

# 港湾維持管理に向けた 水中ソナーの適用に関する検討

道前 武尊<sup>1</sup>・樋渡 和朗<sup>2</sup>・Sivaranjani Jayaprasad<sup>3</sup>・琴浦 毅<sup>4</sup>  
片山 裕之<sup>5</sup>・篠沢 佳久<sup>6</sup>・櫻井 彰人<sup>7</sup>

<sup>1</sup>正会員 五洋建設(株) 技術研究所土木技術開発部  
(〒329-2746 栃木県那須塩原市四区町 1534-1)

E-mail: takeru.michimae@mail.penta-ocean.co.jp

<sup>2</sup>五洋建設(株) 船舶機械部 (〒112-8576 東京都文京区後楽 2-2-8)

E-mail: kazuaki.hiwatari@mail.penta-ocean.co.jp

<sup>3</sup>正会員 五洋建設(株) 技術研究所土木技術開発部  
(〒329-2746 栃木県那須塩原市四区町 1534-1)

E-mail: sivaranjani.jayaprasad@mail.penta-ocean.co.jp

<sup>4</sup>正会員 五洋建設(株) 技術研究所土木技術開発部 (同上)

E-mail: tsuyoshi.kotoura@mail.penta-ocean.co.jp

<sup>5</sup>正会員 五洋建設(株) 技術研究所土木技術開発部 (同上)

E-mail: hiroyuki.katayama@mail.penta-ocean.co.jp

<sup>6</sup>慶應義塾大学 理工学部 管理工学科

(〒223-8522 神奈川県横浜市港北区日吉 3-14-1)

E-mail: shino@ae.keio.ac.jp

<sup>7</sup>慶應義塾大学 理工学部 管理工学科 (同上)

E-mail: sakurai@ae.keio.ac.jp

港湾施設の中で建設後 50 年を経過するものが増加するなか、水中部の点検を実施する潜水士の数は年々減少傾向にある。今後、定常的に発生する港湾施設の点検に対し、潜水士による点検の代替手法として広域かつ短時間に水中部を計測可能な技術を確認することが必要不可欠である。リアルタイム水中ソナーを用いた港湾施設の点検診断手法やガイドラインに定められた点検項目の中で代替可能な項目について確認してきた。本稿では、リアルタイム水中ソナーの取得データを過去のデータと比較する機構を構築し、ガイドラインに定められた点検項目への適応性や、点検にかかる時間の効率化の可能性を検討する。また、既往の研究において点検項目に対する適応性が低く運用が困難と判断したものに対し、水中部の点群データを用いた畳み込みニューラルネットワーク (CNN) の港湾維持管理への利用可能性について報告する。

**Key Words :** *underwater, four-dimensional underwater visualization, realtime 3D sonar system , port construction, maintenance, Convolutional Neural Network , diver*

## 1. はじめに

海洋工事において、ナローマルチビーム (NMB) やリアルタイム水中ソナー (以下、水中ソナー) などで海底地形を取得し、浚渫前後の鉛直方向の変化から浚渫量を算出する ICT 浚渫工が工事に取り入れられるなど、水中音響機器を活用した生産性向上の取り組みは進んでいる。

その一方で、建設後 50 年以上経過する港湾数は全体の約 20%程度と増加の一途をたどる中、港湾の施設の点検診断ガイドライン<sup>1,2)</sup>に沿って技術基準対象施設は定期的に点検を行うものとされている。一般的に、港湾構造物の水中部の点検は潜水士による目視確認によって行われる。港湾構造物の耐用年数が迫る中、潜水士を含む建

設技術職数は減少の一途をたどり慢性的な人員不足が発生している。港湾整備などの事業に従事している潜水士の数は国内で約 3000 人程度である。これは新規港湾事業や他事業に従事している人数を含めるため、点検を必要とする港湾施設数に対して圧倒的に少ない。港湾施設のストックは膨大であり、潜水士の業務負担を軽減させ、効率的に維持管理を行える手法の確立が望まれている。

潜水士による点検の代替手法として、ROV (遠隔操作型) や AUV (自律型) などの潜水機を介した水中映像による目視確認などが挙げられる。但し、潜水機による確認は構造物に対して近接して行う必要があり、1 フレームの視認範囲が狭く、構造物全体の状態を確認するためには時間と熟練の操作技術が必要となる。

一方で、水中ソナーは潜水士や潜水機による近接目視ほどの詳細な確認はできないが、1 フレームの視認範囲が広く、広域での大きな変位を短時間で把握することは可能である。

筆者らは過去に閉鎖されたドック内や室内実験槽などの波浪の影響を受けない環境下において水中ソナー単体の計測精度検証実験を実施し、ノイズ処理後のデータで標準偏差±5cm 程度の成果<sup>3)</sup>を得ている。実海域においてもケーソン式防波堤を対象に計測精度実証実験を実施するとともに、港湾の施設の点検診断ガイドラインに対する適応性について評価した<sup>4)</sup>。

本稿では港湾構造物の維持管理における1次スクリーニングを目的とした。特に、点検診断項目の中で、適応性が高いと判断した「凹凸・出入り」および「洗掘・堆積」を対象として、1年経過した同一箇所のデータを取得し、上記項目の経年変化の評価手法について検討した。また、水中ソナーでは困難であった狭隘な隙間の観察に対して、橋梁のクラック判別などを対象に研究されている畳み込みニューラルネットワーク(CNN)を水中点群データに対して同様に実施することで、人間の視覚では読み取れない点群の中に含まれる隙間を認識できるようになるか試みた。

## 2. 水中ソナーシステム

今回使用した水中ソナーシステムの構成機器と仕様を表-1に示し、特徴を以下に列記する<sup>5)6)</sup>。

- ・海底地形や水中構造物の形状を4次元(X, Y, Z, 時刻)で計測し、表示および記録をすることができる。ソナーにより代表例として50°×50°の範囲を128×128(16,384)本のビームを四角錐状に照射し、最大120mの距離まで計測することができる。
- ・データ更新レートは最大12f/sであるため、水中の動体計測も可能である。船を静止させた状態でも計測することができる。
- ・水中ソナーを艀装した船体の動揺をINS(Inertial Navigation System : 慣性航法装置)で計測補正し、超音波のノイズデータの除去も自動で行うため、従来は不可能であったリアルタイムの3次元表示があらゆる角度で可能である。
- ・作成した3次元モデルを水中ソナーシステム機器に取り込み、現地で映し出される3次元データと同時に表示することが可能である。
- ・機器は重量、構成ともにナローマルチビームソナーと同等で軽量かつ簡易であるため、船体に後付けの艀装をすることが可能であり、特定の船舶や特別な装備を用意することなく対応することができる。

表-1 水中ソナーシステムの構成機器と仕様

機器	項目 ( )内: 本実証実験の使用条件	
水中ソナー	周波数	340~700kHz(375kHz)
	ビーム数	128×128 16,384
	最大レンジ	120m(15m)
	最少レンジ	1m
	レンジ分解能	0.03m
	更新レート	最大12f/s
	計測範囲	25°×25°、50°×50°他(50°×50°)
	1ビーム当たりの角度	1°、0.5°(1°)
	ソナー寸法	380mm×300mm×160mm
	ソナー気中重量	22kg
ソナー水中重量	12kg	
ソナー耐水圧	600m	
INS	方位計測精度	0.01°
	ロール計測精度	0.01°
	ピッチ計測精度	0.01°
	ヒープ計測精度	5%、5cm
	出力レート	最大100Hz
	寸法	160mm×160mm×160mm
GNSS	重量	4.5kg
	精度	水平 8mm+1ppm RMS
	更新レート	20Hz
	重量	1.55kg

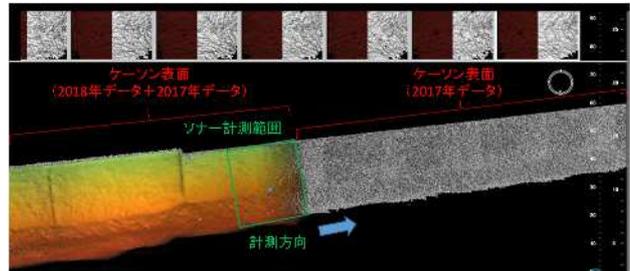


図-1 計測状況 (計測結果表示画面)

## 3. 現地実証実験概要

### (1) 実証フィールドの選定

本稿においては、昨年度に計測したケーソン式防波堤および海底地盤の点群データと1年後に再計測したデータを比較し、維持点検への運用方法を検討することを目的としている。そのため、昨年度に計測した場所と同一箇所を実証フィールド<sup>4)</sup>として選定した。

### (2) 計測内容

水中ソナーおよび水中ソナーシステムを船舶に艀装し、船舶をケーソン式防波堤に対して平行に航行することで、ケーソン側面および海底地盤の点群データを計測した。

また、1年前の取得データを計測結果表示画面に重ね合わせておくことで、視覚的かつリアルタイムに変位状況を確認した。図-1に計測時の表示画面を示す。有色部分が当日計測しているデータ、白黒部分が1年前に取得したデータである。このように、過年度データを計測画面に表示することで、当日の計測データと比較しながら計測を進めることができ、乖離を確認することで、乖離が大きい重大な変位についてはリアルタイムに把握することが可能となった。

## 4. 点検診断への適用性

### (1) 変位算出システム

筆者らが構築したリアルタイム水中ソナーデータ用の変位算出システム<sup>4)</sup>を使用して、今回計測したデータと1年前の計測データを比較した。

図-2 に海底地盤の鉛直方向およびケーソン壁面の水平方向に対し、変位算出システムを適用した例を示す。計測精度が±15cm 程度であることを踏まえ、変位量が-15cm~0cm の範囲を水色、0cm~15cm の範囲を青色、15cm~30cm の範囲を緑色、30cm 以上の範囲を赤色で示した。表示方法については、適宜変更が可能である。

海底地盤の結果では、ケーソン下端部付近や一部で30cm 以上の堆積傾向が出力された。ケーソン壁面では30cm 以上の変位は確認できなかったが、15cm~30cm の範囲での変位が出力された。それぞれの計測で計測誤差があるため、一概に変位を評価できないが、大部分の範囲において前年度との変位が15cm 以内であることから30cm 以上の変位が出力された範囲については相対的な変位があると判断できる。

### (2) 点検診断への適用性

海底地盤の結果から、洗掘や堆積の範囲を明確に表示することが可能となった(表-2)。15cm 以下の変位を抽出するのは機械性能上困難であるが、50cm 単位の変位であれば、リアルタイムでも十分に判断可能であり、大きな変位がある場所については即座に潜水土による調査を実施でき、広域な海底地盤の中から潜水土による調査範囲を絞り、点検の大幅な点検短縮が可能となった。

また、ケーソン壁面の変位状態を確認することで、大きな変位がある箇所を特定することが可能となった。改修を要するような変位箇所を特定することで、潜水土による調査箇所の絞り込みが可能となり、点検の大幅な時間短縮が可能となった。但し、点検項目にある幅3mm のひび割れなど細かい変位については判断することができなかった。

## 5. 点群データを用いた機械学習

水中ソナーを用いた港湾施設の維持管理手法について検討し、水中ソナーを使用して施設全体の大きな変位を把握することが可能なことを示してきた。一方で、劣化、損傷や腐食などの詳細な項目について、水中ソナーから得られるデータでは性能低下度の判断に至る十分な結果を得ることができないことも示した<sup>4)</sup>。現状、大きな変位を水中ソナーで確認し、詳細な部分については潜水土

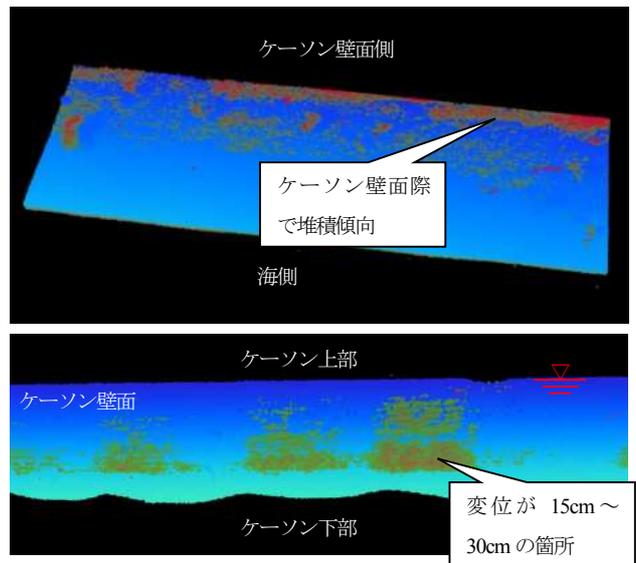


図-2 変位算出システムの適用  
(上：海底地盤，下：ケーソン壁面)

表-2 劣化度・適応性一覧表(洗掘・堆積)

点検項目	劣化度	性能低下度の評価基準	水中ソナー適応性
洗掘 堆積	a	岸壁前面で深さ1m以上の洗掘がある 洗掘に伴い、マウンド等や岸壁本体への影響が見られる	○
	b	岸壁前面で深さ0.5m以上1.0m未満の洗掘がある	○
	c	深さ0.5m未満の洗掘又は堆積がある	○
	d	変状なし	○

による目視確認もしくはROV などから取得できる映像データによる確認によって性能低下度を評価するのが現実的である。

また、目視による確認では見落としや習熟度による判断の差異が発生することが考えられる。そこで、新たな性能低下度評価手法として、水中ソナーから取得した点群データに対し、畳み込みニューラルネットワーク(CNN)を用いて、異常点の抽出を試みた。

### (1) 深層学習

ここで用いるCNNは畳み込み層とプーリング層の繰返しによる特徴マップ抽出部分と、特徴マップからクラス分類や回帰を行う全結合層部分で構成される。このように分類器に加えて、特徴抽出器を学習によって得ることができる点がCNNの利点であり、画像認識分野における物体カテゴリ認識などでハンドクラフト特徴量を用いた手法よりも高い精度を示している。

過去に水中音響機器で取得した点群データを用いた深層学習はほとんど行われたことが無い。そこで、本稿では水中部の点群データに対する深層学習による学習のノウハウや検証の手法を習得し、異常点の抽出可能性を検討することを目的とする。特にエンコーダ・デコーダ型のCNNを用いて、点群データをCNNに入力し、異常点を検出することを試みる。

今回、水中部の隙間を対象とした。まず、室内実験によって恣意的に作り出したブロック間の隙間に対し、畳

み込みニューラルネットワークを適用し、学習方法について検討を行った。そこで得られたノウハウを元に、現地実証データに適用し、検証を行った。

そのための検討手順の概要を図-3に示す。

(2) 室内実験データ

a) 学習用データ

ケーソン間の目地およびコンクリートの亀裂を想定し、現状、計測した点群データからでは目視による確認が難しかった5cmを対象とした。

実験概要を図-4に示す。無響水槽底面に方塊ブロック(0.6m角)を5cmの隙間を持たせて設置した。水中ソナー設置位置は方塊ブロックの前面から2.0mと2.5mの2通りとし、2.0mのデータを学習用にし、2.5mのデータを検証用のデータとした。方塊ブロック間の中心線上に設置した水中ソナーを左右方向に5cm間隔で40cmまで動かして計測した。計測時は、水中ソナーを静止した状態でデータを取得した。取得データは3次元データのため、方塊ブロック正面に点群を投影した画像を用いる。学習用データは14枚、検証用データは17枚である。

学習データの一例を図-5に示す。図中の入力画像(点群データ)から正解画像(方塊ブロック)を復元する。実際に入力画像は画素値が0から255のグレースケール画像である。今回取得したデータだけではデータ数が不十分のため、データを90度、180度および270度回転させ、画像サイズ内で水平移動(41地点)させたものを学習データとして使用した(合わせて14×4×41=2,296枚)。

b) 深層学習

何ケースか深層学習を試みた中で、最も検証結果が良好であったケースのCNN模式図を図-6に示す。

CNNの構造としてU-Net<sup>7)</sup>を用いた。入力画像の大きさは200×200とし、これを畳み込み処理およびプーリング処理を繰り返し、25×25の大きさの特徴マップにまで縮小する。次に逆畳み込み処理を繰り返すことによって200×200の大きさの正解画像に復元する。

図6-4中のconvは畳み込み層を示す。conv1はフィルターの大きさが3×3、枚数が256枚、ストライドは1、パディング(ゼロパディング)は1、活性化関数としてReLUを用いていることを示す。poolingはプーリング層を示し、最大値プーリング、大きさが2×2、ストライドは2であることを示す。Unpoolingは、特徴マップを2×2倍に拡大するアップサンプリング層である。またconv2から出力された特徴マップ(h1)をショートカットによりconv15に入力している。誤差関数には平均二乗誤差、バッチサイズは1、学習にはAdamを用いた。

図-7に入力画像および出力画像を示す。出力画像に隙間が出力されており、今回用いた画像から、正解画像を元に十分な精度で学習できていることが確認できた。

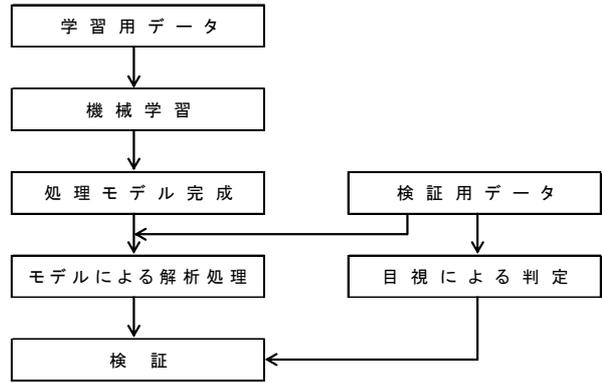


図-3 検討手順

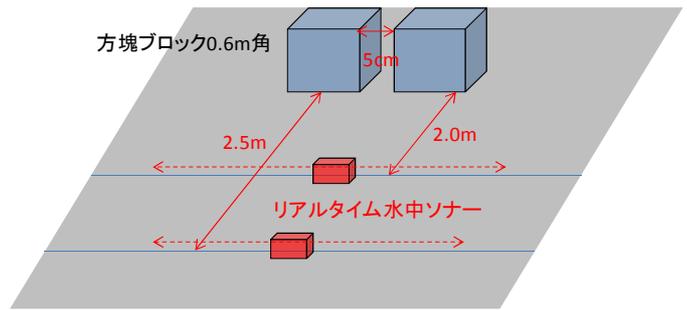


図-4 室内実験概要図

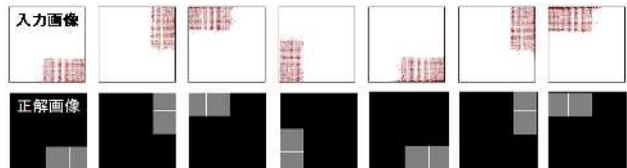


図-5 室内実験における学習データ

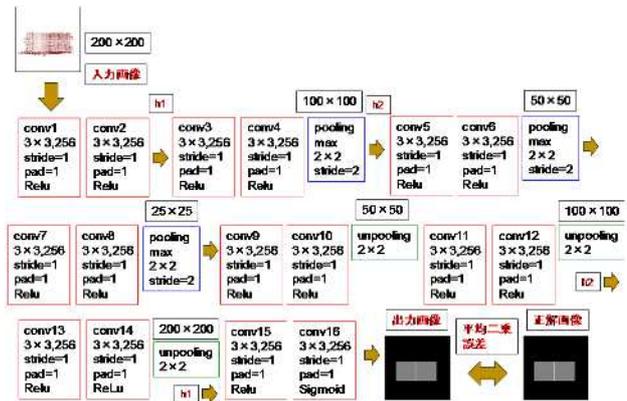


図-6 室内実験におけるCNN模式図

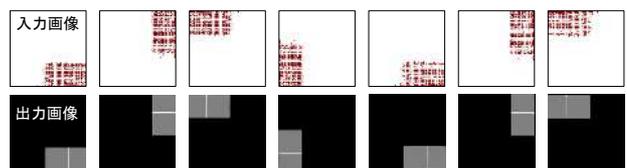


図-7 CNNによる学習結果

c) 検証

図-8に検証結果を示す. 正面に近いと5cmの隙間を認識しているのに対し, 正面から横方向に移動するにしたがい隙間の認識が難しくなっていることが分かる. これは, ソナーに対して, 隙間が角度を持ったことで最小分解能である3cmを下回ったことが原因として考えられる. これより, 正面付近で取得したデータのみを用いると5cm程度の隙間であれば判断できることが分かった.

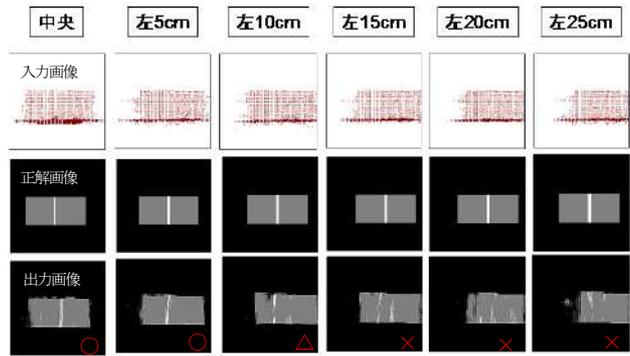


図-8 CNNによる検証結果

(3) 現地実証実験データ

a) 学習用データ

2017年にケーソン式防波堤を対象に取得したデータを学習用データとして用いた. 取得データは3次元データのため, ケーソン正面に点群を投影した画像を入力画像(大きさは2,120×520)として用いた. その画像に対して, 実際に存在する隙間を正解画像として作成した. 学習データは10枚用意した. その一例を図-9に示す. 図を見てわかるように, 画像の大部分を隙間でない部分が占めていることから, 隙間であるデータの中で隙間と予測された割合の再現率(Recall)および隙間と予測した結果の中で実際に隙間である割合の精度(Precision)を重要視し, それらの調和平均であるF値を評価の指標とした.

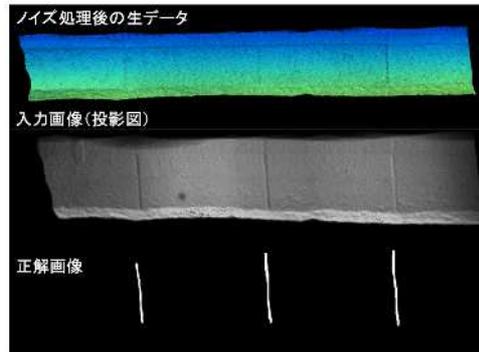


図-9 現場実証実験における学習データ

大きさ2,120×520の学習データを, 大きさ40×40の小領域に重ならないように分割し, これらの小領域を対象にCNNによって学習する. 画像1枚から689(53×13)枚の小領域が切り出されるため, 学習データ数は, 合計6,890枚となる.

b) 深層学習

深層学習におけるCNN模式図を図-10に示す. CNNの構造は, 室内実験データで用いたCNN(図-6)と同じくU-Netとした. 学習方法などは, 室内実験データの場合と同じである.

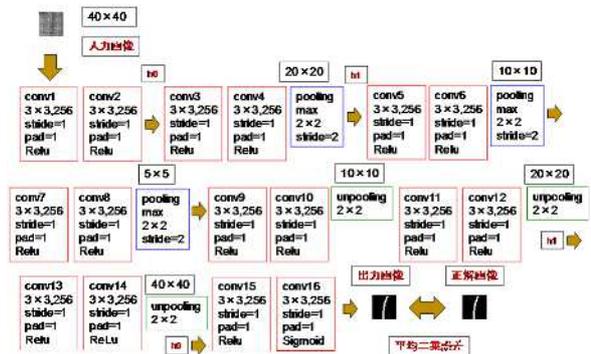


図-10 現場実証実験におけるCNN模式図

学習結果の例を図-11に示す. 左図のように入力画像を見て人の視覚で隙間が明確に判断できる場合は再現率が0.88, 精度が0.91, F値が0.89と高い再現率と精度を有している. 一方で, 右図のように入力画像からは隙間の判断が難しい場合は再現率が0.17, 精度が0.82, F値が0.29と学習も難しい結果となった.



図-11 CNNによる学習結果(学習データ1, 2)

c) 検証

2018年に取得したデータを検証用データとして用いた. 検証結果の例を図-12に示す. 左図のように入力画像を見て人の視覚で隙間が明確に判断できる場合は再現率が0.29, 精度が0.71, F値が0.41と高い精度を有していたが再現率が低い結果となった. 一方で, 右図のように入力画像からは隙間の判断が難しい場合は再現率が0.14, 精度が0.55, F値が0.22と再現率ならびに精度も低い結果となった.

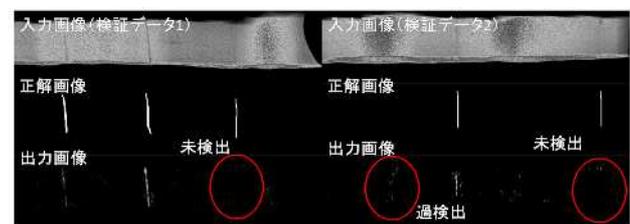


図-12 CNNによる検証結果(検証データ1, 2)

## 6. まとめと今後の展望

### (1) まとめ

まとめについて以下に述べる。

#### a) リアルタイム水中ソナー

・広域な防波堤や航路などに対し、過去のデータを重ね合わせることで、リアルタイムに大きな変位が有る場所を特定し、潜水士の調査を大きな変位が発生している箇所に限定することが可能となった。

・維持管理項目である「洗掘・堆積」に対し、リアルタイムに十分な精度での性能低下度評価が可能となった。

#### b) 深層学習

・人の視覚で判断できる隙間は比較的容易に学習でき、検証用データについては、再現率は低いものの精度は高い結果となった。一方で、人の視覚で判断できない隙間は再現率と精度ともに低く検出が困難であった。

### (2) 課題と今後の展望

課題と今後の展望について以下に述べる。

#### a) リアルタイム水中ソナー

・今回は、システムの精度や運用具合を確認するために1年越しという短いスパンでの検証となった。大多数の港湾構造物が現状の3次元点群データを所有していない中、今後、維持管理への適用を進めていくためには、現状の港湾構造物および新設の港湾構造物の水中点群データを音響機器などで取得し、ストックしておく必要がある。

#### b) 深層学習

・計測対象に正面に位置するデータでは5cmの隙間を認識できていることから、リアルタイム水中ソナーで得ら

れる正面付近の点群データやナローマルチの点群データであれば、比較的安定的に隙間を認識できる可能性があり、今後検証を進めていく。

なお、本研究の一部は、内閣府総合科学技術・イノベーション会議の「SIP I 期インフラ維持管理・更新・マネジメント技術」(管理法人:NEDO)に関連する研究開発として実施した。

ご協力いただきました関係各位に感謝いたします。

### 参考文献

- 1) 港湾の施設の点検診断ガイドライン【第1部 総論】国土交通省港湾局 平成26年7月
- 2) 港湾の施設の点検診断ガイドライン【第2部 実施要領】国土交通省港湾局 平成26年7月
- 3) 道前武尊, 樋渡和朗, 帯田俊司, 琴浦毅, 西畑剛, 平山達也, 野口孝俊: リアルタイム水中ソナーを用いた海上工事の施工・維持管理に向けた検討, 土木学会論文集B3(海洋開発) No. 2, Vol. 33, pp. 1013-1018, 2017
- 4) 道前武尊, Sivaranjani Jayaprasad, 樋渡和朗, 琴浦毅, 帯田俊司, 西畑剛, 平山達也: 港湾維持管理に向けたリアルタイム水中ソナーの計測精度検証, 土木学会論文集B3(海洋開発) No. 2, Vol. 34, pp. 7-12, 2018
- 5) 港湾関連民間技術の確認審査・評価報告書第12004号 4D ソナーによる施工管理システム 一般財団法人沿岸研究センター
- 6) 眞鍋匠: 4D ソナーによる施工管理システム, 港湾荷役, No.6, Vol.58, pp.617-622, 2013
- 7) O. Ronneberger, P. Fischer, and T. Brox: "U-net: Convolutional networks for biomedical image segmentation," Lecture Notes in Computer Science, Vol. 9351, pp. 234-241, 2015

(2019.2.7 受付)

(2019.4.24 受理)

## INVESTIGATION OF MEASUREMENT OF THE REAL-TIME UNDERWATER SONAR FOR PORT MAINTENANCE AND MANAGEMENT

Takeru MICHIMAE, Kazuaki HIWATARI, Sivaranjani JAYAPRASAD, Tsuyoshi KOTOURA, Hiroyuki KATAYAMA, Yoshihisa SHINOZAWA and Akito SAKURAI

In the midst of the increasing Port Structures that have crossed the in-service period of 50 years from construction, there is also deterioration in the number of divers carrying out the underwater investigation. Hence it is indispensable to develop a technique capable of carrying out wider area investigation in a shorter time, as an alternative of the current method of regular inspection of port structures by divers. Using realtime Underwater Sonar, the possible alternative methods has been checked for the inspection items mentioned in the Guidelines on Inspection and Diagnosis methods of Port structures.

In this paper, a tool that compares the present realtime sonar data with the past data is developed. Its adaptability to the inspection items as mentioned in the guidelines and its efficiency on the time taken for inspection has been investigated. While the past research concludes that the adaptability to the inspection items was low, the feasibility of using underwater point cloud data in convolutional neural network for port maintenance is also reported.