

# 人工知能技術を活用した栈橋の 残存耐力評価手法に関する研究

宇野 州彦<sup>1</sup>・白 可<sup>2</sup>・岩波 光保<sup>3</sup>

<sup>1</sup> 正会員 五洋建設(株) 技術研究所 (〒329-2746 栃木県那須塩原市四区町 1534-1)  
E-mail: kunihiko.uno@mail.penta-ocean.co.jp

<sup>2</sup> 正会員 五洋建設(株) 技術研究所 (〒329-2746 栃木県那須塩原市四区町 1534-1)

<sup>3</sup> 正会員 東京工業大学 環境・社会理工学院 (〒152-8552 東京都目黒区大岡山 2-12-1)  
E-mail: iwanami@cv.titech.ac.jp

港湾構造物は塩害に対して厳しい環境下におかれるため適切な維持管理が求められるが、劣化した栈橋の残存耐力を評価する研究はあまり多くはない。著者らはこれまでに、劣化度判定結果を用いた栈橋の残存耐力評価手法を提案し、汎用の構造解析プログラムにより残存耐力評価を行うことを可能とした。一方で、複数栈橋の維持管理優先度を決定するためには、構造解析を必要としないさらに簡易な残存耐力評価手法も望まれている。そこで本研究では、想定外力に対する栈橋の損傷面積率を推定する人工知能技術を導入した残存耐力評価手法を提案し、構築したプログラムの推定精度検証と任意の劣化度分布を有する栈橋の損傷予測を行った。数値情報と画像情報から予測する手法はいずれも高い精度で損傷を推定でき、画像情報の手法により損傷面積率だけでなく損傷分布も把握できることが示された。

**Key Words :** *steel pipe piled pier, residual structural performance, gradient boosting decision tree, neural network, convolutional auto encoder, Chebyshev distance, machine learning*

## 1. はじめに

港湾構造物は一般に塩害に対して厳しい環境下におかれており、より適切な維持管理が求められているものの、鉄筋腐食等により劣化した栈橋の残存耐力や耐震性能に関する研究はあまり多くはない。著者らは、既往の研究(例えば<sup>1)</sup>)を踏まえ、「港湾の施設の維持管理技術マニュアル」<sup>2)</sup>等に基づいた一般定期点検診断で示される梁の劣化度判定結果(a~d)と残存耐力について、載荷実験によりその関係性を明らかにしてきた<sup>3)</sup>。これにより、劣化度に応じた梁部材の骨格モデルを規定することで汎用の構造解析プログラムにより残存耐力評価を行うことが可能となった。さらに耐力評価の精度を向上させるため、電食により腐食させた鉄筋と海洋環境において自然暴露により腐食が生じた鉄筋の腐食生成物の違いや鉄筋膨張圧の持続作用の違いに着目し、また寸法効果の影響にも着目した梁の載荷実験も実施することで、鉄筋腐食方法により梁の初期剛性に違いがあることや、鉄筋腐食率の高い梁は鉄筋降伏後のひずみ硬化が梁全体に与える影響に違いがあることを明らかにした。これらを踏まえて文献<sup>3)</sup>で定義していた劣化骨格モデルの補正を提案している<sup>4)</sup>。その一方で、複数の栈橋を保有する管理者にとっては、

各栈橋の維持管理優先度を決定するために都度構造解析を実施することのない、さらに簡易な残存耐力評価手法が望まれている。

そこで本研究では、地震力等の想定外力に対して生じる栈橋梁の有害ひび割れの発生(使用限界状態におけるひび割れ幅の限界値<sup>5)</sup>)や降伏状態(塑性化)、終局状態といった損傷の栈橋梁総面積に対する比率(以下、損傷面積率)を推定する人工知能技術を導入した残存耐力評価手法を提案し、構築したプログラムの推定精度の検証と、任意の劣化度分布を有する栈橋の損傷予測を行う。推定精度の検証や損傷予測については、文献<sup>4)</sup>において提案している骨格モデルに基づいて構造解析を実施し、得られた損傷結果を正解値として比較を行う。なお本研究においては、上記の損傷面積率を明らかにすることを栈橋の残存耐力評価と位置付けている。

## 2. 数値情報を用いた人工知能による機械学習手法

### (1) 教師データの作成

機械学習に使用する教師データは、梁数や杭列数等の

表-1 各栈橋の諸元

栈橋No.	上部工寸法	梁本数 (本)	梁総面積 (m <sup>2</sup> )	杭本数 (本)	栈橋法線直角方向への列数 (列)
No.1	67m×25m	176	496	60	4
No.2	33m×15m	75	152	35	5
No.3	50m×20m	103	280	30	3

表-2 各劣化度の栈橋面積率パターン (一部)

パターン	各劣化度の面積率			
	a	b	c	d
1	0%	0%	0%	100%
2	0%	20%	0%	80%
3	0%	0%	20%	80%
4	0%	20%	20%	60%
5	0%	40%	0%	60%
34	60%	0%	40%	0%
35	80%	0%	0%	20%
36	80%	20%	0%	0%
37	80%	0%	20%	0%
38	80%	10%	10%	0%
39	100%	0%	0%	0%

異なる3種類 (以下, No.1~No.3) の栈橋 (表-1) を対象とした. 維持管理マニュアルに示される劣化度判定結果<sup>2)</sup>と外力条件を無作為に組み合わせ, 合計702パターンの解析モデルと各々の解析モデルに対応する構造解析結果を基にした説明変数および目的変数で構成される. 栈橋梁の総面積に対して, 各劣化度(a~d)を表-2に示すような面積率で割り振っている. 各劣化度を有する梁を無作為に配置している. 外力条件に関しては紙面の都合上掲載を割愛するが, レベル1地震動は当該栈橋が位置する港湾近傍で想定される地震動, レベル2地震動は東北地方太平洋沖地震及び兵庫県南部地震において観測された地震動を複数使用している. 教師データとなる構造解析結果は, 汎用構造解析プログラムEngineer's Studio<sup>6)</sup>を用いて計算した. 汎用構造解析プログラムで残存耐力を評価する手法については前章で示した通り, 各梁の劣化度に応じた骨格モデルの定義に基づいて栈橋のモデル化を行い, 構造解析から残存耐力を評価した. 以降に示す全ての機械学習手法において, 構造解析結果を正解値として精度の推定や予測を行うことから, 本研究における機械学習を用いた損傷予測は, 汎用構造解析によって得られる損傷結果に整合することを目標とする.

数値情報を用いた機械学習は, 説明変数として劣化度判定結果と外力条件, また栈橋法線直角方向の杭の列数を設定した. 劣化度判定結果は, 先述したように各劣化度を有する梁が栈橋梁総面積に対して占める割合について, 0~1 (0~100%) の比率で表現した. 外力条件は, レベル1もしくはレベル2地震動をOne-hot Encoding<sup>7)</sup>で入力した. 栈橋法線直角方向の杭の列数は, 一般に直杭式横栈橋直下の地盤地表面は傾斜していることが多いため, 法線直角方向の杭列数によって栈橋構造としての見かけの剛性が変化することに着目し, 説明変数として加えている. 目的変数は, 構造解析から得られた栈橋梁の有害ひび割れ, 降伏状態, 終局状態の各損傷面積率とした.




図-1 決定木の構造




図-2 ニューラルネットワークの基本的な構成

(2) 適用する機械学習モデル

数値情報を用いた機械学習手法として, 本研究では勾配ブースティング木<sup>7)</sup>とニューラルネットワーク<sup>8)9)</sup>の2種類の手法を選定し, 適用性の検討を行う.

a) 勾配ブースティング木

まず, 勾配ブースティング木 (以下, GBDT) アルゴリズムの基礎となる, 決定木について説明する. 決定木とは図-1に示すように, 複数のノードと枝で構成される階層的な木構造を学習するモデルであり, 分類や回帰のタスクに用いられる. 各ノードは, 例えば「劣化度はaであるかそうではないか」, 「法線直角方向かそうではないか」といった真偽テストを表しており, この結果に基づいて分岐する. これを階層的に繰り返すことで, 複雑な分離も可能となる. GBDTとは, 複数の決定木を構築してアンサンブル学習を行うモデルである. アンサンブル学習とは, 複数のモデルを組み合わせることで精度を高める手法である. ランダムフォレスト法のように, 複数の異なる決定木を並列に構築するのではなく, 1つ前に作成した決定木の精度を上回るように逐次的に, 直列に学習するモデルである. GBDTの特徴として, パラメータチューニングをさほど必要とせず精度が得られるという利点があり, 正規化を行う必要がないことから説明変数のスケールを直接使用することができる. 本研究では, GBDTの実装としてよく用いられるxg-boost (以下, XGB) を使用する.

b) ニューラルネットワーク

ニューラルネットワーク (以下, NN) は, パーセプトロン構造を複数組み合わせたものであり, 図-2のように

入力層, 中間層 (隠れ層), 出力層と呼ばれる層を持つ. 階層的に信号が処理されることで高度な情報処理を可能とする. 入力層には各説明変数が入ることになり, 中間層へ移行する際 (図中の矢印) において重み係数がかけられることとなる. それ以降も出力層に至るまで各箇所で重み係数が考慮される. 中間層が多層になるものが深層学習 (ディープラーニング) と呼ばれる. NNの特徴としては, 複数のパーセプトロンと活性化関数を用いることで非線形分離が可能であり, 中間層の階層数やニューロン数を増やすことにより, 複雑な分類や回帰が可能となる.

### (3) 解析モデル構築の手順

解析モデルを構築する手順は, まず劣化度判定結果から各劣化度に応じた梁の面積率を算定し, 説明変数と目的変数とを対応させた教師データを作成した後, 機械学習モデルのタイプを選定する. 各モデルにはハイパーパラメータと呼ばれる学習や処理の挙動を制御するパラメータがあり, 事前に設定を行う. GBDTでは決定木の本数や木の深さ (層数) の最大値, 葉を構成するデータ数等で, NNでは中間層の階層数やニューロン数, 活性化関数等がハイパーパラメータに相当する. これらを事前に設定し, 推定誤差が最小となるように重みやバイアス等のパラメータの最適値を探索し, モデルを構築していく. 本研究では, 計702パターンのデータのうち, 後述する4章で用いる損傷予測データを除いた上で, 教師データから無作為に抽出した80%をパラメータの最適化に用いる学習用データとし, 残りの20%をモデルの検証用データとした. 学習に際しては, 過度に学習を進めると検証用データに対する精度や汎化性能が悪化する過学習が発生する可能性があるため, 学習ループにおいて検証精度を監視し, 検証精度が改善しない, もしくは悪化するタイミングで学習をストップさせるEarly Stoppingを採用した. 検証方法は, 交差検証を用いてできるだけ多くの学習データを使用して汎化性能の向上を図った.

### (4) 検証結果

2種類の手法を用いて学習と検証を行った結果を以下に示す. なお本検討は回帰問題であることから, 推定誤差の算定として, 式(1)に示す目的変数の推定値と正解値との差の平均二乗誤差を用いて評価した.

$$\bar{E}^2 = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (1)$$

ここで,

- $\bar{E}^2$  : 平均二乗誤差
- $N$  : サンプル数
- $y_i$  : 推定値
- $t_i$  : 正解値

### a) GBDT

GBDTによる損傷面積率の回帰結果を図-3に示す. 図に示すひび割れ面積率は, 機械学習手法または構造解析において有害ひび割れ発生と判定された梁の面積が, 栈橋梁総面積に占める比率を表したものである. 降伏面積率や終局面積率も同様に, 降伏や終局状態に至った梁の梁総面積に対する比率である. ハイパーパラメータのうち, 決定木の本数を100, 木の深さの最大値を5, 葉を構成するデータ数を10とすることで推定精度の高い結果が得られた. しかし図-3(c)に示すように終局面積率については精度の低い結果となった. これは対象栈橋が3種類であったためサンプル数としては少なかったことと, 劣化が著しく外力がレベル2地震動であっても終局に至る梁はほとんどなかったため終局面積率が低い範囲に集中したことが要因と考えられる. そこで降伏と終局を区別せずに降伏以上として取り扱い, 再度学習と検証を行った. 決定木の本数と葉を構成するデータ数は変えずに木の深さの最大値を6とすることで, 図-4に示すように高い精度で推定することができた.

### b) NN

NNによる損傷面積率の回帰結果を図-5に示す. ハイパーパラメータのうち, 中間層の階層数を3, ニューロン

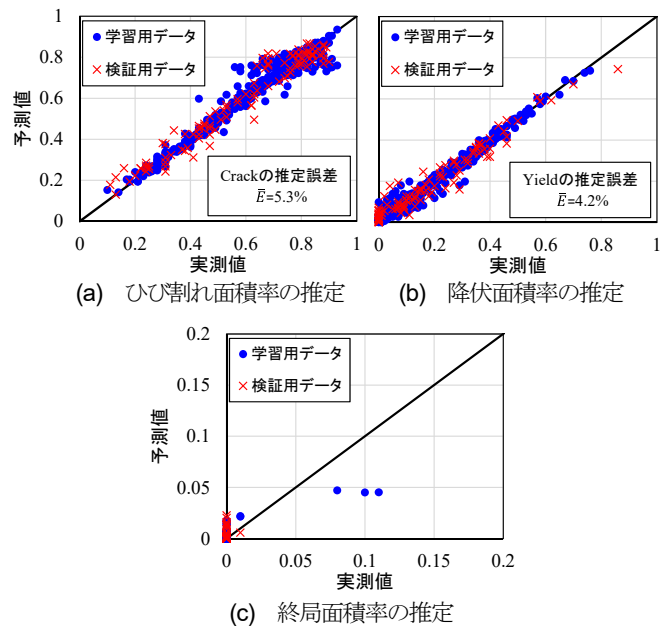


図-3 GBDTによる損傷面積率の回帰結果




図-4 降伏と終局の損傷合計面積率による推定結果 (GBDT)


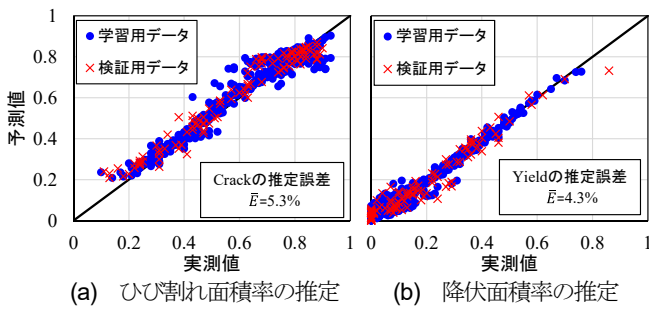


図-5 NNによる損傷面積率の回帰結果




図-6 降伏と終局の損傷合計面積率による推定結果 (NN)

数を96, 活性化関数としてシグモイド関数を用いることで推定精度の高い結果が得られた。しかしGBDTと同様に, 終局面積率については精度の低い結果となった(図-5(c))。したがって, 先ほどと同様に降伏以上としての取り扱いに変更した。中間層の階層数を4とし, ニューロン数と活性化関数は変更せずに再度学習と検証を行うと, 図-6のように高い精度で推定することができた。

### 3. 画像情報を用いた人工知能による機械学習手法

#### (1) 教師データの作成

対象とする教師データは, 数値情報を用いた機械学習と同様に, 計702パターンから損傷予測用のデータを除いたものとする。説明変数の劣化度判定結果と目的変数の各損傷分布結果を画像データとして取り扱うことが前章の手法と異なる点である。画像データについては計算処理の簡便性から, 図-7に示すようにピクセルサイズへの変更処理を行う。損傷分布についても同様にピクセルサ




図-7 画像入力におけるピクセルサイズへの変更処理

イズで出力される。ピクセルサイズに変更することで梁の長さに関する情報が失われるため, 説明変数として梁の長さを追加する。外力条件や法線直角方向の杭列数については, 前章と同様に数値データとして設定する。

#### (2) 適用する機械学習モデル

画像情報を用いた機械学習手法として, 本研究では畳み込みオートエンコーダ<sup>10)</sup>を用いたMAPモデルおよび, 梁間の距離としてチェビシェフ距離を採用し梁の特微量から梁1本ずつに対して損傷を予測しその結果を画像として出力するチェビシェフ距離モデルを選定し, 適用性の検討を行う。モデル構築の手順は前章と同様である。

##### a) MAP モデル

MAPモデル(以下, MAP)のアルゴリズムにおいては, オートエンコーダを模した構造を採用している。オートエンコーダとは, 入力と出力を同じデータとして学習するニューラルネットワークのモデルであり, 全結合層を重ねて入出力の次元数よりも中間層の次元数を小さくし, 最終的に入力と同じデータを復元できるように学習することで, 中間層において入力画像を次元圧縮したのと同等的特徴量を取得できる。MAPモデルのアルゴリズムである畳み込みオートエンコーダは, 畳み込み層で画像処理におけるフィルタのような処理によって特徴量を得ながら, プーリング層<sup>8)</sup>によって特徴マップが縮小されていく。これらの過程で得られた特徴量ベクトルに対して, 逆畳み込み層等を用いて画像サイズを復元, 生成する。

##### b) チェビシェフ距離モデル

チェビシェフ距離モデル(以下, CHEBY)で用いるチェビシェフ距離とは, ユークリッド距離やマンハッタン距離とともに距離を表現する概念の一つである。二次元空間においては縦横二軸のうち座標差の大きな方がチェビシェフ距離である。例えば図-8において点A(1,1)と点B(2,4)はx軸方向の座標差が1, y軸方向の座標差が3であるため, チェビシェフ距離は3となる。図-9に示すような劣化度分布において, 赤色でハッチングした梁(座標(2,1))は同図右側のような特徴量が得られる。この特徴量を表-3のように劣化度の分布割合で表現し, XGBにより損傷予測を行う。これを梁ごとに実施し, 各梁の結果を図として配置することで画像情報としての出力が可能となる。






図-8 チェビシェフ距離の例




図-9 梁の劣化度と分類結果の例

表-3 劣化度の分布割合

説明変数	1				2				...
	d	c	b	a	d	c	b	a	
割合	0.25	0.5	0.25	0	0.4	0	0.2	0.4	...

表-4 混同行列の例

梁の総数: 177本		予測			
		損傷なし	ひび割れ	降伏	終局
正解	損傷なし	67	49	0	0
	ひび割れ	1	11	18	0
	降伏	0	0	29	0
	終局	0	0	1	1

表-5 各手法による予測結果 (損傷面積率)

外力	損傷グレード	構造解析結果 (正解)	数値情報を用いた手法		画像情報を用いた手法	
			XGB	NN	MAP	CHEBY
L1地震動	ひび割れ面積率	83%	84%	84%	87%	80%
	降伏面積率	0%	-	-	0%	0%
	終局面積率	0%	-	-	0%	0%
	降伏+終局面積率	0%	2%	3%	-	-
L2地震動	ひび割れ面積率	32%	33%	33%	30%	33%
	降伏面積率	64%	-	-	67%	63%
	終局面積率	0%	-	-	0%	0%
	降伏+終局面積率	64%	62%	63%	-	-

表-6 画像情報を用いた手法による損傷予測結果と構造解析結果の比較

		予測結果		構造解析結果(正解)
		MAP	CHEBY	
L1地震動	損傷分布			
	正解率	92%	97%	—
L2地震動	損傷分布			
	正解率	89%	92%	—

■ 終局   
 ■ 降伏   
 ■ ひび割れ   
 ■ 正常   
 ■ 梁以外の部位

### (3) 検証結果

2種類の手法を用いて学習と検証を行った結果について、本章では正解率により推定精度を確認する。各梁における予測と正解の結果が4クラス(損傷なし, ひび割れ, 降伏, 終局)のマルチクラス分類であると考え、検証用データ全体の梁数に対して、予測モデルが正解した梁数の割合を算出したものを正解率とする。例えば、予測結果に基づく混同行列が表-4のように得られた場合、正解率は以下のように求められる。

$$\text{正解率 (\%)} = \frac{67 + 11 + 29 + 1}{67 + 49 + 1 + 11 + 18 + 29 + 1 + 1} \times 100$$

MAPにおけるハイパーパラメータとして、エンコーダ層の層数は3, サイズは64, 128, 256, デコーダとして逆畳み込み層を使用し、畳み込みカーネルサイズを5, プーリング層の対象サイズを2とすると、正解率は89%となった。CHEBYにおけるハイパーパラメータは、決定木の本数を100, 木の深さの最大値を13, 葉を構成するデータ数を5とすることで正解率は94%となり、いずれの手法も概ね高い精度であることが示された。

## 4. 学習済みモデルを用いた残存耐力評価

### (1) 対象栈橋および劣化度分布の概要

前章までに示した学習済みモデルを利用して、学習モデル構築に使用していない未知の劣化度を有する栈橋について、損傷予測を行った。予測対象は栈橋No.1とし、図-7に示した劣化度分布を有するものとする。

## (2) 予測結果

学習済みモデルを用いて予測した損傷結果を表-5に示す。正解値として構造解析結果から算出した損傷面積率も併記している。数値情報による手法は、いずれの手法においても概ね正解値に近い損傷面積率を予測できている。しかし、L1地震動が作用した場合、構造解析結果では降伏や終局に至る梁はなかったが、2~3%損傷するという予測結果となった。画像情報による手法についても、いずれの手法も概ね正解値に近い予測となっている。

MAPとCHEBYを比較すると、L1地震動においてはMAPのひび割れ面積率が大きく、L2地震動に対してはMAPの方が降伏の面積率を大きく予想しており、正解値と比較するとMAPの方はやや安全側に予測している状況が窺える。画像情報による手法については、損傷分布の予測結果を構造解析から得られた損傷分布と比較した(表-6)。いずれの手法も損傷の分布や程度を概ね予測できている。正解率としては高い水準となっている。以上より、未知の劣化度分布を有する栈橋に対して、高い精度で損傷を予測できること、数値情報による手法だけでなく画像情報による手法も活用することで、各損傷グレードの損傷面積率だけでなく損傷分布も把握できることが示された。

## 5. まとめ

- 数値情報による手法として、勾配ブースティング木とニューラルネットワークを選定し、いずれの手法も高い精度で推定できることが分かった。
- 画像情報による手法として、畳み込みオートエンコーダを用いたMAPモデルとチェビシェフ距離を用いたモデルを選定し、いずれの手法も高い正解率で推定できることが示された。
- 未知の劣化度分布を有する栈橋において損傷予測を行った結果、いずれの手法も高い精度で損傷を予測で

きることが分かった。画像情報による手法も高い正解率であることから、損傷面積率だけでなく損傷の分布も把握することが可能である。

本研究で得られた手法を、栈橋の一次スクリーニングとして港湾管理者により活用されることが望まれる。今後は、劣化による梁と杭との接合条件が耐力に与える影響を考慮していく必要があると考えている。

## 参考文献

- 1) 高橋宏直, 横田弘, 岩波光保: 港湾施設のアセットマネジメントに関する研究 - 構造性能の低下予測とアセットマネジメントの試行例 -, 国土技術政策総合研究所研究報告, No.29, 2006.
- 2) (一財)沿岸技術研究センター: 港湾の施設の維持管理技術マニュアル (改訂版), 沿岸技術ライブラリー No.49, 2018.
- 3) 宇野州彦, 岩波光保: 劣化度判定結果を活用した残存耐力評価手法の実栈橋への適用, 土木学会論文集 B3 (海洋開発), Vol.74, No.2, pp.1 55-1 60, 2018.
- 4) 宇野州彦, 岩波光保: 鉄筋腐食を有する栈橋上部工を模擬した試験体の残存耐力に与える腐食方法及び縮尺の影響評価, 土木学会論文集 B3 (海洋開発), Vol.75, No.2, pp.1 827-1 832, 2019.
- 5) (公社)日本港湾協会: 港湾の施設の技術上の基準・同解説 (中), pp.596-597, 2018.
- 6) FORUM8 Co., Ltd. : Engineer's Studio Ver. 9.0.2 Manual
- 7) 門脇大輔, 阪田隆司, 保坂桂佑, 平松雄司: Kaggleで勝つ データ分析の技術, pp.111-270, 技術評論社, 2019.
- 8) 斎藤康毅: ゼロから作るディープラーニング-Pythonで学ぶディープラーニングの理論と実装-, pp.39-239, オライリージャパン, 2016.
- 9) 巢籠悠輔: 詳解 ディープラーニング, pp.69-207, マイナビ出版, 2017.
- 10) 鬼塚洋輔, 大山航, 山田太造, 井上聡, 内田誠一: 花押類似検索のための畳み込みオートエンコーダによる画像特徴抽出, 人文科学とコンピュータシンポジウム, pp.257-262, 2018.

(Received February 6, 2020)

(Accepted May 1, 2020)

## EVALUATION METHOD OF RESIDUAL STRUCTURAL PERFORMANCE BY USE OF ARTIFICIAL INTELLIGENCE

Kunihiko UNO, Ke BAI and Mitsuyasu IWANAMI

Appropriate maintenance should be conducted for harbor structures due to their vulnerability towards chloride induced deterioration. We have already proposed an evaluation method of residual structural performance based on the judgement result of deterioration by versatile structural analysis software. On the other side, a simple evaluation method without structural analysis is also demanded when deciding the maintenance priority of several piers. In this study, evaluation methods of residual structural performance introducing artificial intelligence to estimate the damaged area ratio towards assumed external force are proposed. The estimation accuracy of artificial intelligence models are verified and damage estimation for piers with random deterioration distribution are conducted. As a result, for both models utilized numerical information and image showed high estimation accuracy, and the image model can also grasp the damage distribution as well as the damaged area ratio.