

# 场地类别引导的可解释性地表反应谱预测模型

钟兆诚<sup>1,2</sup>, 孙锐<sup>1,2</sup>, 郑桐<sup>1,2</sup>, 陈卓识<sup>1,2</sup>, 齐文浩<sup>1,2</sup>, 王宇<sup>1,2</sup>, 龙潇<sup>1,2</sup>

(1. 中国地震局工程力学研究所 地震工程与工程振动重点实验室, 黑龙江 哈尔滨 150080;

2. 地震灾害防治应急管理部重点实验室, 黑龙江 哈尔滨 150080)

**摘要:** 反应谱是抗震设计的重要依据, 传统数值方法的本构模型不能满足复杂场地和具有强不确定性土体动力过程的模拟, 导致计算结果与实测反应谱之间差距较大。以一维场地反应分析为背景, 从日本 KiK-net 强震台网搜集了 2428 组来自水平场地台站的基岩和地表地震记录, 将土层信息和基岩输入作为主要特征, 使用场地类别引导的分层抽样训练策略, 建立了 BO-XGBoost-SS 地表加速度反应谱预测模型。结果表明, 构建的模型具有良好的预测性能, 对地表加速度反应谱的决定系数  $R^2$  评价指标为 0.87, 各周期点的  $R^2$  均大于 0.8, 应用动态时间规整 (dynamic time warping, DTW) 的距离分析单条反应谱的预测匹配性, 模型在各类场地表现稳定, 克服了数值方法高频低估和长周期异常放大的不足。使用最新地震记录作为外部数据集, 进一步验证了模型的泛化能力。通过 (shapley additive explanations, SHAP) 解释分析特征对模型预测的贡献, 揭示了影响反应谱预测的关键特征, 各特征影响规律和现有研究成果一致。研究结果为场地反应谱预测模型的开发提供训练策略和评估指导, 为机器学习在地震区划和工程结构抗震设计中的应用提供了新思路。

**关键词:** 地表加速度反应谱; 场地类别; 机器学习; 动态时间规整; 可解释性

中图分类号: TU443; P315.9

文献标志码: A

## Interpretable prediction model of ground response spectra guided by site classifications

ZHONG Zhaocheng<sup>1,2</sup>, SUN Rui<sup>1,2</sup>, ZHENG Tong<sup>1,2</sup>, CHEN Zhuoshi<sup>1,2</sup>,

QI Wenhao<sup>1,2</sup>, WANG Yu<sup>1,2</sup>, LONG Xiao<sup>1,2</sup>

(1. Key Laboratory of Earthquake Engineering and Engineering Vibration, Institute of Engineering Mechanics, China Earthquake Administration, Harbin 150080, China; 2. Key Laboratory of Earthquake Disaster Mitigation, Ministry of Emergency Management, Harbin 150080, China)

**Abstract:** The response spectrum is a crucial foundation for seismic design. The constitutive models of traditional numerical simulation methods fail to adequately capture the complex site conditions and dynamic processes of soil with high uncertainty, which causes significant discrepancies between calculated and measured response spectra. This paper used 2428 sets of bedrock and surface seismic records from horizontal site stations by KiK-net in Japan. It established a BO-XGBoost-SS model for predicting ground acceleration response spectra, taking soil layer information and bedrock input as primary features through a stratified sampling training strategy guided by site categories. Results demonstrate that the constructed model exhibits good predictive performance, with an  $R^2$  evaluation metric of 0.87 for surface acceleration response spectrum, with  $R^2$  values above 0.8 for various periods. Applying dynamic time warping (DTW) distance analysis to assess the prediction match of individual response spectrum, the model proposed shows stability across different site categories, overcoming the deficiencies of numerical methods in underestimating high-frequency ground motion and anomalously amplifying long-period

收稿日期: 2024-08-29; 修回日期: 2024-09-25

基金项目: 中国地震局工程力学研究所基本科研业务费专项资助项目 (2024B04); 黑龙江省自然科学基金联合引导项目 (LH2023E021); 国家自然科学基金资助项目 (51808515)

作者简介: 钟兆诚 (1999—), 男, 硕士研究生, 主要从事岩土地震工程研究。E-mail: zzep0pp1p@163.com

通信作者: 郑桐 (1984—), 男, 副研究员, 博士, 主要从事岩土地震工程研究。E-mail: zhengt0928@163.com

response spectrum. Validation with the latest ground motion records as an external dataset further confirms the model's generalization ability. Through shapley additive explanations (SHAP) analysis, the contributions of features to model predictions are elucidated, revealing key features influencing response spectrum predictions, consistent with existing knowledge. The study's findings provide training strategies and assessment guidance for the development of site response prediction models, offering new insights into the application of machine learning in seismic zoning and earthquake-resistant design of engineering structures.

**Key words:** ground acceleration response spectrum; site category; machine learning; dynamic time warping (DTW); explainability

## 0 引言

历次地震事件表明,不同类型的场地对震害的影响存在显著差异<sup>[1]</sup>。反应谱直观地反映了地震动的动力特性,是表征地震工程设计和抗震设防水平的重要参数。场地反应分析通常借助地表加速度反应谱研究特定场地在地震事件中的频谱特性和振幅放大效应。然而,面对地震动的不确定性和土体复杂性,准确预测未来地震中局部场地响应仍是岩土地震工程领域面临的挑战之一。

可以通过统计分析实际强震资料来研究场地条件对地震动特性的影响<sup>[2-3]</sup>,但这需要大量可靠的强震记录作支撑,仅适用于定性分析特定场地。数值分析方法仍是目前最主要的研究手段,也是地震安全性评价、重大工程抗震设计等工作的重要内容<sup>[4-5]</sup>。如我国 GB 17741—2005《工程场地地震安全性评价》<sup>[6]</sup>中规定场地反应采用数值方法计算,但分析模型具体采用什么方法在规范中并没有规定和说明。在无复杂地形的情况下,一维场地反应分析方法基本能够模拟横波在土体中的垂直传播,进而计算得到地表反应谱并供结构抗震设计使用<sup>[7]</sup>。常用的方法分为频域等效线性化方法<sup>[8]</sup>和时域非线性方法,研究人员基于这些方法编制了许多程序并被广泛应用,如 SHAKE<sup>[9]</sup>、LSSRLI-1<sup>[10]</sup>和 DEEPSOIL<sup>[11]</sup>等。普遍认为一维场地反应分析方法都可以很好地估计小型地震情况下的场地响应,但对于大应变和高频条件下的计算存在显著差异。在最近十年中,已有研究者<sup>[12-17]</sup>针对美国和日本的垂直阵列台站开展了大量验证性研究,研究表明无论是等效线性化方法还是非线性方法,在总体上普遍低估了高频地面运动,这无疑挑战了一维场地分析方法的适用性。可以通过考虑更复杂的三维建模、非线性行为模拟或多向地震动的耦合效应<sup>[18]</sup>等来克服这些限制,然而工程实践很少提供计算资源和专业知识,实际应用中并未普及。总之,数值模拟方法通常需要详细了解物理过程,并假设特定形式的本构。然而实际场地具有较强的不确定性,模拟土壤非线性响应需要丰富的分析经验。特别是在软土地地和强震动下,这些常用方法对地面峰值加速度(peak ground acceleration, PGA)的低估较为明显,与实测反应谱有较大偏差。

数据驱动的机器学习算法在减少对本构形式假设依赖方面展示出显著优势,已成为解决复杂工程和非线性问题的有效工具。随着真实记录的不断积累,机器学习也被应用于地震工程领域,如地震预警和地震动参数预测等方面<sup>[19-22]</sup>。DANG 等<sup>[21]</sup>以震级、震源深度、震中距、 $V_{s30}$ 、场地海拔和震源机制为特征参数,开发了基于 XGBoost 的日本地震动预测方程,所提模型能很好地反映日本地震动衰减情况。DERRAS 等<sup>[22]</sup>利用 KiK-net 台网的基岩谱加速度和对应周期开发了人工神经网络推导的地表反应谱预测模型。该模型未考虑土层参数,适合作为利用井下记录预测地表响应的快速计算工具。LI 等<sup>[23]</sup>通过有限元模型计算的土柱地震响应数据库,验证了所提出的深度学习模型的可行性,并使用 KiK-net 中台站 IBRH13 记录的地面运动数据进一步构建了该台站地震反应预测模型。该研究仅分析了单个台站的场地反应,考虑震源参数而忽略了该地点的土层信息,在适用性方面存在局限。综合上述,当前大多数地表反应谱预测模型的研究侧重于预测地震动在不同频率下的衰减关系,但对局部场地条件的影响及地震动频率成分的综合考虑尚显不足。如何有效利用井下记录和局部场地信息,构建准确且具备适用性的地表反应谱预测模型成为当前研究的关键焦点。

本研究建立了一种融合贝叶斯优化的可解释性 XGBoost 地表反应谱预测模型,应用于一维场地分析中。首先,筛选了 43 个来自日本 KIK-net 强震台网符合水平场地条件的台站,并从中下载真实地震动记录和土壤信息(波速剖面、土层厚度等)。根据一系列标准和专业知识的提取训练特征和输出标签。在模型训练阶段,为了解决数据集中场地特征的潜在不平衡,使用场地类别为标签的分层抽样策略并结合高斯过程的贝叶

斯搜索来优化模型。最后,模型评估阶段比较了机器学习算法与等效线性方法、非线性方法的计算结果,综合了统计分析、单条反应谱的定量分析和 SHAP 解释,构成模型预测全过程的可靠评价体系,为岩土工程领域的地震响应分析提供重要的技术支持和应用价值。

## 1 方法介绍

### 1.1 机器学习模型

XGBoost<sup>[24]</sup>和随机森林(random forest, RF)<sup>[25]</sup>分别是基于提升和装袋的集成学习算法。初步使用这 2 种算法开展训练,将 20%的数据集划分为测试集,剩余 80%的数据用于训练目标函数。在定义机器学习超参数范围后,使用十折交叉验证构建目标函数。

JAS 等<sup>[26]</sup>指出,混合机器学习框架具有训练优势,主要体现在优化算法和特征工程技术。本文采用基于高斯过程的贝叶斯优化算法(Bayesian optimization, BO)进行超参数调优,通过建立目标函数的高斯过程模型来寻找下一步的超参数组合,并根据新的样本点更新高斯过程模型,重复前述步骤直到达到停止条件<sup>[27]</sup>。实际问题往往是非凸函数,网格搜索和随机搜索训练耗时长且容易陷入局部优解,而贝叶斯优化能够在更短的时间内找到更好的结果。统一将混合贝叶斯优化的模型称为 BO-ML(machine learning with Bayesian optimization),本文模型均基于该框架进行训练,如 BO-XGBoost,BO-RF。

### 1.2 基于动态时间规整的反应谱匹配分析

动态时间规整(dynamic time warping, DTW)方法通过计算最优映射之间的距离(如欧式距离)来评价 2 个时间序列之间的相似程度,其最早用于语音信号识别和分类<sup>[28]</sup>。通常 DTW 距离越小,相似度越高。反应谱为频域序列,其频域特性在结构动力学中具有物理解释。DTW 并未直接考虑频域响应的特性,但仍然可以利用其非线性时间对齐性质来评价预测反应谱与真实反应谱之间的匹配程度,刘浩等<sup>[29]</sup>以 DTW 距离作为控制加速度反应谱与目标设计谱匹配程度的标准参数。

本文采用 DTW 距离来定量评价预测反应谱与实测反应谱的差距。DTW 路径矩阵见图 1<sup>[30]</sup>,矩阵中的色块代表距离,红色向深蓝色渐变即由近及远;白色实线为最优映射组成的路径,称为规整路径,需满足 2 个条件:首先,反应谱具有周期先后顺序,规整路径从左下角计算至右上角的过程中不应出现跳跃对应现象;其次,路径中的某元素和路径的下一点都随着时间轴单调进行,保证映射线不出现交叉现象。DTW 距离即  $D(m, n)$  可由式(1)递推得到:

$$D(m, n) = \begin{cases} d(p_1, q_j) + D(1, j-1), & i = 1 \\ d(p_i, q_1) + D(i-1, 1), & j = 1 \\ d(p_i, q_j) + \min(D(i-1, j), D(i-1, j-1)), & i \neq 1 \text{ 且 } j \neq 1 \end{cases} \quad (1)$$

式中: $d(p_i, q_j)$ 和  $D(i, j)$ 分别为反应谱 P 的第  $i$  点和反应谱 Q 的第  $j$  点之间的误差值和累积误差值。由于自振周期体系的响应相互独立,DTW 路径矩阵给出的路径越接近对角直线,则预测反应谱越规整。

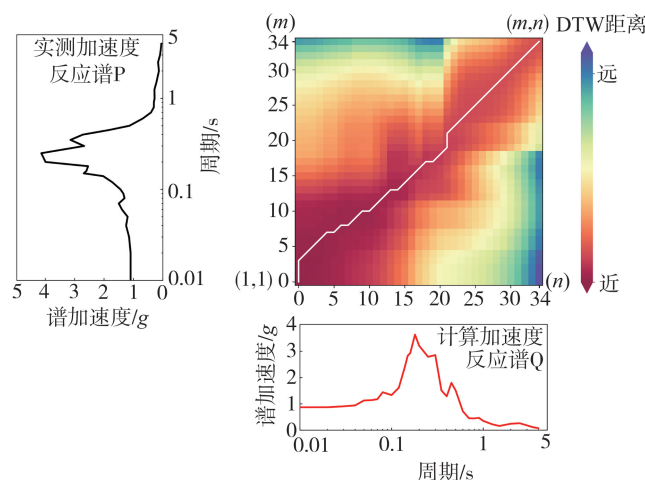


图 1 DTW 算法规整路径示意图

Fig. 1 Schematic diagram of the path of DTW algorithm

### 1.3 统计评估指标

采用均方误差(mean squared error, MSE)、决定系数( $R^2$ )和可解释方差( $E_{\text{var}}$ )作为预测结果的统计评价指标。3个指标的表达式分别为

$$\text{MSE}_T = \frac{1}{n} \sum_{i=1}^n (\hat{y}_{T_i} - y_{T_i})^2 \quad (2)$$

$$R_T^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_{T_i} - y_{T_i})^2}{\sum_{i=1}^n (\bar{y}_{T_i} - y_{T_i})^2} \quad (3)$$

$$E_{\text{var}T} = 1 - \frac{\text{var}(\hat{y}_{T_i} - y_{T_i})}{\text{var}(y_{T_i})} \quad (4)$$

式中: $T$ 为周期点; $n$ 为样本数量; $y_{T_i}$ 为样本点真实值; $\hat{y}_{T_i}$ 为样本点预测值; $\bar{y}_{T_i}$ 为真实值的平均。最终的评估指标为35个周期点统计结果的平均值,记为

$$\text{MSE} = \frac{1}{35} \sum_{T=1}^{35} \text{MSE}_T \quad (5)$$

$$R^2 = \frac{1}{35} \sum_{T=1}^{35} R_T^2 \quad (6)$$

$$E_{\text{var}} = \frac{1}{35} \sum_{T=1}^{35} E_{\text{var}T} \quad (7)$$

## 2 数据预处理

### 2.1 数据集建立和特征选取

使用Python编程语言以及Jupyter Notebook这一交互式计算环境,来进行机器学习实验和数据分析。本文在数据预处理阶段实现了对原始数据的统一处理和参数提取工作。具体而言,包括利用快速傅里叶变换获取卓越频率、采用Nigam-Jennings<sup>[31]</sup>法输出地表反应谱、提取地震动参数等操作。同时,利用土层波速剖面资料编写符合规范的程序,统一获取场地卓越周期、场地类别和剪切波速等场地信息。

KiK-net强震台网遍布日本全岛,每个台站在井上和井下安装有三分量的高灵敏加速度传感器<sup>[32]</sup>。本文以一维水平场地为研究对象,不考虑地形放大效应,选取43个建设在水平场地的台站,从1996年3月1日至2016年11月1日<sup>[33]</sup>的记录中选取基岩和地表的2428对水平向加速度记录,过滤掉PGA小于0.01g的小震,尽可能纳入所有PGA大于0.1g的记录。在0~4.0s区间按对数距离均匀地选取35个谱周期,作为模型的预测周期点。根据我国GB 50011—2010《建筑抗震设计规范》<sup>[34]</sup>中的标准划分场地类别,地震动记录分布见图2,据统计,约60.2%的PGA分布在0.05~0.4g,而大于0.4g的强震记录占7.0%;台站所在场地均含覆盖土层,II、III、IV类台站数量比例为6:29:8,地震记录占比分别为40.36%、48.11%、11.53%。

输入特征包含场地及地震动特性表征参数,即输入峰值基岩加速度(peak bedrock acceleration, PBA)、输入地震动卓越频率、场地覆盖层厚度<sup>[34]</sup>、埋置深度、地表剪切波速、基岩剪切波速、等效剪切波速<sup>[34]</sup>。剪切波速能够代表场地土的刚性,等效剪切波速通过土层剪切波速和厚度计算而得。在进行场地地震反应分析时,常考虑地震波入射时土层与基岩面处的系数和近地表的土层状况<sup>[35]</sup>,因而加入基岩剪切波速和地表剪切波速。埋置深度为实际输入地震动深度。

高度相关的特征对输出有类似的作用,可能降低模型的效率和可解释性<sup>[36]</sup>。因此需检查特征间的相关性,Pearson相关系数定义为




图2 地震动记录分布

Fig. 2 Distribution of ground motion records

$$R = \rho(X, Y) = \frac{\text{COV}(X, Y)}{\sigma_X \sigma_Y} \quad (8)$$

式中:分子为随机变量  $X$  和  $Y$  之间的协方差;分母为随机变量  $X$  和  $Y$  的标准差之积。

所建立数据集的散点图矩阵为 Pearson 相关系数,见图 3。由图可知,7 个特征之间保持较低的 Pearson 相关性,没有明显的线性趋势。峰值基岩加速度的分布范围在  $0 \sim 0.3 g$  之间;覆盖层厚度的分布范围为  $0 \sim 260 m$ ;卓越频率的分布范围在  $0 \sim 24 Hz$  之间,小于  $5 Hz$  的数据约占  $65\%$ ;等效剪切波速的分布范围在  $90 \sim 330 m$ ,  $100 \sim 250 m$  之间的数据约占  $86.5\%$ 。

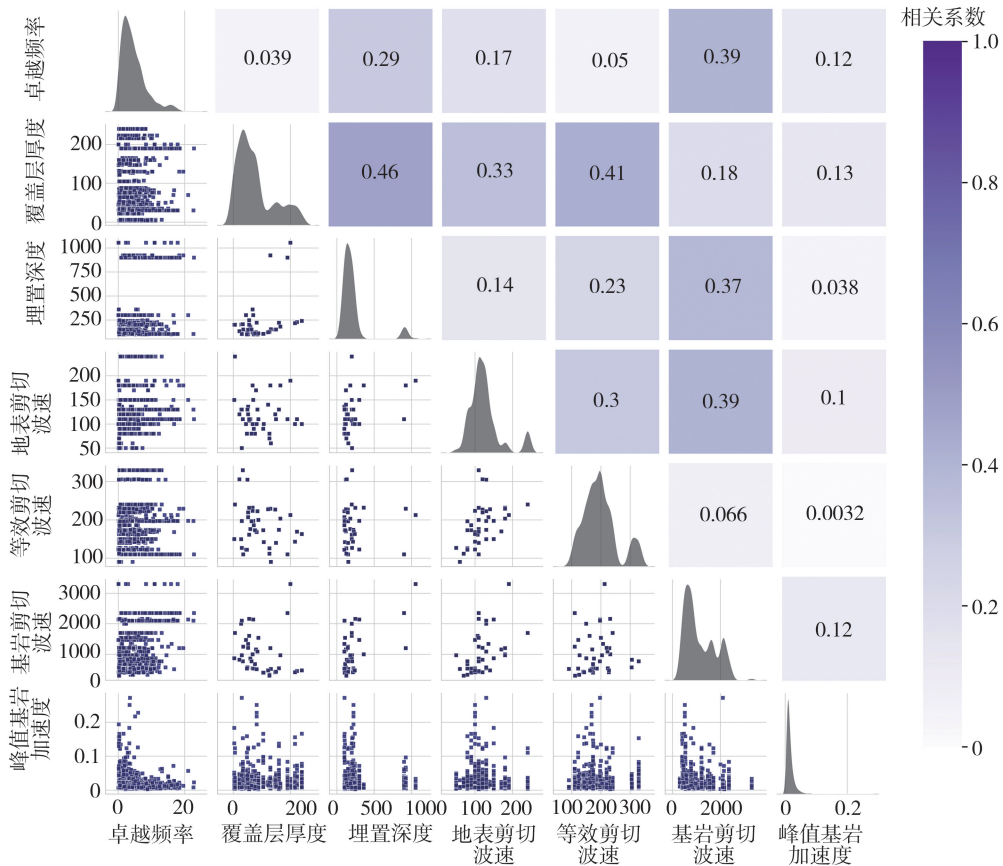


图 3 数据集的散点图矩阵

Fig. 3 Scatter plot matrix of the dataset

### 2.2 基于场地类别的分层抽样训练策略

对于数据驱动模型,领域知识的加入在特征筛选和数据集不平衡问题的处理上尤为重要,同时能够提升模型的性能,并增强其可解释性。在实际应用中,类别不平衡可能会导致模型对样本数量较少的类别进行欠拟合,从而影响模型的泛化能力。类别不平衡问题通常在分类任务中出现,然而,本文在构建地表反应谱预测模型时发现类似问题,所使用台站数据来自不同场地,对于地震动响应存在差异,场地信息在数据子集上的不均匀分布将导致训练的偏差,使得模型可能会更倾向于优化对于较多类别的性能,而忽略较少类别的表现。以输入特征的取值范围作为划分标签,无法得到统一的数据划分。场地类别能够综合考虑土层剪切波速和土层厚度的差异,而不同场地类别对地震动的放大效应及结构的破坏又具有重要影响。因此,使用场地类别作为输入以外的特征纳入模型,引导模型捕捉不同场地条件下,特征与反应谱之间的预测规律,从而改善模型预测性能。

在交叉验证中,数据集通常被划分为多个子集,其中一个子集被保留用于测试模型,其余子集用于训练模型<sup>[37]</sup>。通过重复执行交叉验证过程,可以获得对模型性能的稳健估计。同样,本文在模型训练阶段采用以场地类别为标签的分层十折交叉验证(stratified 10-fold cross validation, Str 10-Fold CV),以提升模型评估的稳定性。

综上所述,本文按照 8:2 的比例将原始数据分层随机抽样为训练集与测试集,然后按场地类别使用分层十折交叉验证进行模型调优,以此形成一种由场地类别引导分层抽样(stratified sampling by site category, SS)的训

练策略。在这个过程中,目标函数设定为均方误差(MSE),并利用高斯贝叶斯搜索来找到最优的超参数组合。平行坐标图见图4,展示了模型经200次迭代的优化过程,目标函数逐渐向左下方收敛,取得训练的最优超参数组合,将最终所得模型命名为BO-XGBoost-SS(XGBR为XGBoost regressor)。

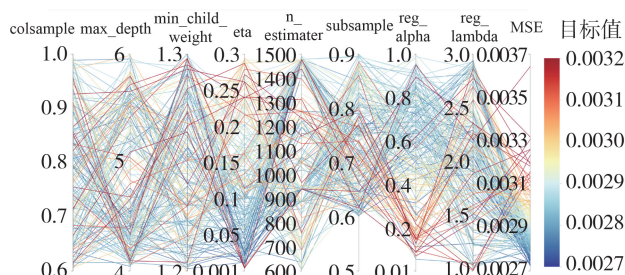


图4 目标函数在200次贝叶斯搜索中的演化

Fig.4 Evolution of the objective function during the 200 iterations of Bayesian optimization

### 3 预测结果分析

#### 3.1 模型输出结果


本文模型与2种机器学习方法的统计比较见表1,其中BO-XGBoost和BO-RF使用简单随机划分和十折交叉验证进行训练。由表1可知,BO-RF在训练集上的MSE、 $R^2$ 都较好,但在交叉验证和测试集上的表现却比BO-XGBoost差,这表明XGBoost对于本文的反应谱多输出预测任务中具有更好的预测能力,其超参数涉及到采样和正则化,具有更精细的超参数范围,因而本研究选择了XGBoost算法进行进一步的优化。3种方法在训练集上的可解释方差均为1,这表明模型的预测能力可以解释训练集中所有的变异性。而 $R^2$ 均在0.93~0.95之间,模型在训练集上的拟合程度较高;对于测试集,BO-XGBoost-SS的各统计指标均优于BO-RF和BO-XGBoost,MSE最小,且总体 $R^2$ 大于87%;在交叉验证结果中,BO-XGBoost-SS的MSE最低,是三者中最优的模型。

表1 超参数调优结果对比

Table 1 Comparison of hyperparameter tuning results

算法		BO-RF	BO-XGBoost	BO-XGBoost-SS
超参数			n_estimators = 699	n_estimators = 1049
		n_estimators = 978	learning_rate = 0.025	learning_rate = 0.01073
		max_depth = 12	max_depth = 4	max_depth = 5
		max_features = 7	min_child_weight = 1.262	min_child_weight = 1.242
交叉验证	策略	10-fold CV	10-fold CV	Str 10-fold CV
	MSE	0.004 10	0.003 35	0.002 72
	$R^2$	0.947 19	0.933 90	0.938 26
	MSE	0.000 81	0.001 05	0.001 03
测试集	$E_{var}$	1	1	1
	$R^2$	0.818 09	0.831 97	0.875 70
	MSE	0.003 50	0.003 15	0.002 53
	$E_{var}$	0.818 58	0.832 26	0.875 80

为了进一步分析本文模型的泛化性能,训练集和测试集在各输出周期点的 $R^2$ 对比见图5。BO-XGBoost的预测结果在某些输出的准确度出现了较为明显的下降,特别是在中长周期段的拟合程度较差,其测试集上的 $R^2$ 低于60%,与训练集结果差距较大,存在明显的过拟合。而本文BO-XGBoost-SS模型由于加入了场地类别的引导,有效地改善了总体泛化误差,各输出在测试集上的决定系数均大于80%,对比BO-XGBoost的 $R^2$ ,长周期段的提升在5%~30%之间。



(a) 训练集与测试集的拟合结果对比

(b) 优化后的测试集 $R^2$ 增幅

图 5 不同周期点决定系数  $R^2$  对比

Fig. 5 Comparison of determination coefficient  $R^2$  at different period points

### 3.2 残差分析

残差蕴含了模型基本假设的重要信息,在回归模型正确的情况下可将残差看作误差的观测值。本文选择 0.01、0.50、1.00 s 这 3 个周期点进行残差分析,为了使不同范围的误差更加平衡,减小异常值影响,本文使用对数残差,公式为

$$\delta = \ln(y) - \ln(\hat{y}) \tag{9}$$

式中,  $y$  和  $\hat{y}$  分别为真实值和预测值。

为了进一步验证所提出模型的性能,加入 SHAKE2000 和 DEEPSOIL 比较数值计算结果。所有方法分布于区间  $(-2, 2)$  的残差均在 99% 以上,而分布于区间  $(-1, 1)$  的残差,BO-XGBoost-SS、SHAKE2000 和 DEEPSOIL 分别为 94.2%、92.4%、92.4%。在  $T=0.01$  s 时,BO-XGBoost-SS 的残差较数值方法小,且全部分布于区间  $(-1, 1)$ ,见图 6;数值方法较 BO-XGBoost-SS 的残差在长周期内出现发散现象,且在图 6 中展示的部分数值方法的残差显示明显的负向偏移,说明 SHAKE2000 和 DEEPSOIL 在长周期存在高估的现象。BO-XGBoost-SS 的残差保持在 0 附近均匀分布,平均值趋近于 0。各方法预测结果的残差概率密度,BO-XGBoost-SS 的残差基本在 0 附近随机分布,符合正态性,而数值方法的残差在中长周期处(如图 7 中  $T=0.5$  s、 $T=1.0$  s 对应的结果)明显向基线左侧偏斜,呈一定的偏态分布,存在一定系统误差,不符合正态性和零均值的特点。

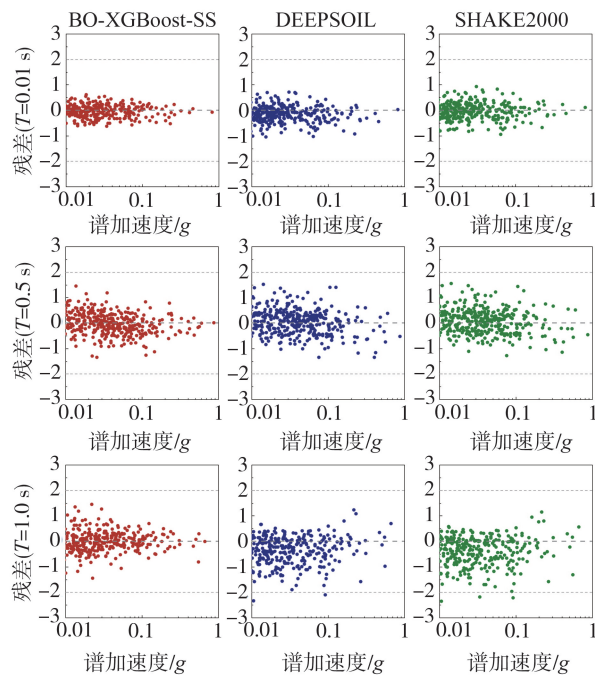


图 6  $T$  为 0.01、0.5、1.0 s 预测结果的对数残差

Fig. 6 Log residuals of the prediction results for  $T$  at 0.01, 0.5, 1.0 s




图 7  $T$  为 0.01、0.5、1.0 s 残差概率密度图对比

Fig. 7 Comparison of residual probability density graph for  $T$  at 0.01, 0.5, 1.0 s

### 3.3 单条预测反应谱的定量评估

以上均方误差等指标仅在统计平均意义上对各输出结果进行评价,往往忽略了物理含义。因此,还需对

单条预测反应谱进行评价。本文对数据集中所有地震动记录的预测结果进行了 DTW 距离的统计分析,见表 2。总体上,XGBoost 算法的 DTW 均值和方差均更小,优于随机森林算法。而 BO-XGBoost-SS 模型优于 BO-XGBoost 模型,其 DTW 均值更低且方差较小,表现稳健。不同场地类别对应的预测结果显示,无论是哪类场地,本文的 BO-XGBoost-SS 模型均优于其他 2 种模型,且各类场地的 DTW 的均值和方差相差不大,比较均衡。3 种方法的 DTW 值均随 PGA 的增大而增大,但 BO-XGBoost-SS 算法的 DTW 最小。

不同场地类别下的平均放大系数谱,机器学习模型在所有情况下都优于数值方法见图 8,可以看到数值方法容易高估长周期段的地震反应,且对于反应谱卓越周期的预测存在偏差,机器学习方法则克服了以上问题。由图 8 可知,数值方法在短周期段的表现比中长周期段更好,相比之下,BO-XGBoost-SS 在全周期段、全类别场地均表现良好,展示了机器学习模型较好的预测能力。

表 2 DTW 统计结果对比

Table 2 Comparison of DTW statistical results

方法与 DTW 总体结果	类别	DTW 统计指标		
		均值	方差	
BO-RF 均值:0.8254 方差:0.6450	场地类别	II	0.8235	0.9000
		III	0.8170	0.5190
		IV	0.8658	0.2917
	PGA 范围	$[0.01,0.05)g$	0.5238	0.0437
		$[0.05,0.1)g$	0.6910	0.1064
		$[0.1,1.1)g$	1.9424	2.1817
BO-XGBoost 均值:0.8106 方差:0.5849	场地类别	II	0.8132	0.7594
		III	0.7738	0.4640
		IV	0.9501	0.4585
	PGA 范围	$[0.01,0.05)g$	0.5053	0.0461
		$[0.05,0.1)g$	0.6872	0.1021
		$[0.1,1.1)g$	1.9030	1.8620
BO-XGBoost-SS 均值:0.7629 方差:0.3844	场地类别	II	0.8070	0.4782
		III	0.7129	0.3266
		IV	0.8040	0.3028
	PGA 范围	$[0.01,0.05)g$	0.4742	0.0510
		$[0.05,0.1)g$	0.7041	0.1233
		$[0.1,1.1)g$	1.6974	0.9163

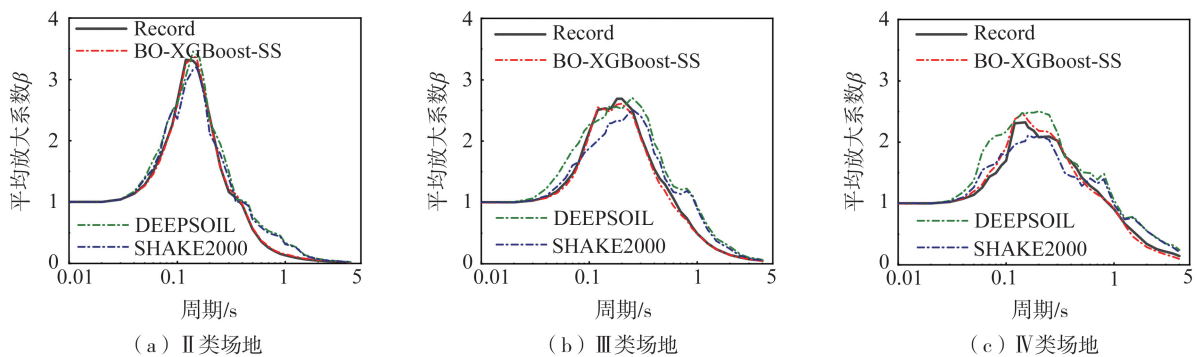


图 8 不同场地类别的放大系数谱平均预测结果

Fig. 8 Average prediction results of amplification coefficient for different site categories

测试集中选出的 6 条代表性记录,对比了以上所有方法的预测结果,BO-XGBoost-SS 的预测结果与实测反应谱非常接近,而其他方法在不同周期点的预测存在不同程度的变化,见图 9。由图 9 可知,机器学习方法的预测是较为准确的,数值方法对于卓越周期附近的预测存在明显偏差,而长周期段总是有异常凸起。从图 9 的大震记录中可以看出,各类方法对于卓越周期前的预测偏向低估,BO-XGBoost-SS 的匹配程度是最好的。从所有结果可以看出,SHAKE2000 对于短周期内的响应接近恒定,这是等效线性化方法无法重现更高频率的响应所造成的。总的来说,数值方法容易高估长周期成分,而对于高频下的响应总是偏向低估,特别是对于 IV 类软土场地的预测结果较差,机器学习的预测则很好的改善了以上问题。

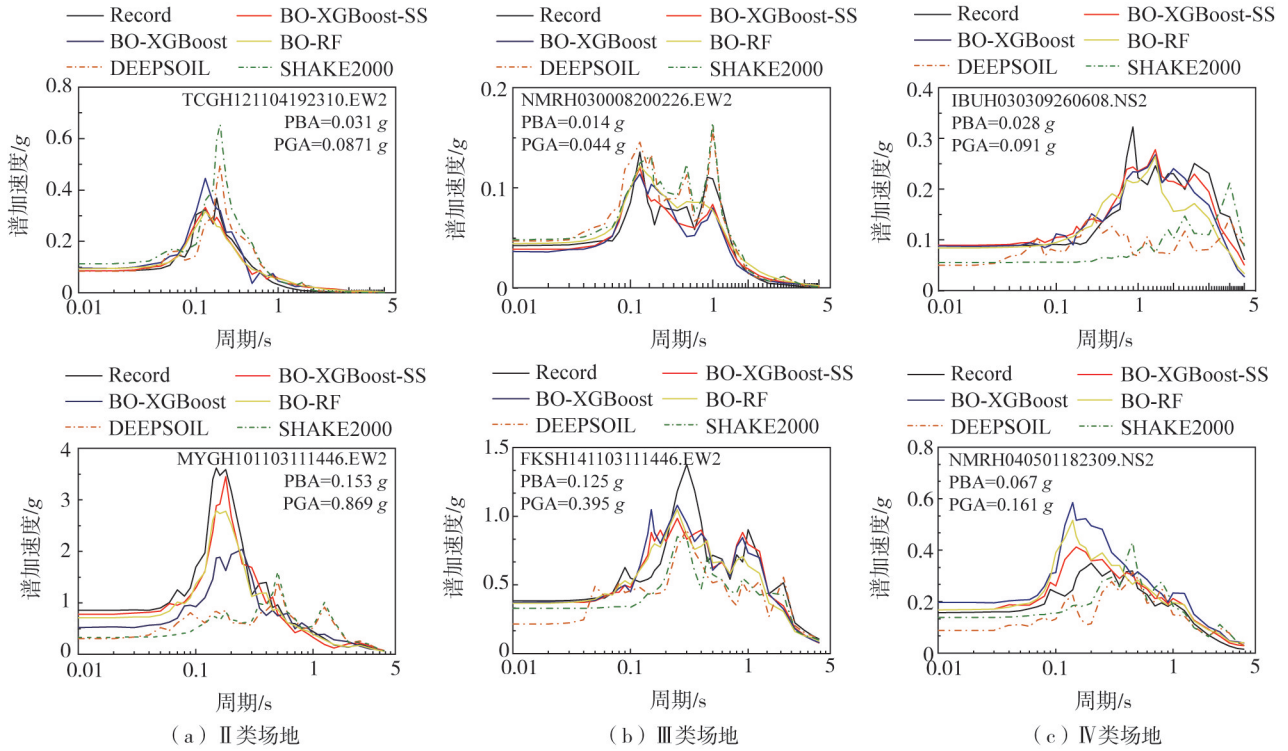


图 9 典型实例的反应谱预测对比

Fig. 9 Comparison of response spectrum predictions for typical examples

## 4 模型适用性与可解释性分析

### 4.1 泛化能力检验

BO-XGBoost-SS 在数据集划分上加入了场地类别的引导,使用了不同的数据子集。为了进一步统一比较,选取了 KiK-net<sup>[33]</sup> 上 2020—2023 年大于 0.05 g 的 180 条最新地震动数据作为外部数据集。表 3 为 3 种方法预测结果的统计,BO-XGBoost-SS 总体  $R^2$  保持在 80% 以上,且 MSE 和  $DTW_{mean}$  均较小,表明泛化能力更好。图 10 为其中较大地震记录的预测结果,BO-XGBoost-SS 对于各类场地预测结果的 DTW 值均较小,且 DTW 路径矩阵更加规整。

表 3 外部数据集预测结果

Table 3 Prediction results of the external dataset

评估指标	BO-XGBoost	BO-XGBoost-SS
$R^2$	0.7520	0.8100
MSE	0.0263	0.0183
$DTW_{mean}$	1.5210	1.2650

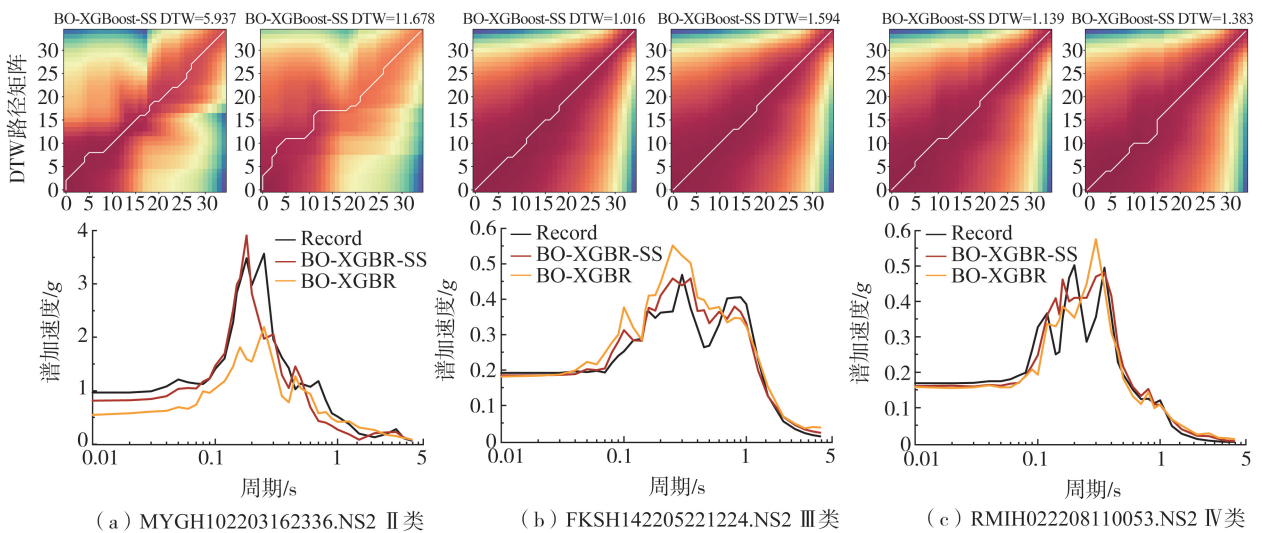


图 10 验证集的反应谱预测结果对比

Fig. 10 Comparison of response spectrum prediction results for validation sets

## 4.2 全局解释与特征依赖性分析

Shapley additive explanations (SHAP) 是由 LUNDBERG 等<sup>[38]</sup> 开发并被广泛应用的可解释算法之一,旨在使黑盒模型更具可解释性。该方法基于联盟博弈论<sup>[39]</sup>,通过计算每个特征对预测结果的贡献值来衡量特征对结果的影响,特征在模型中的作用越大,贡献值的绝对值越大,特征重要性越高。

各周期点的预测结果的平均 SHAP 绝对值见图 11。由图可知,2 个数据子集上的特征重要性极为一致,这表明模型在训练集上学到的特征重要性较好地泛化到了测试集上。从图 10 中的特征贡献可以看出峰值基岩加速度始终是贡献最大的特征,卓越频率的重要性则是随周期的增加越来越重要。对于场地特征,覆盖层厚度在 0~0.25 s 呈现为第二重要特征,基岩剪切波速在短周期较为重要,等效剪切波速在  $T=0.4$  s 后较为重要。

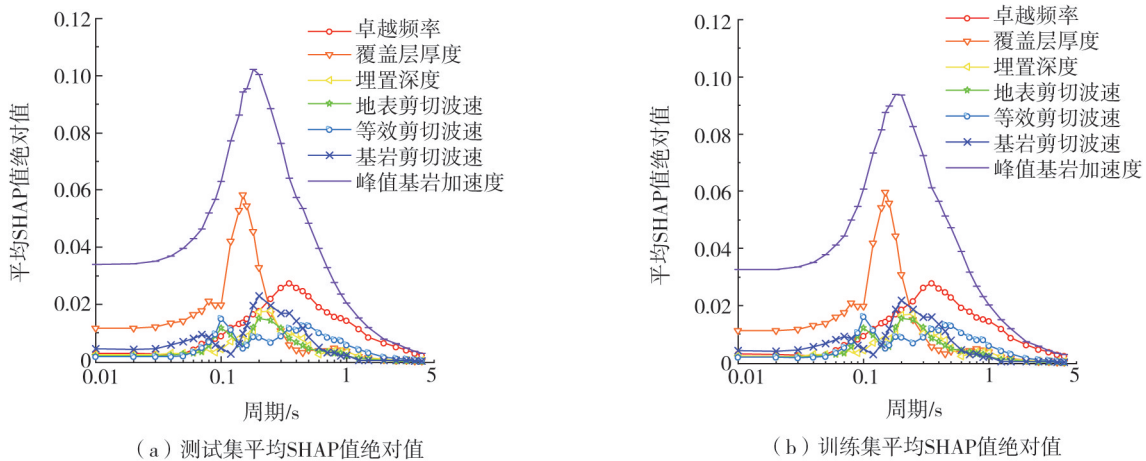



图 11 所有周期点的特征平均 SHAP 绝对值

Fig. 11 Mean(|SHAP value|) of features for all period points

本文选用 0.01、0.5、1.0 s 这 3 个周期点的结果,分析了单因素的特征 SHAP 依赖关系,见图 12。由图 12(a)可知,对于各个周期,当峰值基岩加速度小于 0.02 g 左右时,SHAP 值小于 0,对预测结果有负向影响,峰值基岩加速度大于 0.02 g 左右时,SHAP 值大于 0,对预测结果有正向影响,且随着峰值基岩加速度的增大,SHAP 值也随之增大,表明不同周期的谱加速度均随峰值基岩加速度的增大而增大。由图 12(b)可知,各周期下的卓越频率的最大 SHAP 值均出现在该输入地震动卓越频率相对应的谱周期,  $T=0.5$  s 集中在 2 Hz 而  $T=1.0$  s 集中在 1 Hz,此时对预测结果的正向作用最大,和现有研究成果一致,即当输入地震动的卓越频率与场地基本周期相近时,易产生共振现象,使场地放大效应更明显,而输入地震动的卓越频率与场地基本周期相差较大时,避免了共振现象的发生,降低了场地放大效应。由图 12(c)可知,在反应谱周期较长时覆盖层厚度的 SHAP 值较小,对预测结果贡献较小;在短周期时,随覆盖层厚度的减小,其 SHAP 值逐渐增大,特别是当覆盖层厚度小于 30 m 时,SHAP 值基本为正值,即对谱加速度的预测起增大作用,即覆盖层较薄时,对高频放大较明显。由图 12(d)可知,随着等效剪切波速的增大,SHAP 值有变小的趋势,特别是在反应谱中长周期。当等效剪切波速小于 150 m/s 时,其 SHAP 值基本为正,即对预测结果起正向作用,表明场地越软,基本频率越低,越易在长周期段产生共振现象,对长周期段的反应谱的放大效应越明显,反之亦然。由图 12(e)可知,随着基岩面剪切波速的增大,其 SHAP 值逐渐增大,在波速约 800 m/s 附近由负转正,且随着波速的增大,SHAP 值增大的幅度减小,说明随着基岩剪切波速越大,地表水平峰值加速度和谱加速度有增大趋势。由图 12(f)和(g)可知,地表剪切波速和埋置深度的 SHAP 值均小于前面几个特征的 SHAP 值,二者的影响相对较小,总体来看,SHAP 值均有随地表剪切波速和剖面深度增大而减小的趋势。



(a) 峰值基岩加速度 SHAP 值

(b) 卓越频率 SHAP 值

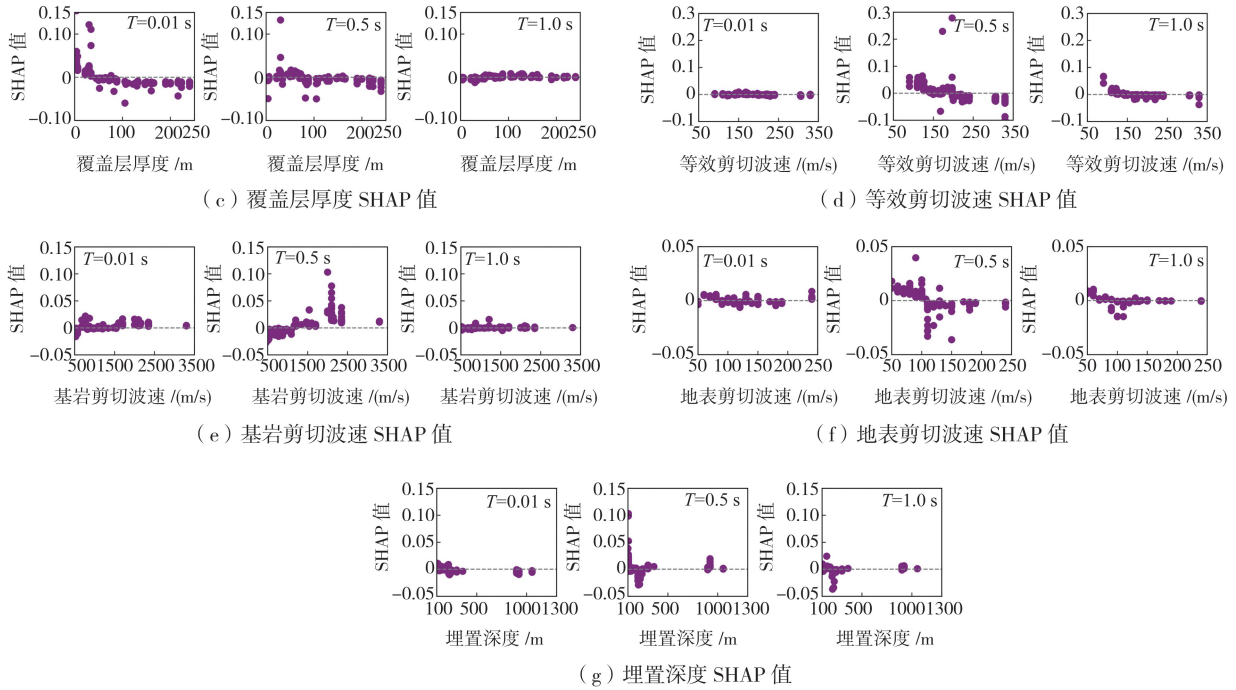


图 12 单因素 SHAP 特征依赖图

Fig. 12 Single factor SHAP feature dependence plot

## 5 结论与展望

本文利用日本 KIK-net 强震台网数据,将机器学习方法应用于场地反应分析,提出了一种场地类别引导的可解释性地表加速度反应谱预测模型 BO-XGBoost-SS,应用于—维场地反应分析中,得到以下结论:

1) 综合考虑场地特征与地震动参数,选取了峰值基岩加速度、卓越频率、覆盖层厚度、埋置深度、地表剪切波速、基岩剪切波速、等效剪切波速 7 个参数作为输入特征;利用高斯过程的贝叶斯方法优化模型,实现了高效超参数搜索。BO-XGBoost-SS 模型使用场地类别引导分层抽样的训练策略,有效改善了场地信息在数据子集上的不均匀分布导致的训练偏差,总体决定系数大于 87.5%,各周期点的  $R^2$  均超过 80%,相较于 BO-XGBoost 整体提升约 4.4%,预测 PGA 的  $R^2$  值达到了 95.3%,而对于长周期段的提升幅度在 5%~30% 之间;与数值方法相比,BO-XGBoost-SS 模型能够克服低估 PGA、高估反应谱长周期的不足。

2) 运用动态时间规整算法定量评估预测反应谱与实测值的匹配性,BO-XGBoost-SS 模型对于 3 种类型场地的预测结果较为平衡,特别是对大于 0.1 g 的强地震动的 DTW 统计结果最小且方差较数值模拟方法有显著降低,预测结果稳健。

3) 使用 2020—2023 年的最新地震动记录作为外部数据集,BO-XGBoost-SS 模型的所有统计结果均优于 BO-XGBoost,总体  $R^2$  在 80% 以上,且在 DTW 矩阵中的路径更加规整,再一次验证了模型良好的泛化能力。利用 SHAP 对模型的预测机理进行后置解释,结果表明 PBA 是影响反应谱预测结果的第一特征,卓越频率、等效剪切波速和覆盖层厚度也有较重要影响。SHAP 值对预测结果的解释与现有认识一致,进一步说明了模型预测结果的可靠性。

综上所述,机器学习方法在场地反应谱预测中展现了较高的可行性和应用前景。在整体样本范围内,机器学习模型能够有效克服常见的预测偏差,表现出良好的稳健性和泛化能力,为场地反应分析提供了创新性的解决方案。然而,安全评估关乎生命与财产安全,任何新方法在广泛应用前,都必须经过严格的验证。现阶段,机器学习模型仍主要作为一种探索性工具。在本文的研究中,数据集主要针对水平场地,以便与—维土层反应数值模拟结果进行对比,因此,模型并不适用于复杂场地条件。未来的工作将扩展数据集,考虑不同地形因素的影响,力求构建更加通用的地震反应预测模型。此外,进一步挖掘 Kik-net 数据,基于台站构建更加多样化的数据集,将是模型优化和验证的重要方向。

## 参考文献:

- [1] IDRISSE I M, SEED H B. An analysis of ground motions during the 1957 San Francisco earthquake[J]. Bulletin of the Seismological Society of America, 1968, 58(6): 2013-2032.
- [2] 李爽, 吕悦军, 方怡, 等. 北京地区中硬场地对地震动加速度反应谱的放大效应研究[J]. 震灾防御技术, 2017, 12(1): 133-144.  
LI Shuang, LV Yuejun, FANG Yi, et al. Seismic amplification effect on seismic acceleration response spectrum of medium-stiff soil site in the Beijing Region[J]. Technology for Earthquake Disaster Prevention, 2017, 12(1): 133-144. (in Chinese)
- [3] 薛俊伟, 刘伟庆, 王曙光, 等. 基于场地效应的地震动特性研究[J]. 地震工程与工程振动, 2013, 33(1): 16-23.  
XUE Junwei, LIU Weiqing, WANG Shuguang, et al. Research on ground motion characteristics considering site conditions[J]. Earthquake Engineering and Engineering Dynamics, 2013, 33(1): 16-23. (in Chinese)
- [4] 廖振鹏. 地震小区划: 理论与实践[M]. 北京: 地震出版社, 1989.  
LIAO Zhenpeng. Seismic safety evaluation of technical tutorials [M]. Beijing: Seismological Press, 1989. (in Chinese)
- [5] 胡聿贤. 地震安全性评价技术教程[M]. 北京: 地震出版社, 1999.  
HU Yuxian. Seismic safety evaluation of technical tutorials[M]. Beijing: Seismological Press, 1999. (in Chinese)
- [6] GB 17741—2005 工程场地地震安全性评价[S]. 北京: 中国标准出版社, 2005.  
GB 17741—2005 Evaluation of seismic safety for engineering sites[S]. Beijing: Standards Press of China, 2005. (in Chinese)
- [7] STEWART J P, KWOK A O L. Nonlinear seismic ground response analysis; Code usage protocols and verification against vertical array data[C]// Geotechnical Earthquake Engineering and Soil Dynamics IV. Sacramento, California, USA; American Society of Civil Engineers, 2008: 1-24.
- [8] IDRISSE I M, SEED H B. Seismic response of horizontal soil layers[J]. Journal of the Soil Mechanics and Foundations Division, 1968, 94(4): 1003-1031.
- [9] SCHNABEL P B, LYSMER J, SEED H B. SHAKE: A computer program for earthquake response analysis of horizontal layer sites[R]. Berkeley: University of California, 1972.
- [10] 李小军. 一维土层地震反应线性化计算程序[M]. 北京: 地震出版社, 1989.  
LI Xiaojun. A Computer program for calculating earthquake response of ground layered soil [M]. Beijing: Seismological Press, 1989. (in Chinese)
- [11] HASHASH Y M A, PARK D. Non-linear one-dimensional seismic ground motion propagation in the Mississippi embayment[J]. Engineering Geology, 2001, 62(1/2/3): 185-206.
- [12] GRIFFITHS S C, COX B R, RATHJE E M. Challenges associated with site response analyses for soft soils subjected to high-intensity input ground motions[J]. Soil Dynamics and Earthquake Engineering, 2016, 85: 1-10.
- [13] RÉGNIER J, TEAM T P. Erratum to International benchmark on numerical simulations for 1D, nonlinear site response (PRENOLIN): Verification phase based on canonical cases[J]. Bulletin of the Seismological Society of America, 2017, 107(3): 1568.
- [14] RÉGNIER J, BONILLA L F, BARD P Y, et al. PRENOLIN: International benchmark on 1D nonlinear site-response analysis: Validation phase exercise[J]. Bulletin of the Seismological Society of America, 2018, 108(2): 876-900.
- [15] KAKLAMANOS J, BRADLEY B A. Challenges in predicting seismic site response with 1D analyses; Conclusions from 114 KiK-net vertical seismometer arrays[J]. Bulletin of the Seismological Society of America, 2018, 108(5A): 2816-2838.
- [16] PILZ M, COTTON F. Does the one-dimensional assumption hold for site response analysis? A study of seismic site responses and implication for ground motion assessment using KiK-net strong-motion data[J]. Earthquake Spectra, 2019, 35(2): 883-905.
- [17] TAO Y M, RATHJE E. Taxonomy for evaluating the site-specific applicability of one-dimensional ground response analysis[J]. Soil Dynamics and Earthquake Engineering, 2020, 128: 105865.
- [18] 宝鑫, 刘晶波, 陆喜欢, 等. 考虑多维地震动及重力作用的土层场地地震反应分析模型[J]. 地震工程与工程振动, 2023, 43(5): 1-11.  
BAO Xin, LIU Jingbo, LU Xihuan, et al. Seismic response analysis model of soil-layer sites considering the combined effect of multidirectional seismic ground motions and gravity[J]. Earthquake Engineering and Engineering Dynamics, 2023, 43(5): 1-11. (in Chinese)
- [19] BOSE M, WENZEL F, ERDIK M. PreSEIS: A neural network-based approach to earthquake early warning for finite faults[J]. Bulletin of the Seismological Society of America, 2008, 98(1): 366-382.
- [20] 李山有, 陈欣, 卢建旗, 等. 基于 XGBoost 的现地地震烈度阈值实时判别模型[J]. 地球科学, 2024, 49(2): 379-390.  
LI Shanyou, CHEN Xin, LU Jianqi, et al. Real-time discrimination model for local earthquake intensity threshold based on XGBoost[J]. Earth Science, 2024, 49(2): 379-390. (in Chinese)
- [21] DANG H T, WANG Z F, ZHAO D K, et al. Ground motion prediction model for shallow crustal earthquakes in Japan based on XGBoost with Bayesian optimization[J]. Soil Dynamics and Earthquake Engineering, 2024, 177: 108391.
- [22] DERRAS B, BARD P Y, COTTON F, et al. Adapting the neural network approach to PGA prediction: An example based on the KiK-net data[J]. Bulletin of the Seismological Society of America, 2012, 102(4): 1446-1461.
- [23] LI L, JIN F, HUANG D R, et al. Soil seismic response modeling of KiK-net downhole array sites with CNN and LSTM networks[J]. Engineering Applications of Artificial Intelligence, 2023, 121: 105990.
- [24] CHEN T Q, GUESTRIN C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California USA. New York: ACM, 2016: 785-794.
- [25] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.

- [26] JAS K, DODAGOUDAR G R. Liquefaction potential assessment of soils using machine learning techniques: A state-of-the-art review from 1994—2021[J]. *International Journal of Geomechanics*, 2023, 23(7): 03123002.
- [27] BERGSTRA J, BARDENET R, BENGIO Y, et al. Algorithms for hyper-parameter optimization [C] // *Proceedings of the 25th International Conference on Neural Information Processing Systems*. Granada, Spain. New York: ACM, 2011: 2546–2554.
- [28] SAKOE H, CHIBA S. Dynamic programming algorithm optimization for spoken word recognition[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1978, 26(1): 43–49.
- [29] 刘浩, 朱敬洲, 徐龙军, 等. 动态时间规整算法在时程反应分析选取地震动中的应用[J]. *地震工程与工程振动*, 2019, 39(5): 223–233.  
LIU Hao, ZHU Jingzhou, XU Longjun, et al. Application of dynamic time warping algorithm in selecting ground motion for time history response analysis[J]. *Earthquake Engineering and Engineering Dynamics*, 2019, 39(5): 223–233. (in Chinese)
- [30] PIYUSH SHANKER A, RAJAGOPALAN A N. Off-line signature verification using DTW[J]. *Pattern Recognition Letters*, 2007, 28(12): 1407–1414.
- [31] NIGAM N C, JENNINGS P C. Calculation of response spectra from strong-motion earthquake records[J]. *Bulletin of the Seismological Society of America*, 1969, 59(2): 909–922.
- [32] OKADA Y, KASAHARA K, HORI S, et al. Recent progress of seismic observation networks in Japan: Hi-net, F-net, K-NET and KiK-net[J]. *Earth, Planets and Space*, 2004, 56(8): xv–xxviii.
- [33] National Research Institute for Earth Science and Disaster Resilience (NIED). Strong-motion seismograph networks (K-NET, KiK-net) [EB/OL]. (2019-03-28)[2023-09-10]. <https://www.kyoshin.bosai.go.jp/>.
- [34] GB 50011—2010 建筑抗震设计规范[S]. 北京: 中国建筑工业出版社, 2010.  
GB 50011—2010 Code for seismic design of buildings[S]. Beijing: China Architecture & Building Press, 2010. (in Chinese)
- [35] 曾金艳, 李自红, 陈文. 基岩输入参数对场地地震反应的影响分析[J]. *西北地震学报*, 2009, 31(2): 110–114.  
ZENG Jinyan, LI Zihong, CHEN Wen. Analysis on influence of the input parameters of bedrock on site earthquake response[J]. *Northwestern Seismological Journal*, 2009, 31(2): 110–114. (in Chinese)
- [36] JAS K, DODAGOUDAR G R. Explainable machine learning model for liquefaction potential assessment of soils using XGBoost-SHAP[J]. *Soil Dynamics and Earthquake Engineering*, 2023, 165: 107662.
- [37] STONE M. Cross-validators choice and assessment of statistical predictions[J]. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 1974, 36(2): 111–133.
- [38] LUNDBERG S M, LEE S I. A Unified approach to interpreting model predictions [C] // *Conference and Workshop on Neural Information Processing Systems*. California: NIPS Press, 2017: 4765–4774.
- [39] SHAPLEY L S. A value for n-person games [J]. *Contributions to the Theory of Games*, 1953, 2(28): 307–317.