

ディープラーニングによる繊維補強コンクリートの諸特性の推定

田坂 誠一* 角野 嘉則* 方 航大** スレイン ヴィチェット**

Prediction of Properties of Fiber Reinforced Concrete Using Deep Learning

Seiichi TASAKA, Yoshinori KAKUNO, Koudai KATA, Sreng VICHET

ABSTRACT

Prediction of mechanical and categorical properties of fiber reinforced concrete is presented by using deep learning (DL) procedures. For the purpose of extracting important features of the categorical data, a feature analysis is conducted to the two sets of data with the deep auto-encoder and classical principal component analysis. The regression and classification analyses are then performed to predict outcome variables. It is shown that the DL regression analysis produces comparable prediction results to those of the classical regression equation, and the DL classification analysis achieves the accuracy of 61% and 75% derived from confusion matrixes for the two data.

KEY WORDS : fiber reinforced concrete, deep learning, regression, classification

1. はじめに

コンクリート構造物は、せん断力や引張力の作用による脆性的破壊に起因する構造耐力の急激な低下やひび割れの拡大による早期劣化等が生じる危険性を有している。このような事象への対策の一つとして、コンクリートを短繊維で補強した繊維補強コンクリート (FRC) の適用が有効と考えられており、これまで多くの研究事例がある^{1,2)}。

FRC は鋼材や有機材料等種々の材料で製造された短繊維とセメント・コンクリートとの複合材料であり、その施工性や力学的特性は多くの因子に関係する。一般に、コンクリートの調合パラメータ、短繊維の幾何学的・機械的特性、FRC の力学的性能等に関するパラメータは数多く存在するため、FRC の諸特性を特徴付けるパラメータを推定し特定することが FRC の効果的な設計・施工方法の開発において重要な課題と考えられる。このような観点から、これまで実験データの統計的分析、特に重回帰分析により導出された回帰式を

用いて 諸特性の推定 (予測) を行う方法が提案されている³⁻⁸⁾。しかしながら、回帰式の有効性は使用したデータや採用した説明変数等に依存するため、データが更新されると再度分析を行って推定の有効性を検討する必要があることから、所与の回帰係数を持つ回帰式の応用性は非常に限定的と考えられる。データの更新や目的変数と説明変数の多様な関係に柔軟に対応するには、回帰式の導出手法では限界があり、新たな推定方法を検討する必要がある。また、FRC の特性には数値データだけでなく記号等の非数値データも含まれるため、カテゴリカルデータを対象とした分類分析にも適用可能な推定方法が望ましい。

本論では、FRC の力学的性能や短繊維の機械的・幾何学的性質等に関係する諸特性の推定を効率的に行う目的のため、多くの変数を含む複雑なデータに対して回帰分析や分類分析を行うことが可能なニューラルネットワーク手法、特に複数の隠れ層を有するディープラーニング (DL) 手法による推定について考察する。DL の手法を用いれば、データの更新に柔軟に対応できるシステムが構築できるほか、入出力の非線形関係を

*建築学科 **建築・都市システム工学専攻

反映したデータの特徴分析を行うことができる。

DL にはいくつかのライブラリが公開されているが、ここでは機械学習とデータ解析のためのソフトウェアである H20^{9, 10)} の R ライブラリ^{11, 12)} を使用し、文献 5) と 8) のデータを対象とした分析を行う。

2. 分析方法

2・1 概要

文献 5) と 8) のデータをそれぞれデータ A、データ B とし、データごとに DL を適用して FRC の諸特性の推定を行う。これらのデータは、FRC の説明変数の種類、データ数や全データ数に対するカテゴリ数等の割合等がそれぞれ異なっている。

表 1 に各データのデータ数、説明変数及び目的変数を示す。文献 5) には多くの目的変数が設定されているが、ここでは FRC の圧縮強度 (F_c) と曲げ試験時の最大荷重 (以下、曲げ最大荷重という) (P_{max}) を対象とする。データ数にはプレーン試験体のデータは含まれていない。

表 1 データの概要

データ A (文献 5))		
データ数		38
目的変数	回帰	F_c, P_{max}
	分類	ID
説明変数	回帰	$d_f, L_f, f_{tf}, E_f, f_c, f_t, E_c, K_c$
	分類	同上
データ B (文献 8))		
データ数		72
目的変数	回帰	F_c
	分類	V_f^*
説明変数	回帰	$C, W/C, S, G, SF, V_f, L_f/d_f, f_t$
	分類	$C, W/C, S, G, SF, L_f/d_f, f_t, F_c$

表 1 の記号の意味は以下の通りである。

- F_c : FRC の圧縮強度 (MPa)
- P_{max} : FRC の曲げ最大荷重 (kN)
- ID : 繊維種
- d_f : 繊維の直径 (mm)
- L_f : 繊維長 (mm)
- f_{tf} : 繊維の引張強度 (MPa)
- E_f : 繊維の弾性係数 (GPa)

- f_c : セメント・コンクリートの圧縮強度 (MPa)
- f_t : セメント・コンクリートの引張強度 (MPa)
- E_c : セメント・コンクリートの弾性係数 (GPa)
- K_c : セメント・コンクリートの破壊靱性値 ($MPa \cdot m^{0.5}$)
- C : セメント単位質量 (kg/m^3)
- W/C : 水セメント比
- S : 細骨材単位質量 (kg/m^3)
- G : 粗骨材単位質量 (kg/m^3)
- SF : シリカフューム単位質量 (kg/m^3)
- V_f : 繊維混入率 (%)
- L_f/d_f : アスペクト比

回帰分析では、各々の目的変数に対してすべての説明変数を適用した推定を行う。陽な回帰式を得るのではなく、学習データによって学習を行った DL モデルに試験データ (学習データには含まれないデータ) を適用して目的変数の推定データを生成し、試験データと推定データの相関特性や平均平方二乗誤差 (RMSE) 等により推定の精度を検討する。また、説明変数の重要度 (変数重要度) により目的変数に対する各説明変数の影響の大きさを調べる。

分類分析では、データ A については繊維種 (ID) の記号を下記のようにカテゴリカルデータとしている。() の数字はそれぞれのデータ数を表す。文献 5) ではポリエチレン繊維 (PE) は繊維の物理的特性に応じて更に 9 種類の繊維種に細分化されているが、ここではこれらを纏めて PE とした。

- PIT : ピッチ系炭素繊維 (3)
- PAN : パン系炭素繊維 (3)
- ARA : アラミド繊維 (7)
- STE : スチール繊維 (6)
- PE : ポリエチレン繊維 (11)
- PP : ポリプロピレン繊維 (3)
- PA : ポリアリレート繊維 (1)
- PVA : ポリビニルアルコール繊維 (4)

文献 8) ではカテゴリカルデータは定義されていないため、データ B では繊維混入率を下記のように分類してカテゴリカルデータ (V_f^*) に変換する。() の数字はそれぞれのデータ数を表す。分類分析ではデータ A、B とともに FRC の圧縮強度を説明変数に加えている。カテゴリカルデータの推定の評価は混同行列や対数損失等を用いて行う。

$$V_f=0 \text{ 及び } 0.5\% \rightarrow V_f^*=low (38)$$

$V_f=1.0\% \rightarrow V_f^*=middle (19)$

$V_f=1.5\%$ 及び $2.0\% \rightarrow V_f^*=high (15)$

過学習を避けて汎化性能を高める機能を活用するため、ここでは回帰分析において交差検証を適用する。学習データは全データの80%とし、このうちの20%を交差検証に用いる。残りの20%は試験データとして使用し、学習後のシステムの推定精度を確認する。また、活性化関数は tanh 関数、エポック数は2000とする。

2・2 パラメータチューニング

DLには数多くのパラメータが存在するが、ここでは特に隠れ層の構成（層数と各層のノード数）と分析精度の関係について、h2o.grid 関数を用いて検討を行った。データ A と B のそれぞれに当該関数を適用した結果を回帰分析と分類分析に分けて表2に示す。例えば、隠れ層の構成が[100, 300]のとき隠れ層は2層、各層のノード数は入力側から順に100と300である。精度の測定は、回帰分析では残差 (residual deviance)、分類分析では対数損失を使用した。これらの値が小さいほど精度が高いと判断される。seed 値を指定していないので隠れ層の構成に対応する残差や対数損失の値は関数を適用する毎に異なることから、表中には10回の適用結果を平均した値を記載している。結果によれば、精度が最大となる隠れ層の構成は分析問題により異なること、隠れ層の数や各層のノード数が増大しても精度は必ずしも向上しないこと等がわかる。本論では、この結果に鑑み、いずれの場合も隠れ層の構成を[50, 50, 50]として分析を行うこととする。

2・3 カテゴリカルデータの特徴分析

DLによる推定に先立ち、それぞれのカテゴリカルデータの特徴をオートエンコーダ (AE) と主成分分析 (PCA) により分析した。AE は入力データと同じ出力データを持つニューラルネットワークで、教師なし学習によりデータの特徴を抽出するための装置である。AE では隠れ層を[100, 10, 2, 10, 100]の5層とし第3層の二つのノードによる分類状況を調べた。PCA では h2o.pcomp 関数を使用し、主成分数を2として分析を行った。いずれの場合もカテゴリー表示が密集して判読が困難になることを避けるため、表示データは20個前後とした。

図1にデータ A の分析結果を示す。横軸は第1成分、縦軸は第2成分を表す。参考のため、 F_c と P_{max} を説明変数に含める場合 (ケース1) と含めない場合 (ケース2) について分析を行った。結果によれば、スチール

表2 隠れ層の構成と精度

a) データ A、回帰分析

隠れ層の構成	残差
[50, 50, 50]	9.14
[100, 100, 100]	9.69
[200]	11.05
[100, 300]	12.04
[200, 200, 200]	13.22
[200, 200]	13.97
[50]	14.01
[200, 300]	14.69
[500, 500]	24.94

b) データ A、分類分析

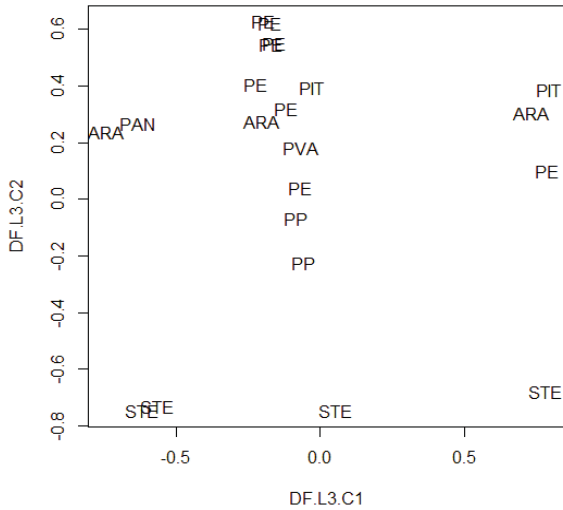
隠れ層の構成	対数損失
[100, 100, 100]	0.49
[100, 300]	0.49
[50, 50, 50]	0.53
[200]	0.56
[200, 200]	0.68
[200, 200, 200]	0.73
[200, 300]	0.89
[50]	1.15
[500, 500]	2.83

c) データ B、回帰分析


隠れ層の構成	残差
[50, 50, 50]	8.00
[200]	8.15
[100, 100, 100]	10.35
[100, 300]	11.78
[200, 200]	14.41
[50]	16.23
[200, 200, 200]	19.77
[200, 300]	21.95
[500, 500]	88.88

d) データ B、分類分析

隠れ層の構成	対数損失
[200]	0.86
[50]	0.90
[50, 50, 50]	1.16
[200, 200, 200]	1.64
[100, 100, 100]	1.68
[100, 300]	1.96
[200, 200]	2.70
[200, 300]	3.04
[500, 500]	6.50

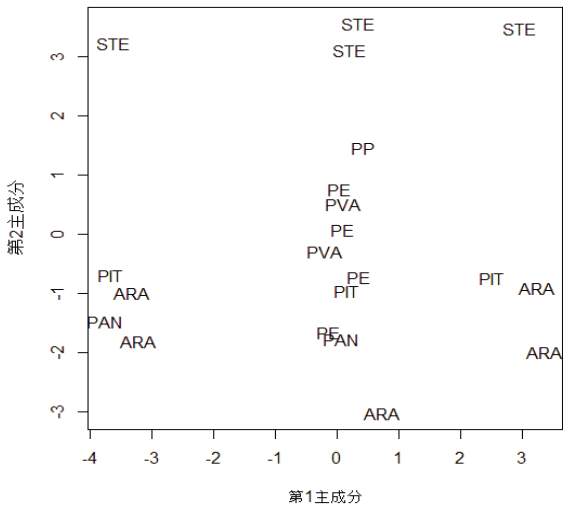


(a) F_c と P_{max} を含む場合、AE




(d) F_c も P_{max} も含まない場合、PCA

図1 データAの特徴分析結果



(b) F_c と P_{max} を含む場合、PCA



(c) F_c も P_{max} も含まない場合、AE

繊維 (STE) は他の繊維種と明確に分離されていることがわかる。また、ポリエチレン繊維 (PE) はやや拡散した状況にあり分類精度を高めるには更に細分化されたカテゴリー設定が必要と考えられる。アラミド繊維 (ARA) も若干拡散の傾向にあるが、PE やピッチ系炭素繊維 (PIT)・パン系炭素繊維 (PAN) などの炭素繊維に近い分類になっている。AE ではケース1について入出力の $RMSE=0.35$ 、変数重要度 ($VI=L_f(1.00)$)、 P_{max} (0.99)、 $K_c(0.97)$ () の数値は相対重要度)、ケース2について $RMSE=0.36$ 、 $VI=L_f(1.00)$ 、 $f_t(0.972)$ 、 $f_c(0.966)$ であった。ケース1では P_{max} の重要度が高いが、両ケースとも分類精度はほとんど変わらず、説明変数では L_f の影響が大きいことが推察される。なお、PCA では2成分による分析の累積寄与率はケース1で66%、ケース2で69%であった。

図2にデータBの分析結果を示す。繊維混入率が低いデータ (low) はある程度分類されているが、middle と low の分類が不十分なデータや、一部に low と high が重なるなど特徴抽出が難しい状況も見られる。使用材料の単体量はほとんど変えず繊維混入率だけを変える調合が多いことから、分類精度を高めるには更にデータ数や説明変数の種類を増加させる等の対策が必要と思われる。また、参考のため F_c を説明変数として含む場合と含まない場合の結果を掲載しているが、両者の分類状況はほとんど変わらず ($RMSE$ は両者ともに0.18程度)、 F_c の重要度も4位以下であった。

3. 推定結果と考察

3・1 データA

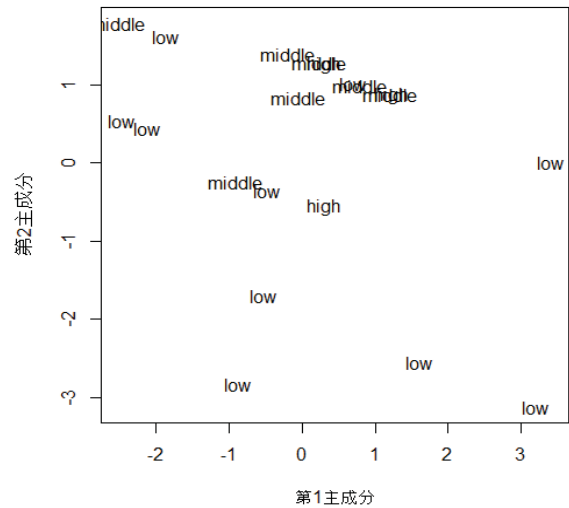
3・1・1 回帰分析

F_c に対する DL による推定結果、及び比較のため文献 5) の回帰式に試験データを適用して求めた推定結果を図 3 に示す。縦軸は推定データ (予測値)、横軸は試験データを表している。実線は回帰直線、点線は勾配 45 度の基準線である。試験データは全データからランダムに抽出した 20% (8 個) を使用し、学習後の DL モデル及び当該文献の回帰式に適用して推定データを求めた。ここでの RMSE は試験データと推定データの RMSE である。DL では重要度の高い上位 3 つの説明変数は、降順に d_f 、 K_c 、 f_t であったが、回帰式で採用された変数は L_f と K_c である。結果によれば、DL と回帰式の推定精度はほぼ同程度と考えられる。5 回の交差検証の平均残差は 20.3 であった。

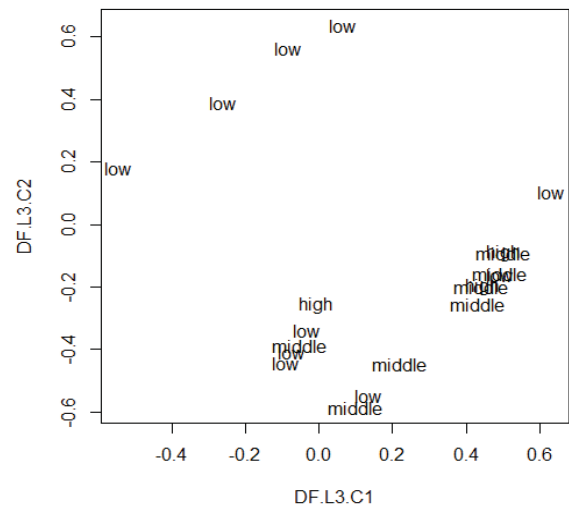
図 4 は P_{max} に対し、DL と同文献の回帰式による推定結果を比較したものである。 F_c と比較すると P_{max} の推定精度は両者ともにやや低下しており、相関特性では DL は回帰式に比較してかなり劣っている。また、DL では VI は降順に E_f 、 $L_f \cdot d_f$ 、 K_c であったが、回帰式では f_t と K_c が採用されている。5 回の交差検証の平均残差は 15.3 であった。モデルの平均残差は圧縮強度の場合より小さいが、試験データの数が少なく、分散も小さいため、回帰直線の適合度が低下したものと考えられる。

3・1・2 分類分析


全データの 80% を学習データ、20% を試験データとし、データのランダム振分けと DL モデル構築及び推定を計 10 回繰り返して得た混同行列を表 3 に示す。DL モデルでは交差検証等の検証は行っていない。表の行方向は試験データ、列方向は推定データを表す。例え



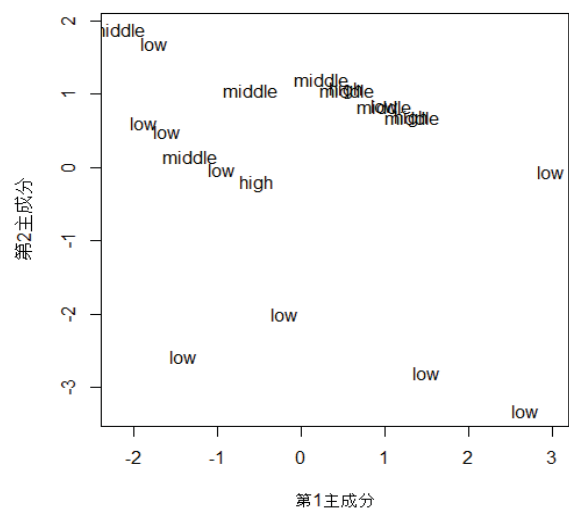
(b) F_c を含む場合、PCA



(c) F_c を含まない場合、AE




(a) F_c を含む場合、AE




(d) F_c を含まない場合、PCA

図 2 データ B の特徴分析結果




(a) DL (相関係数=0.83、RMSE=4.95)




(b) 回帰式 (相関係数=0.75、RMSE=2.67)

図4 P_{max} の回帰分析 (データ A)



(b) 回帰式 (相関係数=0.89、RMSE=4.34)

図3 F_c の回帰分析 (データ A)



(a) DL (相関係数=0.52、RMSE=4.52)

ば、繊維種 PAN のデータは合計 7 個存在し、そのうち 4 個は正しく分類されているが、残りの 3 個は誤って他の繊維種に分類されている。繊維種 X を X に分類した個数を TP、X 以外の繊維種を X 以外に分類した個数を TN とすると、全データに対するモデルの分類精度は $(TP+TN) / \text{全データ数}=61\%$ となり、かなり低い結果となった。繊維種別の分類状況は概ね以下のようなものである。

- ①PA、PP や PE は自身以外の (複数かつ多数の) 繊維種に誤分類されることが多い。
- ②PP は PVA に、PIT は PE に誤分類されることが多い。

①は 2 クラス分類における第 1 種過誤に相当し、特に当該繊維種以外の多数の繊維種に誤推定されるものは特徴付けが難しい繊維種と考えられる。②は第 2 種過誤に相当し、ある繊維種は他のどのような繊維種に誤分類されやすいかについて情報を得ることができる。

表3 データ A の混同行列

		推定データ								合計
		ARA	PA	PAN	PE	PIT	PP	PVA	STE	
試験データ	ARA	10	0	0	6	0	0	0	0	16
	PA	0	1	0	0	0	0	0	0	1
	PAN	1	0	4	1	0	1	0	0	7
	PE	1	1	0	14	0	2	0	1	19
	PIT	0	0	0	2	3	0	1	0	6
	PP	2	0	0	0	0	4	4	0	10
	PVA	0	1	0	3	0	2	7	0	13
	STE	2	0	0	0	0	0	0	6	8
	合計	16	3	4	26	3	9	12	7	80

表 4 繊維種別の分類評価

	精度	再現率	適合率	F値
ARA	85.0%	62.5%	62.5%	62.5%
PA	97.5%	100.0%	33.3%	50.0%
PAN	96.3%	57.1%	100.0%	72.7%
PE	78.8%	73.7%	53.8%	62.2%
PIT	96.3%	50.0%	100.0%	66.7%
PP	86.3%	40.0%	44.4%	42.1%
PVA	86.3%	53.8%	58.3%	56.0%
STE	96.3%	75.0%	85.7%	80.0%

表 3 を基に、繊維種ごとに 2 クラス分類の分割表を作成し、分類評価を行った結果を表 4 に示す。適合率は第 1 種過誤に、再現率は第 2 種過誤に関係する。F 値は再現率と適合率の調和平均であり、分類の優劣の総合的な指標と考えられている。結果によれば、第 1 種過誤の発生率が最も小さい繊維種は PAN と PIT であり、最も大きい繊維種は PVA であった。また、第 2 種過誤の発生率が最も小さい繊維種は PA であり、最も大きい繊維種は PP であった。F 値が最も大きい繊維種は STE であり、最も小さいものは PP であった。STE と PP は引張強度や弾性係数が他の繊維種に比較して小さく、繊維径は大きいという共通の特徴がある。一方、試験体の調合では、STE は 2 種類の繊維長と 3 種類の水結合材比 (W/B) を使用しているが、PP は 3 種類の繊維長と 1 種類の W/B を使用している。W/B の値が変わると FRC の圧縮強度や引張強度などの説明変数も変化するため、このことが両者の分類評価の相違の原因となった可能性がある。


3・2 データ B

3・2・1 回帰分析

F_c に対する DL による推定結果及び比較のため文献 8) の回帰式による推定結果を図 5 に示す。試験データは全データからランダムに抽出した 20% (15 個) を使用し、学習後の DL モデル及び当該文献の回帰式に適用して推定データを求めた。回帰式ではすべての説明変数を適用している。DL では、VI は降順に C、S、 L_f/d_f であった。結果によれば、DL の推定精度は回帰式より良好であった。


3・2・2 分類分析

データ A の分類分析と同様の方法で得たデータ B の混同行列を表 5 に、繊維混入率別の分類評価を表 6 に示す。全データに対するモデルの分類精度は 75% である。データ A に比較して分類精度が高いのは、各カテ



(単位: MPa)

(a) DL (相関係数=0.97、RMSE=2.48)



(単位: MPa)

(b) 回帰式 (相関係数=0.70、RMSE=9.75)

図 5 F_c の回帰分析 (データ B)

表 5 データ B の混同行列

		推定データ			
		high	middle	low	合計
試験データ	high	21	7	2	30
	middle	8	26	10	44
	low	1	9	66	76
	合計	30	42	78	150

表 6 繊維混入率別の分類評価

	精度	再現率	適合率	F値
high	88.0%	70.0%	70.0%	70.0%
middle	77.3%	59.1%	61.9%	60.5%
low	85.3%	86.8%	84.6%	85.7%

ゴリーに属するデータ数がより多いことによると考えられる。繊維混入率別の分類状況では、high と low は両者ともに middle に誤分類されるものが多く、high が low に、あるいは low が high に誤分類されるものは少ない。分類評価では F 値が最も大きいものは low であるが、これは繊維が存在しない場合は繊維のアスペクト比や引張強度などの説明変数の値がすべて 0 になり、分類性能が高められたためと考えられる。繊維が存在する場合は、これらの値は繊維混入率に依存せず一定であり、特に middle と high の分類情報には寄与しない。一方、middle は最も F 値が小さく、精度も低い。middle の推定データでは high よりも low に誤分類されるケースがやや多いが、これは繊維混入率=0.5%のデータが影響していると考えられる。

4. まとめ

本研究では、既往の文献から収集したデータに基づき、FRC の諸特性の推定を DL による回帰分析や分類分析の手法を用いて行った。DL には数多くのパラメータが存在するため事前にパラメータチューニングを行い、加えて AE と PCA によるカテゴリカルデータの特徴分析を行った。回帰分析では DL による推定と文献の回帰式による推定を比較し、分類分析では混同行列を求めて推定の精度等の確認を行った。主たる結論は以下の通りである。

- (1) 回帰分析では、DL と回帰式ともに、 F_c の推定精度が P_{max} を上回った。
- (2) 回帰式による推定に比較して、DL による推定結果は試験データ数に強く依存する傾向があった。
- (3) スチール繊維 (STE) は、炭素繊維や有機繊維とは明瞭に区別される傾向があり、分類分析での精度や F 値も高かった。
- (4) 各繊維種を 2 クラス分類で比較すると、第 1 種過誤の発生率が高いのはポリアリレート繊維 (PA) とポリプロピレン繊維 (PP) であり、第 2 種過誤の発生率が高いのはポリプロピレン繊維 (PP) とピッチ系炭素繊維 (PIT) であった。
- (5) 同様に、第 1 種過誤の発生率が最も低いのはパン系炭素繊維 (PAN) とピッチ系炭素繊維 (PIT) であり、第 2 種過誤の発生率が最も低いのはポリアリレート繊維 (PA) であった。
- (6) 繊維混入率をカテゴリカルデータに変換して行った分類推定の F 値は、low が最も高く middle が最も低かった。
- (7) 混同行列から算定した各データ (A と B) の分類精

度はそれぞれ 61% と 75% であった。

参考文献

- 1) 金久保利之：繊維補強コンクリートの構造部材への適用に関する研究の現状、コンクリート工学、Vol.50、No.5、2012、433-437.
- 2) 菊田貴恒、三橋博三：繊維補強コンクリートの構成要素と材料の基本的性能、コンクリート工学、Vol.50、No.5、2012、414-417.
- 3) 村上聖ほか：浦野鋼繊維補強コンクリートの力学的特性に及ぼすアスペクト比、繊維体積率、セメント水比の相互作用の定量化、熊本大学工学部研究報告、42 (3)、1993、203-207.
- 4) 村上聖、浦野登志雄、三井宜之：鋼繊維補強コンクリートの力学パラメータに及ぼす調合因子の相互作用の定量分析、コンクリート工学論文集、第 7 巻、第 1 号、1996、23-30.
- 5) 中村裕、三橋博三：短繊維補強セメント系複合材料の力学的性能に及ぼす材料因子の影響に関する基礎的研究、日本建築学会構造系論文集、第 541 号、2001、1-8.
- 6) D.Maruthachalam、R.K.Rajalaxmi、B. G. Vishnuram : Statistical Modeling of Fiber Reinforced High Performance Concrete、International Journal of Scientific & Engineering Research、Volume 3、Issue 6、June、2012、1-5.
- 7) Mohammad S. Islam、Shahria Alam : Principal Component and Multiple Regression Analysis for Steel Fiber Reinforce Concrete Beams、International Journal of Concrete Structures and Materials、Vol.7、No.4、2013、303-317.
- 8) G. Murali et al : Prediction of Compressive Strength of Fiber Reinforced Concrete Containing Silica Fume Using MLR Model、Caribbean Journal of Science and Technology、Vol.2、2014、257-262.
- 9) D. Cook : Practical Machine Learning with H2O、O'Reilly Media, Inc.、2017.
- 10) H2O.ai : <https://www.h2o.ai/>
- 11) The R Project for Statistical Computing : <https://www.r-project.org/>
- 12) Package 'h2o' (R Interface for H2O) : <https://cran.r-project.org/web/packages/h2o/h2o.pdf>