

論文 回帰型の機械学習によるあと施工アンカーのせん断力-変位関係の予測精度

末長 大佑*1・高瀬 裕也*2・高橋 宗臣*3・阿部 隆英*4

要旨: 本論文では、あと施工アンカーのせん断力-変位 ($Q-\delta$) 関係を対象として、既報で実施した LightGBM (LG) に加え、回帰型の機械学習であるサポートベクター回帰 (SVR), さらにニューラルネットワーク (NN) を追加した計 3 手法により予測精度を検証した。その結果、学習パラメータ内の予測では LG が $Q-\delta$ 関係を高精度で予測できたが、学習パラメータ外の条件に対しては予測精度が低下した。一方、SVR は外側耐震改修マニュアルで規定される $\delta=2.0\text{mm}$ までの範囲では予測できなかったものの、それ以降の範囲では学習パラメータ外についても概ね良好に予測しており、NN はすべての条件で良好に予測できた。

キーワード: 機械学習, LightGBM, サポートベクター回帰, ニューラルネットワーク, あと施工アンカー

1. はじめに

近年、人工知能 (AI) の活用が目されている。AI を活用することで、これまで人間が行ってきた作業が省力化され、生産性の向上や労働力不足の解消、人件費の削減などにつながる。建築や土木の構造分野においても AI の活用事例は多数報告されており、機械学習によるコンクリート構造物の塩害劣化予測¹⁾、ニューラルネットワーク (NN) による鉄筋コンクリート (RC) 梁のせん断耐力の評価²⁾、複数の機械学習によるせん断力を受けるアンカー筋のコーン状破壊耐力の評価³⁾や鋼繊維補強コンクリートの圧縮強度および曲げ強度の予測⁴⁾、深層学習を用いた RC 部材のひび割れ幅認識⁵⁾などが挙げられる。

既報⁶⁾において、無機系接着剤により定着したあと施工アンカーのせん断載荷実験を対象として、決定木による手法である LightGBM (LG) により、せん断力-変位 ($Q-\delta$) 関係を予測した。その結果、学習データに含まれる範囲については $Q-\delta$ 関係を良好に予測した一方で、LG のような決定木による機械学習アルゴリズムでは、予測結果が学習データの目的変数のどれかにしか分類されないことから、学習パラメータから逸脱するデータを予測した場合、予測精度が低下することを報告した。

文献^{2)~4)}において、サポートベクター回帰 (SVR) や NN などの回帰型の機械学習アルゴリズムにより、構造部材の最大耐力を良好に予測できることが報告されている。そこで、本論文では、あと施工アンカーの $Q-\delta$ 関係の正側包絡曲線を対象に、既報⁶⁾で実施した LG に、回帰型の機械学習として SVR, さらに NN を追加した計 3 手法により機械学習モデルを構築し、その予測精度について検証することを目的とする。

2. 実験概要

本章では、本論文で対象とする試験体について述べる。加力方法の詳細は文献^{7)~10)}に譲ることとし、本論文では簡潔に触れることとする。

2.1 実験パラメータおよび試験体形状

表-1 に実験パラメータを示す。主なパラメータは、接着剤、アンカー筋径 d_a 、穿孔径 ϕ 、コンクリート圧縮強度 f_c 、引張応力比 r_N である。接着剤は、市販品の有機系接着剤 (Ep) と無機系接着剤 (Ce)⁹⁾ の 2 種に、寒中工事に適用するため Ce に亜硝酸リチウムを主成分とする耐寒促進剤を配合した無機系接着剤 (CeW)⁹⁾、さらに CeW に比べ流動性が高く充填性のよい無機系接着剤 (CmW)⁹⁾ を加えた計 4 種類を使用した。アンカー筋には D16, D19, D22, D25 の 4 種類を用い、 f_c は $13.0\sim 39.0\text{N/mm}^2$ とした。ここで、 r_N はアンカー筋の降伏強度 f_y に対する実験時に与える一定引張力の比率であり、0.00, 0.33, 0.66 の 3 段階としている。

図-1 に試験体を示す。本実験では既存建物のブレース補強による間接接合部を模擬した試験体を使用している。試験体の施工手順は、1) 既存部コンクリートの打設、2) 湿式コアドリルで穿孔、3) 接着剤を注入、4) 定着長さ $7d_a$ または $10d_a$ でアンカー筋を定着、5) 新設部グラウトの圧入である。なお、本実験ではアンカー筋が負担する純粋なせん断力を計測するため、既存部コンクリートと新設部グラウトの接合面にグリースを塗布し、摩擦の影響を最小限に抑えた。

2.2 載荷方法

図-2 に加力装置を示す。加力装置は、鉛直方向に最大荷重 150kN のスクリージャッキを 2 本、せん断方向に最大荷重 500kN の油圧アクチュエータを 1 本使用して

*1 室蘭工業大学 大学院工学研究科 環境創生工学系専攻 環境建築学コース (学生会員)

*2 室蘭工業大学 大学院工学研究科 もの創造系領域 准教授 博士 (工学) (正会員)

*3 日本ヒルティ (株) マーケティング本部 修士 (工学) (正会員)

*4 飛島建設 (株) 技術研究所 研究開発グループ 第四研究室 博士 (工学) (正会員)

ムのモデル構築の流れを示す。

(1) LightGBM

図-3(a)に LightGBM (LG) の構造を示す。LG は、決定木アルゴリズムに基づいた勾配ブースティングによる手法である。学習データに対して Leaf-wise と呼ばれる、分岐させるべき葉に絞りに成長する決定木が構築され、その結果を次の学習データに反映して決定木が再構築される手法であり、直列的に学習が進められる。本論文では、決定木の最大深さを 9 層とし、過学習を防ぐため、early_stopping_rounds を 100 回に設定している。

(2) サポートベクター回帰

図-3(b)にサポートベクター回帰 (SVR) の構造を示す。SVR とは、主に二値分類に用いられるサポートベクターマシン (SVM) と同様、決定境界とそれに最も近い点 (サポートベクター) の距離 (マージン) が最大となる境界を決める手法である。この際、SVR では ε -不感損失関数が用いられ、予測値との誤差が $\pm\varepsilon$ 以内では損失を 0 とみなすが、 ε を超えた場合には損失として回帰式が構築される。本論文ではカーネル関数に rbf (Radial basis function) カーネルを使用し、他のパラメータはデフォルト値とした。

(3) ニューラルネットワーク

図-3(c)にニューラルネットワーク (NN) の構造を示す。NN は、人間の脳の神経回路を模した数理モデルである。入力層、隠れ層、出力層の 3 層から構成され、各層内にあるニューロンがそれぞれ重みをかけて次の層のニューロンへと繋がり、さらに次の層へと複雑に繋がることで、学習モデルが構築される。本学習モデルでは、入力層のニューロン数を後述する表-2 の説明変数と合わせ 8 個、隠れ層にはニューロン数が 64 個と 32 個の 2 層を設け、出力層のニューロン数を 1 個とした。ここで、活性化関数は計算効率の良い正規化線形関数 (ReLU) を用いている。

3.2 学習モデルの構築

表-2 に学習データを示す。本学習では、目的変数をせん断力 Q とし、説明変数はコンクリートの圧縮強度 f_c 、グラウトの圧縮強度 f_g 、アンカー筋の公称断面積 A_s 、穿孔径比 $r_\phi (= \phi/d_a)$ 、アンカー筋の降伏強度 f_y 、付着強度 τ_a 、引張応力比 r_N およびせん断変位 δ の 8 項目とした。学習データには表-1 に示す 34 体の試験体のうち 29 体を使用した。総データ数は 7,920 行であり、その中から 8 割をモデル構築に用いる訓練データ、残りの 2 割が検証データとしてランダムに抽出され、学習が進められる。

3.3 各アルゴリズムの学習精度

図-4 に各アルゴリズムの学習精度を示す。学習精度の評価には、次式に示す二乗平均平方根誤差 $RMSE$ および決定係数 R^2 を用いる。






図-3 各機械学習アルゴリズムの構造

表-2 学習データ

f_c	f_g	A_s	r_ϕ	f_y	τ_a	r_N	δ	Q
(N/mm ²)	(N/mm ²)	(mm ²)	(= ϕ/d_a)	(N/mm ²)	(N/mm ²)		(mm)	(kN)
19.9	71.6	198.6	1.38	392	26.4	0.00	0.0024	1.6554
19.9	71.6	198.6	1.38	392	26.4	0.00	0.0030	1.7351
19.9	71.6	198.6	1.38	392	26.4	0.00	0.0043	1.9581
19.9	71.6	198.6	1.38	392	26.4	0.00	0.0058	2.4041
25.1	68.6	387	1.27	409	17.8	0.00	7.9904	82.079
25.1	68.6	387	1.27	409	17.8	0.00	7.9962	82.494
25.1	68.6	387	1.27	409	17.8	0.00	8.0000	81.825

表-3 テストデータの一例

f_c	f_g	A_s	r_ϕ	f_y	τ_a	r_N	δ	Q
(N/mm ²)	(N/mm ²)	(mm ²)	(= ϕ/d_a)	(N/mm ²)	(N/mm ²)		(mm)	(kN)
19.9	71.6	198.6	1.38	392	26.4	0.00	0.00	
19.9	71.6	198.6	1.38	392	26.4	0.00	0.01	
19.9	71.6	198.6	1.38	392	26.4	0.00	0.02	
19.9	71.6	198.6	1.38	392	26.4	0.00	0.03	
19.9	71.6	198.6	1.38	392	26.4	0.00	7.98	
19.9	71.6	198.6	1.38	392	26.4	0.00	7.99	
19.9	71.6	198.6	1.38	392	26.4	0.00	8.00	

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

ここで、 n はテストデータ数、 y_i は実験値、 \hat{y}_i は予測値、 \bar{y} は実験値の平均値である。同図より、LG の学習精度が最も良く、 $RMSE = 0.94$ 、 $R^2 = 0.99$ となっている。一方、同図(b)に示す SVR の学習精度を見ると、特に荷重が小さい範囲で過大評価する傾向が見られたため、 $RMSE = 6.70$ とバラツキが大きくなっており、 $R^2 = 0.91$ と LG に

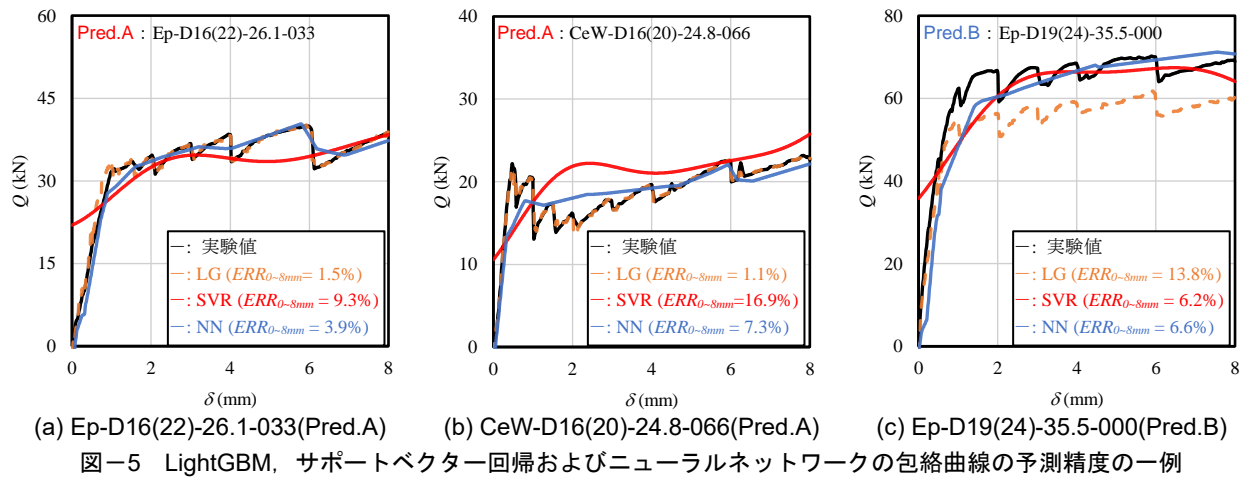



表-4 Q-δ関係の ERR の平均の一覧

Average	LightGBM			サポートベクター回帰			ニューラルネットワーク		
	0.0~2.0mm	2.0~8.0mm	0.0~8.0mm	0.0~2.0mm	2.0~8.0mm	0.0~8.0mm	0.0~2.0mm	2.0~8.0mm	0.0~8.0mm
Pred.A (29 体)	2.0%	0.8%	1.0%	17.1%	7.7%	9.6%	7.6%	3.4%	4.2%
Pred.B (5 体)	11.4%	10.4%	10.8%	15.2%	4.8%	7.2%	15.7%	7.2%	9.3%
Ep (10 体)	3.6%	2.2%	2.5%	17.7%	5.9%	8.5%	8.0%	2.9%	4.1%
Ce, CeW, CmW (24 体)	3.3%	2.2%	2.4%	16.4%	7.8%	9.6%	9.1%	4.3%	5.3%
r _N =0.00 (23 体)	3.5%	2.0%	2.3%	16.7%	5.9%	8.1%	7.9%	3.3%	4.3%
r _N =0.33, 0.66 (11 体)	3.0%	2.7%	2.7%	17.1%	10.2%	11.8%	10.7%	5.2%	6.4%
全試験体 (34 体)	3.4%	2.2%	2.4%	16.8%	7.3%	9.3%	8.8%	3.9%	5.0%

比べ精度が劣っている。また、同図(c)に示す NN の学習精度は、 $RMSE = 2.34$ と LG に比べややバラツキが大きいものの、 $R^2 = 0.98$ と良好に予測できている。

4. 各アルゴリズムの予測精度の比較

4.1 包絡曲線の予測精度

本 4.1 節では、各学習モデルを用いて、実験値の包絡曲線に対する予測精度を検証する。ここで、学習データに用いた試験体 29 体の予測を Pred.A、逆に学習データに用いていない試験体 5 体の予測を Pred.B と呼称する。

表-3 にテストデータの一例を示す。Pred.A の予測の際、学習データと同一のものとならないよう配慮するため、 δ を規則的な数値に設定した。また、本論文では次式に示す誤差率 ERR を用いて、各アルゴリズムの Q - δ 関係

の予測精度を評価する。

$$ERR = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n |y_i|} \times 100(\%) \quad (3)$$

図-5 に各学習モデルの Q - δ 関係の予測精度の一例を、表-4 に ERR の平均の一覧を示す。本論文では、正負交番荷重した実験結果から包絡曲線を抽出しているため、 Q が荷重サイクルに応じ波打つように増減している。図-5(a), (b) に示す Pred.A の予測結果を見ると、LG の予測結果は実験結果の Q にほとんど一致している一方で、SVR, NN の予測結果は、実験値の波打つ挙動を再現していない。これは、LG のような決定木ベースの学習モデルでは、説明変数に応じて学習データ内の Q に分類されるのに対し、SVR や NN といった回帰型の学習モデルでは、説明変数に基づく回帰式によって Q が予測されることに

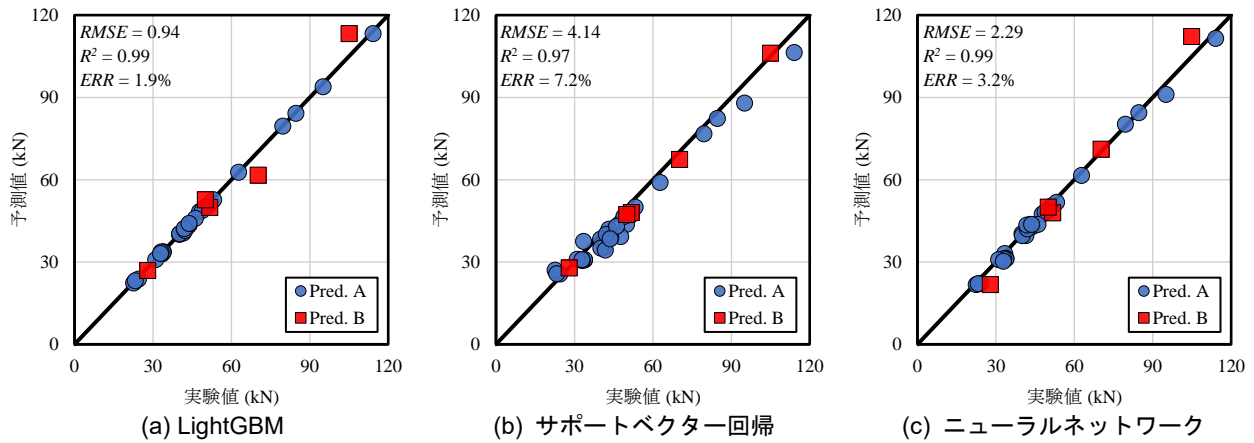


図-6 LightGBM, サポートベクター回帰およびニューラルネットワークの最大せん断力の予測精度

起因すると考えられる。また, SVR の予測結果を見ると, 図-4(b)の学習精度でも, 荷重が小さい範囲で実験値を過大評価しており, 外側耐震改修マニュアル¹¹⁾で規定される $\delta=2.0\text{mm}$ 以下の挙動を予測できていない。このため, 表-4のPred.Aを見ると, $\delta=0.0\sim 2.0\text{mm}$ のERRはLG, NNの2.0%, 7.6%に対し, SVRは17.1%と大きくなっている。一方, $\delta=2.0\sim 8.0\text{mm}$ の範囲については, SVRはLG, NNに比べ誤差は大きいものの, 概ね実験値に近い挙動を示した。この結果, 同範囲のSVRのERRは7.7%となり, $\delta=0.0\sim 2.0\text{mm}$ の範囲に比べ精度よく再現できている。

次に, 図-5(c)に示すPred.Bの予測結果について検証する。LGの予測結果を見ると, LGは学習データの Q にしか分類できないため, 実験値と予測値の誤差が大きくなったことから, 表-4に示す全範囲でERRが10.0%を超えており, Pred.Aに比べ予測精度が低下した。一方, SVRとNNの予測結果を見ると, LGに比べ実験値に近い挙動を示している。この結果, $\delta=0.0\sim 2.0\text{mm}$ のSVR, NNのERRはそれぞれ15.2%, 15.7%とLGより大きいものの, $\delta=2.0\sim 8.0\text{mm}$, $0.0\sim 8.0\text{mm}$ のERRは10.0%未満となり, LGに比べ小さくなった。

4.2 最大せん断力の予測精度

図-6に, 各学習モデルによる最大せん断力の予測精度を, 表-5に各学習モデルの最大せん断力の一覧を, 表-6にERRの平均の一覧を示す。すべての学習モデルで最大せん断力を良好に予測できているが, 学習データに用いた試験体の予測であるPred.Aの最大せん断力の予測精度を見ると, LGの予測結果は実験値にほとんど一致しているため, ERRの平均は0.7%と小さくなった。一方, SVRの予測結果は, ほとんどの試験体で実験値を過小評価したため, ERRの平均は8.0%となった。また, NNは最大せん断力を良好に予測できているものの, 若干のバラツキがみられたため, ERRは2.6%となった。

次に, Pred.Bの最大せん断力の予測精度を見ると, LGの予測結果は4.1節で述べた Q - δ 関係の予測精度と同様,

表-5 最大せん断力の予測結果の一覧

試験体名	実験値(kN)	LG(kN)	SVR(kN)	NN(kN)
Ep-D16(22)-19.9-000	51.5	51.1	47.1	50.5
Ep-D16(22)-20.9-000	43.2	43.0	42.0	43.8
Ep-D16(28)-20.9-000	49.9	49.9	43.8	48.9
Ep-D16(32)-20.9-000	51.7	49.9	48.1	48.0
Ep-D16(22)-26.1-000	47.7	48.4	39.3	47.5
Ep-D16(22)-26.1-033	40.0	40.1	38.4	40.4
Ep-D16(22)-26.1-066	33.4	33.1	37.6	33.2
Ep-D16(22)-35.5-000	48.9	48.9	46.6	48.3
Ep-D16(22)-39.0-000	53.2	52.8	50.1	51.8
Ep-D19(24)-35.5-000	70.2	61.8	67.4	71.2
Ce-D16(20)-13.0-000	41.5	40.6	35.5	39.7
Ce-D16(20)-13.0-033	33.9	33.7	30.8	31.4
Ce-D16(20)-24.8-000	42.9	42.8	38.9	42.8
Ce-D16(20)-24.8-033	33.8	33.7	30.9	31.1
Ce-D16(20)-24.8-066	24.4	23.8	25.7	22.3
Ce-D16(22)-39.0-000	50.0	52.8	47.4	50.0
CeW-D16(20)-13.0-000	40.1	40.3	35.2	39.6
CeW-D16(20)-13.0-033	33.0	33.7	30.6	31.1
CeW-D16(20)-13.0-066	22.5	22.4	27.1	21.8
CeW-D16(20)-24.8-000	43.9	43.7	38.9	42.9
CeW-D16(20)-24.8-033	31.0	30.9	31.0	30.9
CeW-D16(20)-24.8-066	23.2	23.2	25.8	22.2
CeW-D16(20)-25.1-000	42.1	41.5	40.2	42.2
CeW-D22(28)-25.1-000	79.6	79.5	76.8	80.3
CeW-D22(32)-25.1-000	95.1	93.9	87.9	91.1
CeW-D25(32)-25.1-000	114.1	113.3	106.5	111.6
CmW-D16(20)-25.1-000-1	46.1	46.0	43.1	43.7
CmW-D16(20)-25.1-000-2	41.9	42.2	34.4	43.5
CmW-D16(20)-25.1-033	32.9	33.1	31.0	30.3
CmW-D16(20)-25.1-066	27.9	27.0	27.8	21.8
CmW-D16(28)-25.1-000	43.7	44.1	38.5	43.8
CmW-D19(24)-25.1-000	62.8	62.8	59.0	61.6
CmW-D22(28)-25.1-000	84.7	84.2	82.4	84.5
CmW-D25(32)-25.1-000	104.9	113.3	106.1	112.3

表-6 最大せん断力のERRの平均の一覧

	LG	SVR	NN
全試験体 (34体)	1.9%	7.2%	3.2%
Pred. A (29体)	0.7%	8.0%	2.6%
Pred. B (5体)	7.3%	3.4%	6.0%

Pred.Aと比べ予測精度が低下しており, 特にデータ数の少ないD19以上の試験体で精度が低下したため, ERRの平均は7.3%となった。しかし, 回帰型の学習モデルであるSVRとNNの予測結果はLGに比べバラツキが小さく

なっている。特に SVR の予測結果は Pred.A に比べ良好に再現できており、*ERR* の値も 3.4%と、SVR に関しては Pred.A に比べ予測精度が向上した。結果として、Pred.B の最大せん断力の予測精度は SVR, NN, LG の順に良くなり、Pred.A とは逆の傾向を示した。

5. おわりに

本論文では、LG, SVR および NN の 3 手法により、あと施工アンカーの Q - δ 関係の予測精度を検証した。その結果から、以下の知見を得た。

- 1) LG によりあと施工アンカーの Q - δ 関係を予測した結果、学習データに含まれる Pred.A の予測結果は実験値の波打つような包絡挙動にも一致し、高精度で予測できたが、学習データに含まれない Pred.B では予測精度が低下した。
- 2) SVR によりあと施工アンカーの Q - δ 関係を予測した結果、変位の小さい範囲はほとんど予測できなかったが、 $\delta=2.0\sim 8.0\text{mm}$ の範囲では概ね良好に Q - δ 関係を予測できた。
- 3) NN によりあと施工アンカーの Q - δ 関係を予測した結果、 $\delta=0.0\sim 2.0\text{mm}$ の範囲の *ERR* がやや大きくなったが、Pred.A, Pred.B とともに良好に予測できた。
- 4) 各学習モデルによりあと施工アンカーの最大せん断力を予測した結果、Pred.A では LG が、Pred.B では SVR が最も精度よく最大せん断力を予測できた。

今後、他の既往の研究も含め、様々な実験結果も対象として、予測精度を検証する予定である。

以上、本研究成果は、ずれ変形を考慮したあと施工アンカーの設計に寄与すると考えられる。さらに柱や梁、あるいはフレーム解析にも本成果を応用することができ、さらなる発展が期待される。

謝辞

本研究の一部は日本建築あと施工アンカー協会より助成を受け実施しました。また、住友大阪セメント・安藤博士、日本ヒルティ・石垣氏、飛鳥建設・石田博士より多大なるご協力を頂きました。ここに謝意を表します。

参考文献

- 1) 吉見映輝, 富山潤, 須田裕哉: 機械学習によるコン

クリート構造物の塩害劣化予測に関する研究, コンクリート工学年次論文集, Vol.44, No.1, pp.478-483, 2022.6

- 2) 輿水良亮, 尾崎允彦, 佐藤靖彦: 力学的解釈を組合せたニューラルネットワークによるせん断補強筋を持たない RC はりのせん断耐力予測, 土木学会論文集 E2, Vol.78, No.1, pp.46-61, 2022.2
- 3) Oladimeji B. Olalusi, Panagiotis Spyridis: Machine learning-based models for the concrete breakout capacity prediction of single anchors in shear, *Advances in Engineering Software*, Vol.147, 2020.9
- 4) Min-Chang Kang, Doo-Yeol Yoo and Rishi Gupta : Machine learning-based prediction for compressive and flexural strengths of steel fiber-reinforced concrete , *Construction and Building Materials*, Vol.266, 2020.10
- 5) 村上奨太, 鎌田聖也, 高瀬裕也, 溝口光男: 様々な学習モデルによる鉄筋コンクリート部材のひび割れ幅計測に関する考察, 日本建築学会技術報告集, Vol.28, No.69, pp.673-678, 2022.6
- 6) 末長大佑, 松永健也, 高瀬裕也, 阿部隆英: 3 次元 FEM 解析および機械学習による無機系アンカーのせん断荷重-変位関係の評価, コンクリート工学年次論文集, Vol.44, No.2, pp.163-168, 2022.6
- 7) Matsunaga K., Takase Y. and Abe T. : Modeling of dowel action for cast-in and post-installed anchors considering bond property, *Engineering Structures*, Vol.245, 2021.10
- 8) 松永健也, 高瀬裕也, 阿部隆英, 折田現太, 安藤重裕: 氷点下で定着した無機系あと施工アンカーの特性と力学挙動評価, 日本建築学会構造系論文集, Vol.87, No.796, pp.556-566, 2022.6
- 9) 高瀬裕也, 阿部隆英, 折田現太, 安藤重裕: 氷点下でも施工可能な無機系アンカーの定着性能, コンクリート工学, Vol.60, No.6, pp.525-532, 2022.6
- 10) 末長大佑, 木林巧, 矢野悠佑雅, 松永健也, 高瀬裕也: 表層部が凍害劣化したコンクリートに定着したあと施工アンカーのせん断抵抗性能, コンクリート構造物の補修, 補強, アップグレード論文報告集, Vol.22, pp.469-474, 2022.10
- 11) 日本建築防災協会: 既存鉄筋コンクリート構造物の「外側耐震改修マニュアル」, 2009