

11 - 4 地震動予測への機械学習技術の適用

Application of Machine Learning Techniques to Ground-Motion Prediction

防災科学技術研究所

National Research Institute for Earth Science and Disaster Resilience

地震による予測対象地点での揺れの強さ、もしくは揺れの時系列を予測することを目的とする地震動予測は、事前の地震ハザード評価や事中の緊急地震速報、事後の被害推定などにおいて活用されている。近年その予測やそれを支える基礎情報の作成などに機械学習が適用されてきている。ここでは、①少数の説明変数に基づく地震動指標値の予測、②少数の説明変数に基づく地震動時系列の予測、③時系列情報に基づく地震動指標値の予測、④時系列情報に基づく地震動時系列の予測、⑤その他関連する研究、の 5 分野における機械学習の適用状況に関して簡単なレビューを行う。

①少数の説明変数に基づく地震動指標値の予測：地震による任意地点での震度や最大加速度などの揺れの強さ（地震動指標値）を予測することには、これまで地震動予測式と呼ばれる過去の地震動記録に基づいた経験式を用いられてきた。この場合、地震からの距離や地震のマグニチュードなどが説明変数として使われる。この予測問題を教師あり機械学習と見なし、機械学習に基づいて予測モデルを作成することがこれまでに多数行われている^{1,2)}。既存の予測式に比べて、学習したデータの範囲内では予測精度が向上すること³⁾、またより柔軟な予測が可能であること^{4,5)}が示されている。

②少数の説明変数に基づく地震動時系列の予測：地震による任意地点での地震波形などの地震動時系列の作成には、数値シミュレーションや経験的手法、統計的手法などが用いられてきた。この問題に対して機械学習モデルの一つである生成モデルの適用が近年進められており、敵対的生成ネットワーク GAN の一種である Conditional GAN によって過去の地震動波形記録を学習することで、観測を模倣した疑似データを生成することが試みられている^{6,7)}。別のアプローチとして、Physics Informed Neural Network と呼ばれる物理則を考慮するニューラルネットワーク技術を適用した研究もある^{8,9,10)}。

③時系列情報に基づく地震動指標値の予測：地震が発生し、ある観測点に到着した地震動のはじめ数秒間から、その地点での最終的な揺れの強さを予測することは、オンサイト緊急地震速報と呼ばれる。これまでは生波形記録から抽出した特徴変数から最終的な揺れの大きさを予測することが行われてきた。近年はこのタスクを機械学習で行おうという研究が進められている^{11,12)}。また複数観測点の記録を使って、複数地点での予測を試みた研究もある¹³⁾。

④時系列情報に基づく地震動時系列の予測：緊急地震速報の研究分野においては近年揺れから揺れの予測が盛んに研究されており、これにも機械学習が適用されている^{14,15,16)}。また地震動シミュレーションで得られる長周期波形の情報から短周期波形を取得し、それらを組み合わせることで広帯域な地震動を作成する研究にも機械学習は適用されている^{17,18)}。

⑤その他関連する研究：観測点毎に異なるサイト増幅特性の推定に機械学習を適用した研究¹⁹⁾や地震ハザードシナリオの分解・再構築に機械学習を適用した研究²⁰⁾などがある。

以上にまとめたように地震動予測と機械学習を組み合わせた研究によって多くの研究成果が得られており、今後のさらなる飛躍が期待される。他方で、地震動の観測データは根本的に不均衡であり、これが予測モデルに与える影響が懸念される。数値シミュレーションなどを用いたデータ拡

張²¹⁾・物理モデルとのハイブリッド^{22,23)}などの対応が考えられる。

(久保久彦)

KUBO Hisahiko

参考文献

- 1) Derras et al. (2012), Adapting the neural network approach to PGA prediction: an example based on the KiK-net data. *Bull Seismol Soc Am*, **102**, 1446–1461.
- 2) Trugman and Shearer (2018), Strong correlation between stress drop and peak ground acceleration for recent M 1–4 earthquakes in the San Francisco Bay area. *Bull Seismol Soc Am*, **108**, 929–945.
- 3) Khosravikia and Clayton (2021), Machine learning in ground motion prediction. *Comput Geosci*, **148**, 104700.
- 4) Okazaki et al. (2021), Ground-motion prediction model based on neural networks to extract site properties from observational records. *Bull Seismol Soc Am*, **111**, 1740–1753.
- 5) Lilienkamp et al. (2022), Ground-motion modeling as an image processing task: introducing a neural network based, fully data-driven, and nonergodic approach. *Bull Seismol Soc Am*, **112**, 1565–1582.
- 6) Florez et al. (2022), Data-driven synthesis of broadband earthquake ground motions using artificial intelligence. *Bull Seismol Soc Am*, **112**, 1979–1996.
- 7) Esfahani et al. (2023), TFCGAN: Nonstationary ground-motion simulation in the time–frequency domain using conditional generative adversarial network (CGAN) and phase retrieval methods. *Bull Seismol Soc Am*, **113**, 453–467.
- 8) Song et al. (2021), A versatile framework to solve the Helmholtz equation using physics-informed neural networks. *Geophys J Int*, **228**, 1750–1762.
- 9) Okazaki et al. (2022) Physics-informed deep learning approach for modeling crustal deformation. *Nat Commun*, **13**, 7092.
- 10) Rasht-Behesht et al. (2022), Physics-informed neural networks (PINNs) for wave propagation and full waveform inversions. *J Geophys Res: Solid Earth*, **127**, e2021JB023120.
- 11) Jozinović et al. (2020), Rapid prediction of earthquake ground shaking intensity using raw waveform data and a convolutional neural network. *Geophys J Int*, **222**, 1379–1389.
- 12) Zhang et al. (2022) Learning source, path and site effects: CNN-based on-site intensity prediction for earthquake early warning. *Geophys J Int*, **231**, 2186–2204.
- 13) Münchmeyer et al. (2020), The transformer earthquake alerting model: a new versatile approach to earthquake early warning. *Geophys J Int*, **225**, 646–656.
- 14) Otake et al. (2020), Deep learning model for spatial interpolation of real-time seismic intensity. *Seismol Res Lett*, **91**, 3433–3443.
- 15) Datta et al. (2022), DeepShake: Shaking intensity prediction using deep spatiotemporal RNNs for Earthquake Early Warning. *Seismol Res Lett*, **93**, 1636–1649.
- 16) Tamhidi et al. (2022), Conditioned simulation of ground-motion time series at uninstrumented sites using gaussian process regression. *Bull Seismol Soc Am*, **112**, 331–347.
- 17) Paolucci et al. (2018), Broadband ground motions from 3d physics-based numerical simulations using

- artificial neural networks. *Bull Seismol Soc Am*, **108**, 1272–1286.
- 18) Okazaki et al. (2021), Simulation of broad-band ground motions with consistent long-period and short-period components using the Wasserstein interpolation of acceleration envelopes. *Geophys J Int*, **227**, 333–349.
 - 19) Pan et al. (2022), Deep-neural-network-based estimation of site amplification factor from microtremor H/V spectral ratio. *Bull Seismol Soc Am*, **112**, 1630–1646.
 - 20) Imai et al. (2021), A sample generation of scenario earthquake shaking maps via a combination of modal decomposition and empirical copula toward seismic hazard assessment. *Bull Seismol Soc Am*, **111**, 3341–3355.
 - 21) Withers et al. (2020), A machine learning approach to developing ground motion models from simulated ground motions. *Geophys Res Lett*, **47**, e2019GL086690.
 - 22) Kubo et al. (2020), Hybrid predictor for ground-motion intensity with machine learning and conventional ground motion prediction equation. *Sci Rep*, **10**, 11871.
 - 23) Okazaki et al. (2021), Monotonic neural network for ground-motion predictions to avoid overfitting to recorded sites. *Seismol Res Lett*, **92**, 3552–3564.