

地震荷重特徴抽出を備えた深層カーネル学習代替モデルによる地震リスク解析の効率化
(シンポジウム講演概要)

Deep kernel learning surrogate model with extracting seismic feature for seismic risk analysis
(Proceedings of Symposium on Applied Mechanics)

才田 大聖 (筑波大・シス情) 西尾 真由子 (筑波大・シス情)
Taisei SAIDA, University of Tsukuba
Mayuko NISHIO, University of Tsukuba
E-mail: saida.taisei.tj@alumni.tsukuba.ac.jp

This study developed a deep kernel learning surrogate model to reduce computational costs of a seismic risk analysis. This model uses convolutional neural networks (CNN) to extract seismic load features. Furthermore, the explainability of the surrogate model are obtained by estimating the contribution of each part of the seismic load by Gradient-weighted Class Activation Mapping (Grad-CAM) and by estimating the contribution of each structural parameter by ARD. In the validation, a surrogate model was constructed for the seismic response analysis of isolated RC piers. It was shown that the computational cost can be reduced and that the model has explainability.

1. はじめに

インフラ構造物の地震リスク評価では、限界状態に対する故障確率を確率論的に計算する地震リスク解析を行う必要がある。この際に、劣化などによる構造パラメータの不確定性だけでなく、地震荷重に対する不確定性も考慮することが重要である。これら不確定性を考慮し地震リスクを計算するために、モンテカルロ計算が用いられるが、数万回以上の計算が必要となることもあり計算コストが大きい。

そこで本研究では、深層カーネル学習による代替モデルを構築し、地震リスク解析の計算コストの低減を図る。代替モデルとは、数値解析を代替する機械学習モデルであり、少数の計算結果から精度の良い代替モデルが構築できれば、計算コストが低減できる。本研究で開発する代替モデルは、畳み込みニューラルネットワーク (CNN) による地震荷重の特徴抽出が組み込まれることで、地震荷重の不確定性に対処できる。また、工学分野ではなぜその結果が得られたのかといった説明性があることが重要である。開発した代替モデルは Gradient-weighted Class Activation Mapping (Grad-CAM) によって、地震荷重の中でどの部分が出力に寄与していたかを推定する。さらに、関連度自動決定 (ARD) カーネルの使用によって、地震荷重と構造パラメータの中で何が出力に寄与していたかを推定する。これら

の推定された寄与度によって、代替モデルの説明性を担保する。

検証では、免震 RC 橋脚の地震リスク解析を対象に代替モデルを構築し、代替モデルの予測精度、予測分布について評価を行う。さらに、ARD カーネルと Grad-CAM¹⁾によって推定された寄与度の妥当性について評価する。

2. 代替モデル構築手法

本研究では、Fig. 1 に示す深層カーネル学習によって代替モデルを構築する。深層カーネル学習²⁾は深層学習による特徴抽出力とガウス過程によるノンパラメトリック性を兼ね備えた機械学習手法である。深層カーネル学習では、通常のガウス過程回帰におけるカーネル関数 $k(\mathbf{x}, \mathbf{x}')$ が次のように拡張される。

$$k(\mathbf{x}, \mathbf{x}') \rightarrow k(g(\mathbf{x} | \mathbf{w}), g(\mathbf{x}' | \mathbf{w})) \tag{1}$$

ここで、 g は重み $\mathbf{w}$ をもつ深層学習機による非線形写像である。すなわち、(1) は深層学習機を通した空間内でガウス過程を行っている と解釈できる。本研究では、 g に CNN を採用し、ベースとなるカーネル関数 k には Matern52 カーネルを採用した。さらに、CNN 部に Grad-CAM、ガウス過程部に ARD カーネルを適用し、代替モデルの説明性向上を図った。




Fig. 1 Deep kernel learning surrogate model architecture

3. RC 免振橋脚の地震応答解析

本研究では、RC 橋脚の地震応答解析を代替モデル構築の対象とした。本橋脚は、道路橋の耐震設計に関する資料に記載の免震 RC 橋脚であり、2 自由度系でモデル化した。履歴特性として、橋脚部を Takeda モデル、支承部をバイリニアモデルとした。また、数値積分法はニューマーク β 法、時間増分は 0.001 秒として計算した。粘性減衰は、免震支承では 0%、橋脚では 2% のレイリー減衰を仮定した。構造パラメータの不確定性として、質量や剛性など 8 つのモデルパラメータで、諸元地に対して $\pm 10\%$ を上下限值とする一様分布を設定した。地震荷重における不確定性として、1 種地盤で観測された Level2 地震動 20 波形を用いた。

4. 代替モデル構築結果

まず、構造パラメータ及び地震種類について、ラテン超方格法で 10000 点の入力データを 2 回サンプリングし、その入力点について 3. で述べた地震応答解析を行い、橋脚及び支承の最大変位を計算した。そのうち片方を訓練用、もう片方を評価用とした。代替モデルの精度については決定係数、予測分布については定性的なグラフの重ね合わせで評価した。また、Grad-CAM 及び ARD によって推定された寄与度を工学的な見地から妥当性を判断した。

代替モデルの予測精度について、ここでは、訓練用データセットからランダムに 10 回サンプリングした 300 の訓練データで構築した 10 の代替モデルについて評価した。その結果、決定係数の平均と標準偏差は、橋脚の最大変位について 0.976 と 0.0053、支承の最大変位について 0.977 と 0.034 であった。双方の予測について、決定係数が 0.97 を超えており、代替モデルは高精度であったといえる。

次に代替モデルにおける支承の最大変位の予測分布について、Fig. 2 に示す。図は青で予測を、赤で数値解析による正解データを示す。Fig. 2 から代替モデルの予測分布と正解データの分布は概ね一致していることが確認できる。

さらに、代替モデルの説明性について、Grad-CAM によって応答スペクトルの部分ごとの寄与度を可視化したもの




Fig. 2 Distribution of max displacement at bearing predicted by surrogate model

を Fig. 3 に示す。今回用いた解析モデルの固有周期は 0.3 秒付近と 1.0 秒付近であるが、図を見ると、固有周期付近で寄与度が大きくなった様子が確認できる。しかし、固有周期とは外れた周期の寄与が大きくなる場合もあった。また、ARD によるパラメータ寄与度を Fig. 4 に示す。図中の「F」は地震荷重、「f」は構造パラメータから計算された固有周期を示す。図を見ると、外力の寄与が、構造パラメータとしては固有周期の寄与が大きかったことが分かる。

5. 結論

本研究では、CNN によって地震荷重の特徴を抽出する深層カーネル学習による代替モデルを開発した。また、本モデルは Grad-CAM および ARD カーネルを組み込むことで、説明性の担保を図った。免震 RC 橋脚の地震応答解析を対象に代替モデルが構築された結果、300 の訓練データ数で 10000 の MC 計算と同等の予測分布が得られることが示された。さらに、Grad-CAM によって地震荷重の寄与度が、ARD によってパラメータの寄与度が算出でき、代替モデルの説明性を得ることができることが示された。

謝辞

本研究は JST 創発的研究支援事業 JPMJFR205T の支援を受けたものです。ここに記して謝意を表します。

参考文献

- 1) R.R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, D. Batra: Grad-CAM: Visual explanations from deep networks via Gradient-based localization, Proceedings of the IEEE International Conference on Computer Vision, 2016: pp. 618–626.
- 2) A.G. Wilson, Z. Hu, R. Salakhutdinov, E.P. Xing: Deep Kernel Learning, Proceedings of the 19th International Conference on Artificial Intelligence and Statistics, PMLR, Cadiz, Spain, 09–11 May 2016: pp. 370–378.




Fig. 3 Contribution of seismic loads estimated by Grad-CAM




Fig. 4 Contribution of each parameter estimated by ARD kernel