

# 論文 機械学習による接着系アンカーの付着—すべり挙動の評価

塩越 汰斗\*1・矢野 悠佑雅\*1・末長 大佑\*1・高瀬 裕也\*2

**要旨**：近年、様々な分野で人工知能の活用が注目されている。本研究では、コンクリート強度  $f_c$ 、相対動弾性係数  $DM$  をパラメータとして接着系アンカーの付着実験を実施し、付着応力—すべり量 ( $\tau$ - $s$ ) 関係を機械学習により再現できるか検証した。その結果、決定木を用いた手法は、学習データ数を多く含むパラメータの試験体については、精度よく予測でき、ニューラルネットワーク (NN) は学習データ数による影響が少なく、安定して精度よく予測できた。また、パラメトリックスタディを実施し、パラメータの違いに適応する学習モデルの構築を目指した結果、NN が最も合理的な予測結果を得ることができた。

**キーワード**：機械学習, 決定木, ニューラルネットワーク, パラメトリックスタディ, 接着系アンカー

## 1. はじめに

近年、様々な分野で人工知能 (AI) の活用が注目されている。AI を用いることにより、これまで人為的に行ってきた作業の効率化、人的コストの削減が実現化され、AI は工学分野の発展に大きく寄与しているといえる。

建築・土木分野においても、AI を活用した研究が多数報告<sup>1)2)</sup>されている。例えば、複数の機械学習によるアンカー筋のコーン状破壊耐力の予測<sup>1)</sup>、ニューラルネットワークを用いた RC 梁のせん断耐力の予測<sup>2)</sup>、ランダムフォレストを用いた洪水時の水位予測<sup>3)</sup>などの研究事例

が挙げられる。また、先行研究<sup>4)</sup>では、あと施工アンカーのせん断実験を対象として、AI の一種である機械学習により荷重変位関係を再現している。しかし、接着系アンカーの付着実験や、表層の強度が異なるコンクリートに対しても、機械学習により再現可能かどうか確認されていない。

そこで本研究では、接着剤種類、アンカー筋径  $d_a$ 、コンクリート強度  $f_c$ 、相対動弾性係数  $DM$  をパラメータとして接着系アンカーの付着実験を実施し、付着応力—すべり量 ( $\tau$ - $s$ ) 関係を機械学習により再現できるか検証す

表-1 試験体パラメータ

試験体名	接着剤	$d_a$	$\phi$	$l_e$	$f_c$	$E_c$	$f_t$	$f_y$	$E_s$	$f_a$	$n$	DM 実測値	機械学習		
													予測データ		
Ep-D13-24.5-DM60											3	57.9/ 64.0/ 59.0	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D13-24.5-DM80		13	16					455	170		2	84.0/ 82.1	○/ ○	○/ ○	○/ ○
Ep-D13-24.5-DM100											2	-/ -	-/ -	-/ -	-/ -
Ep-D19-24.5-DM60		19	24		24.5	23.6	1.9	541	179		3	61.6/ 54.8/ 57.1	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D16-24.5-DM60											2	63.8/ 57.4	-/ -	-/ -	-/ -
Ep-D16-24.5-DM80								556	197		3	80.9/ 79.9/ 83.6	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D16-24.5-DM100	Ep									228	2	-/ -	-/ -	-/ -	-/ -
Ep-D16-19.9-DM60											3	55.2/ 58.8/ 63.5	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D16-19.9-DM80				4.5 $d_a$	19.9	22.2	2.7				3	70.9/ 84.2/ 77.7	○/ ○/ ○	○/ ○/ ○	○/ ○/ ○
Ep-D16-19.9-DM100								568	208		3	-/ -/ -	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D16-39.0-DM60		16	22								3	64.6/ 61.6/ 64.8	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D16-39.0-DM80					39.0	26.8	2.6				3	82.7/ 80.0/ 79.0	-/ -/ -	-/ -/ -	-/ -/ -
Ep-D16-39.0-DM100											3	-/ -/ -	-/ -/ -	-/ -/ -	-/ -/ -
Ce-D16-25.1-DM100-1					25.1	21.1	2.3	556	197	37.6	3	-/ -/ -	-/ -/ -	-/ -/ -	-/ -/ -
Ce-D16-25.1-DM100-2										49.1	2	-/ -	-/ -	-/ -	-/ -
Ce-D16-39.0-DM60	Ce										3	60.5/ 61.4/ 60.5	-/ -/ -	-/ -/ -	-/ -/ -
Ce-D16-39.0-DM80					39.0	26.8	2.6	568	208	44.0	3	75.0/ 84.6/ 79.7	○/ ○/ -	○/ ○/ -	○/ ○/ -
Ce-D16-39.0-DM100											3	-/ -/ -	-/ -/ -	-/ -/ -	-/ -/ -

$d_a$  : アンカー筋径(mm),  $\phi$  : 穿孔径(mm),  $l_e$  : 定着長さ(mm),  $f_c$  : コンクリートの圧縮強度(N/mm<sup>2</sup>),  $E_c$  : コンクリートのヤング係数(kN/mm<sup>2</sup>),  $f_t$  : コンクリートの割裂強度(N/mm<sup>2</sup>),  $f_y$  : アンカー筋の降伏強度(N/mm<sup>2</sup>),  $E_s$  : アンカー筋のヤング係数(kN/mm<sup>2</sup>),  $f_a$  : 接着剤の圧縮強度(N/mm<sup>2</sup>),  $n$  : 試験体数(体),  $DM$  : 相対動弾性係数(%),  $DM$  実測値と予測データは、通し番号 1~3 の試験体を「J」で区切って表記している。

\*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)

る。また、各機械学習アルゴリズムにより、パラメトリックスタディを実施し、パラメータの違いに適応する機械学習モデルを構築できるか検証する。

## 2. 実験概要

### 2.1 実験パラメータおよび試験体の諸元寸法

表-1 に試験体パラメータを示す。試験体パラメータは、接着剤種を有機系接着剤 (Ep), 無機系接着剤 (Ce) の2種,  $d_a$  を 13, 16, 19mm の3種,  $f_c$  を 19.9~39.0N/mm<sup>2</sup> の間で4種, 表層の強度低下程度を表す相対動弾性係数  $DM$  (表層から 30mm) は 100, 80, 60% の3種である。同一のパラメータに対し, 2~3 体の試験体を作成し, 計 49 体の試験体を対象に実験を行った。 $DM$  の低下方法は, 三好ら<sup>5)</sup>が提案する液体窒素を用いた手法により, 簡易的に行った。また,  $DM$  の測定方法は, 矢野ら<sup>9)</sup>と同様に試験体側面 8 箇所 で計測した。

図-1(a), (b)にそれぞれ  $DM=100%$  と  $DM=80, 60%$  の試験体の諸元寸法を示す。 $DM=100%$  の試験体は一度に複数のアンカー筋を定着可能なコンクリートベッドを用いた。また, 外側耐震改修マニュアル<sup>7)</sup>によると, アンカー筋の中心からの距離が有効埋め込み長さ以上の範囲は, 付着破壊時の引張耐力に影響がないとされていることから, これを考慮してアンカー筋の間隔を決定した。 $DM=80, 60%$  の試験体はコンクリートの表層を均一に劣化させるため, アンカー筋を一本ずつ定着可能なコンクリートブロックを用いた。加力時にコンクリートの割裂破壊が起こらないよう, 試験体の周囲に鉄筋とグラウトを用い, 各試験体を連結した。これらの試験体でも,  $DM=100%$  と同様に十分なアンカー筋間隔を確保した。

### 2.2 加力方法

図-2 に加力装置を示す。加力方式は, 320kN のセンターホールジャッキでアンカー筋に鉛直上向きの引張力を加え, その引張力を 500kN のロードセルによって計測した。また, アンカー筋を中心に挟み込むような位置に 2 カ所, 変位計を設置し, 鉛直変位を計測した。これら 2 カ所の変位の平均値をすべり量  $s$  (mm) として用いた。加えて, 加力時にコンクリートがコーン状破壊することを防ぐため, ラムチェアー下部に反力板 (330mm×250mm×15mm, 穴径: 25mm) を設置した。さらに, コンクリート表面と反力板の間に 7 号珪砂を敷き詰め, 反力が反力板に均一に伝達されるよう配慮した。

### 2.3 実験結果

表-2 に実験結果における試験体ごとの最大付着応力  $\tau_{max}$ , 最大付着応力時変位  $s_{max}$  の一覧を示す。パラメータごとに  $\tau_{max}$ ,  $s_{max}$  の値を比較しても, ばらつきの少ない結果となった。また,  $DM$  や  $f_c$  の値が大きくなるにつれ,  $\tau_{max}$  が増加する傾向が見られた。さらに, Ce と Ep を比




図-1 試験体諸元寸法




図-2 加力装置

表-2 実験結果の一覧

試験体名	試験体番号			試験体番号		
	1	2	3	1	2	3
	$\tau_{max}$			$s_{max}$		
Ep-D13-24.5-DM60	17.8	17.5	19.8	3.69	4.13	3.21
Ep-D13-24.5-DM80	23.1	23.3	/	3.63	4.14	/
Ep-D13-24.5-DM100	23.0	24.1	/	3.25	3.06	/
Ep-D19-24.5-DM60	20.9	21.1	20.2	3.11	2.93	2.84
Ep-D16-24.5-DM60	22.6	20.4	/	4.36	5.39	/
Ep-D16-24.5-DM80	27.2	26.3	25.9	3.83	3.79	3.04
Ep-D16-24.5-DM100	30.0	26.4	/	4.51	3.99	/
Ep-D16-19.9-DM60	21.9	23.1	23.8	4.03	3.20	3.14
Ep-D16-19.9-DM80	23.6	26.5	25.0	2.60	3.07	4.96
Ep-D16-19.9-DM100	25.8	26.9	26.6	2.40	2.68	2.57
Ep-D16-39.0-DM60	30.0	29.7	27.9	4.13	4.07	3.58
Ep-D16-39.0-DM80	28.9	32.9	26.9	2.95	6.61	2.67
Ep-D16-39.0-DM100	34.5	32.5	32.8	6.20	4.87	4.64
Ce-D16-25.1-DM100-1	21.9	21.8	19.4	2.31	1.89	2.29
Ce-D16-25.1-DM100-2	17.8	20.5	/	1.01	1.43	/
Ce-D16-39.0-DM60	21.0	27.0	23.8	1.67	1.42	1.63
Ce-D16-39.0-DM80	25.0	27.2	24.3	1.18	0.99	1.12
Ce-D16-39.0-DM100	30.5	33.6	28.5	1.61	3.14	1.85

$\tau_{max}$ : 最大付着応力 (N/mm<sup>2</sup>),  $s_{max}$ : 最大付着応力時変位 (mm)

較すると、Ceの方が $s_{max}$ の値が小さい結果となった。

### 3 機械学習による予測

#### 3.1 機械学習の概要

本研究では、LightGBM、ランダムフォレスト、XGBoost、ニューラルネットワークの4種類の機械学習アルゴリズムを用いて、実験値を学習させ、接着系アンカーの $\tau$ - $s$ 関係の予測モデルを構築した。以下に、各アルゴリズ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。LightGBM (Light Gradient Boosting Machine)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機械学習アルゴリズムである。入力された学習データに対して、Leaf-wiseと呼ばれる、分岐させるべき葉を優先的に成長させる決定木である。これにより、予測モデルの構築に要する時間が短縮され、効率的に学習することができる。

##### (2) ランダムフォレスト

図-3(b)にランダムフォレスト (RF)の構造を示す。RFは、アンサンブル学習のバギングと複数の決定木を用いた機械学習アルゴリズムである。入力された学習データに対して、Level-wiseと呼ばれる、各層ごとに一括で成長する決定木が一つ構築され、RFでは、独立した決定木が生成される。その決定木が複数構築され、その結果から多数決により予測結果が出力されるため、並列的な学習が可能である。

##### (3) XGBoost

図-3(c)にXGBoost (XB)の構造を示す。XGBoost (eXtreme Gradient Boosting)は、LGと同様、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機械学習アルゴリズムであるが、XBでは、Level-wiseによる決定木が構築される。

##### (4) ニューラルネットワーク

図-3(d)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てつくられており、入力層、隠れ層、出力層から構成される。各層のニューロンにそれぞれ重みをかけ、次の層のニューロンと繋がり、それが繰り返されることで予測モデルが構築される。本学習では、順伝播型 NN (Feed-forward Neural Network)を用い、入力層のニューロン数は後述の説明変数の11個、隠れ層のニューロン数は64個と32個の2層、出力層のニューロン数は1個とした。

### 3.2 機械学習モデルの構築

#### (1) 学習データ

表-3に学習データの一例を示す。本学習では、目的変数を $\tau$ とし、説明変数をコンクリート圧縮強度 $f_c$ 、DMを考慮した圧縮強度 $f_{DM}$ 、 $f_{DM}$ と $f_c$ の差 $f_{DM}-f_c$ 、アンカー筋の降伏強度 $f_y$ 、アンカー筋種 $Anchor$ 、接着剤種 $ad$  (1, 2



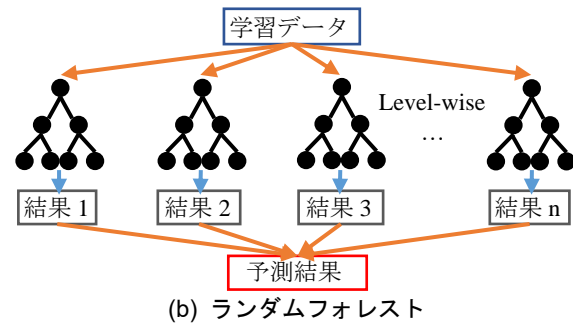



図-3 機械学習アルゴリズムの構造

表-3 学習データの一例

$f_c$	$f_{DM}$	$f_{DM}-f_c$	$f_y$	$Anchor$	...	$l/d_a$	$s$	$\tau$
24.5	16.9	-7.6	455	13	...	4.40	0	0.069347
24.5	16.9	-7.6	455	13	...	4.40	0.17	2.912562
24.5	16.9	-7.6	455	13	...	4.40	0.33	5.201003
⋮								
39.0	27.6	-11.4	568	16	...	3.99	10.04	3.785694

表-4 予測データの一例

$f_c$	$f_{DM}$	$f_{DM}-f_c$	$f_y$	$Anchor$	...	$l/d_a$	$s$	$\tau$
24.5	20.9	-3.6	455	13	...	4.39	0	未知数
24.5	20.9	-3.6	455	13	...	4.39	0.01	
24.5	20.9	-3.6	455	13	...	4.39	0.02	
⋮								
24.5	20.9	-3.6	455	13	...	4.39	10.00	

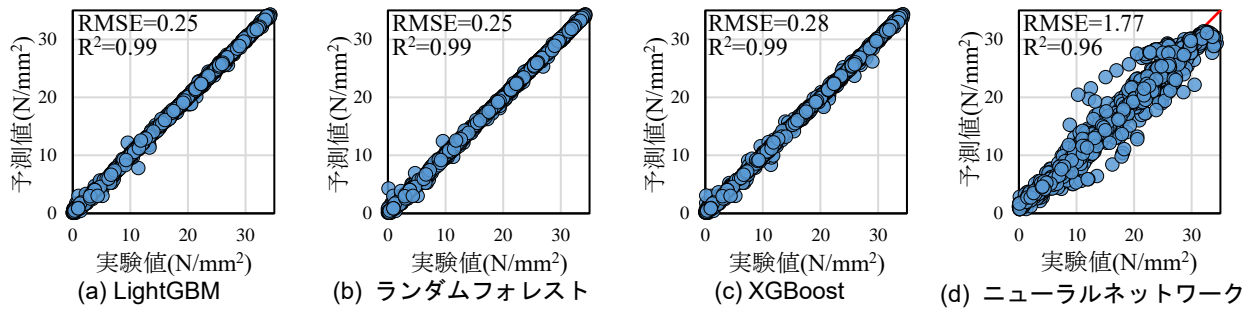


図-4 各アルゴリズムの学習精度




図-5 各アルゴリズムの  $\tau_{max}$  の予測精度




図-6 各アルゴリズムの  $s_{max}$  の予測精度

でそれぞれ  $C_e$  と  $E_p$  を識別する), 接着剤の圧縮強度  $f_a$ , アンカー筋径  $d_a$  に対する穿孔径  $\phi$  の割合  $\phi/d_a$ , アンカー筋径  $d_a$  に対する埋め込み深さ  $l_e$  の割合  $l_e/d_a$ , すべり量  $s$  の 11 項目とした。  $f_{DM}$  は次式<sup>8)</sup>より算出される。

$$f_{DM} = f_{c,100} \cdot (0.0074 \cdot (DM(y) - 100) + 1) \quad (1)$$

ここで  $DM(y)$  は  $y=30\text{mm}$  の  $DM$  の実測値であり,  $f_{c,100}$  は  $DM=100\%$  の  $f_c$  である。表-1 に示す 42 体の試験体から得られたデータをつなぎ合わせ, 全 25,840 行の連続したデータを学習データとした。全学習データのうち無作為に抽出された 8 割が訓練データとしてモデルの構築に用いられ, 残りの 2 割が検証データとしてアルゴリズムの学習精度が確認されながら学習が進められる。表-4 に予測データの一例を示す。一方, 予測データは  $s$  が未知数であることから,  $s$  を 0.01mm 間隔で 0~10mm まで規則的な値に設定した。また,  $\tau$  は予測対象であることから, 表-4 では, 空欄となっている。

## (2) 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

表-5 各アルゴリズムによる  $ERR(0\sim 10\text{mm})$  の一覧

試験体名	LG	RF	XB	NN
Ep-D13-24.5-DM80-2	5.4%	4.7%	8.9%	18.3%
Ep-D13-24.5-DM80-3	10.3%	10.1%	8.4%	12.0%
Ep-D16-19.9-DM80-1	4.4%	5.2%	4.3%	25.6%
Ep-D16-19.9-DM80-2	9.0%	5.9%	9.9%	13.2%
Ep-D16-19.9-DM80-3	6.7%	4.9%	5.7%	14.6%
Ce-D16-39.0-DM80-1	7.1%	7.8%	8.4%	17.9%
Ce-D16-39.0-DM80-2	39.3%	50.7%	40.5%	5.0%
平均	11.7%	12.8%	12.3%	15.2%

の評価は二乗平均平方根誤差  $RMSE$ , および決定係数  $R^2$  を用いて行う。  $RMSE$ ,  $R^2$  は次式により算出される。

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

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

ここで,  $n$  はデータ数,  $y_i$  は実験値,  $\hat{y}_i$  は予測値,  $\bar{y}$  は




図-7 各アルゴリズムの $\tau$ - $s$ 関係の予測精度の一例

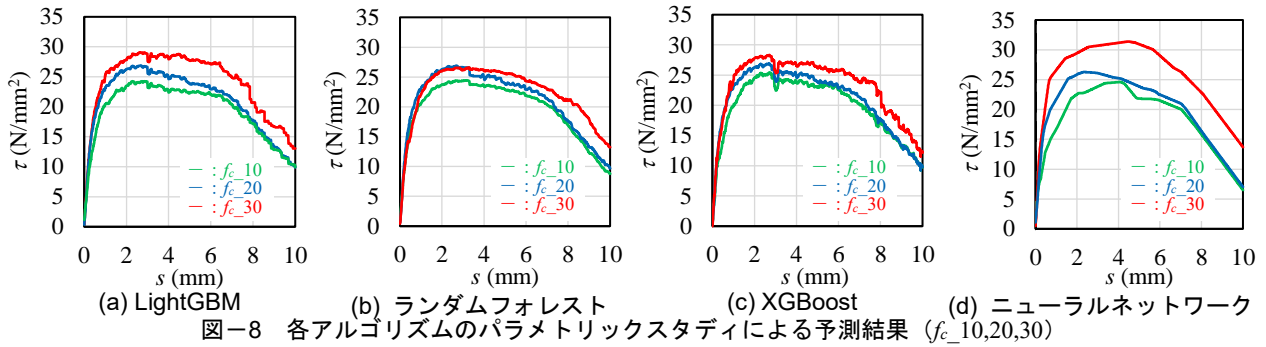


図-8 各アルゴリズムのパラメトリックスタディによる予測結果 ( $f_c$ \_10,20,30)

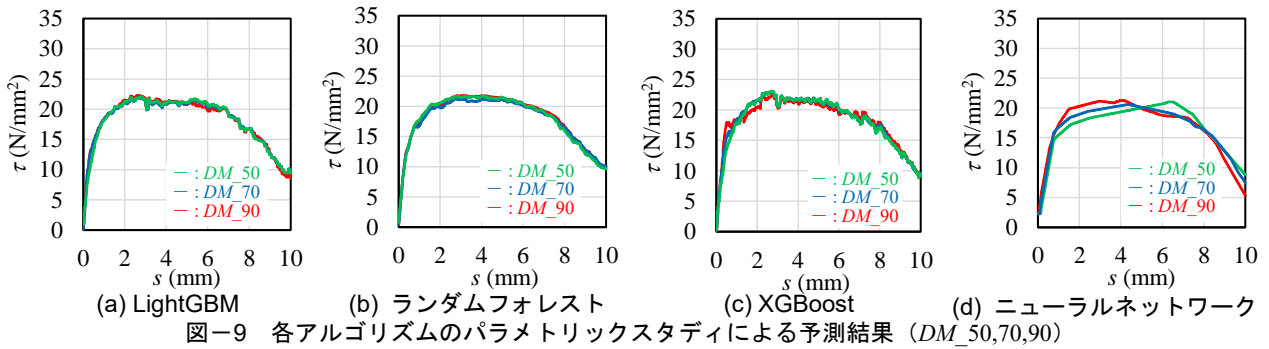


図-9 各アルゴリズムのパラメトリックスタディによる予測結果 ( $DM$ \_50,70,90)

実験値の平均値である。図-4(a)~(c)より決定木を用いたアルゴリズムは、 $RMSE$ が0.25~0.28の値であり、 $R^2$ は0.99以上の高い精度で予測できた。図-4(d)のNNは、 $RMSE$ が1.76、 $R^2$ は0.96であり、決定木に比べるとやや精度は悪いが、どのアルゴリズムも精度よく予測できた。

### 3.3 各アルゴリズムの予測結果

本節では、各学習モデルを用いて、 $\tau_{max}$ 、 $s_{max}$ 、 $\tau$ - $s$ 関係の予測精度を検証する。本論文では、予測精度を次式に示す誤差率  $ERR$  により評価した。

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

図-5および図-6にそれぞれ各アルゴリズムの $\tau_{max}$ と $s_{max}$ の予測精度を示す。図-5、6(a)~(d)より、各アルゴリズムの予測精度は、 $\tau_{max}$ が $ERR=4.7\sim 8.0\%$ 、 $s_{max}$ が17.6~30.6%であった。この値を比較すると $\tau_{max}$ の方が、比較的精度良く予測できたといえる。

表-5に各アルゴリズムによる $ERR$  (0~10mm)の一覧を、図-7に各アルゴリズムの $\tau$ - $s$ 関係の予測精度の一

表-6 パラメトリックスタディの予測データ

	$f_c$	$f_{DM}$	$f_{DM} - f_c$	$f_y$	Anchor	ad	$f_y$	$\phi/d_a$	$l_e/d_a$
$f_c$ _10	10	10	0	568	16	2	228	1.38	4.5
$f_c$ _20	20	20	0	568	16	2	228	1.38	4.5
$f_c$ _30	30	30	0	568	16	2	228	1.38	4.5
$DM$ _50	20	12.6	-7.4	568	16	2	228	1.38	4.5
$DM$ _70	20	15.6	-4.4	568	16	2	228	1.38	4.5
$DM$ _90	20	18.5	-1.5	568	16	2	228	1.38	4.5

例を示す。表-5において、試験体パラメータに着目して $ERR$ を比較すると、CeよりもEp、D13よりもD16の方が $ERR$ は小さく、予測精度が高い。これは、EpとD16が、CeとD13よりも学習データに多く含まれていることに起因していると考えられる。次に、アルゴリズムごとと比較すると、決定木を用いたLG、RF、XBの方が全試験体の $ERR$ の平均は、NNよりも値が小さく、決定木を用いた手法の方が、精度が良かった。中でもLGの $ERR$ の平均値が最も低かった。一方で、表-5のCe-D16-39.0-DM80-2のLG、RF、XBの結果に着目すると、 $ERR$ が非常に大きくなっている。この要因として、決定木を用い

たアルゴリズムでは、学習データに含まれる値しか出力されず、学習データの精度にエラーがある場合、もしくは予測する説明変数の値によって別の学習データに近いと判断された場合は、予測精度が極端に悪くなることも起こり得るためと考えられる。

これに対し、NN のように説明変数に基づく回帰式によって予測されるアルゴリズムは、影響が少ないため精度が良かった。

### 3.4 パラメトリックスタディ

続いて、パラメトリックスタディによる予測精度の検証を行った。表-6 にパラメトリックスタディの予測データを示す。本実験結果より、 $f_c$ 、 $DM$  が低下するにつれ  $\tau_{max}$  も低下した。そこで、 $f_c$  と  $DM$  に着目し、それぞれ試験体パラメータに含まれない3段階 ( $f_c=10, 20, 30\text{N/mm}^2$ ,  $DM=50, 70, 90\%$ ) に変化させた予測データを使用し、 $\tau_{max}$  が段階的に低下するか検証した。また、 $f_c$ 、 $DM$  以外の説明変数は学習データの多い値に統一し、 $f_c$ 、 $DM$  の変化の影響を確認できるようにした。

図-8, 9 に各アルゴリズムのパラメトリックスタディによる予測結果を示す。図-8(a)~(c)より  $f_c$  を変化させた結果、決定木を用いた手法は、わずかに値が変化するのに対し、図-8(d)の NN は決定木に比べ、比較的大きく変化した。次に、図-9(a)~(c)より  $DM$  を変化させた結果、決定木を用いた手法は、ほぼ値が変化しないが、図-9(d)の NN は決定木に比べ、わずかに変化した。決定木を用いた手法は、学習していないデータに対して精度が落ちるが、NN は回帰によって予測されるため、NNの方が合理的な予測結果を得られたと考えられる。

### 4. まとめ

本論文では、コンクリート強度と劣化度合いが異なる付着実験の  $\tau$ - $s$  関係を、4種類の機械学習手法で評価した。その結果から以下の知見を得た。

- 1) 各学習モデルにより  $\tau_{max}$ 、 $S_{max}$  を予測した結果、どちらも概ね精度よく予測できた。
- 2) LG, RF, XB の3種類の決定木を用いた手法により  $\tau$ - $s$  関係を予測した結果、学習データを多く含むパラメータの試験体については、精度よく予測できた。
- 3) NN により  $\tau$ - $s$  関係を予測した結果、決定木を用いた手法に比べ、やや精度は落ちたが、学習データ数が少ないパラメータの試験体に対しても、精度が落ちなかった。
- 4)  $f_c$ 、 $DM$  が段階的に低下したデータに対してパラメトリックスタディによって検証した結果、決定木を用いた手法に比べ NN の方が、合理的な予測結果を得ることができた。

以上から、学習データが多い場合は決定木、学習データが限られている場合や未知のデータを予測する際には、NN が最適であると判断される。

### 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・高橋氏、石垣氏、飛島建設・阿部博士、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) Oladimeji B. Olalusi, et al. : Machine learning-based models for the concrete breakout capacity prediction of single anchors in shear, *Advances in Engineering Software*, Vol.147, 2020.9
- 2) 興水良亮, 他2名 : 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 (材料・コンクリート構造)*, Vol.78, No.1, pp.46-61, 2022.2
- 3) 岡崎亮太, 他2名 : 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
- 4) 末長大佑, 他3名 : 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
- 5) 三好慶大, 及川雄大, 高瀬裕也, 濱幸雄 : 凍害劣化を模擬したコンクリートに対する断面修復材の付着すべり特性に関する基礎的研究, *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.21, pp.544-549, 2021.10
- 6) 矢野悠佑雅, 末長大佑, 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対する接着系アンカーの付着特性, *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.463-468, 2022.10
- 7) 日本建築防災協会 : 既存鉄筋コンクリート造建築物の「外側耐震改修マニュアル」, 2002
- 8) 周藤将司, 緒方英彦 : 凍害劣化の生じたコンクリートの力学特性および現地非破壊試験による動弾性係数の評価法に関する研究, *農業農村工学会論文集*, No.303(84-3), pp.I\_291-I\_299, 2016.12