」は、本研究のノイズ処理プログラムの開発対象に含めなかった。その理由は、平面展開後のノイズ除去を行うためには、測深データを3次元のまま取り扱う必要があり、メモリーと計算量が膨大な量となってしまう、汎用的な計算機では処理が困難となるからである。

本研究で開発したノイズ処理プログラムは、図-3のとおり、学習プロセスと推論プロセスの2つの部分から構成される。

学習プロセスの入力データは、過去に手動でノイズ処

理を行い、ノイズである測深データがノイズフラグにより明示されているデータである。入力データは前処理を行い、前処理が完了したデータが深層学習に用いられる。そして、深層学習を行い、推論に使用する学習済みモデルを作成（出力）する。

推論プロセスの入力データは、学習プロセスの入力データとは異なり、どの測深データがノイズか不明なのでノイズフラグは無い。学習プロセスと同様に前処理を行った後、学習済みモデルに入力すると、ノイズフラグの付いた測深データが出力される。

(3) 開発したプログラムの特徴

マルチビーム測深データは3次元の点群データであり、それぞれの測深データが平面座標（X座標及びY座標）、水深値（Z座標）、測線番号、ピング番号、ビーム番号の情報を格納している。そのため、3次元の点群データをそのまま機械学習で取り扱おうとすると、膨大なメモリーが必要となり、また計算量も相当に多くなる。

そこで、本研究では、本来は3次元の点群データである測深データを2次元の画像データとして取り扱うことで、プログラム実行に必要なメモリーや計算量を削減し、汎用的な計算機でも処理が行えるように工夫した。

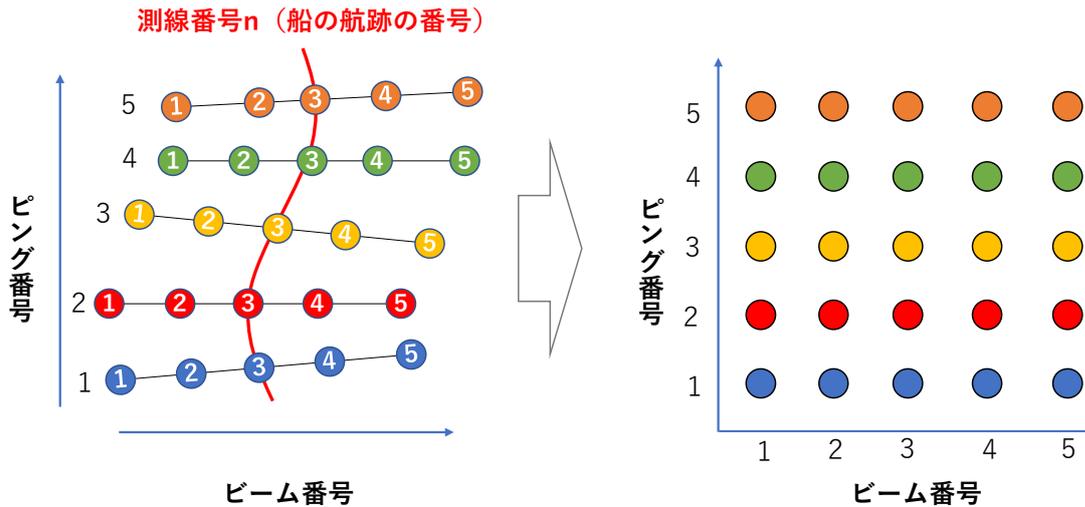


図-4 3次元の点群データを2次元の画像データへ変換する模式図

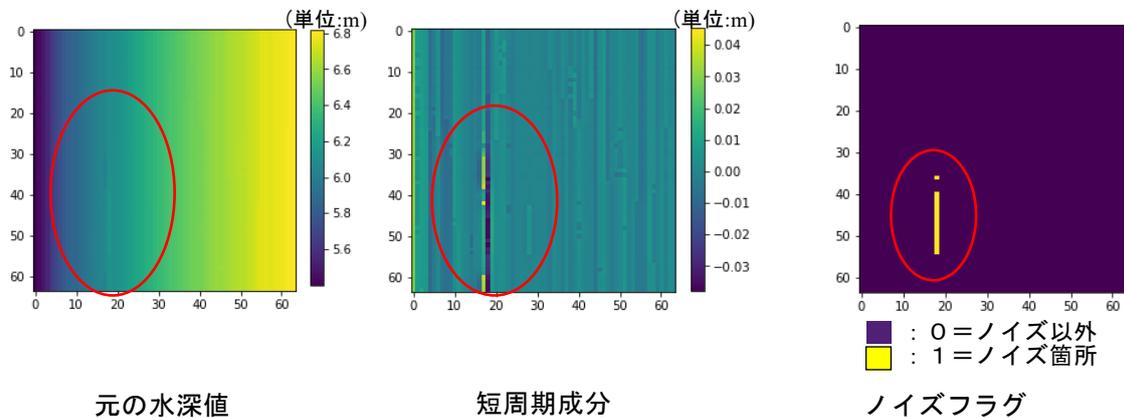


図-5 データ規格化の模式図

3次元の点群データを2次元の画像データへ変換する模式図は、図-4のとおりである。マルチビーム測深データは、測線ごとにビーム番号とピング番号で整理することができる。ビーム番号は、1回に発射する複数本のビームのうち、何本目のビームで取得したデータであるかを示す。ピング番号は、一定の発振間隔で発射するビームのうち、何回目に発射したビームであるかを示す。

図-4のとおり、測量船の航跡は必ずしも直線では無いため、測深データは格子状に等間隔で取得されているものではない。しかし、ビーム番号とピング番号で概ねの位置関係は固定されていることから、測深データをビーム番号とピング番号で格子状に整列した行列と見なすことができる。すると、測深データは、ビーム番号とピング番号で格子位置を指定され、水深値を輝度（濃淡）とする2次元の画像データとして取り扱うことが可能である。

なお、このように測深データを2次元の画像データとして取り扱うことは、メモリーや計算量を削減できるだけでなく、画像処理分野で開発・利用されている機械学習の各種の知見を適用できるという長所もある。

2.2 データの前処理

(1) パッチデータ化

機械学習では、学習プロセスを効率的に実行するため、入力データを一定量のまとまりに分割して学習を行うことがあり、「ミニバッチ学習」と呼ばれる。本研究でもミニバッチ学習を採用する。

ミニバッチ学習を行うため、データの前処理の第1段階として、入力データである測深データを64行64列のパッチデータへ分割する。

(2) データ規格化

測深データには、実際の海底地形を反映した空間的に長周期で変化する起伏と、ノイズによる短周期で変化する起伏が重畳する。長周期及び短周期で変化する起伏が重畳した測深データを、そのままの状態でも学習プロセスに入力しても学習が非効率である。

そこでデータの前処理の第2段階として、実際の海底地形を反映した長周期成分を除去し、ノイズによる短周期成分のみを抽出する、データ規格化を行う。データ規格化は、画像処理分野のエッジ検出で使用されるガウシアンフィルターを採用する。パッチデータにガウシアンフィルターをかけて、元の水深値を引いて残差を抽出することにより、ノイズによる短周期成分が強調され、正常な水深値はゼロとなる入力データが作成できる。

図-5は、データ規格化の模式図である。左側が元の測深データ、中央がガウシアンフィルターをかけて元の水深値を引いた残差である。参考として右側には、手動で判別したノイズの位置を黄色く示す。右側の図のノイズに該当する位置について、左側及び中央の図を確認すると、元の測深データ（左側）ではノイズが不鮮明であるが、データ規格化を行った中央の図ではノイズの位置が鮮明化されている。

なお、感度分析のために、ガウシアンフィルターの大きさは、3行3列、5行5列、10行10列、30行30列の4種類を比較した。

(3) データ拡張

教師データの種類を増やして頑健性の高いモデルを作成するため、データの前処理の第3段階としてデータ拡張を行う。なお、データ拡張は学習プロセスの前処理のみで行い、推論プロセスの前処理では実施しない。

データ拡張の手順としては、1回の学習が終了してパラメータを更新し、次の学習を始める前に、入力するパッチデータをランダムに上下又は左右反転させる。

2.3 学習プロセス

本研究で開発したノイズ処理プログラムは、画像処理分野で実績のあるCNN（Convolutional Neural Network）に基づくプログラムである。特にCNNの中でも、ノイズ除去に特化した計算モデルであるDnCNN（Denoising Convolutional Neural Network）⁹⁾を参考に、プログラム開発を行った。なお、CNN及びDnCNNは入力層と出力層の間の中間層が複数あるため、機械学習の中でも深層学習に分類される。

図-6に、学習プロセスの計算手順を示す。データの前処理で説明したとおり、測深データはパッチデータに分割され、ガウシアンフィルターをかけて元の水深値との残差が抽出される。

前処理の完了したパッチデータは、始めに入力層に入れられる。入力層は畳み込み層（Conv: Convolutional Layer）であり、活性化関数はReLU（Rectified Linear Unit）¹⁰⁾である。

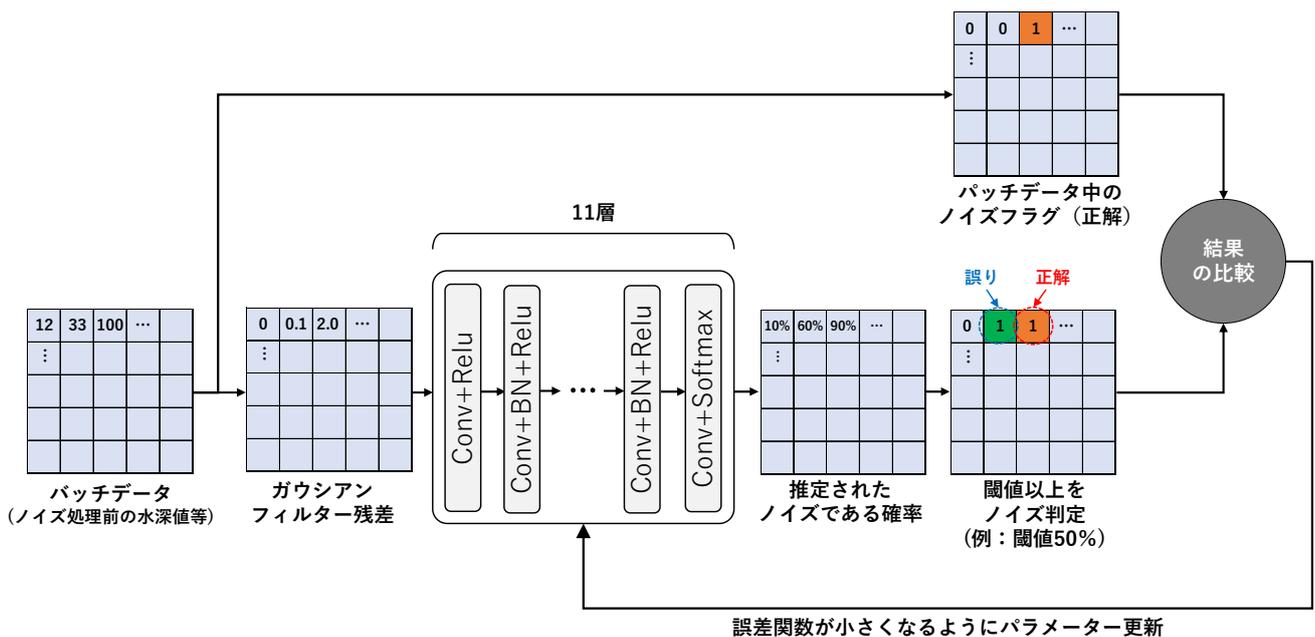


図-6 学習プロセスの計算手順

入力層の次に使用する中間層は、畳み込み層及びバッチ正規化層 (BN: Batch Normalization Layer) の2層から構成される。活性化関数は入力層と同じReLUである。

中間層の次に使用する出力層は畳み込み層であり、活性化関数がソフトマックス関数 (Softmax) である。

出力層から出力される結果は、パッチデータの各格子のノイズ確率の推定値である。予め設定したノイズ判定閾値により、各格子がノイズか正常水深か判定される。図-6の例では、ノイズ判定閾値が50%であるので、ノイズ確率が10%の格子は「0」(正常水深)、ノイズ確率が60%と90%の格子は「1」(ノイズ)と判定されフラグが付けられる。

1回の学習プロセスの最後の手順は、その回の学習プロセスで得られたノイズ推定結果とパッチデータ中の正解のノイズフラグの比較である。比較結果(誤差)は損失関数を用いて計算し、誤差を小さくする方向に入力層・中間層・出力層のネットワークの重み付けパラメータを更新する。

本研究では、損失関数にCross Entropyを使用し、損失関数の最小値を求めるオプティマイザとしてRAdam¹¹⁾を使用する。RAdamの学習率は0.0001に設定する。ネットワークの重み付けパラメータの初期値は、活性化関数がReLUである場合に適した方法と考えられる、He¹²⁾の正規分布を適用する。

1つのパッチデータで重み付けパラメータの更新が終わったら、次のパッチデータでも同じ計算手順を実行し、入力データに含まれる全てのパッチデータについて重み付けパラメータの更新を行う。なお、全てのパッチデータについて学習プロセスが1巡することを、1エポックと呼ぶ。

1エポックが終了し、全てのパッチデータの重み付けパラメータが更新されたら、最初のパッチデータを入力層に入れるところへ戻り、中間層・出力層・正解のノイズフラグとの比較・重み付けパラメータの更新を繰り返す。この繰り返し作業を、誤差が十分に小さくなり収束するまで継続し、最終的に得られた重み付けパラメータが学習済みモデルとなる。

なお、感度分析のために、DnCNNの層数(入力層・中間層・出力層の合計の層数)は、6層、11層、17層、19層の4種類を比較した。また、DnCNNのフィルターサイズは、3行3列、5行5列、7行7列の3種類、DnCNNのフィルター数は、64個、128個、256個の3種類を比較した。さらに、ノイズ判定閾値は50%、70%、90%の3種類を比較した。

2.4 推論プロセス

推論プロセスでは、前処理としてパッチデータ化とデータ規格化を行う。学習は行わないので、データ拡張は不要である。

そして、前処理の完了した測深データを学習済みモデルに入力し、入力層・中間層・出力層を経て各格子のノイズ判定を行う。ノイズと判定された水深値にノイズフラグが付いた測深データが出力され、推論プロセスは実行完了となる。推論プロセスは学習済みモデルを1回実行するだけであり、学習プロセスのような繰り返し計算や重み付けパラメータの更新は行われない。

3. 開発したノイズ処理プログラムの精度検証

3.1 使用した教師データと精度検証用テストデータ

学習プロセスで使用する教師データと推論プロセスで使用する精度検証用テストデータとして、ICT浚渫工で実際に計測されたマルチビーム測深データを収集した。収集したマルチビーム測深データは、合計で12工事分である。

収集したマルチビーム測深データの概要を表-1に示す。表-1には、マルチビーム測深で使用された測深機のメーカー(X社、Y社、Z社)、スワス角、水深(最浅値、平均値、最深値)、底質(砂、粘土シルト)、データ全点数及びノイズ点数が記載されている。

本研究で開発したノイズ処理プログラムでは、入力データに測深機のメーカー、スワス角、底質が不要なため、これらの情報は深層学習の結果へ影響しない。また、水深は入力データに含まれるが、データの前処理においてデータ規格化を行うため、水深の絶対値も深層学習の結果へ影響しない。以上のことから、入力データの特徴のうち深層学習の結果へ影響する要素は、ノイズ率のみと考えられる。ノイズ率は、ノイズ点数÷データ全点数で算出される数値である。

本研究では、深層学習を効率的に実行する手法を検討するため、教師データの特徴が深層学習の結果に与える影響について分析する。上述のとおり、深層学習の結果に影響を及ぼす可能性がある教師データの特徴としてはノイズ率が考えられるので、ノイズ率が1%未満の測深データを「グループA」、ノイズ率が1%以上の測深データを「グループB」として2つに分類する。表-1のとおり、グループAには6工事分の測深データ、グループBにも6工事分の測深データが含まれる。各グループの測深データのうち、1つの測深データは精度検証用テストデータと

して使用し (TA-1及びTB-1) , 残りの5つの測深データを教師データとして使用する (A-1~A-5及びB-1~B-5) .

なお, 教師データのデータ全点数は, グループAが175,616,913点, グループBが167,726,934点である. 一方, 教師データのノイズ率の単純平均値は, グループAが0.19%, グループBが3.88%である. 教師データのデータ全点数はグループAとグループBで同程度であるため, 仮に深層学習の結果がグループAとグループBで異なるな

らば, その要因はデータ全点数の違いではなく, ノイズ率の違いによるものと考えられる.

また, 測深データの一例として, ノイズ率が最も小さい測深データA-1の海底地形を図-7に, ノイズ率が最も大きい測深データB-5の海底地形を図-8に示す. 両図とも, 図の上段がノイズ除去前の測深データ, 図の下段が手動によるノイズ除去後の測深データである.

表-1 使用したマルチビーム測深データの一覧

| | | 測深機 | スワス角 (°) | 最浅水深 (m) | 平均水深 (m) | 最深水深 (m) | 底質 | 全点数 (点) | ノイズ点数 (点) | ノイズ率 (%) |
|-------|------|-----|----------|----------|----------|----------|-------|------------|-----------|----------|
| グループA | A-1 | Z社 | 55 | 3.8 | 11.35 | 13.9 | 粘土シルト | 86,902,698 | 9,812 | 0.011 |
| | A-2 | X社 | 50 | 10.3 | 12.69 | 14.9 | 粘土シルト | 12,345,831 | 11,462 | 0.093 |
| | A-3 | X社 | 45 | 10.5 | 14.41 | 19.0 | 砂 | 12,100,608 | 19,304 | 0.160 |
| | A-4 | Y社 | 55 | 2.3 | 9.02 | 11.3 | 粘土シルト | 34,475,520 | 76,085 | 0.221 |
| | A-5 | X社 | 45 | 2.5 | 10.91 | 18.0 | 砂 | 29,792,256 | 133,663 | 0.449 |
| | TA-1 | X社 | 45 | 2.5 | 10.92 | 18.0 | 砂 | 21,590,773 | 73,002 | 0.338 |
| グループB | B-1 | Y社 | 40 | 7.1 | 13.95 | 15.9 | 砂 | 95,046,580 | 1,087,603 | 1.144 |
| | B-2 | Y社 | 55 | 3.2 | 6.70 | 8.6 | 粘土シルト | 41,741,312 | 808,386 | 1.937 |
| | B-3 | X社 | 55 | 0.6 | 11.23 | 21.0 | 粘土シルト | 5,687,806 | 142,411 | 2.504 |
| | B-4 | X社 | 55 | 0.0 | 16.03 | 29.7 | 粘土シルト | 3,682,770 | 167,952 | 4.560 |
| | B-5 | X社 | 55 | 7.6 | 13.17 | 21.1 | 粘土シルト | 21,568,466 | 1,996,124 | 9.255 |
| | TB-1 | X社 | 55 | 10.2 | 12.72 | 15.0 | 粘土シルト | 18,940,018 | 696,514 | 3.677 |

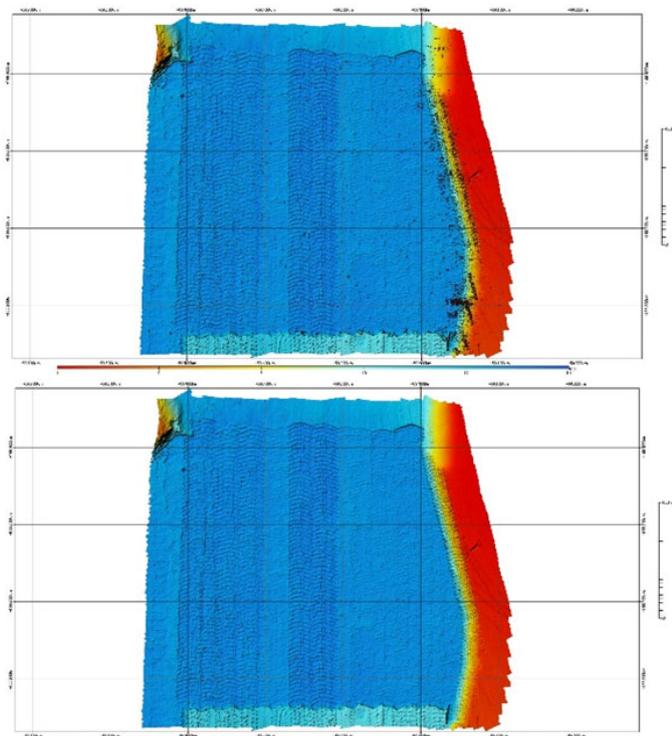


図-7 測深データA-1 (上段がノイズ除去前, 下段が手動によるノイズ除去後)

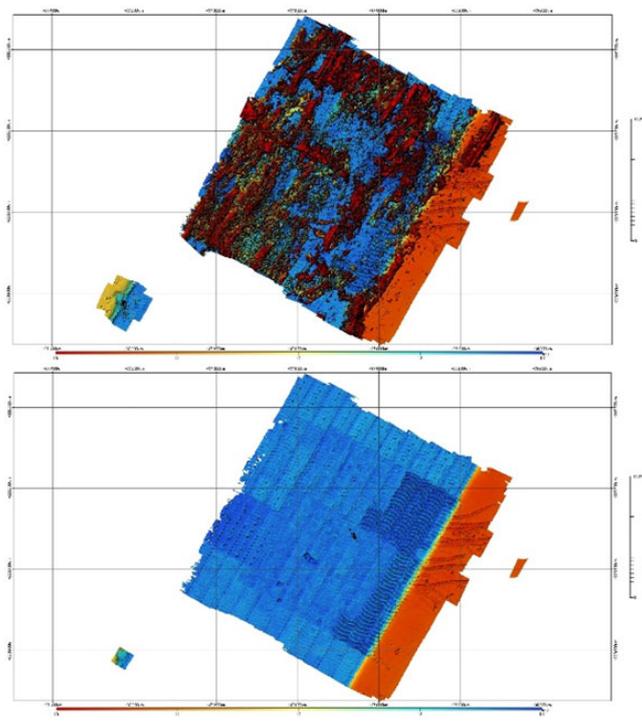


図-8 測深データB-5 (上段がノイズ除去前, 下段が手動によるノイズ除去後)

3.2 精度検証の結果

(1) 精度検証に用いる指標

機械学習の精度検証を行う手法の1つとして、混同行列が使用される。混同行列の模式図を図-9に示す。

| | 実際のノイズ (Positive) | 実際の正常水深 (Negative) |
|-----------------------|-----------------------------|-----------------------------|
| ノイズと判定 (Positive) | TP True Positive 真陽性 | FP False Positive 偽陽性 |
| 正常水深と判定 (Negative) | FN False Negative 偽陰性 | TN True Negative 真陰性 |

図-9 混同行列の模式図

ノイズ処理プログラムの計算結果は、必ず混同行列中の4区分のいずれかに分類できる。例えば、実際は正常水深であるデータがノイズ処理プログラムでノイズと判定された場合、その計算結果はFP (False Positive: 偽陽性) に分類される。

そして、ノイズ処理プログラムの計算結果に含まれる一つ一つの測深データについて、TP・FP・FN・TNの分類が行われ混同行列が作成できると、次に適合率 (Precision) ・認識率 (Recall) ・F値という3つの指標が計算できる。適合率・認識率・F値の定義は、式(1)～式(3)のとおりである。

$$\text{適合率} = \frac{TP}{TP + FP} \quad \text{式(1)}$$

$$\text{認識率} = \frac{TP}{TP + FN} \quad \text{式(2)}$$

$$\text{F値} = \frac{2 \times \text{適合率} \times \text{認識率}}{\text{適合率} + \text{認識率}} \quad \text{式(3)}$$

適合率は、ノイズと判定したデータのうち、実際にノイズであるデータの割合を表す。FP (実際は正常水深であるが誤ってノイズと判定したデータ) が多いと適合率は小さくなる。

一方、認識率は、実際はノイズであるデータのうち、ノイズと正しく判定したデータの割合を表す。FN (実際はノイズであるが誤って正常水深と判定したデータ) が多いと認識率は小さくなる。

一般的に、適合率と認識率はトレードオフの関係にあるものと考えられる。すなわち、適合率が大きければ認識率は小さくなり、適合率が小さければ認識率は大きく

なる。そこで、適合率と認識率の両方を1つの指標で評価するために考えられたのがF値である。F値は式(3)のとおり、適合率と認識率の調和平均となっている。

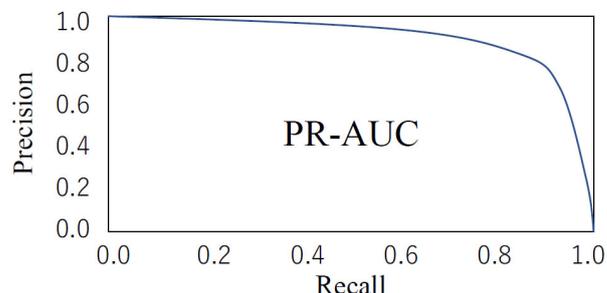


図-10 PR-AUCの模式図

なお、ノイズ判定閾値を0%にすると認識率が1.0、適合率が0.0になる。逆に、ノイズ判定閾値を100%にすると認識率が0.0、適合率が1.0になる。このように、ノイズ判定閾値を0%から100%へ変化させると、図-10に示すPR曲線を描くことができる。PR曲線より下側の面積をPR-AUC (Precision-Recall Area Under the Curve) と呼び、PR-AUCも機械学習の精度検証の指標の1つである。

ノイズ判定閾値が変わると適合率・認識率・F値も変わるため、適合率・認識率・F値は、ノイズ判定閾値を固定した場合の個別の推論プロセスの評価指標として使用する。一方、学習プロセス (学習モデル) の評価指標としては、ノイズ判定閾値を0%から100%まで変化させた場合の総合的な評価ができるPR-AUCを用いる。

(2) 学習プロセスの感度分析結果

学習プロセスにおける、各種パラメータの感度分析の結果を表-2に示す。感度分析の対象とするパラメータは、前処理で使用するガウシアンフィルターのサイズ、DnCNNの層数、DnCNNのフィルターサイズ、DnCNNのフィルター数である。なお、ノイズ判定閾値についても感度分析を行うが、ノイズ判定閾値の感度分析の結果は推論プロセスの精度検証結果と合わせて説明する。また、表-2の感度分析を行う際は、教師データとしてグループAとグループBの両方を使用する。

感度分析の結果は、Train PR-AUC, Valid PR-AUC, Train Loss, Valid Lossの4つで評価する。ここで「Loss」は、損失関数で計算される誤差を表す。

表-2 学習プロセスにおけるパラメータの感度分析結果

| ケース | ガウシアンフィルターサイズ | DnCNN層数 | DnCNNフィルターサイズ | DnCNNフィルター数 | Train PR-AUC | Valid PR-AUC | Train Loss | Valid Loss |
|-----|---------------|---------|---------------|-------------|--------------|--------------|------------|------------|
| 1 | 5×5 | 19 | 3×3 | 64 | 0.82 | 0.85 | 0.04 | 0.05 |
| 2 | 5×5 | 17 | 3×3 | 64 | 0.82 | 0.85 | 0.04 | 0.05 |
| 3 | 5×5 | 11 | 3×3 | 128 | 0.84 | 0.83 | 0.03 | 0.04 |
| 4 | 5×5 | 6 | 3×3 | 256 | 0.80 | 0.83 | 0.04 | 0.05 |
| 5 | 5×5 | 11 | 5×5 | 128 | 0.85 | 0.85 | 0.03 | 0.05 |
| 6 | 5×5 | 11 | 7×7 | 128 | 0.86 | 0.85 | 0.03 | 0.05 |
| 7 | 3×3 | 11 | 3×3 | 128 | 0.84 | 0.83 | 0.03 | 0.04 |
| 8 | 10×10 | 11 | 3×3 | 128 | 0.84 | 0.83 | 0.03 | 0.04 |
| 9 | 30×30 | 11 | 3×3 | 128 | 0.83 | 0.83 | 0.03 | 0.04 |

機械学習では、教師データに対して学習プロセスを繰り返すうちに、教師データに対しては高い精度で推論できるが、学習に使用していないその他の入力データに対しては推論の精度が必ずしも高くない学習モデルが作成される。このような学習モデルは過剰適合又は過学習と呼ばれる。

過剰適合を回避するための1つの対策として、教師データをTrainデータとValidデータに予め分ける手法がある。学習データとしてはTrainデータのみを使用し、Trainデータによる学習の結果として、Train PR-AUCとTrain Lossを計算する。同時に、学習データとして使用しないValidデータに対しても、Valid PR-AUCとValid Lossを計算し、学習モデルの評価はTrain PR-AUC、Valid PR-AUC、Train Loss、Valid Lossの4つの指標で行う。

本研究では、教師データの80%をTrainデータ、残りの20%をValidデータとして予め分割し、学習プロセスを実行する。Train PR-AUC及びValid PR-AUCの両方が大きく（理論上の最大値は1.0）、Train Loss及びValid Lossの両方が小さくなる学習モデルが最良のものと評価できる。

図-11～図-19は、表-2に示す全9ケースに関し、学習プロセスの繰り返し回数（エポック）に対して、Train PR-AUC、Valid PR-AUC、Train Loss、Valid Lossの4つの指標がどう変化するかを図示したものである。各図とも左側にTrain PR-AUCとValid PR-AUC、右側にTrain LossとValid Lossをプロットしている。

本研究ではエポックの上限を150回に設定し、PR-AUCが20エポックを経過しても変化しない時点を取束と判定して、学習プロセスを打ち切ることとする。図-11～図-19の桃色の縦線は、学習プロセスが取束して打ち切りを行ったエポックを示す。どのケースにおいても、おおよそ80エポックまでに学習プロセスは取束している。

a) DnCNNの層数とフィルター数の感度分析結果

ケース1～ケース4までを比較すると、表-2のとおり、ケース3がTrain PR-AUC及びValid PR-AUCが大きく、Train Loss及びValid Lossが小さい。

Valid PR-AUCに限れば、ケース1は0.85、ケース2は0.85であり、ケース3の0.83よりも大きい。しかし、図-11及び図-12が示すとおり、ケース1とケース2はTrain LossとValid Lossの乖離が大きく、過剰適合が発生している可能性がある。

以上のことから、ケース1～ケース4の中ではケース3が最良の学習モデルと判断し、DnCNNの層数は11層、DnCNNのフィルター数は128と設定する。

b) DnCNNのフィルターサイズの感度分析結果

DnCNNのフィルターサイズについては、ケース3・ケース5・ケース6を比較する。表-2のとおり、Train PR-AUC及びValid PR-AUCは、ケース5・ケース6がケース3よりも大きく、逆にTrain Loss及びValid Lossは、ケース3がケース5・ケース6よりも小さい。このため、表-2のみでは、どのケースが最良の学習モデルであるかを判断することは難しい。

しかし、図-15及び図-16を見ると、ケース5とケース6はTrain LossとValid Lossの乖離が大きく、過剰適合が発生している可能性がある。

以上のことから、ケース3・ケース5・ケース6の中ではケース3が最良の学習モデルと判断し、DnCNNのフィルターサイズは3行3列（3×3）と設定する。

c) ガウシアンフィルターのサイズの感度分析結果

ガウシアンフィルターのサイズについては、ケース3とケース7～ケース9を比較する。表-2のとおり、これら4ケースの間では、Train PR-AUC・Valid PR-AUC・Train Loss・Valid Lossに有意な違いが見られない。

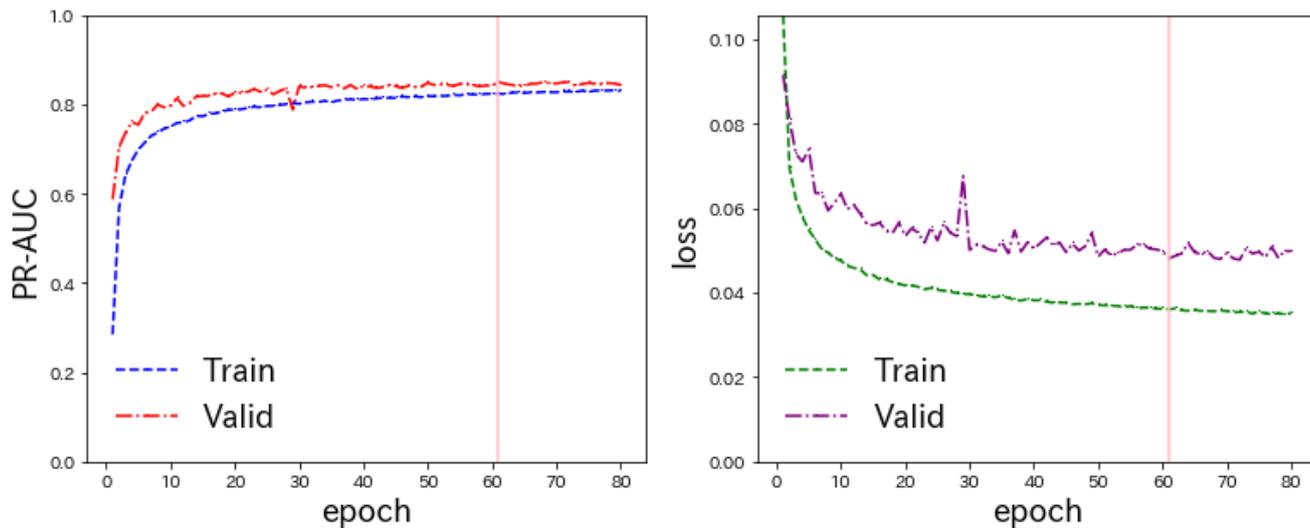


図-11 ケース1 (表-2) の学習結果

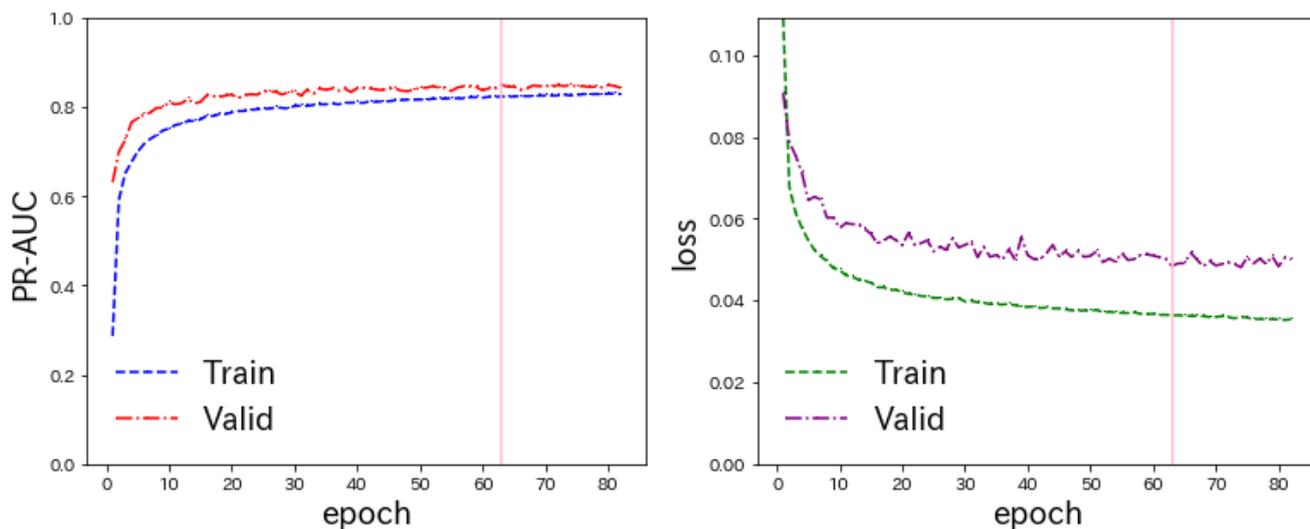


図-12 ケース2 (表-2) の学習結果

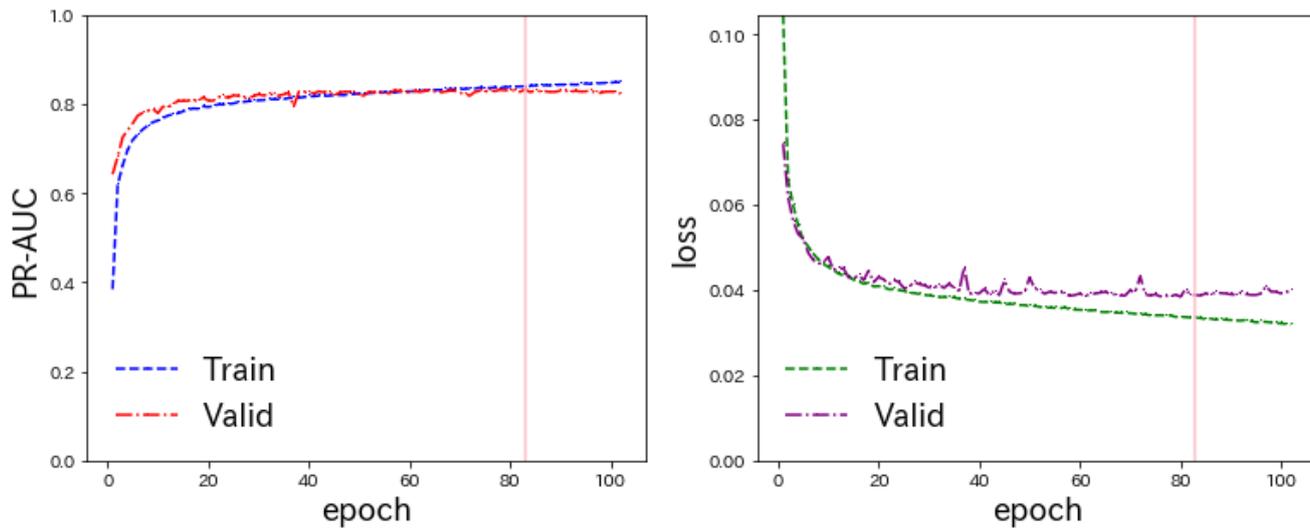


図-13 ケース3 (表-2) の学習結果

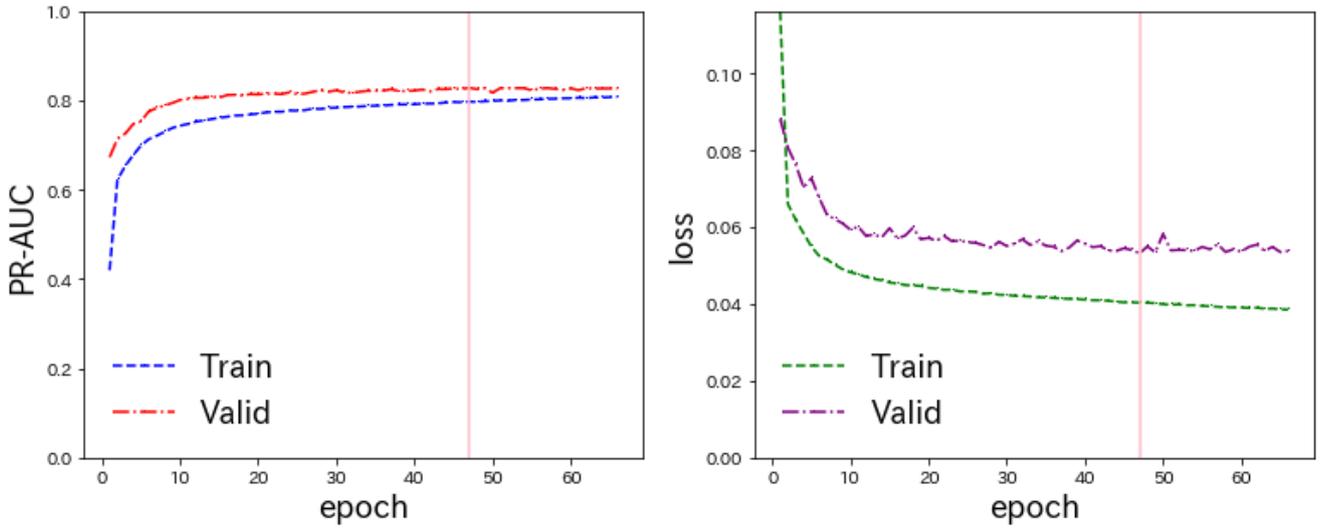


図-14 ケース4 (表-2) の学習結果

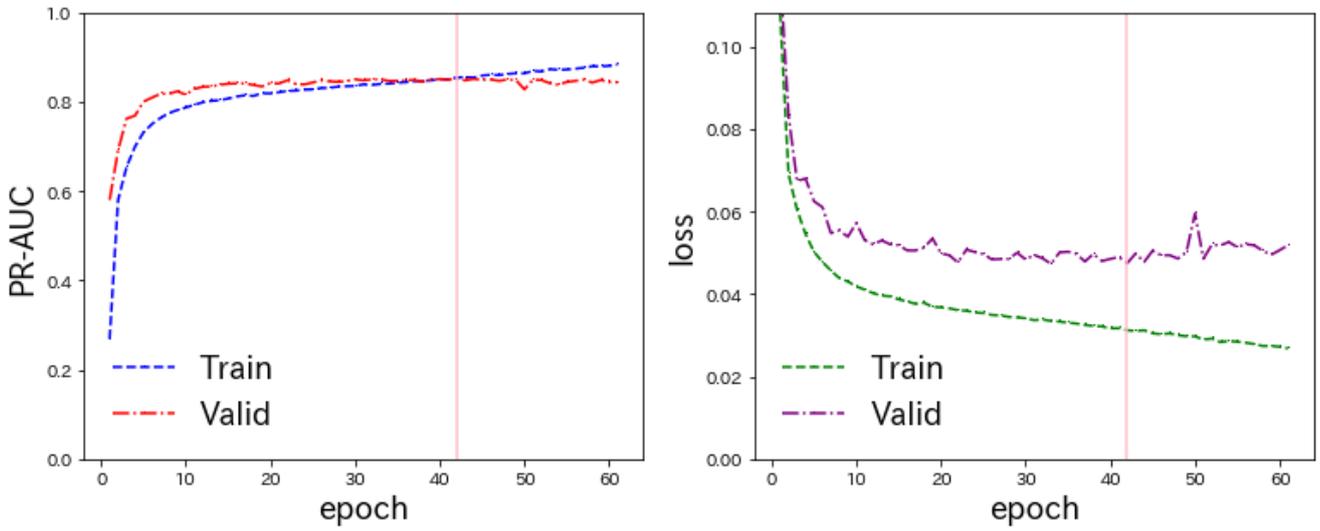


図-15 ケース5 (表-2) の学習結果

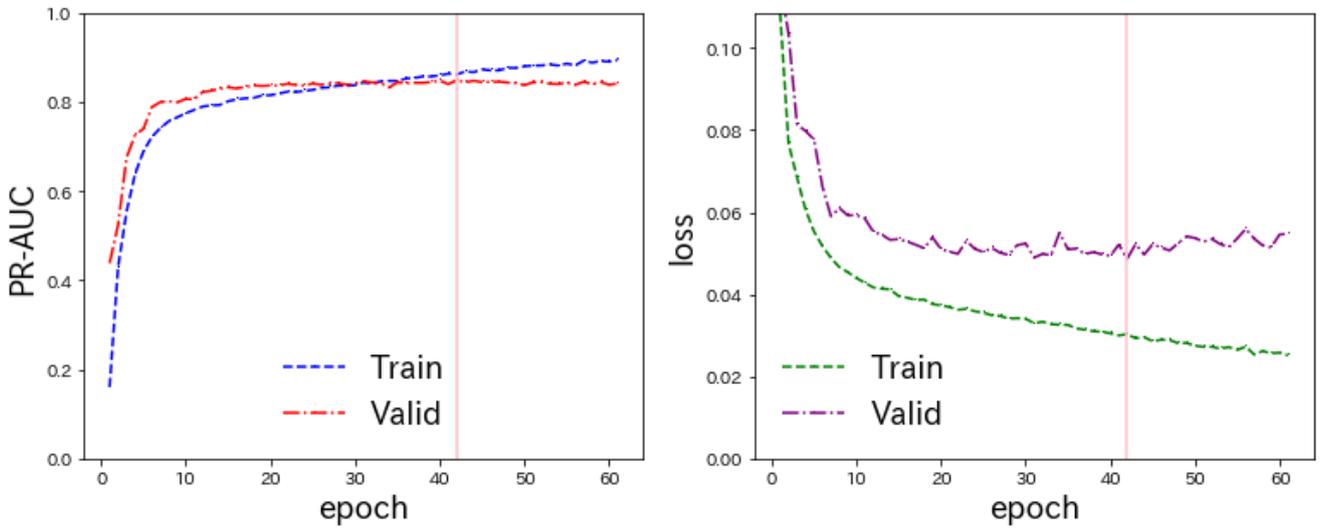


図-16 ケース6 (表-2) の学習結果

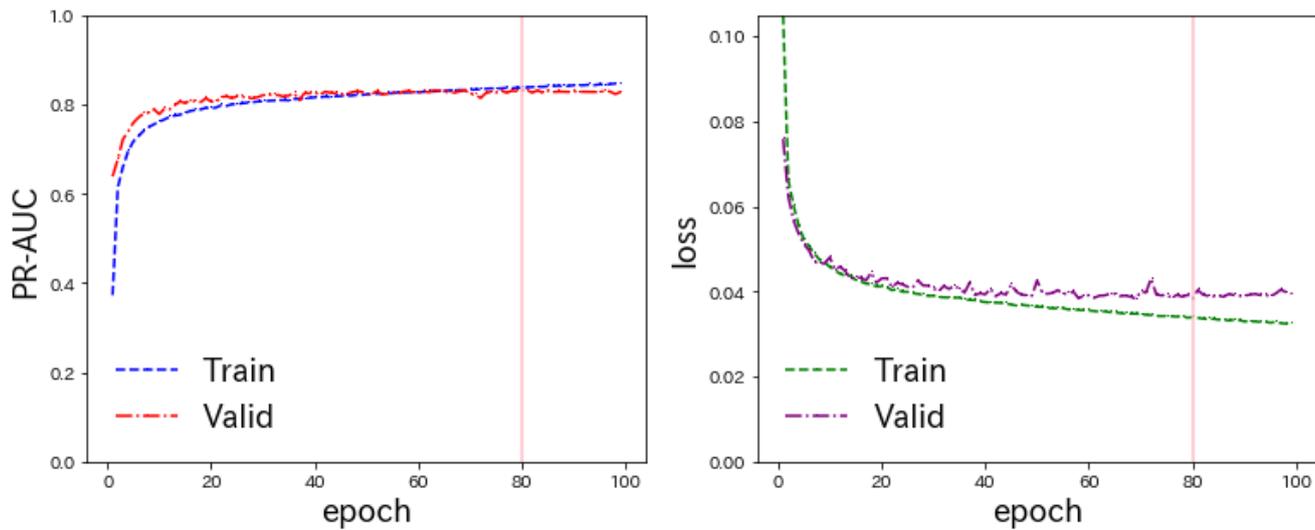


図-17 ケース7 (表-2) の学習結果

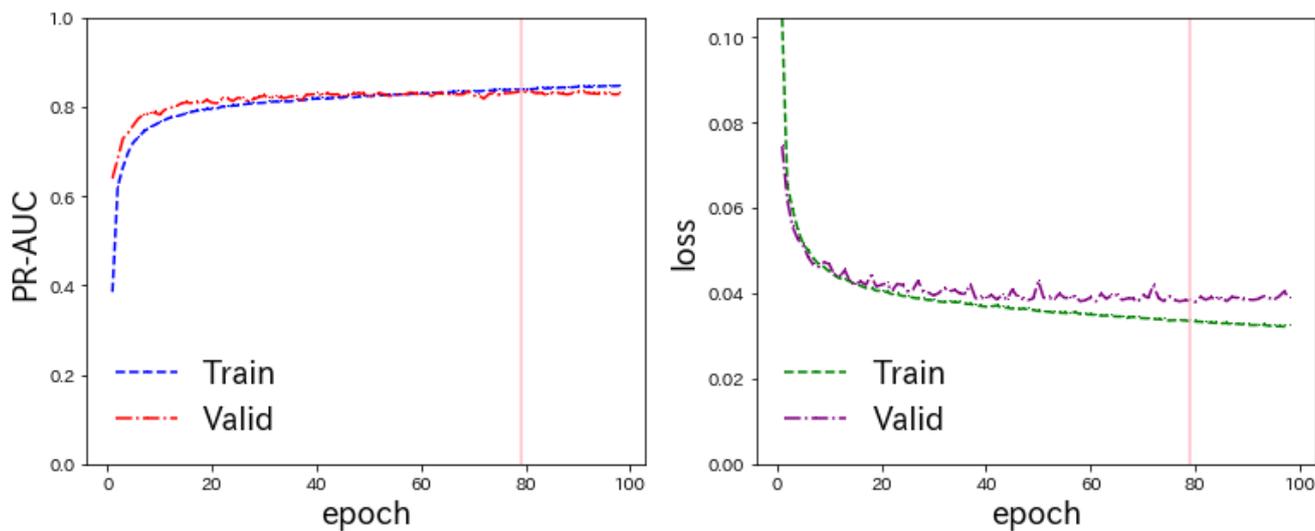


図-18 ケース8 (表-2) の学習結果

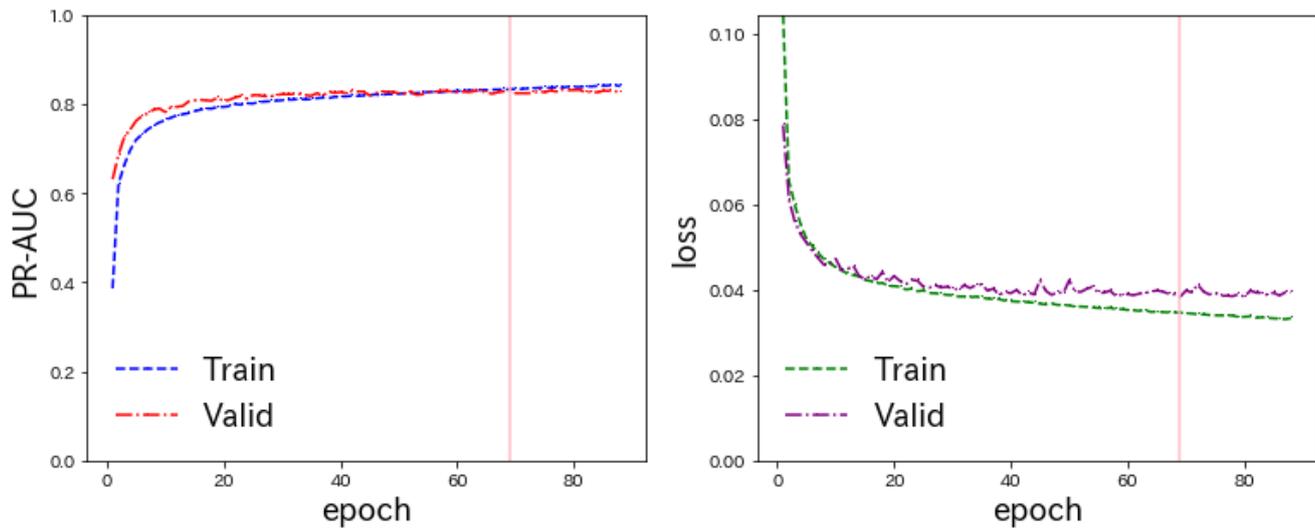


図-19 ケース9 (表-2) の学習結果

また、図-13と図-17～図-19が示すとおり、どの図（ケース3、ケース7～9）においてもTrain LossとValid Lossの顕著な乖離は見られず、過剰適合が発生している可能性も低い。

以上のことから、ケース3とケース7～ケース9の間では、学習モデルに有意な違いは無いものと考えられる。すなわち、ガウシアンフィルターのサイズが3行3列（3×3）、5行5列（5×5）、10行10列（10×10）、30行30列（30×30）のいずれであっても、学習の結果に大きな影響は無い。そこで本研究では、ガウシアンフィルターのサイズを便宜的に5行5列に設定して、これ以降の検討を進める。

(3) 異なる教師データによる学習プロセスの結果

表-1に示すとおり、本研究では、ノイズ率が1%未満のグループAとノイズ率が1%以上のグループBの2種類の教師データを使用する。教師データをグループA、グループB、グループA+Bとした場合の学習プロセスの結果を表-3に示す。また、図-20及び図-21に、学習プロセスの繰り返し回数（エポック）に対して、Train PR-AUC、Valid PR-AUC、Train Loss、Valid Lossの4つの指標がどう変化するかを示す。図-20は教師データがグループA、図-21は教師データがグループBの結果である。教師データがグループA+Bの結果は、図-13（表-2のケース3）として掲載済みである。

学習プロセスで使用する各種パラメータは、前項の検討結果から、どの教師データを使用する場合でも、ガウシアンフィルターのサイズは5行5列、DnCNNの層数は11層、フィルターサイズは3行3列、フィルター数は128を採

用する。この設定は、表-2のケース3に相当するものである。

まず、グループAとグループBを比較すると、教師データをグループAとする方が、Train PR-AUC、Valid PR-AUC、Train Loss、Valid Lossの全てが小さい結果となった。Lossは小さいがPR-AUCも小さいため、表-3だけではグループAとグループBのどちらが良い教師データであるかは判断できない。

しかし、図-20を見ると、教師データをグループAとする場合は、Train PR-AUCとValid PR-AUCに乖離が見られ、過剰適合が発生している可能性がある。したがって、過剰適合の発生が懸念されるグループAよりも、グループBを教師データとした方がより良い学習モデルを作成できると評価できる。

さらに、グループBとグループA+Bを比較すると、教師データをグループBとする方が、Train PR-AUC、Valid PR-AUC、Train Loss、Valid Lossの全てが大きい結果となった。PR-AUCは大きい Lossも大きいため、表-3だけではグループBとグループA+Bのどちらが良い教師データであるかは判断できない。

表-3 異なる教師データによる学習プロセスの結果

| 教師データ | Train PR-AUC | Valid PR-AUC | Train Loss | Valid Loss |
|-------|--------------|--------------|------------|------------|
| グループA | 0.78 | 0.70 | 0.01 | 0.01 |
| グループB | 0.85 | 0.85 | 0.04 | 0.05 |
| A+B | 0.84 | 0.83 | 0.03 | 0.04 |

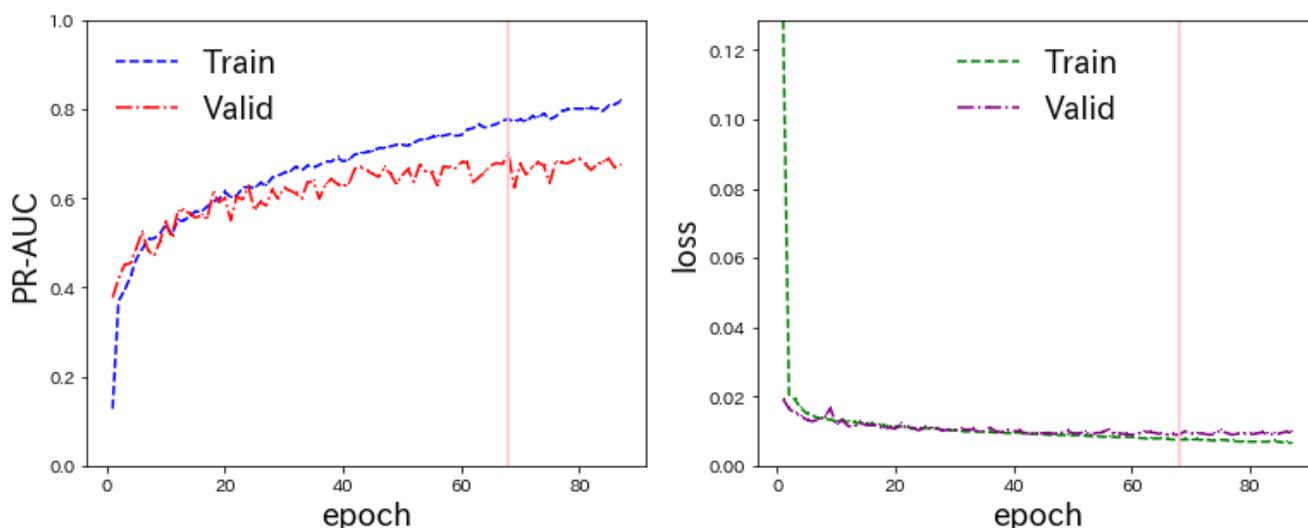


図-20 教師データがグループAの場合の学習結果

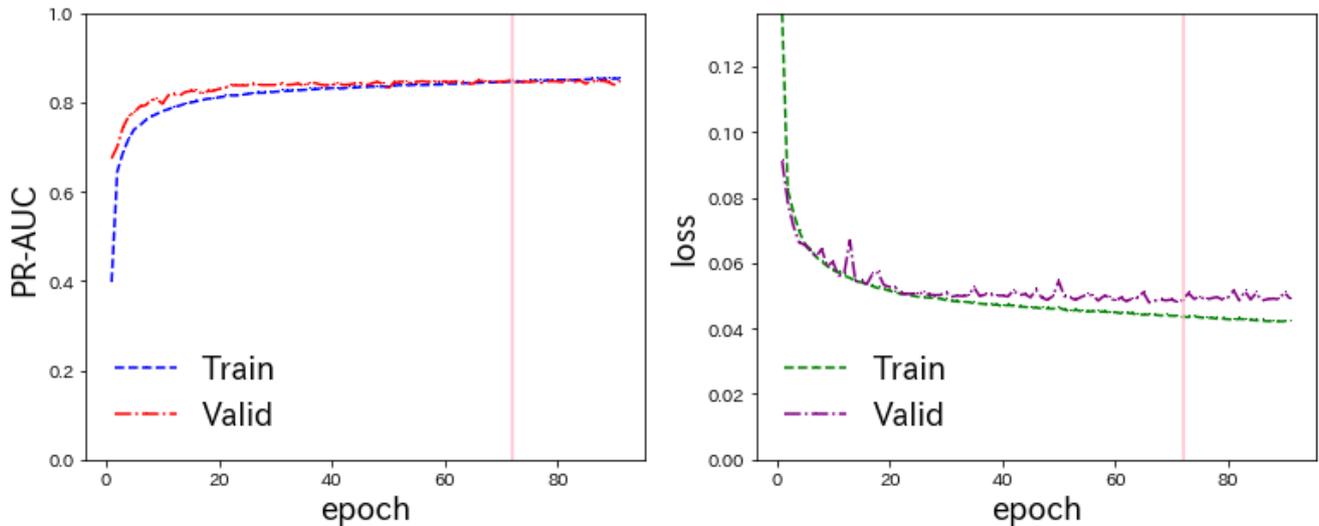


図-21 教師データがグループBの場合の学習結果

また、図-21及び図-13を見ると、グループBとグループA+Bのどちらにおいても過剰適合が発生している可能性は小さい。以上のことから、学習プロセスの結果のみでは、グループBとグループA+Bのどちらが良い教師データであるかを判断することは難しい。

(4) 推論プロセスの精度検証結果

前項で説明した、教師データをグループA、グループB、グループA+Bとする場合の学習プロセスで作成された学習モデルについて、推論プロセスの結果を表-4及び表-5に示す。表-4は推論プロセスの結果を適合率、認識率、F値で評価したものであり、表-5は表-4の適合率、認識率、F値の算定根拠となったTP, FP, FN, TNを整理したものである。学習モデルでノイズ処理を行った対象は、表-1のテストデータA (TA-1) とテストデータB (TB-1) である。テストデータAはノイズ率が0.34%と小さく、テストデータBはノイズ率が3.68%と大きい。

まず、推論プロセスの対象となるデータに着目する。教師データの種類によらず、テストデータBを推論する方がテストデータAを推論するよりも、適合率及び認識率が高いことから、ノイズ率の大きい測深データの方が推論の精度が高い。すなわち、ノイズを正確に判別しやすいと評価できる。

次に、教師データの種類に着目する。教師データをグループB又はグループA+Bとする方が、教師データをグループAとするよりも、適合率及び認識率が高い。ただし、テストデータAを推論する場合は、グループB又はグループA+Bの方がグループAよりも適合率は高くなるが、認識率は同程度である。ノイズ率の大きいグループB又

はデータ数の多いグループA+Bを教師データとして学習した方が、推論の精度が高いと評価できる。

第3に、ノイズ判定閾値に着目する。一部の例外は見られるが、基本的にノイズ判定閾値を90%から70%、50%へ下げるほど、適合率は低下し、認識率は増大する。ノイズ判定閾値が低いと、ノイズの検出漏れは少なくなるが、ノイズとして判定するものに誤りが多くなるためと解釈できる。なお、適合率の低下よりも認識率の増大の方が顕著であるため、ノイズ判定閾値を下げると結果としてF値が増大している。

推論プロセスによるノイズ処理の結果を、図-22と図-23に示す。図-22はテストデータA (TA-1) に対するノイズ処理の結果、図-23はテストデータB (TB-1) に対するノイズ処理の結果である。図-22及び図-23は、今回の検討で最も推論精度が高いと評価できる、教師データにグループA+Bを使用し、ノイズ判定閾値を90%とする場合の結果である。両図とも、左上に水深、右上にTP (赤点)、左下にFP (緑点)、右下にFN (青点) を図化している。TPとFNを足し合わせると、真のノイズの分布図になる。

図-22及び図-23のどちらにおいても、真のノイズのうち推論プロセスで正常水深と判定しノイズとして検出できなかったデータ (FN) は、TPと同じ位置に分布している。一方、実際は正常水深であるのにノイズとして誤判定されたデータ (FP) は、TPと同じ位置には分布せず、特定の地点に偏在している。FPの分布と水深の分布を比較すると、FPは水深が深く海底地形が急変しているところに多く発生していると評価できる。

表-4 推論プロセスの精度検証結果（適合率，認識率，F値）

| ノイズ判定閾値 | | テストデータA | | | テストデータB | | |
|----------------|-----|---------|-------|-------|---------|-------|-------|
| | | 90% | 70% | 50% | 90% | 70% | 50% |
| 教師データ グループA | 適合率 | 0.443 | 0.464 | 0.472 | 0.963 | 0.945 | 0.929 |
| | 認識率 | 0.239 | 0.308 | 0.359 | 0.351 | 0.415 | 0.453 |
| | F値 | 0.311 | 0.370 | 0.407 | 0.514 | 0.576 | 0.609 |
| 教師データ グループB | 適合率 | 0.662 | 0.634 | 0.597 | 0.997 | 0.991 | 0.980 |
| | 認識率 | 0.226 | 0.300 | 0.357 | 0.555 | 0.579 | 0.591 |
| | F値 | 0.337 | 0.408 | 0.447 | 0.713 | 0.731 | 0.737 |
| 教師データ A+B | 適合率 | 0.787 | 0.776 | 0.746 | 0.997 | 0.991 | 0.981 |
| | 認識率 | 0.192 | 0.267 | 0.313 | 0.561 | 0.583 | 0.593 |
| | F値 | 0.308 | 0.398 | 0.441 | 0.718 | 0.734 | 0.739 |

表-5 推論プロセスの精度検証結果（TP，FP，FN，TN）

| ノイズ判定閾値 | | テストデータA | | | テストデータB | | |
|----------------|----|------------|------------|------------|------------|------------|------------|
| | | 90% | 70% | 50% | 90% | 70% | 50% |
| 教師データ グループA | TP | 17,463 | 22,466 | 26,177 | 244,205 | 288,845 | 315,189 |
| | FP | 21,969 | 25,917 | 29,333 | 9,441 | 16,851 | 24,027 |
| | FN | 55,539 | 50,536 | 46,825 | 452,309 | 407,669 | 381,325 |
| | TN | 21,495,802 | 21,491,854 | 21,488,438 | 18,234,063 | 18,226,653 | 18,219,477 |
| 教師データ グループB | TP | 16,475 | 21,926 | 26,050 | 386,311 | 403,309 | 411,483 |
| | FP | 8,412 | 12,657 | 17,600 | 1,154 | 3,721 | 8,242 |
| | FN | 56,527 | 51,076 | 46,952 | 310,203 | 293,205 | 285,031 |
| | TN | 21,509,359 | 21,505,114 | 21,500,171 | 18,242,350 | 18,239,783 | 18,235,262 |
| 教師データ A+B | TP | 13,997 | 19,523 | 22,859 | 390,758 | 405,793 | 413,139 |
| | FP | 3,778 | 5,620 | 7,793 | 1,218 | 3,707 | 7,898 |
| | FN | 59,005 | 53,479 | 50,143 | 305,756 | 290,721 | 283,375 |
| | TN | 21,513,993 | 21,512,151 | 21,509,978 | 18,242,286 | 18,239,797 | 18,235,606 |

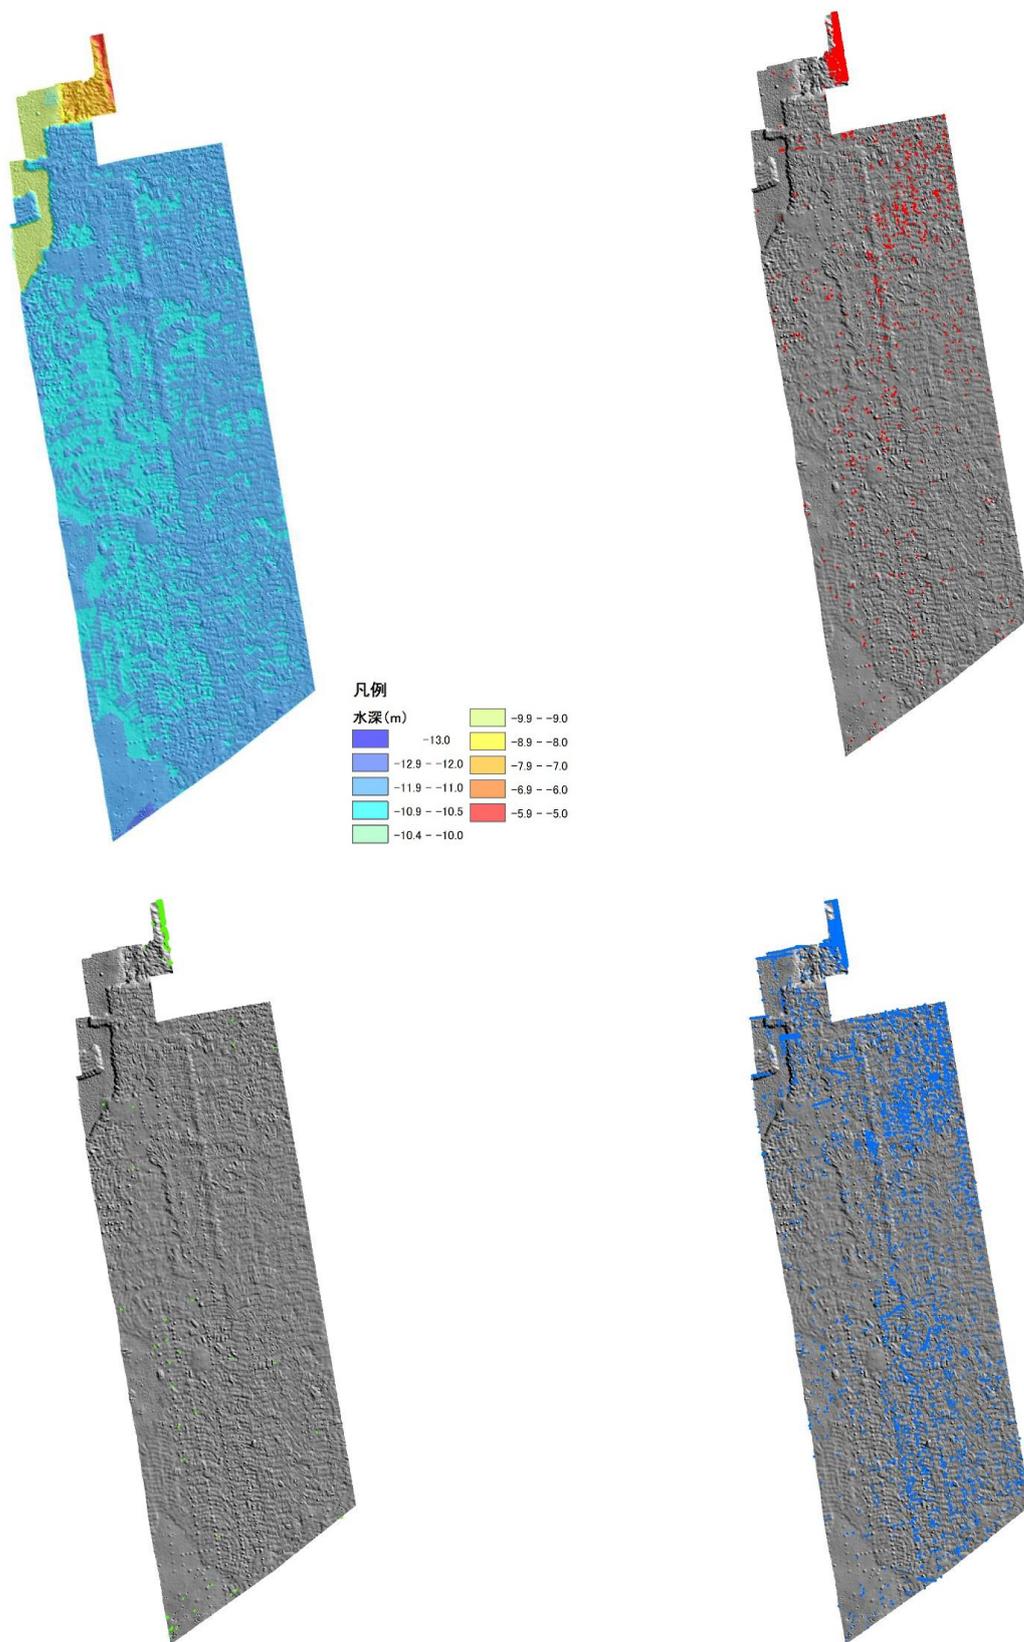


図-22 テストデータAに対するノイズ処理の結果（左上：水深，右上：TP，左下：FP，右下：FN）

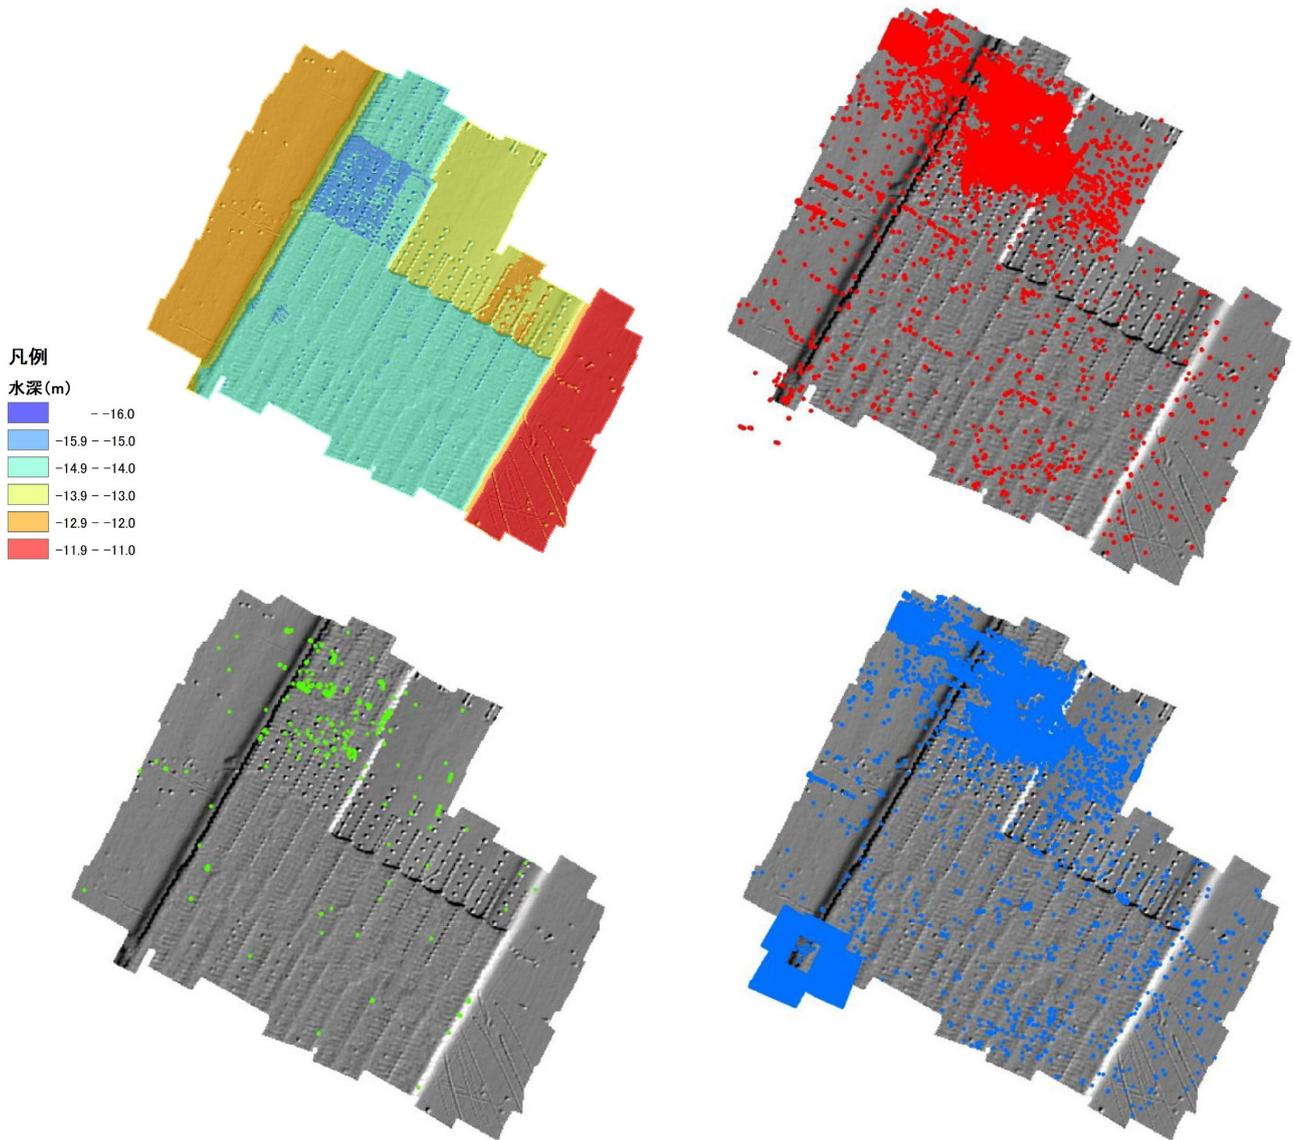


図-23 テストデータBに対するノイズ処理の結果（左上：水深，右上：TP，左下：FP，右下：FN）

(5) 推論プロセスの計算所要時間の計測結果

推論プロセスの計算所要時間の計測結果を、表-6に示す。推論プロセスには、CPUの動作周波数が3.70GHz、実装RAMの容量が16.0GBの性能を持つ、汎用的な計算機を使用した。

表-6 推論プロセスの計算所要時間の計測結果

| ノイズ判定閾値 | テストデータA | | | テストデータB | | |
|---------|---------|-----|-----|---------|-----|-----|
| | 90% | 70% | 50% | 90% | 70% | 50% |
| グループA | 11分 | 11分 | 11分 | 19分 | 20分 | 19分 |
| グループB | 11分 | 11分 | 11分 | 20分 | 20分 | 20分 |
| A+B | 14分 | 14分 | 14分 | 28分 | 28分 | 28分 |

表-6が示すとおり、テストデータAよりもテストデータBの推論プロセスの方が、計算所要時間が長い。ただし、最長でも28分で推論プロセスを完了している。

3.3 考察

(1) 教師データ

学習プロセス及び推論プロセスの精度検証結果から、ノイズ率の小さいグループAよりも、ノイズ率の大きいグループB又はデータ点数が大きいグループA+Bを教師データに使用した方が、推論の精度は高く、過剰適合も発生しづらいことが明らかになった。

本研究の結果のみでは、教師データのノイズ率が大きいことと、教師データのデータ点数が多いことの、どちらが、学習プロセス及び推論プロセスの精度向上に寄与

しているかは不明である。また、ノイズの多い・少ないの分界点をノイズ率1%とすることの妥当性、十分な精度を達成するのに必要な教師データのデータ点数は明らかになっておらず、今後の検討が必要である。

(2) 推論精度

表-4に示すとおり、本研究ではF値が最大で0.739となり、その時の適合率は0.981、認識率は0.593である。すなわち、ノイズ処理プログラムがノイズと判定する測深データは、約98%の確率で真のノイズである。一方、真のノイズのうち、ノイズ処理プログラムが検出できるのは約59%であり、残り41%のノイズは検出できていない。

したがって、ノイズ処理プログラムの実行のみでは、現行の手作業によるノイズ処理と同等の精度を保証することは困難である。このため、ノイズ処理プログラムで一度ノイズ処理を行った後、ノイズと判定されていない測深データを中心に検出漏れのノイズが無いか、技術者が手作業で精査することが必要である。換言すれば、深層学習によるノイズ処理プログラムは、手作業によるノイズ処理の対象範囲を絞り込むためのスクリーニングという活用が考えられる。

図-24は、局所的な浅所のノイズ処理の模式図である。左が手動によるノイズ処理であり、黄色の枠内に浅所が残っている。一方、右は深層学習によるノイズ処理プログラムの推論結果であり、黄色の枠内の浅所をノイズとして誤判定し除去している。これはFPの状況に該当し、本来残すべき浅所をノイズとして除去しているため、航行安全上、危険な結果である。したがって、航行安全の観点からは、FPを最小化し、適合率を最大化するような学習モデルが望ましい。

ノイズ判定閾値を90%から70%、50%へ下げるほど、適合率は低下するが、認識率は向上する。スクリーニングの効果を上げるためには、ノイズ判定閾値を低く設定し、認識率を向上させて、検出漏れを減らすことが有効と思

われる。しかし、上述のとおり、航行安全の観点からは、認識率の向上よりも適合率を最大化することが重要（安全側）であるため、原則として、ノイズ判定閾値は高い水準に設定する方が良いと評価できる。

(3) 計算所要時間

本研究で推論の対象としたテストデータBについては、ICT浚渫工の受注者アンケートの結果、データ解析時間が10時間という回答を得た。また、測深データのノイズ処理に従事する海洋調査関係企業へ別途ヒアリングした結果、測深データのデータ解析時間のうち、ノイズ処理が占める割合は約80%であるという回答を得た。

以上のことから、テストデータBについて、手動のノイズ処理作業に要した時間は、約8時間（約480分）と見積もることができる。

したがって、テストデータBに限れば、ノイズ処理時間は現行の手作業の約480分に対して、深層学習によるノイズ処理プログラムでは28分まで短縮可能と評価できる。

しかし、前項で説明したとおり、深層学習によるノイズ処理プログラムを実行した後、技術者が手動・目視で再精査する必要があるため、推論プロセスの計算所要時間に、技術者による再精査の作業時間を上乗せする必要があることに留意しなければならない。

また、ノイズ処理の対象となる測深データ、ノイズ処理を行う技術者の技術力等によっても、ノイズ処理時間は大幅に変化する可能性がある。ノイズ処理プログラムによる作業時間短縮効果は、今後さらなる精査が必要である。



図-24 局所的な浅所のノイズ処理の模式図（左：手動によるノイズ処理，右：深層学習によるノイズ処理）

4. おわりに

4.1 主要な結論

本研究では、深層学習により自動的にノイズ処理を行うプログラムを開発した。開発したプログラムの特徴は、マルチビーム測深データを画像データとして取り扱うことにより、汎用的な計算機で推論プロセスを実行可能な点である。

開発したノイズ処理プログラムの精度検証を実際の浚渫工の測深データで行った結果、下記の主要な結論が得られた。

- ・教師データは、ノイズ率が小さい測深データよりも、ノイズ率が大きいもの又はデータ点数が多いものの方が、推論精度が高くなる。
- ・推論の精度は、F値が最大となる条件で、適合率0.981、認識率0.593である。認識率が低いため、開発したノイズ処理プログラムは、手作業によるノイズ処理を完全に代替することは困難であるが、手作業によるノイズ処理の対象範囲を絞り込むためのスクリーニングという活用が考えられる。
- ・汎用的な計算機を用いた場合でも、推論プロセスは30分以内に完了可能である。同じ測深データを手作業でノイズ処理した場合は約480分を要するので、ノイズ処理時間を短縮できる可能性が高い。しかし、深層学習によるノイズ処理プログラムを実行した後も、手作業による再精査が必要であるので、ノイズ処理プログラムによる作業時間の短縮効果は慎重に判断しなければならない。
- ・航行安全の観点からは、浅所をノイズとして誤って除去しないことが最優先である。このため、ノイズ判定閾値を高く設定し、認識率の向上よりも適合率を最大化する学習モデルが望ましい。

4.2 今後の課題

本研究では、学習プロセスの各種パラメータの設定、教師データの作成方法、推論プロセスの精度検証、計算所要時間等について、一定の結論を得ることができた。

しかし、本研究で得られた結論が、多種多様な測深データについて同様に成立するかは更なる検討が必要であり、開発したノイズ処理プログラムの適用事例を蓄積することが重要である。

また、施工現場の出来形計測等で実際に使用することを考えるならば、提出資料や審査項目等の運用に係る詳細を検討することが必要である。

なお、本資料は、既投稿論文¹³⁾に基づいて加筆・補足

して作成したものである。

(2022年6月2日受付)

謝辞

アンケートデータ及びマルチビーム測深データをご提供いただいた国土交通省港湾局及び各地方整備局、またヒアリングにご対応頂いた（一社）海洋調査協会会員企業の関係各位に、ここに記して深甚なる謝意を表する。

参考文献

- 1) 国土交通省港湾局：港湾におけるi-Construction推進委員会第4回資料，pp.61-62，2022。
<https://www.mlit.go.jp/kowan/content/001481664.pdf>
(最終閲覧日2022年6月2日)
- 2) 国土交通省港湾局：港湾におけるICT導入検討委員会第7回資料，pp.13-22，2019。
<https://www.mlit.go.jp/common/001274017.pdf> (最終閲覧日2022年6月2日)
- 3) 楠勝浩：浅海用ナローマルチビーム音響測深機のデータを海図に採用するために、海洋調査技術，第4巻，1号，pp.39-46，1992。
- 4) 卷俊宏，浅田昭：マルチビーム測深データの動揺補正とノイズ除去に関する研究，海洋音響学会誌，Vol.31，No.1，pp.28-38，2004。
- 5) 住吉昌直，栗田洋和，安原徹，橋本崇史，小川遥，長澤亮佑，長野勝行，吉澤信，眞保智彦，秋山裕平：マルチビーム水深測量成果におけるCUBE水深の採用について－海外水路機関における最適化の事例紹介，海洋情報部研究報告，第58号，pp.66-79，2020。
- 6) 長田康輝，辰巳大介，坂田憲治：ICT浚渫工の生産性向上に向けた出来形測量・水路測量の作業効率化に関する検討，国土技術政策総合研究所資料，第1200号，32 p.，2022。
- 7) Le Deunf, J., Nathalie, D., Thierry, S., François, G., Etienne, J., Lucas, V., and Romain, B.: Outlier Detection for Multibeam Echo Sounder (MBES) Data: From Past to Present, IEEE OCEANS, pp.1-10, 2019.
- 8) Stephens, D., Smith, A., Redfern, T., Talbot, A., Lessnoff, A., and Dempsey, K.: Using Three Dimensional Convolutional Neural Networks for Denoising Echosounder Point Cloud Data, Applied Computing and Geosciences, Vol.5, pp.1-10, 2020.
- 9) Zhang, K., Zuo, W., Chen, Y., Meng, D., and Zhang, L.: Beyond a Gaussian Denoiser: Residual Learning of

Deep CNN for Image Denoising, IEEE Transactions on Image Processing, Volume 26, Issue 7, pp.3142-3155, 2017.

- 10) Nair, V., and Hinton, G. E.: Rectified Linear Units Improve Restricted Boltzmann Machines, Proceedings of the 27th International Conference on Machine Learning, pp.807-814, 2010.
- 11) Liu, L., Jiang, H., He, P., Chen, W., Liu, X., Gao, J., and Han, J.: On the Variance of the Adaptive Learning Rate and Beyond, 8th International Conference on Learning Representations, 2020.
<https://openreview.net/pdf?id=rkgz2aEKDr>
(最終閲覧日2022年6月2日)
- 12) He, K., Zhang, X., Ren, S., and Sun, J.: Delving Deep into Rectifiers: Surpassing Human-level Performance on Imagenet Classification, Proceedings of the IEEE International Conference on Computer Vision, pp.1026-1034, 2015.
- 13) 小川雅史, 辰巳大介 : ICT浚渫工におけるマルチビーム測深データを対象とした深層学習によるノイズ処理の検討, 土木学会論文集B3 (海洋開発), 78巻, 2号, 2022 (印刷中) .