

地震応答解析サンプルに基づく AI による最適解の算出

山田 猛矢*¹ ○吉崎 雄一*²
中尾 方人*³ 古田 智基*⁴

キーワード：人工知能 地震応答解析 木造住宅 データベース

1. はじめに

建築構造物の地震時の挙動を推定（シミュレーション）する方法に地震応答解析がある。しかしながら、地震応答解析を行うためには高度な理論と経験およびテクニックが必要であり、高い信頼性を有さなければならない。さらに、解析の精度を確保するためには、履歴モデルを複雑な荷重-変形関係にフィッティングさせなければならない。現状では地震応答解析を簡単に行うことはできない。そこで、地震応答解析を簡便に行う方法として、応答結果値のデータベースを利用することを考える。信頼性が高く、複雑な履歴モデルにフィッティングできる市販ソフト（SNAP）を使用して、対象構造物の構造種別、床面積、階数等の範囲を決めて、応答結果値のデータベースを作成する。このデータベースを利用することで高い信頼性を確保できる。しかしながら、データベースにおける構造物の諸条件と求めたい構造物の諸条件は一致しないため、それを補完する手段として AI を用いる。すなわち、データベースを AI に学習させることで、求めたい構造物の諸条件を満たす応答結果値を導き出し補完する。この手法が確立すれば、簡便的に信頼性の高い地震応答解析を行うことが可能となる。

2. 研究の目的

AI にデータベースを学習させることにより、求めたい構造物の諸条件を満たす最適解（応答結果値）を導き出す。なお、本報では 2 階建て（2 質点）の木造住宅を対象に、応答変位に着目した最適解を導く。

3. データベース

市販ソフト SNAP を用いてデータベースを作成する。地震波には BCJ-L2 波を使用し、構造物のパラメータは 1 階壁量充足率 α_1 、壁量充足率比 α_2 、合板負担率 α_3 、床面積比 α_4 とした。1 階壁量充足率は 1.0~2.0 の範囲で 0.1 刻み、壁量充足率比は 1.0~2.0 の範囲で 0.2 刻み、合

板負担率は 0.0~0.8 の範囲で 0.2 刻み、床面積比は 0.7~1.0 の範囲で 0.1 刻みにおいて各パラメータを設定し、1F-2F 間および 2F-RF 間の層間変位を計算しデータベースを作成する。表 1 が作成したデータベース（全部で 1320 データ）の一部である。

4. AI アルゴリズム

4.1 補完を試みた AI アルゴリズム

まずは、多くの AI アルゴリズムの中で、どのアルゴリズムが最適解を導き出すか、データベースから学習モデルを作成し試行テストを実施する。各アルゴリズムにはそれぞれ得意・不得意があるが、課題が与えられた際の、最適解を導くアルゴリズムの決定手法は未だ確立していない。現在のところ、AI を利用する際は、いくつかの AI アルゴリズムをテストし、より良い結果を導くアルゴリズムを見つけ出し、そのパラメータ調整を行うことで精度を得ている。したがって、まずは様々な AI アルゴリズムにデータベースを学習させ、モデルを作成しテストすることで、使用するアルゴリズムを決めなければならない。

今回我々が試す AI アルゴリズムは、一般的によく利用されているアルゴリズムおよび scikit-learn の Web サイト 2) に掲載されている algorithm cheat-sheet に従って選出されたアルゴリズムである。具体的には、以下の 13 種類のアルゴリズムに対してデータベースを学習させ、テストを実施した。

- BaggingRegressor
- ElasticNet
- k-近傍法
- MLPRegressor
- SVM
- SVR(kernel = 'linear')
- SVR(kernel = 'rbf')
- ブースティング回帰木
- ランダムフォレスト
- リッジ回帰
- 決定木
- 最小二乗法
- Lasso

表 1：データベース

α_1 1 階壁量充足率	α_2 壁量充足率比	α_3 合板負担比	α_4 床面積比	層間変位	
				2F-RF	1F-2F
1.0	1.0	0.0	0.7	57.26	180.28
1.1	1.0	0.0	0.7	161.71	49.68
...					
2.0	2.0	0.8	1.0	11.44	48.82

4.2 関数近似

AIでの補完とともに、比較のために関数近似も行った。関数近似については、データベースから得られる層間変位 $D(\alpha_1, \alpha_2, \alpha_3, \alpha_4)$ を用いて、次のように計算する。ここでは、1F-2F 間の層間変位 $D'(1.03, 1.0, 0.0, 0.7)$ を求めたいとする。データベース (表 1) を見ると、 $\alpha_1 = 1.03$ より大きく、また近い値として $\alpha_1^+ = 1.1$ があり、小さく近い値として $\alpha_1^- = 1.0$ がある。関数近似は、この 2 つの値および $\alpha_2 = 1.0, \alpha_3 = 0.0, \alpha_4 = 0.7$ から得られる層間変位を用いて近似する。

$$D(1.0, 1.0, 0.0, 0.7) = 180.28$$

$$D(1.1, 1.0, 0.0, 0.7) = 49.68$$

から、 α_1 の変化量 $\Delta\alpha_1 = 0.1$ のとき、層間変位の変化量 $\Delta D = -130.6$ となり、 α_1 と α_1^- の差 $d\alpha_1 = 0.03$ から次のように近似する。

$$D'(1.1, 1.0, 0.0, 0.7) = D(1.0, 1.0, 0.0, 0.7) + \frac{\Delta D}{\Delta\alpha_1} d\alpha_1$$

一般的には 4 つのパラメータが、すべてのデータベースと異なる値となるので、 $\alpha_2, \alpha_3, \alpha_4$ もそれぞれ α_1 と同様に变化させる。さらに 2 つ同時にパラメータを变化させたもの (すべての組合せについて考慮する)、3 つ同時にパラメータを变化させたもの (こちらもすべての組合せについて考慮する)、4 つのパラメータを变化させたものから次のように近似する。

$$\begin{aligned} D(\alpha_1 + d\alpha_1, \alpha_2 + d\alpha_2, \alpha_3 + d\alpha_3, \alpha_4 + d\alpha_4) \\ = D(\alpha_1, \alpha_2, \alpha_3, \alpha_4) + \Delta C_1 + \Delta C_2 + \Delta C_3 + \Delta C_4 \end{aligned}$$

ただし、

$$\Delta C_1 = \sum_{i=1}^4 \frac{\Delta D}{\Delta\alpha_i} d\alpha_i$$

$$\Delta C_2 = \sum_{i=1}^3 \sum_{j=i+1}^4 \frac{\Delta^2 D}{\Delta\alpha_i \Delta\alpha_j} d\alpha_i d\alpha_j$$

$$\Delta C_3 = \sum_{i=1}^2 \sum_{j=i+1}^3 \sum_{k=j+1}^4 \frac{\Delta^3 D}{\Delta\alpha_i \Delta\alpha_j \Delta\alpha_k} d\alpha_i d\alpha_j d\alpha_k$$

$$\Delta C_4 = \frac{\Delta^4 D}{\Delta\alpha_1 \Delta\alpha_2 \Delta\alpha_3 \Delta\alpha_4} d\alpha_1 d\alpha_2 d\alpha_3 d\alpha_4$$

また、

$$\Delta\alpha_1 = \alpha_1^+ - \alpha_1^-$$

$$\frac{\Delta D}{\Delta\alpha_1} = \frac{D(\alpha_1 + \Delta\alpha_1, \alpha_2, \alpha_3, \alpha_4) - D(\alpha_1, \alpha_2, \alpha_3, \alpha_4)}{\Delta\alpha_1}$$

$$\frac{\Delta^2 D}{\Delta\alpha_1 \Delta\alpha_2} = \frac{1}{\Delta\alpha_1} \left(\frac{\Delta D(\alpha_1 + \Delta\alpha_1)}{\Delta\alpha_2} - \frac{\Delta D(\alpha_1)}{\Delta\alpha_2} \right)$$

$$\frac{\Delta D(\alpha_1 + \Delta\alpha_1)}{\Delta\alpha_2} = \frac{D(\alpha_1 + \Delta\alpha_1, \alpha_2 + \Delta\alpha_2, \alpha_3, \alpha_4) - D(\alpha_1 + \Delta\alpha_1, \alpha_2, \alpha_3, \alpha_4)}{\Delta\alpha_2}$$

$$\frac{\Delta D(\alpha_1)}{\Delta\alpha_2} = \frac{D(\alpha_1, \alpha_2 + \Delta\alpha_2, \alpha_3, \alpha_4) - D(\alpha_1, \alpha_2, \alpha_3, \alpha_4)}{\Delta\alpha_2}$$

関数近似においては、この近似式を用いて補完を行う。

5. 評価方法

本研究では、AIによる補完値および関数近似による補完値を評価する方法として、回帰問題において一般的によく使われる決定係数

$$R^2 = 1 - \frac{\sum_i (x_i - D'_i)^2}{\sum_i (x_i - \bar{x})^2}$$

を用いる。ただし、 x は真の値、 \bar{x} は x の平均値、 D' は補完値を表す。式からわかるように、決定係数は真の値と補完値との差が小さいとき 1 に近づく (最大値は 1)。つまり決定係数が 1 に近いほど良い補完ができていることになる。

6. テスト結果

各 AI アルゴリズムに対してデータベースを学習させ、モデルを作成し、テストデータを用いた補完テストを行った。テストデータは、各パラメータに乱数を振った 30 個のデータ (表 2) とした。テストデータによる補完値の決定係数が表 3 である。また 30 個のテストデータに対し、正解値 (SNAP で計算した結果) と補完値をプロットしたのが図 1、2 である (ここでは 2 種類の AI アルゴリズムのみ掲載)。本図では、斜線上に点が近くなるほど精度がよいこととなる。図 3 は、同様に関数近似をプロットしたものである。

表 2: テストデータ

α_1 1 階壁量充足率	α_2 壁量充足率比	α_3 合板負担比	α_4 床面積比	層間変位	
				F3-F2	F2-F1
1.81	1.04	0.78	0.71	42.89	54.63
1.28	1.05	0.74	0.88	98.22	41.75
...					
1.24	1.99	0.12	0.95	16.13	133.22

表 3 : 決定係数

	2F-RF	1F-2F	平均
BaggingRegressor	0.18	0.80	0.49
ElasticNet	0.09	0.17	0.13
k-近傍法	0.79	0.95	0.87
MLPRegressor	0.41	0.10	0.26
SVM	0.43	0.51	0.47
SVR(kernel='linear')	0.40	0.71	0.56
SVR(kernel='rbf')	0.74	0.91	0.82
ブースティング回帰木	0.52	0.88	0.70
ランダムフォレスト	0.19	0.80	0.49
リッジ回帰	0.31	0.75	0.53
決定木	0.11	0.81	0.46
最小二乗法	0.31	0.76	0.53
Lasso	0.40	0.72	0.56
関数近似	0.85	0.96	0.91

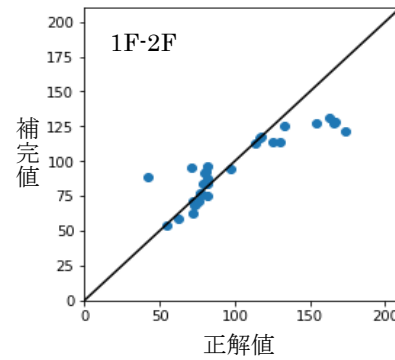
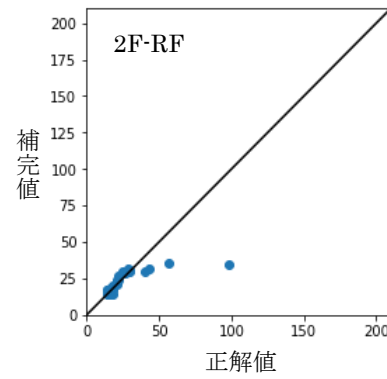


図 2 : SVR(kernel='linear')


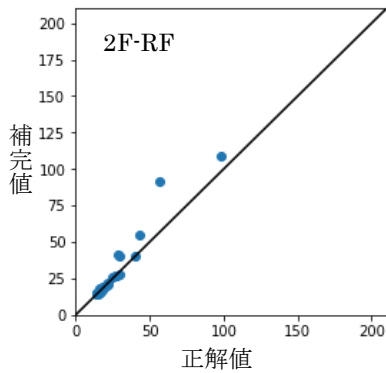


図 1 : k-近傍法

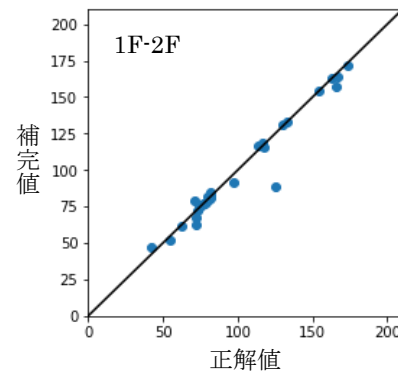



図 3 : 関数近似

表 3 から、関数近似の決定係数（平均）が 0.91 と最も高いが、AI アルゴリズムは与えられた課題に適応したパラメータ調整を行うことで急激に精度があがるため、デフォルト状態における決定係数 0.87 というのは良い結果であり、最適解を導き出すことができる可能性を有している。そこで、k-近傍法のパラメータ調整を行い、最適解を導き出すモデルの作成を行う。

k-近傍法の重要パラメータは、n_neighbors と weights と言われており、ここを中心にパラメータ調整を行った。パラメータを下の設定パラメータのように取った際に、決定係数（平均）が 0.93 となり、精度が飛躍的に向上した（表 4）。また、パラメータ調整後の正解値と補完値のグラフを図 4 に示す。

設定パラメータ

- n-ighbors = 46
- weights = 'distance'
- algorithm = 'ball_tree'
- leaf_size = 20
- p=1

表 4：パラメータ調整後の決定係数

	2F-RF	1F-2F	平均
k-近傍法	0.91	0.96	0.93

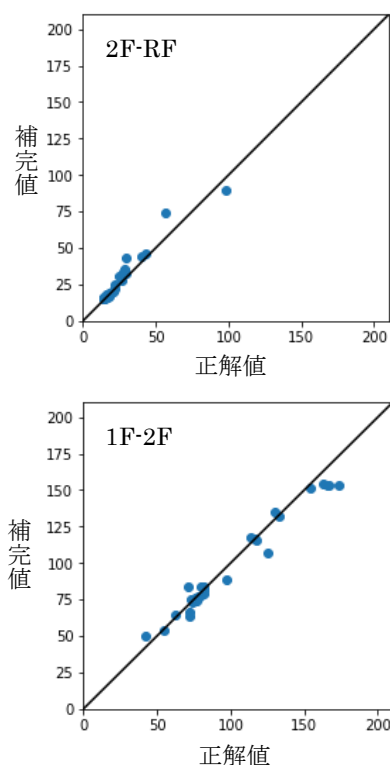


図 4：パラメータ調整後の k-近傍法

7. 考察

パラメータ調整後の k-近傍法による AI の決定係数が関数近似を上回り、精度良い最適解を導くことができた。今回用いた関数近似は、求めたいパラメータ α_i の近傍の大きい値 α_i^+ と小さい値 α_i^- のセットが 4 つ ($\alpha_1, \alpha_2, \alpha_3, \alpha_4$) あり、これらの組合せで層間変位を補完していた。つまり $2^4 = 16$ 個の層間変位の値をデータベースから得て補完値を計算している。一方、k-近傍法のパラメータ調整で一番効果があったのが n_neighbors であり、デフォルト値 5 をパラメータ調整後は 46 としている。この n_neighbors というパラメータは、補完値を計算するために使用する近傍値の数を指定するパラメータである。つまり 5 個の近傍値では関数近似に及ばなかったが、46 個の近傍値で補完を行うことにより、精度良い補完を行うことができたと考えられる。

8. まとめ

本研究は、信頼性が高く複雑な履歴モデルに対応できる市販ソフト SNAP を用いてデータベースを作成し、それを AI に学習させることにより、求めたい構造物の諸条件を満たす応答変位を導き出すという試みを行った。13 種類の AI アルゴリズムと関数近似で任意のパラメータの補完を行ったところ、関数近似の決定係数が 0.91 と最も高かった。しかしながら、この結果は AI アルゴリズムのパラメータをデフォルトで計算したためであり、当然の結果であった。13 種類の AI アルゴリズムの中では、k-近傍法の決定係数が 0.87 と最も高かったことから、我々はこの課題を解決するのに適しているアルゴリズムは k-近傍法であると判断し、パラメータ調整を行った。その結果、決定係数が 0.93 となり、関数近似より精度の高い結果が得られた。

今回はパラメータ 4 種類に対する、1F-2F 間、2F-RF 間の層間変位の補完を実施したが、パラメータ数が増えた際にも精度よく最適解を導くことができるかの検討が必要である。

[参考文献]

- 1) Andreas C. Muller, Sarah Guido, 中田秀基(訳), Python ではじめる機械学習, オライリー・ジャパン, 2017
- 2) "scikit-learn: machine learning in python" <http://scikit-learn.org/stable/index.html>, 2018.10.5
- 3) 柴田明徳, 最新耐震構造解析, 森北出版, 1981

- *1 第一工業大学工学部情報電子システム工学科 講師 修士(理学)
- *2 第一工業大学工学部情報電子システム工学科 学部生
- *3 横浜国立大学大学院都市イノベーション研究院 特別研究員 博士(工学)
- *4 西日本工業大学デザイン学部建築学科 教授 工学博士