

# 基于深度神经网络的竖向地震动 加速度反应谱预测模型

高铭宇<sup>1,2</sup>, 公茂盛<sup>1,2</sup>, 左占宣<sup>1,2</sup>, 贾佳<sup>1,2</sup>, 刘博<sup>1,2</sup>, 王晓敏<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:** 竖向地震动对工程结构地震响应有重要影响, 发展可靠的竖向地震动预测模型是地震工程领域的一项重要课题。传统的地震动预测主要基于实际强震动记录, 采用最小二乘回归方式得到地震动参数预测模型, 但是传统最小二乘回归通常假设变量之间是线性关系或预设的函数形式, 这可能无法完全捕捉地震数据中复杂的非线性关系, 而深度学习模型能够从数据中学习规律并对复杂的数据分布提供更高的预测精度。因此通过深度学习的方法, 基于 NGA-West2 数据库选取了 9 953 条竖向地震动记录, 然后计算反应谱并进行模型训练与预测, 建立了 Self-DNN 竖向地震动反应谱预测模型, 并与传统预测模型以及 DNN 神经网络模型进行了对比。结果表明, 本文基于深度学习算法建立的竖向地震动反应谱预测模型具有较好的可靠性和准确性, 可以取得良好的预测效果。研究结果可以为竖向地震动反应谱预测和结构抗震设计等工作提供参考。

**关键词:** 竖向地震动; 地震动反应谱; 神经网络; 深度学习; 预测模型

中图分类号: P315

文献标志码: A

## Vertical ground motion acceleration response spectrum prediction model based on deep neural networks

GAO Mingyu<sup>1,2</sup>, GONG Maosheng<sup>1,2</sup>, ZUO Zhanxuan<sup>1,2</sup>, JIA Jia<sup>1,2</sup>, LIU Bo<sup>1,2</sup>, WANG Xiaomin<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:** Vertical ground motions have a significant impact on the seismic response of engineering structures, making the development of reliable vertical ground motion prediction models an important topic in the field of earthquake engineering. Traditional ground motion predictions are primarily based on actual strong motion records, using least squares regression to derive seismic motion parameter prediction models. However, conventional least squares regression often assumes linear relationships or predefined functional forms between variables, which may fail to fully capture the complex nonlinear relationships inherent in seismic data. In contrast, deep learning models can learn patterns from data and provide higher prediction accuracy for complex data distributions. In this study, deep learning methods were applied, and 9 953 vertical ground motion records from the NGA-West2 database were selected for model training and prediction. The self-DNN vertical seismic response spectrum prediction model was established and its performance was compared with traditional prediction models and a DNN neural network models. The results indicate that the vertical seismic response spectrum prediction model established using deep learning

收稿日期: 2025-01-15; 修回日期: 2025-04-09

基金项目: 黑龙江省自然科学基金资助项目(LH2022E122); 国家自然科学基金项目(52178514); 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(2024C17); 国家科技重点研发计划课题省级资助项目(GX18C005)

作者简介: 高铭宇(1999—), 男, 硕士生, 主要从事地震工程研究。E-mail: 15369528309@163.com

通信作者: 公茂盛(1976—), 男, 研究员, 博士, 主要从事地震工程研究。E-mail: gmshiem@163.com

algorithms achieves high accuracy and delivers excellent predictive performance. These findings and analyses provide valuable references for vertical seismic response spectrum prediction and structural seismic design.

**Key words:** vertical ground motion; ground motion response spectra; neural network; deep learning; prediction model

## 0 引言

可靠的地震动参数预测是地震动参数区划、工程抗震设计的重要基础,对于地震安全评估、地震灾害分析,以及城市结构和基础设施的设计至关重要。前人研究较多关注在水平地震动,但是对于大跨度结构和超高层建筑,竖向地震动的影响较大,在实际工程中不可忽略。一般而言,竖向地震动预测的传统研究方法通常包括两种:①用竖向地震动与水平地震动的峰值比或谱比  $V/H$  来间接反映竖向地震动的作用;②把竖向地震动作为独立变量来进行分析。但是,由于非弹性衰减和非线性场地效应的影响<sup>[1]</sup>,  $V/H$  有时不能完全捕捉到竖向与水平地震动之间的诸多差异,有必要对竖向地震动参数进行单独预测。传统回归方法主要采用非线性最小二乘法确定地震震级、震源特性、传播介质、场地中各个参数与地震动参数之间规律关系,并建立预测方程,从而对地震动参数进行预测。

传统的最小二乘回归方法通常假设变量之间是线性关系或预设的函数形式。STEWART 等<sup>[2]</sup> 计算了活动构造区域浅层地壳地震的竖向地震动反应谱,并采用传统回归方法建立了地面运动预测方程中的 SBSA16 模型。该模型共考虑 3 项分别为震源项、路径项和场地项。以矩震级  $M_w$ 、断层距  $R_{JB}$ 、场地  $V_{S30}$  和断层类型作为自变量。该模型适用于地震矩震级  $M_w$  为 3~8、断层距  $R_{JB}$  为 0~300 km 的地震,  $V_{S30}$  的适用范围为 200~1 500 m/s。BOZORGNIA 等<sup>[3]</sup> 选用 NGA-West2 数据库中的竖向地震动数据,建立了地面运动预测方程中的 CB16 模型。该模型是 NGA 模型中考虑因素最全面的模型,主要考虑了震级、断层距、断层类型、上盘效应、场地条件、盆地效应、震源深度、破裂面倾角、非弹性衰减等因素,适用范围:  $M_w$  为 3.3~8.5,  $R_{np}$  为 0~300 km,  $V_{S30}$  为 150~1 500 m/s。李宁等<sup>[4]</sup> 基于太平洋地震工程研究中心 (Pacific Earthquake Engineering Research Center, PEERC) 数据库,研究了地震动竖向与水平加速度分量峰值比  $a_v/a_h$  与矩震级、断层距、场地条件和断层类型的统计规律,给出了  $a_v/a_h$  的合理取值。李恒等<sup>[5]</sup> 采用全球范围 128 次地震的 3 235 组三分量强地面运动记录,分析了加速度竖向分量反应谱与水平分量反应谱的比值  $V/H$  的整体特征,研究了  $V/H$  随震级、震中距、局部场地条件和震源机制的变化关系。然而,使用最小二乘回归法通常在小规模数据集上表现良好,但面对大规模数据时可能无法有效利用数据的潜在信息,因而可能无法完全捕捉地震数据中复杂的非线性关系,特别是在数据不均衡的情况下,其泛化能力弱。

近年来,很多学者利用机器学习对地震动参数进行了合理预测,JI 等<sup>[6]</sup> 主要应用 NGA-West2 数据库,以矩震级、断裂类型、断裂深度等参数作为震源项参数,以断层距和破裂长度作为传播介质项参数,以等效剪切波速作为场地项参数,建立了地震动累积绝对速度的神经网络模型。WITHERS 等<sup>[7]</sup> 采用南加州地震中心 (Southern California Earthquake Center, SCEC) 地震动记录,选取了矩震级、断层距、等效剪切波速和断层类型作为输入参数,仅建立了包含一个隐藏层的神经网络模型,用来预测地震动的幅值特征,对于一些缺乏地震动记录的地区,采用人工模拟地震动,并用 NGA-West2 中的记录对神经网络模型预测性能进行一定的评估,指出对于缺乏地震动记录的地区,可利用模拟地震动来生成大量用于深度学习的数据样本。余聪等<sup>[8]</sup> 主要选用日本 K-NET 数据集,并选取加速度幅值、速度幅值、位移幅值、破坏烈度、傅里叶谱幅值、速度平方积分、累积绝对速度和阿里斯亚烈度 8 个参数,建立了支持向量机地震动峰值预测模型,预测效果良好。DERRAS 等<sup>[9]</sup> 选用日本 KiK-net 作为机器学习数据库,并选取震级、震源深度、震中距、场地共振频率和  $V_{S30}$  作为输入参数,峰值地面加速度 PGA 作为输出参数,设置了一个 3 层的神经网络,每个隐藏层都包含 20 个神经元,并进行了一定的超参数设置和优化算法选取,得到了预测结果,并提出了机器学习方法是一种很有价值的对地震动参数进行预测的方法,可以和经典回归方法共同使用。贾佳等<sup>[10]</sup> 基于机器学习算法对土耳其地震中获得的 660 组地震动记录的显著持时进行预测,建立了预测模型并开展了残差分析,并将预测模型与传统持时预测公式预测结果对比,预测效果良好。靳超越等<sup>[11]</sup> 筛选处理了 2021 年云南漾濞地震的地震动记录,基于机器学习算法对前震和余震下地震动记录进行特征提取,并根据提取得到的特征母波时程来模拟主震的强

震动记录。朱景宝等<sup>[12]</sup>基于日本 K-NET (Kyoshin net) 地震动数据库中震级 3.0~7.5 级的地震事件,建立了用于震级估算的深度卷积神经网络 DCNN-M 模型,能够实时对震级进行估算。李逸群<sup>[13]</sup>建立全球范围的余震数据库,并在此基础上开展基于深度神经网络的余震衰减关系的预测研究,并总结归纳了俯冲带板间余震和俯冲带板内余震地震动衰减关系规律,预测结果可靠。

通过上述分析可以发现,针对地震动反应谱进行预测研究多是针对水平地震动并且回归方法较多采用传统最小二乘回归,采用深度学习神经网络方法对竖向地震动反应谱进行预测的研究较少。基于此,本文选取 NGA-West2 中 9953 条竖向地震动记录,参考 SBSA16 模型,选取矩震级和断层类型作为震源项,矩震级和断层距作为路径项,矩震级、断层类型、断层距和  $V_{S30}$  作为场地项进行输入,利用深度学习算法建立了竖向地震动反应谱预测模型,并与传统经验公式及 DNN 模型预测结果进行对比,验证了本文建立的基于深度学习竖向地震动反应谱预测模型具有可靠性和合理性。

## 1 地震动数据选取

在地震动数据的选取时遵循以下 3 个原则:①地震动记录应包含震级、距离及场地等完整相关参数信息;②地震矩震级  $M_w$  为 4.0~8.0,断层距  $R_{JB}$  为 0~300 km;③单次地震事件的地震动记录数量  $\geq 4$  条。基于上述原则,本文从美国 NGA-West2 数据库中选取了 9953 条地震动记录,每条记录包含 3 个分量,本文只对竖向分量开展研究。这些地震动记录总共来自全球 204 次地震,其矩震级-距离分布、矩震级-场地  $V_{S30}$  分布如图 1 所示。由图可知,本文所选地震动记录矩震级  $M_w$  主要集中在 4.0~7.0,而在 7.0~8.0 的地震动记录相对偏少;断层距  $R_{JB}$  主要集中分布在 5~300 km,5 km 以下的记录相对偏少;场地  $V_{S30}$  主要集中分布在 200~800 m/s。本文首先对这些地震动记录分别计算了阻尼比为 5% 的加速度反应谱,其次建立了 Self-DNN 预测模型,并选取周期  $T=0$  s 时的加速度反应谱谱值 PGA 以及周期  $T=0.2$ 、1.0、3.0 s 时的加速度反应谱谱值  $S_a$  (acceleration response spectrum value) 这几个指标作为代表项进行分析。




图 1 矩震级 ( $M_w$ )、断层距 ( $R_{JB}$ ) 和场地 ( $V_{S30}$ ) 分布情况

Fig. 1 Distributions of moment magnitude ( $M_w$ ), fault distance ( $R_{JB}$ ), and site ( $V_{S30}$ )

## 2 深度学习网络

### 2.1 Self-DNN 深度学习网络

深度学习网络<sup>[14]</sup>是指利用多层神经网络模型进行特征学习和模式识别的计算,从大量数据中寻求参数特征和参数之间的客观规律,并利用不断调整权重和设定激活函数进一步学习到输入参数与输出参数之间的非线性关系。DNN 神经网络的主要优点在于其强大的特征学习能力和非线性建模能力,能够通过多层隐藏层自动提取数据的多层次特征,从而有效捕捉复杂的非线性关系,在大规模数据集上表现优异,与传统回归的地震动参数预测模型相比,不需要预设公式并且能捕捉到复杂的震源和场地效应,但是单利用这一网络无法通过计算不同特征权重让模型自动学习判断出哪些特征影响较大,可能导致对关键特征的识别不够精确进而使得预测结果不够准确。因此,本文为了进一步提升模型的预测性能,对 DNN 神经网络模型进行了改进,建立了 Self-DNN 神经网络模型,如图 2 所示。

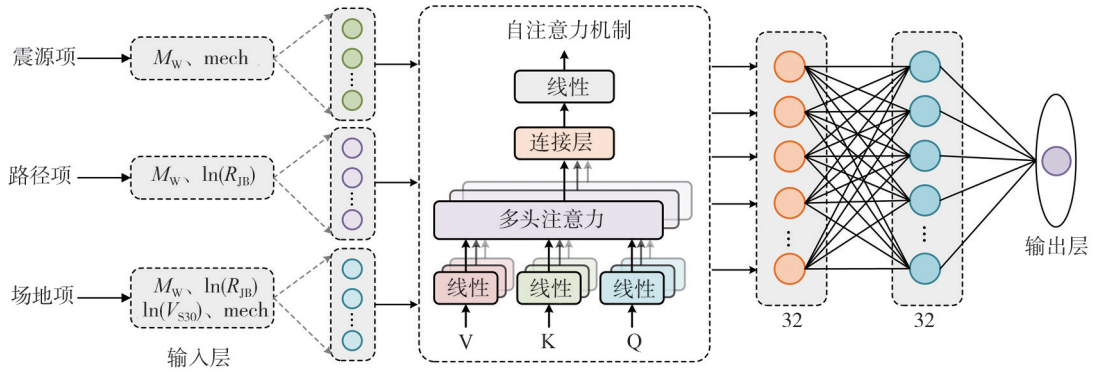


图 2 神经网络结构图

Fig. 2 Neural network architecture diagram

由图 2 可知,本文模型在多个子网络的输出拼接之后加入了自注意力机制,通过计算不同特征的权重,让模型能够自动学习并判断出哪些特征对最终的输出影响比较大,并能够动态调整对子网络输出的关注度,将更高的权重分配给相对重要的特征,而减少对不重要特征的关注,动态权重的分配可以使得模型对高维复杂的输入进行细致处理,增强模型表达能力,提升模型性能。本文建立的 Self-DNN 多输入神经网络共有 3 组输入特征,分别为震源项、路径项和场地项,每组输入特征均有各自的参数,为了保证参数选取的合理性,本文主要参考 PEER 报告<sup>[15]</sup>中竖向地震动反应谱传统预测公式 SBSA16 模型中震源项、路径项和场地项的参数选取方式,同样在震源项中考虑矩震级  $M_w$ 、断层类型  $mech$ ,路径项中考虑矩震级  $M_w$ 、断层距  $\ln(R_{JB})$ ,场地项中考虑矩震级  $M_w$ 、断层距  $\ln(R_{JB})$ 、剪切波速  $\ln(V_{s30})$ 、断层类型  $mech$ ,将这些参数分别输入到各自的 32 个神经元中,形成 3 个子网络,并将 3 个子网络的输出进行拼接后经由 1 个自注意力机制层后输入到 2 个均含 32 个神经元的隐藏层中,并最终得到输出的参数预测。另外,在建立 Self-DNN 竖向地震动参数预测模型时,本文采用 Python 语言和 Tensorflow 框架<sup>[16]</sup>对神经网络进行训练,因为神经网络可能会一次学习到同一次地震事件不同的地震动记录,进而影响到对地震动数据特征的准确学习而影响训练结果,为了防止这种情况,因此在划分数据集前先将地震动数据集进行打乱处理,然后按照 8:1:1 的比例将数据集划分成训练集测试集和验证集。

### 2.2 损失函数定义

在深度学习模型的构建过程中,损失函数主要是用来衡量预测值与真实值之间差异的函数,不仅是优化算法的核心要素,更是模型性能的关键评估指标。不同类的损失函数,如均方误差 MSE、平均绝对误差 MAE、均方根误差 RMSE,分别代表真实值与预测值差的平方和的平均值,真实值与预测值差的绝对值的平均值以及均方误差 MSE 的平方根,各自具备特定的数学特性和适用场景,MSE 容易受异常值的影响而产生较大误差,而 MAE 更新梯度始终相同,对于很小的损失值会有较大的梯度,为了避免这一点,本文综合以上 3 个指标的结果并结合决定系数  $R^2$ 来共同评价模型性能。上述均方误差 MSE、平均绝对误差 MAE、均方根误差 RMSE 以及决定系数  $R^2$ 分别如式(1)~式(4)所示:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \tag{1}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \tag{2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{3}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{4}$$

式中:  $n$  代表地震动的条数;  $y_i$  代表第  $i$  条地震动加速度反应谱的真实值;  $\hat{y}_i$  代表第  $i$  条地震动加速度反应谱的预测值;  $\bar{y}$  代表所有地震动加速度反应谱真实值的平均值。另外,本文还选用了自适应学习率的 Adam 梯度下降优化算法<sup>[17]</sup>,从而减小输出误差。

### 3 预测结果与分析

#### 3.1 模型拟合效果

本文主要针对竖向地震动峰值 PGA 和反应谱  $S_a$  这两个参数,采用深度学习算法进行训练,得到了其预测模型。为验证预测结果可靠性和准确性,本文选用 PGA、 $S_a(T=0.2\text{ s})$ 、 $S_a(T=1.0\text{ s})$  和  $S_a(T=3.0\text{ s})$  这几个指标,把各自预测模型的真实值与预测值进行对比,结果如图 3 所示。由图 3 可以发现,测试集中绝大多数数据点在  $45^\circ$  基准线区域内且均匀分布在两侧,证明了本文深度学习模型具有良好预测能力。对于 PGA 和  $S_a(T=0.2\text{ s})$ ,当真实值位于  $0.001\text{ g}$  以内时,数据点多位于基准线的上方,说明预测结果偏大;当真实值超过  $0.1\text{ g}$  时,数据点多位于基准线的下方,说明预测结果偏小。对于  $S_a(T=1.0\text{ s})$ ,当真实值位于  $10^{-4}\text{ g}$  以内时,预测结果偏大;而当真实值超过  $0.10\text{ g}$  时,预测结果偏小。对于  $S_a(T=3.0\text{ s})$ ,当真实值位于  $10^{-5}\text{ g}$  以内时,预测结果偏大;当真实值超过  $0.01\text{ g}$  时,预测结果偏小。随着周期  $T$  的不断增大,数据点越接近于基准线,预测更准确。为了对模型的预测效果进行评估,本文选用了 MSE、MAE、RMSE、 $R^2$  这几个指标,将本文模型与 DNN 模型和 SBSA16 模型<sup>[2]</sup> 分别进行了对比,如图 4 所示。通过与其他模型对比分析可以看出,本文模型的 MSE、MAE、RMSE 这几个指标数值均低于 DNN 模型和 SBSA16 模型,在这 3 个指标上展现出良好性能优势。对于 PGA 和  $S_a(T=0.2\text{ s})$ ,通过 MSE 对比发现,本文模型和 DNN 模型均显著低于传统 SBSA16 模型,本文模型 MSE 约低于 DNN 模型 21% 和 36%;MAE 指标显示,本文模型和 DNN 模型也都显著低于 SBSA16 模型,且本文模型更低,约低于 DNN 模型 12% 和 27%;RMSE 的表现与 MSE 相近。对于  $S_a(T=1.0\text{ s})$  和  $S_a(T=3.0\text{ s})$ ,本文模型的 MSE 约低于 DNN 模型 32% 和 29%,MAE 约低于 DNN 模型 31% 和 26%,RMSE 的表现和 MSE 相似,证明本文模型在预测精度上具有显著优势。在模型的拟合效果  $R^2$  上,本文模型始终更接近于 1;对于 PGA 和  $S_a(T=0.2\text{ s})$ ,本文模型的  $R^2$  约高于 DNN 模型 7% 和 14%;对于  $S_a(T=1.0\text{ s})$  和  $S_a(T=3.0\text{ s})$ ,本文模型的  $R^2$  约高于 DNN 模型 15% 和 9%,说明本文模型具备良好预测能力。

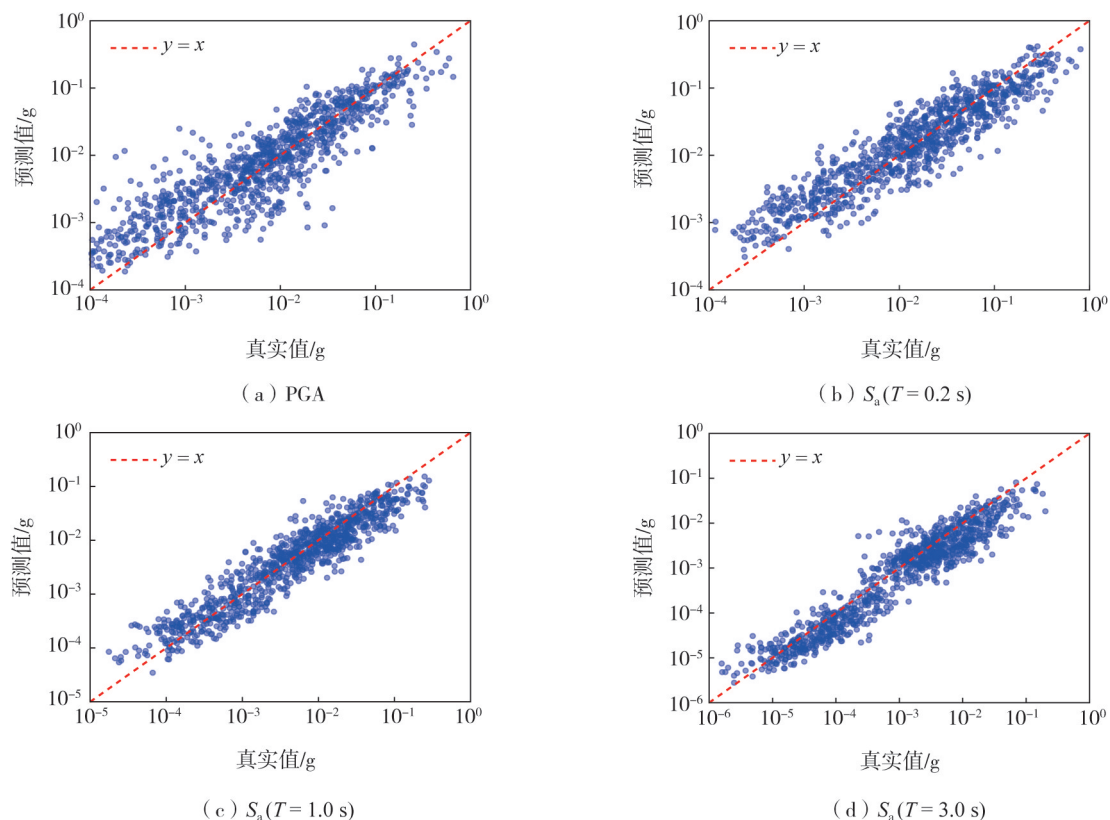


图 3 测试集数据真实值和预测值对比

Fig. 3 Comparison of actual and predicted values for the test dataset

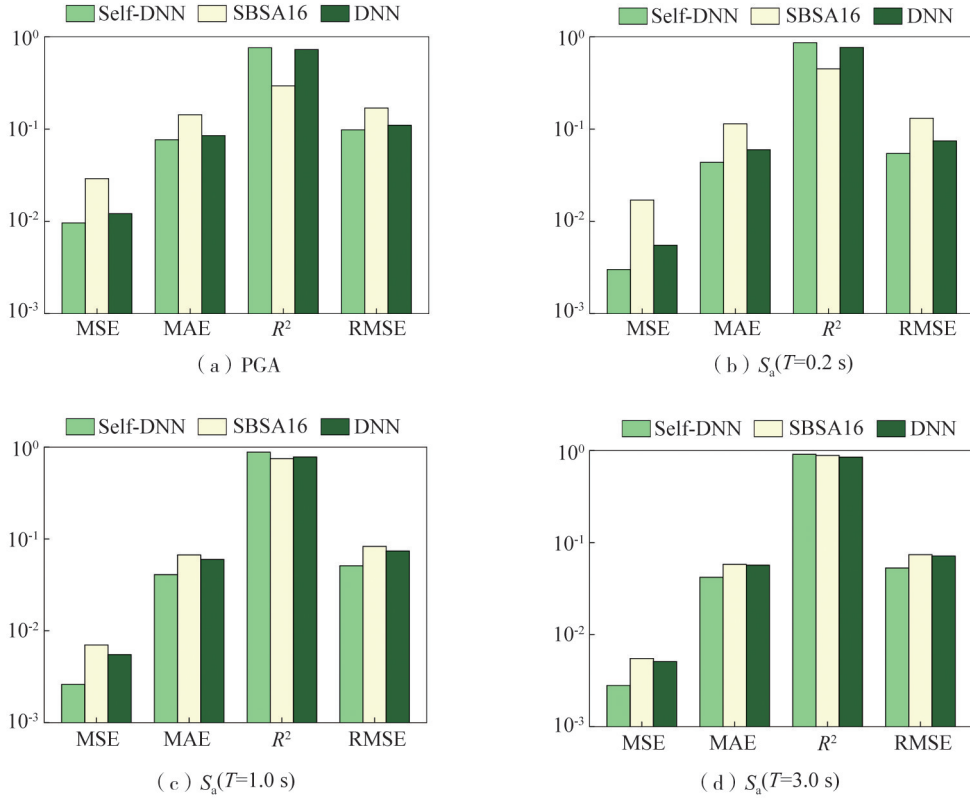


图4 不同模型的性能指标(以 Self-DNN 测试集数据为基准)

Fig.4 Performance metrics of different models (Using Self-DNN test dataset as the benchmark)

### 3.2 残差分析

除了对预测模型的 MSE、MAE、RMSE、 $R^2$  这几个指标进行评估以外,模型的性能还可以通过残差分析来预测评估,残差能有效反映模型的预测误差,一条地震动记录预测值与真实值的差如式(5)所示,并参考文献[18]。残差又可分为事件间残差和事件内残差,事件间残差是一次地震得到的所有地震动记录的残差和再除以地震动记录条数,计算公式如式(6)所示,事件内残差是一次地震记录的误差和这次地震事件间残差的差值,计算公式如式(7)所示:

$$\ln(y)_{ij} - \overline{\ln(y)}_{ij} = R_{ij} = \eta_i + \varepsilon_{ij} \quad (5)$$

$$\eta_i = \frac{1}{n} \sum_{j=1}^n R_{ij} \quad (6)$$

$$\varepsilon_{ij} = R_{ij} - \eta_i \quad (7)$$

式中: $R_{ij}$ 是一条地震动记录预测值与真实值的差; $\ln(y)_{ij}$ 和 $\overline{\ln(y)}_{ij}$ 分别代表第*i*次地震的第*j*条记录观测得到的真实值和预测模型预测得到的预测值; $\eta_i$ 和 $\varepsilon_{ij}$ 分别代表事件间残差和事件内残差; $n$ 是一次地震的地震动个数。事件间残差是各次地震事件的残差,事件内残差是所有地震动记录真实值和预测值二者之差。

为了进一步评估模型预测结果准确性和合理性,本文对 PGA 和  $S_a(T=0.2\text{ s})$  深度学习模型的预测结果进行了残差分析,残差与  $M_w$ 、 $R_{JB}$  和  $V_{S30}$  的分布结果如图 5 和图 6 所示。从图中可以看出,对于 PGA,事件内残差在  $R_{JB}$  位于 5~10 km 时稍偏向小于 0 的一侧,随着  $R_{JB}$  的不断增大无显著变化,而随着  $V_{S30}$  以及  $M_w$  的变化也无显著变化,事件间残差随着  $M_w$  的不断增大呈现出先稍偏向小于 0,然后又稍大于 0 的趋势,但是整体变化幅度极小。对于  $S_a(T=0.2\text{ s})$ ,事件内残差在  $R_{JB}$  位于 5~10 km 时稍偏向于大于 0 的一侧,在  $R_{JB}$  大于 10 km 时变化趋势先略增大后略减小,变化幅度极小;事件内残差随着  $M_w$  基本没有明显偏移,分布较为均匀;当  $V_{S30}$  在 900 m/s 以内时没有明显偏移,但当  $V_{S30}$  超过 900 m/s 时呈现先变大后稳定的趋势;而事件间残差随  $M_w$  分布整体略低于 0 基准线但并无明显偏移。总体来说,事件内残差主要集中分布在  $[-2, 2]$  范围内,事件间残差主要集中分布在  $[-1, 1]$  内,且在 0 基准线两边分布较为均匀,预测结果具有一定可靠性。

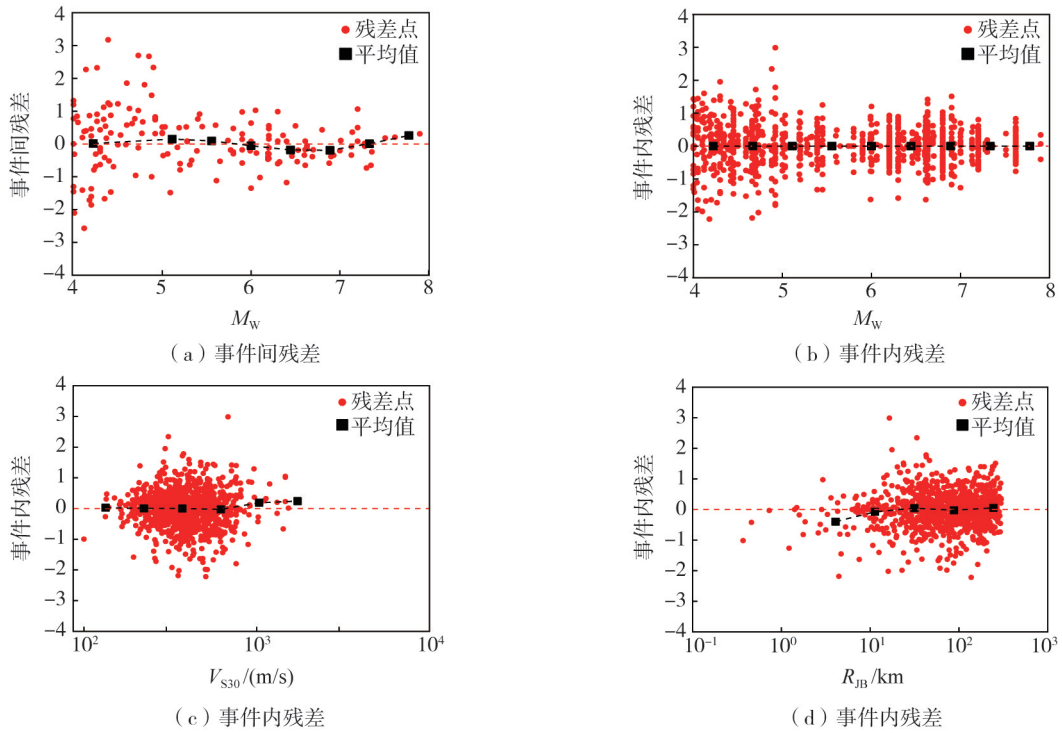


图 5 PGA 事件内和事件间残差

Fig. 5 Intra-event and Inter-event residuals of PGA

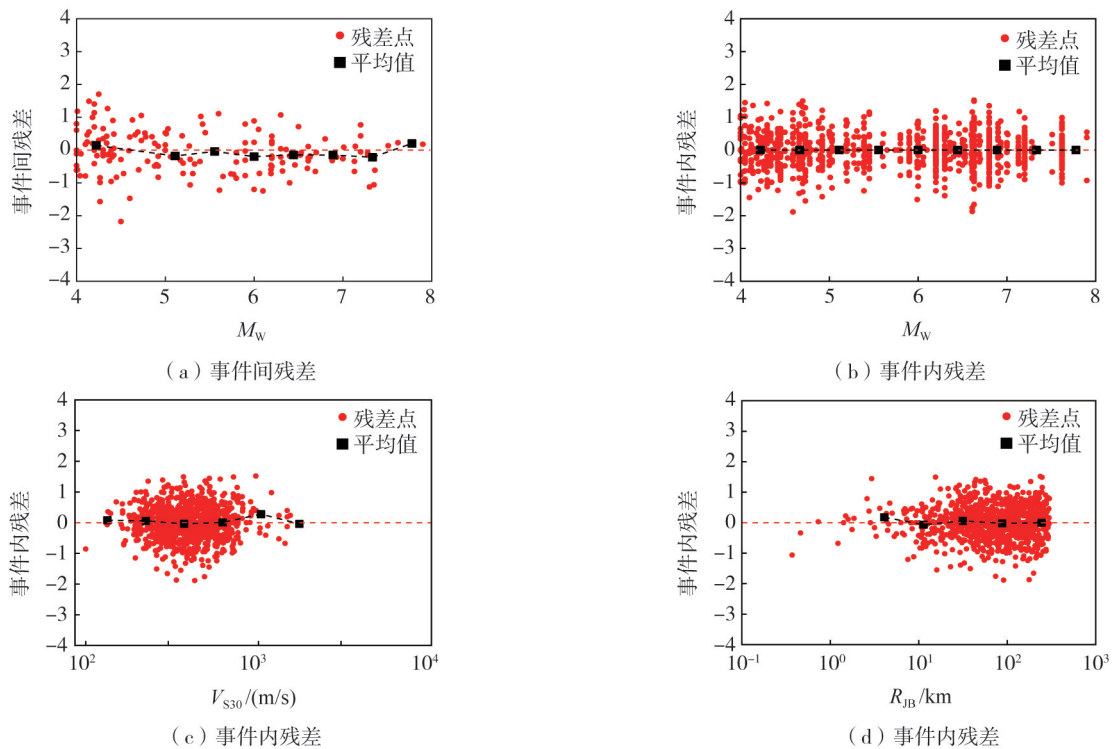


图 6  $S_a(T=0.2\text{ s})$  事件内和事件间残差

Fig. 6 Intra-event and Inter-event residuals of  $S_a(T = 0.2\text{ s})$

### 3.3 与传统方法及 DNN 预测模型预测结果对比

#### 3.3.1 PGA 与 $S_a$ 随 $R_{JB}$ 的变化规律对比

为了进一步验证所提 Self-DNN 深度学习模型预测结果合理性,对矩震级  $M_w = 5$  的走滑地震在  $V_{S30} = 750\text{ m/s}$  进行断层距  $R_{JB}$  在 300 km 以内的 PGA 和不同周期  $S_a$  进行预测,并和传统方法预测模型 SBSA16 以及 DNN 神经网络预测模型对比,结果如图 7 所示,由图可以看出,PGA 和不同周期  $S_a$  的值均随断层距  $R_{JB}$  的

增大而不断减小,说明近场区域对竖向地震动的峰值影响很大,在近场区域容易产生峰值较大的竖向地震动,而在中远场区域影响则逐渐减小。对于 PGA,当  $R_{JB}$  在 30 km 以内时,SBSA16 模型的预测值大于 DNN 模型和本文模型,且 DNN 模型的预测值要低于本文模型;当  $R_{JB}$  大于 30 km 时,随着  $R_{JB}$  的不断增大,尤其是在中远场时,SBSA16 和 DNN 模型的预测值略低于本文模型,但二者相差不大。对于  $S_a$ ,当  $T=0.2$  s 时,SBSA16 模型的预测值整体大于本文模型和 DNN 模型,且 DNN 模型的预测值整体要低于本文模型;  $T=1.0$  s、 $R_{JB}$  在 10 km 以内时,SBSA16 模型预测值偏大,本文模型和 DNN 模型相差不大,当  $R_{JB}$  大于 10 km 时,DNN 模型和 SBSA16 模型预测值要高于本文模型,但 3 个模型相差不大;而当  $T=3.0$  s 时,DNN 模型的预测值要高于本文模型和 SBSA16 模型,当  $R_{JB}$  在 70 km 以内时,SBSA16 模型的预测值大于本文 Self-DNN 模型,而当  $R_{JB}$  位于 70~300 km 时,SBSA16 模型的预测值要低于本文模型。本文模型的适用范围为  $M_w=4\sim 8$ ,但当  $M_w$  超过 7 时,预测结果受数据分布不均匀的影响较大,预测的不确定性增大。

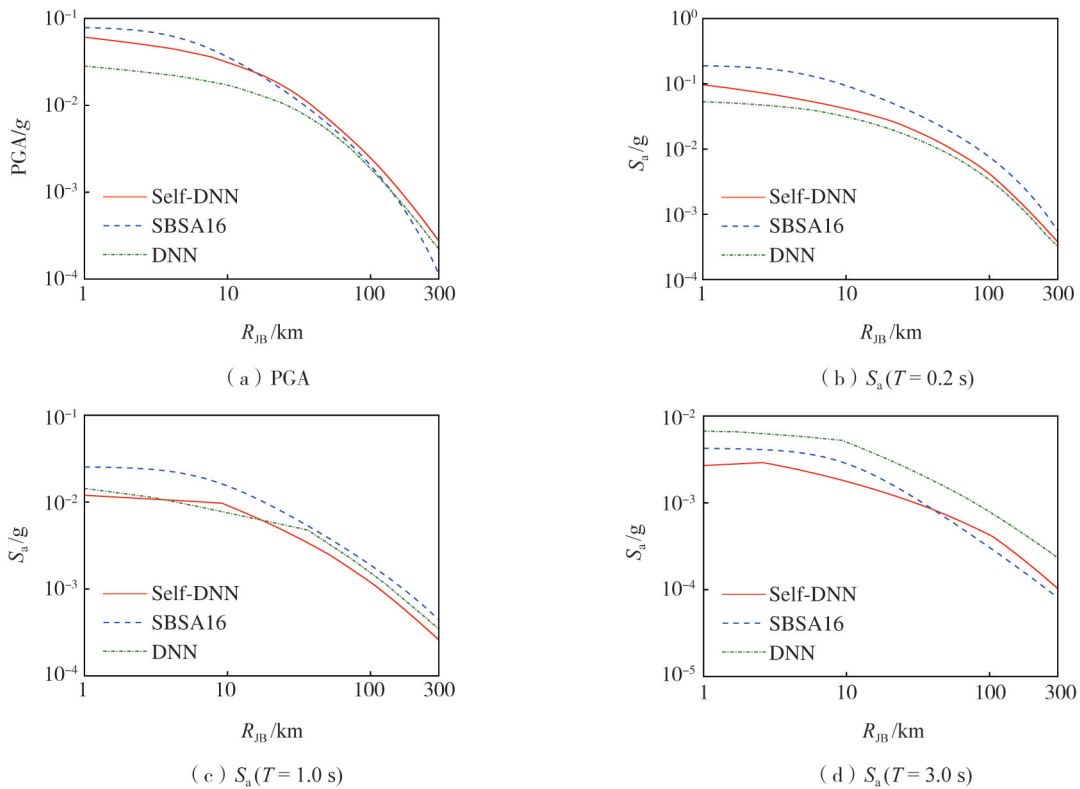


图 7  $V_{s30}=750$  m/s,走滑地震, $M_w=5$  时 PGA、 $S_a$  随  $R_{JB}$  分布

Fig. 7 PGA and  $S_a$  distributions with respect to  $R_{JB}$  for a strike-slip earthquake with  $V_{s30} = 750$  m/s and  $M_w = 5$

### 3.3.2 PGA 与 $S_a$ 随 $M_w$ 的变化规律对比

图 8 为  $R_{JB} = 50$  km,  $V_{s30} = 750$  m/s,走滑地震在  $M_w = 4, 5, 6, 7, 8$  时进行 PGA 和不同周期的  $S_a$  预测,并和传统方法预测模型 SBSA16 以及 DNN 神经网络预测模型对比。由图可以看出,峰值均随矩震级  $M_w$  的不断增大而增大,并且在中大震时增大幅度变缓,震级对峰值的影响同样不可忽略,尤其是当震级很大时,竖向地震动峰值也较大。对于 PGA,当矩震级  $M_w$  在 4.0~4.5 时,SBSA16 模型预测值略大,本文 Self-DNN 模型和 DNN 模型预测结果相近;当矩震级  $M_w$  在 4.5~6.0 时,DNN 模型预测值偏低,本文模型和 SBSA16 模型预测效果接近;当矩震级  $M_w$  大于 6.0 时,其余两个模型预测值相差不大且均低于本文 Self-DNN 模型。对于  $S_a$ ,在  $T=0.2$  s、矩震级  $M_w$  在 4~5 时,DNN 模型的预测值略小于本文模型和 SBSA16 模型,本文模型预测值和 SBSA16 模型预测值较为接近;当矩震级  $M_w$  介于 5~7 时,SBSA16 模型的预测值偏大,DNN 模型预测值略低于本文模型;而当矩震级  $M_w$  大于 6.8 时,DNN 模型的预测值更大。在  $T=1.0$  s 时,当矩震级  $M_w$  小于 5 时,DNN 模型的预测值略大于其余两个模型,SBSA16 模型预测值略低于本文模型;当  $M_w$  介于 5~7 时,3 个模型预测效果较为接近;而当  $M_w$  大于 7 时,其余两个模型预测值稍低于本文模型;在  $T=3.0$  s 时,3 个模型预测值整体差别不大,在震级较大时 DNN 模型的预测值略大。

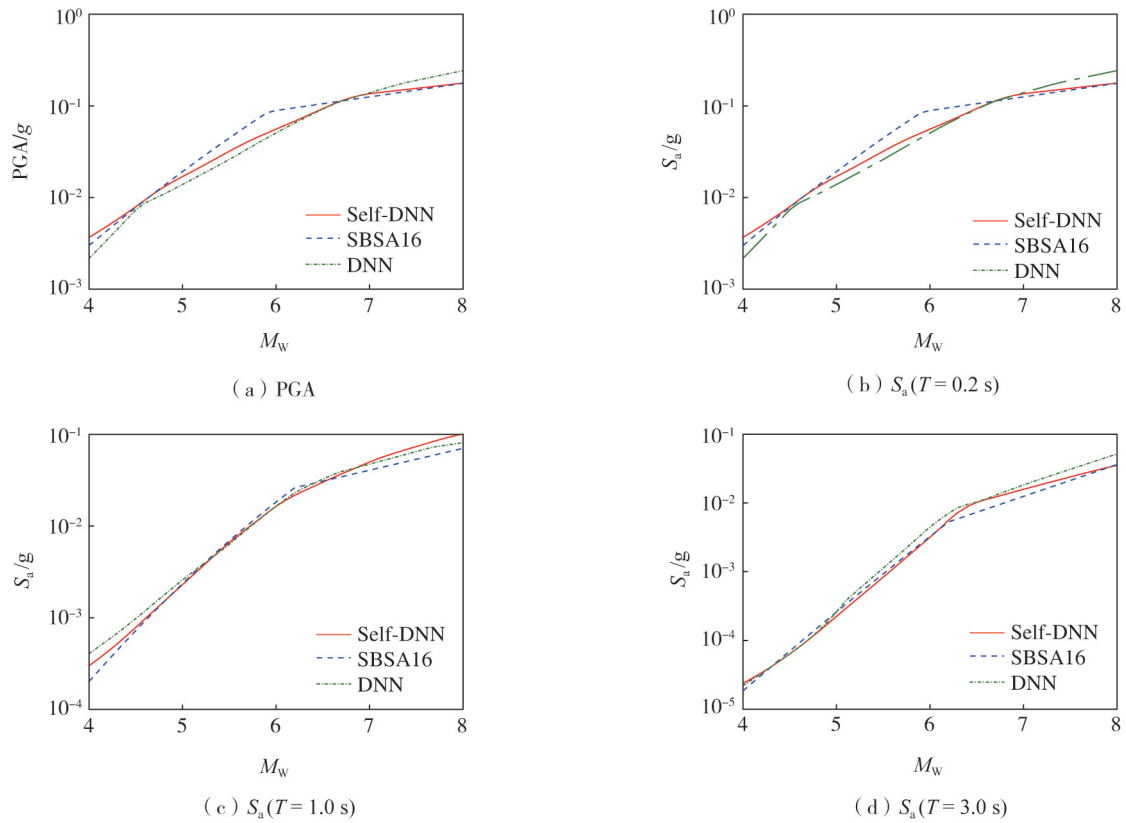



图8  $V_{s30} = 750 \text{ m/s}$ , 走滑地震,  $R_{jB} = 50 \text{ km}$  时 PGA、 $S_a$  随  $M_w$  分布

Fig. 8 PGA and  $S_a$  distributions with respect to  $M_w$  for a strike-slip earthquake with  $V_{s30} = 750 \text{ m/s}$  and  $R_{jB} = 50 \text{ km}$

### 3.3.3 PGA 与 $S_a$ 随 $V_{s30}$ 的变化规律对比

图9表示的是  $M_w = 5$ 、 $R_{jB} = 30 \text{ km}$  时, 走滑地震进行场地  $V_{s30}$  在  $100 \sim 1000 \text{ m/s}$  以内的 PGA 和不同周期的  $S_a$  预测, 并和传统方法预测模型以及 DNN 神经网络预测模型对比。由图可以看出, 峰值均随  $V_{s30}$  的不断增大而减小, 并且随着  $V_{s30}$  的不断增大减小幅度逐渐变缓, 场地  $V_{s30}$  对竖向地震动的影响不可忽略, 场地越软, 竖向地震动的峰值越大。对于 PGA, DNN 模型和 SBSA16 模型的预测值整体低于本文 Self-DNN 模型。而对于  $S_a$ , 在  $T = 0.2 \text{ s}$  时, SBSA16 模型整体预测值高于本文模型和 DNN 模型, 而  $V_{s30}$  介于  $500 \sim 700 \text{ m/s}$  时, 本文模型预测值和 DNN 模型预测值相差不大; 当  $V_{s30}$  小于  $500 \text{ m/s}$  时, DNN 模型预测值低于本文模型。当  $T = 1.0 \text{ s}$  时, SBSA16 模型的预测值整体高于其他两个模型; 当  $V_{s30}$  介于  $500 \sim 700 \text{ m/s}$  时, 本文 Self-DNN 模型预测值和 DNN 模型预测值接近; 当  $V_{s30}$  介于  $700 \sim 1000 \text{ m/s}$  时, DNN 模型预测值要高于本文模型; 而当  $V_{s30} = 100 \sim 500 \text{ m/s}$  时, DNN 模型预测值略小于本文模型。在  $T = 3.0 \text{ s}$  时, DNN 模型的预测值整体大于其余两个模型, 且 SBSA16 模型的预测值整体低于本文模型。






图 9  $M_w = 5$ ,走滑地震,  $R_{JB} = 30$  km 时 PGA、 $S_a$ 随  $V_{S30}$ 分布

Fig. 9 PGA and  $S_a$  distributions with respect to  $V_{S30}$  for a strike-slip earthquake with  $M_w = 5$  and  $R_{JB} = 30$  km

### 3.4 反应谱预测结果分析

本文进一步对竖向地震动的反应谱进行预测分析。图 10 表示的是  $M_w = 5, 6, 7$ ,  $R_{JB} = 70$  km, 走滑地震在场地  $V_{S30}$  为 750 m/s 时的不同周期的  $S_a$  预测值。由图可知,当周期  $T = 0 \sim 0.2$  s 时,反应谱谱值随着周期  $T$  的不断增大而不断增大,在  $T = 0.2$  s 时达到顶峰。这是因为在短周期时地震动的高频能量较丰富,短周期结构具有较高自振频率,能够与地震动中的高频成分形成共振,从而放大加速度响应;在  $T = 0.2 \sim 6.0$  s,反应谱的谱值随着周期  $T$  的不断增大呈现递减的趋势,这是因为单自由度体系结构自振周期长,地震动主要成分集中在较短周期内,二者间频率不匹配,导致反应谱谱值低。当  $M_w = 5$  时,SBSA16 模型的预测值高于本文模型和 DNN 模型;在  $T = 0 \sim 0.025$  s 时,DNN 模型的预测值要高于本文模型;在  $T > 0.025$  s 时,DNN 模型的预测值低于本文模型。在  $M_w = 6, T = 0 \sim 0.35$  s 时,SBSA16 模型的预测值要高于其余两个模型,其余两个模型预测值相差并不是很大;在  $T = 0.35 \sim 6.0$  s 时,DNN 模型和 SBSA16 模型预测值要高于本文模型。当  $M_w = 7$  时,DNN 模型预测值整体偏高,SBSA16 模型预测值要高于本文模型。




图 10  $M_w = 5, 6, 7, R_{JB} = 70$  km,  $V_{S30} = 750$  m/s 走滑地震  $S_a$  随周期  $T$  变化图

Fig. 10 Variation of  $S_a$  with period  $T$  for strike-slip earthquakes with  $M_w = 5, 6, 7, R_{JB} = 70$  km and  $V_{S30} = 750$  m/s

更进一步,为了说明不同断层类型对竖向地震动反应谱的影响,本文分别对不同断层类型下的竖向地震动反应谱进行了预测对比分析,图 11 表示的是  $M_w = 6, R_{JB} = 50, 100, 150$  km, 不同断层类型地震在场地  $V_{S30}$  为 750 m/s 时的不同周期的  $S_a$  预测值,由图可知,当  $R_{JB} = 50$  km,  $T = 0 \sim 0.2$  s 时逆断层下的竖向地震动预测值略高于其余两个断层,其余两个断层类型下的预测值相差不大,在  $T = 1 \sim 6$  s 时,正断层下的竖向地震动预测值高于其余两个模型,当  $R_{JB} = 100, 150$  km, 在  $T = 0 \sim 0.2$  s 时逆断层下的竖向地震动预测值同样高于其余两个断层,并且随着断层距的不断减小,逆断层下的竖向地震动在短周期时的预测值要更高于其余两个断层。由此可知,在短周期时逆断层的地面振动较为剧烈,这是因为在短周期时逆断层的运动与高频地震波的传播相匹配,使得逆断层在短周期反应谱上表现得较显著,而在长周期时低频地震波与正断层的运动方式较契合,使得正断层在长周期反应谱上贡献更大。




图11  $M_w=6$ ,  $R_{JB}=50, 100, 150$  km,  $V_{S30}=750$  m/s 不同断层类型地震  $S_a$  随周期  $T$  变化图

Fig. 11 Variation of  $S_a$  with period  $T$  for different fault type earthquakes with  $M_w=6$ ,  $R_{JB}=50, 100, 150$  km and  $V_{S30}=750$  m/s

## 4 结论

本文选取 NGA-West2 数据库中 9953 条竖向地震动记录,以矩震级  $M_w$ 、断层距  $R_{JB}$ 、不同断层类型、场地  $V_{S30}$  作为输入参数,按照震源项、路径项和场地项 3 组进行输入;采用深度学习算法进行网络训练,建立了竖向地震动 PGA 和不同周期  $S_a$  的预测模型;选用了 MSE、MAE、RMSE 和  $R^2$  这 4 个指标进行本文模型与传统预测公式模型及 DNN 神经网络预测模型的对比,并通过预测值与真实值对比和残差分析证明了预测结果的合理性。最后,将本文模型与用传统回归方法建立的预测公式以及 DNN 模型在一定条件下的预测结果进行了对比,进一步验证本文深度学习模型的合理性。主要得到以下结论:

1) 对本文预测模型进行事件内和事件间残差分析表明,事件内残差主要集中分布在  $[-2, 2]$  内,事件间残差主要集中分布在  $[-1, 1]$  内并在残差为 0 的基准线两侧呈现均匀分布,而且随着矩震级  $M_w$ 、断层距  $R_{JB}$ 、场地  $V_{S30}$  等参数均无明显变化趋势,证明本文深度学习模型预测结果具有合理性和可靠性。

2) 对本文深度学习预测模型与传统预测公式和 DNN 神经网络模型的 4 个性能指标对比表明,本文深度学习模型的 MSE、MAE、RMSE 均低于传统预测公式和 DNN 模型,  $R^2$  高于传统预测公式和 DNN 模型,证明本文深度学习模型预测结果更准确。

3) 竖向地震动反应谱预测结果分析表明,反应谱的谱值随着断层距的不断增大而逐渐减小,并且随着断层距的增加衰减加快;随着矩震级的不断增大而增大,并且增长速度逐渐变缓;随着场地  $V_{S30}$  的不断增大而减小并且衰减速度逐渐变慢。

4) 在  $M_w=5, 6, 7$  这 3 个不同震级,在短周期时反应谱谱值随着周期  $T$  的不断增大而增大,在  $T=0.2$  s 时达到顶峰;而在长周期时反应谱谱值随着周期  $T$  的不断增大而减小。不同断层类型预测结果对比分析表明,逆断层在短周期反应谱上表现得较显著,而在长周期部分正断层对反应谱的贡献较大。

## 参考文献:

- [1] 姜治军, 胡进军, 张齐, 等. 考虑土层非线性效应的四川地区场地放大系数模型[J]. 岩土工程学报, 2016, 38(9): 1650-1659.  
JIANG Zhijun, HU Jinjun, ZHANG Qi, et al. Site amplification factor model for Sichuan region considering nonlinear soil effects[J]. Chinese Journal of Geotechnical Engineering, 2016, 38(9): 1650-1659. (in Chinese)
- [2] STEWART J P, BOORE D M, SEYHAN E, et al. NGA-West2 equations for predicting vertical-component PGA, PGV, and 5%-damped PSA from shallow crustal earthquakes[J]. Earthquake Spectra, 2016, 32(2): 1005-1031.
- [3] BOZORGNIYA Y, CAMPBELL K W. Vertical ground motion model for PGA, PGV, and linear response spectra using the NGA-West2 database[J]. Earthquake Spectra, 2016, 32(2): 979-1004.
- [4] 李宁, 刘洪国, 刘平, 等. 近断层竖向地震动特征统计分析[J]. 土木工程学报, 2020, 53(10): 120-128.  
LI Ning, LIU Hongguo, LIU Ping, et al. Statistical analysis of vertical ground motion characteristics in near-fault regions[J]. China Civil Engineering Journal, 2020, 53(10): 120-128. (in Chinese)
- [5] 李恒, 秦小军. 竖向与水平向地震动加速度反应谱比特性分析[J]. 地震工程与工程振动, 2010, 30(1): 8-14.  
LI Heng, QIN Xiaojun. Study on characteristics of vertical to horizontal acceleration response spectral ratio[J]. Journal of Earthquake Engineering and Engineering Vibration, 2010, 30(1): 8-14. (in Chinese)
- [6] JI D F, LIU J, WEN W P, et al. Prediction of cumulative absolute velocity based on refined second-order deep neural network[J]. Journal of

- Earthquake Engineering, 2022, 26(15): 8021–8040.
- [ 7 ] WITHERS K B, MOSCHETTI M P, THOMPSON E M. A machine learning approach to developing ground motion models from simulated ground motions[J]. Geophysical Research Letters, 2020, 47(6): e2019GL086690.
- [ 8 ] 余聪, 宋晋东, 李山有. 基于支持向量机的现地地震预警地震动峰值预测[J]. 振动与冲击, 2021, 40(3): 63–72, 80.  
YU Cong, SONG Jindong, LI Shanyou. Prediction of peak ground motion for on-site earthquake early warning based on SVM[J]. Journal of Vibration and Shock, 2021, 40(3): 63–72, 80. (in Chinese)
- [ 9 ] 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.
- [ 10 ] 贾佳, 公茂盛, 赵一男. 基于机器学习算法的 2023 年土耳其地震显著持时预测模型[J]. 世界地震工程, 2023, 39(3): 27–38.  
JIA Jia, GONG Maosheng, ZHAO Yinan. Prediction model of ground-motion significant duration of 2023 Turkey earthquake based on machine learning algorithm[J]. World Earthquake Engineering, 2023, 39(3): 27–38. (in Chinese)
- [ 11 ] 靳超越, 胡进军, 胡磊, 等. 基于机器学习的地震动特征提取与模拟——以 2021 年云南漾濞 6.4 级地震为例[J]. 世界地震工程, 2021, 37(4): 73–80.  
JIN Chaoyue, HU Jinjun, HU Lei, et al. Machine learning-based seismic feature extraction and simulation: A case study of the 2021 Yangbi  $M_{6.4}$  earthquake[J]. World Earthquake Engineering, 2021, 37(4): 73–80. (in Chinese)
- [ 12 ] 朱景宝, 宋晋东, 李山有. 基于支持向量机的 2021 年 2 月 13 日日本福岛近海  $M_{7.3}$  级地震震级估算[J]. 世界地震工程, 2021, 37(2): 74–81.  
ZHU Jingbao, SONG Jindong, LI Shanyou. Magnitude estimation for the February 13, 2021  $M_{7.3}$  earthquake near the coast of Fukushima Japan based on support vector machine[J]. World Earthquake Engineering, 2021, 37(2): 74–81. (in Chinese)
- [ 13 ] 李逸群. 基于深度学习的余震地震动衰减关系研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.  
LI Yiqun. Aftershock ground motion attenuation relationships based on deep learning [D]. Harbin: Harbin Institute of Technology, 2019. (in Chinese)
- [ 14 ] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436–444.
- [ 15 ] Pacific Earthquake Engineering Research Center. NGA-West2 ground motion prediction equations for vertical ground motions[R]. University of California, Berkeley, 2013.
- [ 16 ] ABADI M, BARHAM P, CHEN J, et al. TensorFlow: a system for large-scale machine learning [C] // Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI16). USA: USENIX Association, 2016.
- [ 17 ] KINGMA D P, BA J L. Adam: A method for stochastic optimization [C] // Proceedings of the International Conference on Learning Representations. San Diego: ICLR, 2015.
- [ 18 ] BALTAY A S, HANKS T C, ABRAHAMSON N A. Uncertainty, variability, and earthquake physics in ground-motion prediction equations[J]. Bulletin of the Seismological Society of America, 2017, 107(4): 1754–1772.