

苏闻浩,刘启方. 2024. 基于 BP 神经网络的场地等效剪切波速变化预测研究[J]. 地震研究, 47(2): 280–289, doi:10.20015/j.cnki.ISSN1000-0666.2024.0016.

Su W H, Liu Q F. 2024. Research on prediction of site equivalent shear wave velocity change based on BP neural network[J]. *Journal of Seismological Research*, 47(2): 280–289, doi:10.20015/j.cnki.ISSN1000-0666.2024.0016.

基于 BP 神经网络的场地等效剪切波速变化预测研究*

苏闻浩, 刘启方*

(苏州科技大学 江苏省结构工程重点实验室, 江苏 苏州 215009)

摘要: 利用日本 KiK-net 台网提供的 407 个台站的 30 952 条地震动记录, 提出了一种基于 BP 神经网络的场地等效剪切波速比变化预测模型。模型采用了均方误差函数及 Adam 优化算法, 由 3 个输入参数、5 个隐藏神经元及 1 个输出参数组成。输入参数为地面峰值加速度 PGA 、Arias 烈度 I_a 及场地剪切波速 $V_{S_{30}}$, 输出为场地等效剪切波速比 (V_{S_r})。研究表明: 该神经网络模型残差对于各输入变量整体呈现出无偏的特性, 在大部分的软硬场地中均有较好的预测性能, 该模型预测得到的 PGA 关于 $V_{S_{30}}$ 的相关系数曲线与用传统的最小二乘法回归得到的函数曲线相比, 其相关系数有更好的表现。该模型预测曲线显示, B 类场地在 PGA 达到 175 cm/s^2 时, 场地剪切波速下降 5%, D、E 类场地在 PGA 达到 140 cm/s^2 时, 场地剪切波速下降 5%, 多数场地的非线性阈值为 $50\sim 100\text{ cm/s}^2$ 。 PGA 在该网络模型中占据着较高的权重, 为场地等效剪切波速变化的最主要控制参数。该网络模型捕捉到场地等效剪切波速比随 PGA 的增大下降的趋势, 而较为松软的 D、E 类场地受 PGA 影响更大, 下降幅度更大。

关键词: 神经网络; 等效剪切波速; 场地非线性; 参数预测; 地表峰值加速度

中图分类号: P315.7 **文献标识码:** A **文章编号:** 1000-0666(2024)02-0280-10

doi:10.20015/j.cnki.ISSN1000-0666.2024.0016

0 引言

场地非线性研究是地震工程领域的重要课题之一, 它对近断层地震动模拟、地震动预测方程的建立、震害评估等都具有重要的理论意义和工程应用价值。早期的研究表明, 场地非线性反应阈值介于 $100\sim 200\text{ cm/s}^2$ (Beresnev, Wen, 1996), 近期的研究则表明场地非线性反应阈值低于该值, 如 Rubinstein (2011) 通过美国加州地震动记录研究发现地震动强度达到 35 cm/s^2 时就能观察到场地非线性反应; 一些学者基于日本 KiK-Net 台网的地震动观测数据证实了非线性场地反应普遍存在于中等强度的地震动中, 如 Ghofrani 等 (2013)

估计的 49 个台阵的场地非线性反应阈值介于 $40\sim 150\text{ cm/s}^2$; Wu 等 (2010) 估计的 6 个 KiK-Net 台阵的场地非线性反应阈值介于 $20\sim 80\text{ cm/s}^2$; Regnier 等 (2013) 估计的 36 个 KiK-Net 台阵的场地非线性反应阈值介于 $20\sim 500\text{ cm/s}^2$ 。

近年来, 有大量的研究表明神经网络在处理复杂回归预测问题时具有较好表现, 且在处理地震动预测问题时具有优势 (Derras *et al*, 2014; 万永革, 李鸿吉, 1995), 基于数据驱动的人工神经网络可以在不构建具体函数关系式的前提下直接构建端到端的预测模型, 如 Kerb 和 Ting (2005) 基于多层前馈神经网络, 利用 30 个台站的历史地震记录, 估算了高速铁路系统车站的峰值加速度; Alavi 和 Gandomi (2011) 将人工神经网络和模拟

* 收稿日期: 2023-02-05.

基金项目: 国家自然科学基金项目 (51978434).

第一作者简介: 苏闻浩 (1998-), 硕士研究生在读, 主要从事地震工程研究工作. E-mail: 18862633233@163.com.

通信作者简介: 刘启方 (1969-), 研究员, 博士生导师, 主要从事地震工程研究工作.

E-mail: Qifang_liu@126.com.

退火算法相结合,使用震级、震中距、场地等效剪切波速和断层机制来预测地面峰值加速度、峰值速度和峰值位移; Dhanya 和 Raghukanth (2017) 基于人工神经网络构建了一个适用于浅源地震的地震动参数预测模型,利用震级、震中距、场地剪切波速 V_{S30} 和震源机制这 4 个参数预测地面峰值速度、加速度和 5% 的阻尼谱加速度。

场地非线性所导致的场地等效剪切波速的下降是场地分析中的重要问题,目前的研究中多使用传统回归的方法来回归单个台站的变化曲线,该方法仅能反映特定台站的情况且无法应用于部分数据量较少的台站,存在一定的局限性。本文建立了一个 BP 神经网络预测模型,用来预测在地震动作用下,场地的剪切波速下降情况并判断产生非线性变化的大致区间。

1 数据库创建

1.1 数据选取

日本 KiK-net 台网具有较为完整的场地信息

和大量的井上井下地震动信息,站井的深度分布介于 100 ~ 2 500 m。本文搜集整理了 KiK-net 台网观测到的地表与井下地震动记录。考虑到大震发生后场地的剪切波速会在短期内快速恢复到 90% 以上并呈现出长期缓慢恢复的性质(苗雨等, 2018), 因此对 $PGA > 500 \text{ cm/s}^2$ 地震后 100 d 内的数据进行删减,将各地震动事件东西向及南北向作为两次独立的观测结果(董凯月, 2020), 最终筛选出近 20 年来具有完整地质资料的 407 个台站中的 30 952 条地震动记录。对数据进行基线校正和 1 ~ 13 Hz 滤波处理后,数据库中 $PGA < 20 \text{ cm/s}^2$ 的记录共 17 584 条, $PGA > 20 \text{ cm/s}^2$ 的记录部分组成如图 1 所示。 $20 \text{ cm/s}^2 < PGA < 60 \text{ cm/s}^2$ 的记录共 7 910 条, $PGA > 60 \text{ cm/s}^2$ 的记录共有 5 458 条。本文所选地震动记录的震级与震中距散点分布如图 2 所示。根据美国 NEHRP 规范(表 1),统计出每类场地地震动记录所占比例,如图 3 所示,图中无 A 类场地, B 类场地所占比例为 7%, E 类场地所占比例最低,为 2.1%, 本文选取的台站以 C 类和 D 类为主。

表 1 NEHRP 规范分类

Tab. 1 Site classification by NEHRP specification

场地类别	A	B	C	D	E
$V_{S30} / (\text{m} \cdot \text{s}^{-1})$	$V_{S30} > 1\ 500$	$760 < V_{S30} \leq 1\ 500$	$360 < V_{S30} \leq 760$	$180 < V_{S30} \leq 360$	$V_{S30} \leq 180$

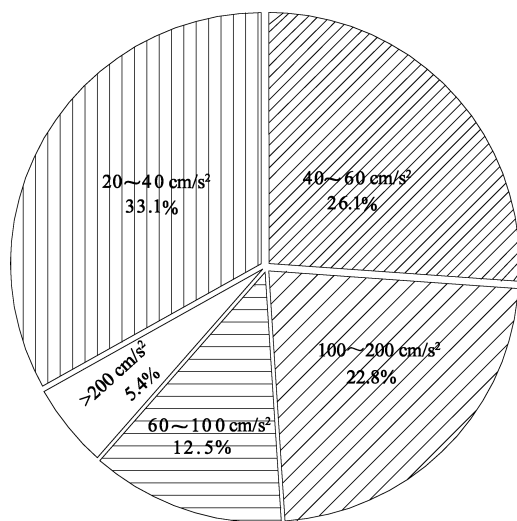


图 1 KiK-net 台网 $PGA > 20 \text{ cm/s}^2$ 记录分布

Fig. 1 The distribution of $PGA > 20 \text{ cm/s}^2$ records

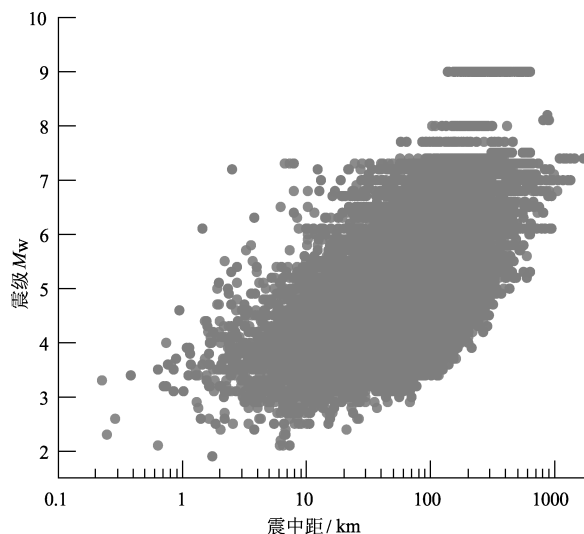


图 2 本文选取地震动记录的震级与震中距散点分布

Fig. 2 Distribution of magnitude and epicentral distance

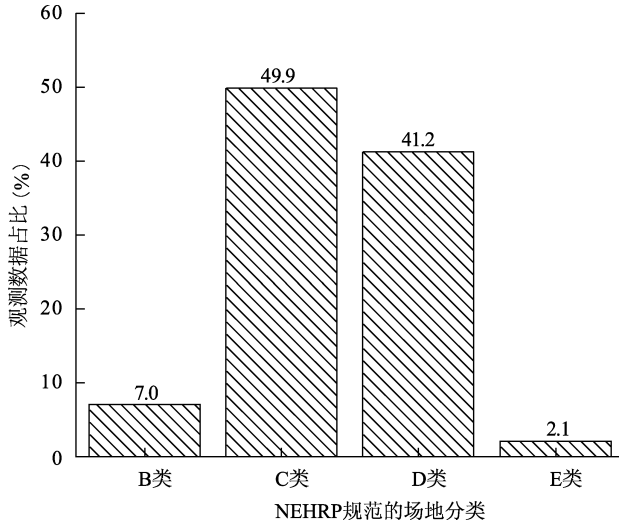


图3 根据 NEHRP 规范划分的场地分类统计
各场地地震记录所占比例

Fig. 3 Proportion of PGA at each site according
to NEHRP specification

1.2 等效剪切波速估计

本文通过井上井下解卷积求取场地等效剪切波速 (张亚沛, 2019; 刘启方, 陈长龙, 2022)。设地表和井下加速度记录的傅立叶谱分别为 $U_1(\omega)$ 和 $U_2(\omega)$, 应用解卷积法首先计算系统的传递函数 $G(\omega)$:

$$G(\omega) = \frac{U_1(\omega)}{U_2(\omega)} = \frac{U_1(\omega) U_2^*(\omega)}{|U_2(\omega)|^2} \quad (1)$$

式中: * 表示复共轭, 分子为地表与井下加速度在频域内的互相关函数, 分母为井下加速度的功率谱。为了避免分母中谱值很小引起的不稳定性, 一般采用 $U_2'(\omega)$ 对 $U_2(\omega)$ 进行校正:

$$|U_2'(\omega)|^2 = \begin{cases} |U_2(\omega)|^2 & \text{当 } |U_2(\omega)| \geq 0.1 \max |U_2(\omega)| \\ 0.1 \max |U_2(\omega)|^2 & \text{当 } |U_2(\omega)| < 0.1 \max |U_2(\omega)| \end{cases} \quad (2)$$

对 $G(\omega)$ 进行傅立叶反变换到时域 $g(t)$, 即为井下脉冲输入时地表的响应。通过脉冲响应 (脉冲的峰值到时) 获得井下台站到地表地震波的传播时间, 用该站井深度除以传播时间, 计算该场地土体等效剪切波速 V_s 。

场地等效剪切波速比 V_{s_r} 计算公式为:

$$V_{s_r} = \frac{V_s}{V_{s_0}} \quad (3)$$

式中: V_{s_0} 为该场地的原始等效剪切波速值, 取该场地 $PGA < 20 \text{ cm/s}^2$ 的弱震动作用下场地等效剪切波速的平均值 (苗雨等, 2018, 2021)。

2 BP 神经网络模型搭建

2.1 BP 神经网络模型

BP 神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络。该网络模型具有函数逼近的属性, 可以在不考虑输入与输出间具体函数关系的前提下, 通过机器学习的方法, 构建出一种输入与输出的映射, 拟合任意复杂的连续函数。BP 神经网络包括一个输入层、多个隐藏层和一个输出层, 每一层由不同数量的人工神经元组成, 网络结构如图 4 所示。

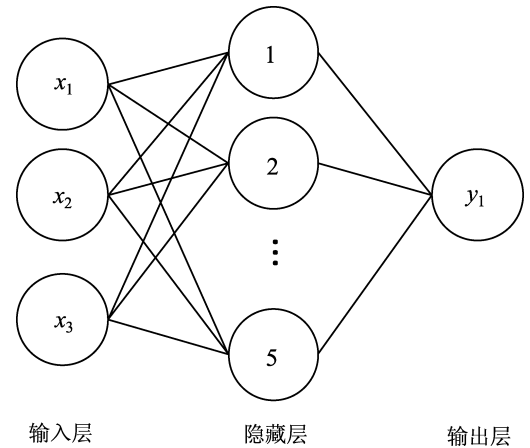


图4 BP 神经网络结构

Fig. 4 Multilayer perceptron of BP Neural Network

隐藏层中第 i 个神经元的输出可以写为:

$$y_{ij} = \varphi(\sum w_{ij} + b_j) \quad (4)$$

式中: w_{ij} 表示神经网络中第 i 层与第 $i-1$ 层神经元之间的权重; b_j 表示神经网络中第 i 层第 j 个神经元线性层的偏置; φ 表示激活函数。激活函数的类型有很多种, 本文输出层采用线性激活函数 linear (式 5), 隐藏层采用 tanh 激活函数 (式 6):

$$\text{linear}(x) = x \quad (5)$$

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (6)$$

2.2 网络模型的开发及评价指标

目前,研究人员多以 PGA 来表征场地的非线性阈值 (Chin, Aki, 1991; Wu *et al*, 2010; Wang *et al*, 2019), 由于该值仅能表征某次事件的峰值强度, 因此本文还使用了 Arias 烈度 (I_a) 来表征某次事件整体能量大小 (Benito, Herraiz, 1997; Chousianitis *et al*, 2014, 2016), 以及场地剪切波速 V_{s30} 来表征场地情况。经过多次尝试, 建立了一个包含 3 个输入参数 (PGA 、 I_a 、 V_{s30})、5 个隐藏神经元、1 个输出参数 (V_{s_r}) 的 BP 神经网络模型, 其预测过程可表示为:

$$V_{s_r} = f[PGA, \ln(I_a), V_{s30}] \quad (7)$$

式中: I_a 为 Arias 烈度, 由于其值分布范围过广, 因此取其自然对数, 以减小其分布范围, 从而加快神经网络梯度的更新, 以有效提高神经网络的收敛速度, 加速模型的训练。

本文采用 Adam 优化算法进行神经网络模型训练, 它可以根据学习环境自适应调整学习率, 使得神经网络得以更快收敛, 同时对初始的超参数设置不敏感, 方便了神经网络的学习 (Kingma, Ba, 2014)。对模型预测效果的评价, 本文选用 MSE 作为模型的损失函数 (Dhanya *et al*, 2017), 使用 MSE , 其计算公式分别为及皮尔逊相关系数作为模型的评价指标:

$$MSE(x, y) = \frac{1}{m} \sum_{i=1}^m (x_i - y_i)^2 \quad (8)$$

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (9)$$

式中: x_i 为目标数据或记录数据; y_i 为预测数据; m 为该批数据点总数; \bar{x} 、 \bar{y} 为该批次目标数据和预测数据的均值。

3 网络模型性能分析

3.1 模型性能

本文筛选出地震动记录较多、 PGA 分布较广的 6 个包含不同场地类型的台站作为测试台站进行

图像分析及模型评价, 其场地情况见表 2, 测试台站不参与训练。

表 2 本文所选 6 个台站场地情况

台站代号	$V_{s30}/(m \cdot s^{-1})$	NEHRP 规范场地分类
MYGH04	850	B
TCGH07	419	C
FKSH19	338	D
IBRH11	242	D
IBRH13	335	D
NMRH04	168	E

本文使用场地非线性研究中常用的传统双曲线回归模型作为模型 1, 表示为:

$$y = \frac{1}{1 + kx} \quad (10)$$

式中: x 为 PGA ; y 为场地等效剪切波速比; k 为回归参数。使用模型 1, 对 6 个台站的 V_{s_r} 关于 PGA 的变化做了回归分析, 拟合参数见表 3。通过训练所得 BP 神经网络模型对 6 个台站的 V_{s_r} 进行预测, 模型 1 与神经网络模型预测结果如图 5 所示。由于 V_{s_r} 为场地等效剪切波速与弱震动作用下场地等效剪切波速均值的比值, 因此比弱震动作用下场地等效剪切波速均值高的计算值会出现 V_{s_r} 大于 1.0 的结果。

表 3 使用模型 1 得到 V_{s_r} 关于 PGA 变化的回归参数

台站代号	MYGH04	TCGH07	FKSH19
k	2.8×10^{-4}	4.3×10^{-4}	2.9×10^{-4}
台站代号	IBRH13	IBRH11	NMRH04
k	3.1×10^{-4}	3.1×10^{-4}	2.7×10^{-4}

由图 5 可见, 用 BP 神经网络模型预测所得曲线与模型 1 拟合曲线整体上较为相似, 两者均呈现出 V_{s_r} 随 PGA 的增大而逐渐减小的特性。在测试台站的各场地类型中, 当 $PGA = 50 \text{ cm/s}^2$ 时, 用 BP 神经网络模型得到的 V_{s_r} 预测值均未小于 0.99; 当 $PGA = 100 \text{ cm/s}^2$ 时, 各场地 V_{s_r} 下降幅度约为 2% ~ 3%, 场地 V_{s_r} 开始呈现非线性变化, 多数场地的非线性阈值约为 50 ~ 100 cm/s^2 ; 当 $PGA >$

100 cm/s^2 后, 场地 V_{S_r} 的非线性变化较为显著。在测试台站中, 对于较硬的 B 类场地, 其 PGA 达到 175 cm/s^2 左右时, 场地 V_{S_r} 下降约 5%; 对于较松软的 D、E 类场地, PGA 达到 140 cm/s^2 左右时,

V_{S_r} 即下降约 5%。图中 E 类场地的 BP 神经网络预测曲线波动较大, 推测是由于 E 类场地训练数据相对较少, 训练不够充分所导致。训练得到的 BP 神经网络模型各层参数见表 4、5。

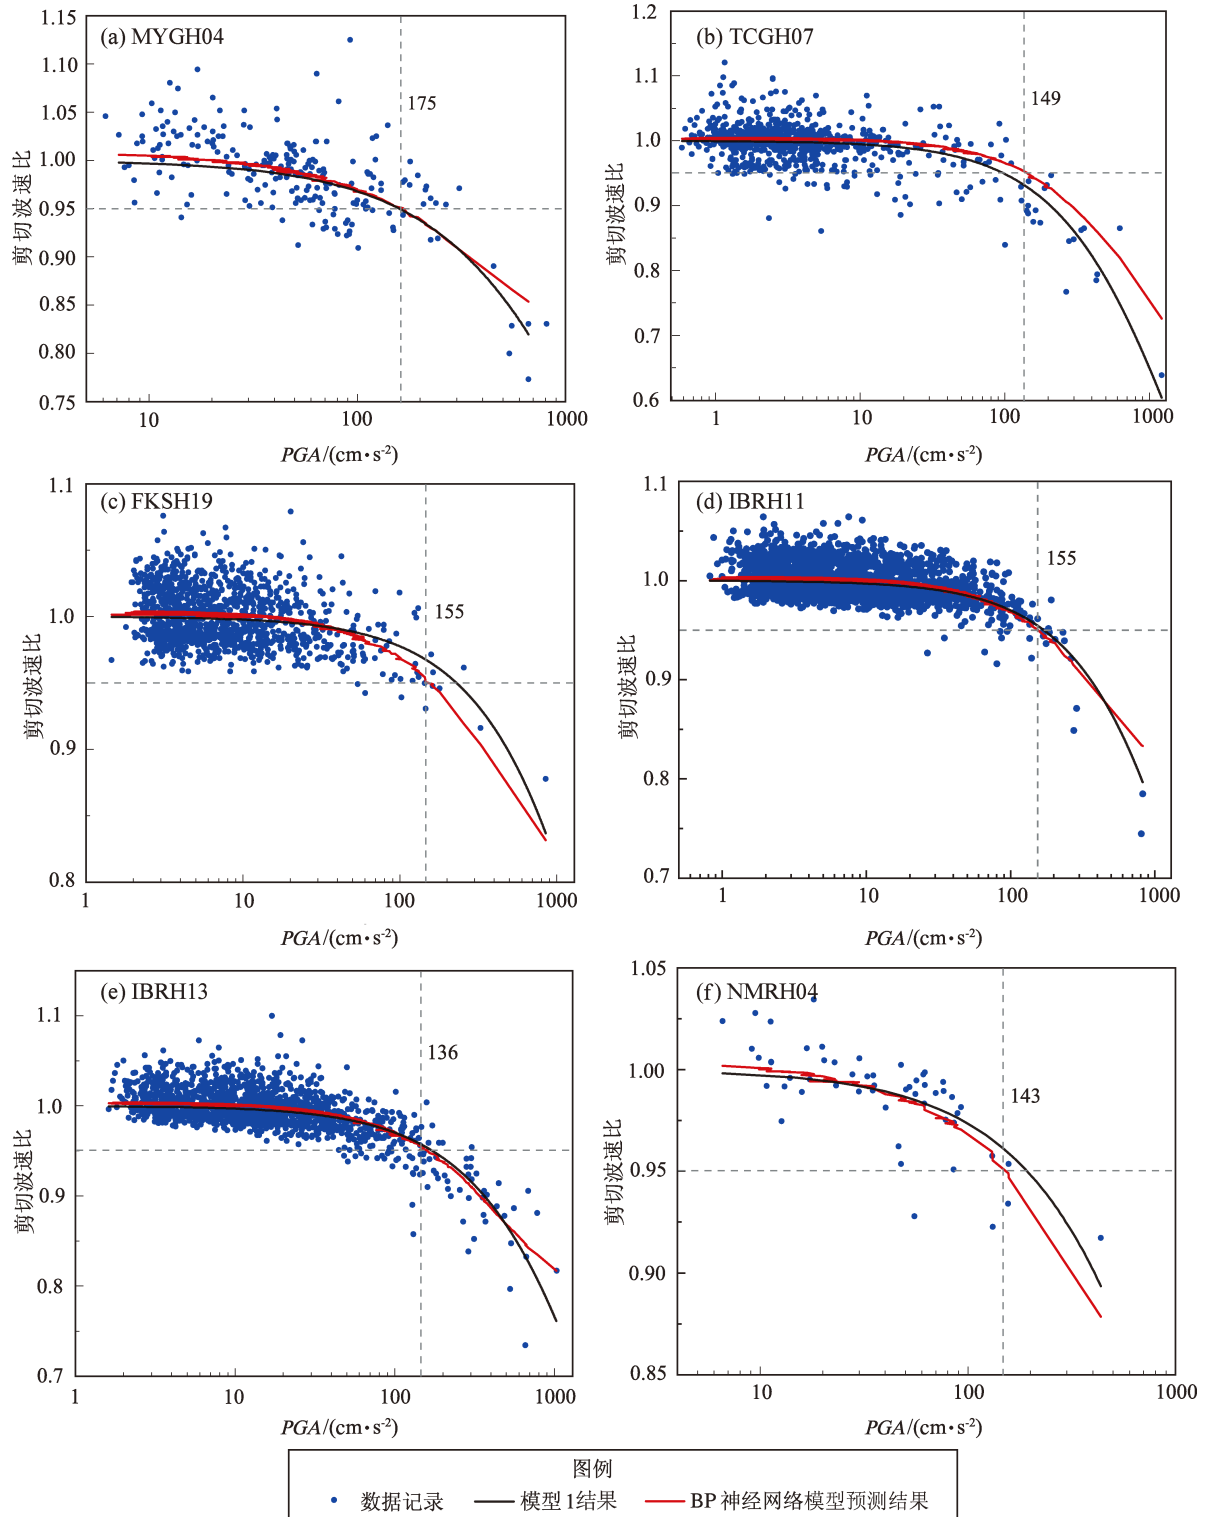


图5 本文所选6个台站的等效剪切波速比随 PGA 变化的预测曲线

Fig. 5 Predicted curves of the equivalent shear wave velocity ratio of six stations changing with PGA

表 4 输入层 - 隐藏层神经元参数

Tab. 4 Neuron parameters of the input layer and the hidden layer

权值	输入参数	隐藏层神经元/m				
	i	1	2	3	4	5
$W_{i,m}$	PGA	3.484	-0.071	-0.337	0.775	0.547
	$\ln(I_a)$	0.460	-0.195	0.860	-0.266	-0.281
	$V_{S_{30}}$	0.096	-0.610	0.798	0.310	-0.559
b_m		-0.292	0.269	0.959	-0.057	-0.784

表 5 隐藏层 - 输出层神经元参数

Tab. 5 Neuron parameters of the hidden layer and the output layer

权值	输出参数	隐藏层神经元/m				
	j	1	2	3	4	5
$W_{j,m}$	V_{S_r}	0.197	0.219	-0.054	0.212	-0.241
b_j		-0.115				

训练完成后，训练集的 MSE 为 6×10^{-4} ，测试台站数据集的 MSE 为 6.7×10^{-4} 。训练集与测试台站数据集的均方误差相似，模型整体表现良好，未出现过拟合现象。

使用 BP 神经网络模型及模型 1 计算得到 6 个台站的 Person 相关系数，结果见表 6。从表中可见，BP 神经网络模型对场地等效剪切波速比的预测相较于模型 1，其相关系数相对较高，其预测表现均不弱于模型 1，整体上有着更好的预测性能。

表 6 用 BP 神经网络模型和最小二乘法计算得到的相关系数对比

Tab. 6 Comparison of correlation coefficients of different models

台站	NEHRP 规范划分的 场地分类	相关系数 r	
		BP 神经网络模型	模型 1
MYGH04	B	0.689	0.689
TCGH07	C	0.649	0.647
IBRH11	D	0.520	0.510
IBRH13	D	0.739	0.724
FKSH19	D	0.647	0.643
NMRH04	E	0.732	0.737

3.2 残差分析

通常使用残差分析作为主要手段分析神经网络的性能。残差分析可以反映预测的输出与输入变量的整体性关系，可分析该网络在整个数据区

间上整体预测性能的好坏 (Dhanya, Raghukanth, 2020)。本文将残差定义为预测值与目标值之差，如下所示：

$$R_i = y_{\text{pred}} - y_{\text{target}} \quad (11)$$

图 6 展示了 BP 神经网络模型 3 个输入变量 PGA 、 $\ln(I_a)$ 和 $V_{S_{30}}$ 对应于输出变量 V_{S_r} 的模型残差，图中橙色误差棒为各区间上的所有残差作均值及标准差处理。表 7 给出了 3 个输入变量在各区间的残差分布统计，由表可见，在各个区间上，该网络模型均值残差均在 0 附近，整体呈现出无偏特性，对于 PGA 及 I_a 较高的强震数据，可能是由于数据量较少且数据的离散度较大，因此其残差有着相对更大的标准差。 $V_{S_{30}}$ 为 120 ~ 1 270 m/s 时，均有较低的均值残差及标准差，表明其在多数软硬场地中均有较好的预测性能。

表 7 PGA 、 $\ln(I_a)$ 和 $V_{S_{30}}$ 在各区间的残差分布统计

Tab. 7 Statistics of residual error distribution in each interval of PGA , $\ln(I_a)$ and $V_{S_{30}}$

输入参数	分布区间	均值	方差	标准差
$PGA/$ ($\text{cm} \cdot \text{s}^{-2}$)	1 ~ 4	3.68×10^{-4}	3.24×10^{-4}	0.018
	4 ~ 10	3.39×10^{-4}	5.29×10^{-4}	0.023
	10 ~ 40	-2.34×10^{-4}	6.25×10^{-4}	0.025
	40 ~ 100	3.43×10^{-4}	8.41×10^{-4}	0.029
	100 ~ 400	9.03×10^{-4}	1.85×10^{-3}	0.043
	400 ~ 1 100	-5.56×10^{-3}	3.48×10^{-3}	0.059
$\ln(I_a)$	-2 ~ 0	1.11×10^{-3}	4.41×10^{-4}	0.021
	0 ~ 2	-9.26×10^{-4}	4.84×10^{-4}	0.022
	2 ~ 4	4.98×10^{-4}	6.25×10^{-4}	0.025
	4 ~ 6	4.88×10^{-4}	7.29×10^{-4}	0.027
	6 ~ 8	1.15×10^{-3}	1.02×10^{-3}	0.032
	8 ~ 10	-1.89×10^{-3}	2.20×10^{-3}	0.047
$V_{S_{30}}/$ ($\text{m} \cdot \text{s}^{-1}$)	10 ~ 12	-1.87×10^{-3}	2.30×10^{-3}	0.048
	120 ~ 300	-7.03×10^{-5}	4.76×10^{-4}	0.022
	300 ~ 500	-2.38×10^{-6}	6.67×10^{-4}	0.026
	500 ~ 700	1.94×10^{-3}	9.67×10^{-4}	0.031
	700 ~ 900	5.28×10^{-4}	1.12×10^{-3}	0.033
	900 ~ 1 100	-3.51×10^{-3}	1.30×10^{-3}	0.036
	1 100 ~ 1 270	-2.13×10^{-3}	5.65×10^{-4}	0.024

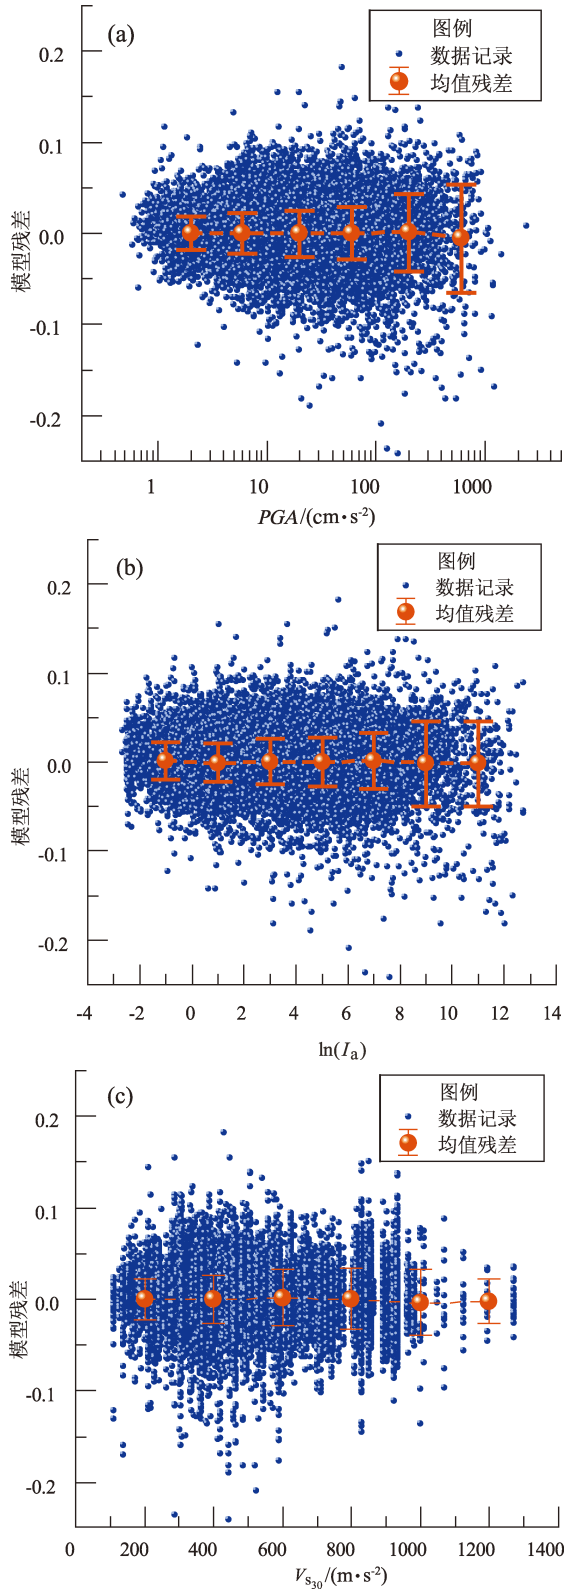


图6 BP神经网络模型输入变量PGA (a)、 $\ln(I_a)$ (b) 和 V_{s30} (c) 相对于输出变量 V_{s_r} 的残差
Fig. 6 Residuals of the input variables PGA (a), $\ln(I_a)$ (b) and V_{s30} (c) of the BP neural network model corresponding to the output variable V_{s_r}

3.3 敏感性分析

对于具有明确函数形式的回归分析, 每个变量的相对重要性可以从优化后得到的系数中确定。但是在BP神经网络中, 由于网络本身是高度复杂的互连节点, 所以想要得到其相关性较为困难。许多研究者尝试了各种技术来获得输入节点对输出的相对影响 (Gevrey *et al*, 2003), 其中最简单直接的方法之一是 Garson (1991) 提出的基于隐藏神经元的连接权值与输入节点相关权值的划分, 根据该方法, 特定输出变量 j 的每个输入变量 i 的相关重要性 RI 为:

$$RI_i(\%) = \frac{\sum_{m=1}^p r_{i,m}}{\sum_{i=1}^n \sum_{m=1}^p r_{i,m}} \times 100\% \quad (12)$$

$$\text{其中 } r_{i,m} = \frac{|W_{i,m} \times W_{j,m}|}{\sum_{i=1}^n |W_{i,m} \times W_{j,m}|} \quad (13)$$

式中: $W_{i,m}$ 为输入层-隐藏层各神经元所对应的权值; $W_{j,m}$ 为隐藏层-输出层各神经元权值; n 和 p 分别为输入参数个数及隐藏层神经元数量。

通过表4、5中的权值, 将式(12)应用于BP神经网络模型上, 所得到的输入参数相对输出参数 V_{s_r} 的相关权重如图7所示。由图7可见, PGA 在该模型中所占权重较大, 为该模型的主要控制参数。

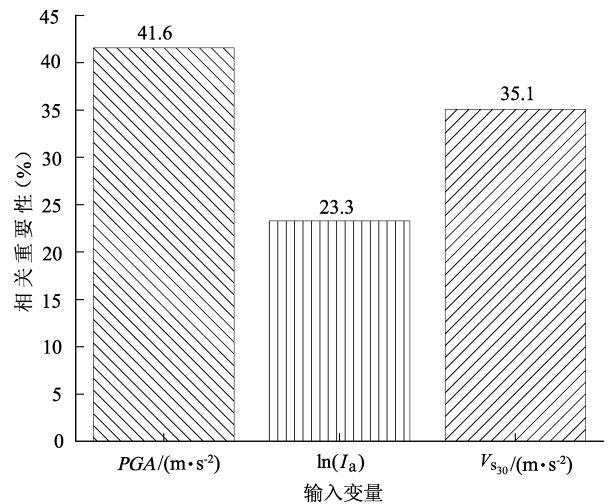


图7 BP神经网络模型输入变量PGA、 $\ln(I_a)$ 和 V_{s30} 相对于等效剪切波速比 V_{s_r} 的相关权重
Fig. 7 Relative importance of PGA, $\ln(I_a)$ and V_{s30} relative to equivalent shear wave velocity ratio V_{s_r}

控制部分输入变量不变, 绘制输出变量随某一输入变量的变化关系曲线, 是神经网络模型验证的常用手段。由于 PGA 为该网络模型的主要控制参数, 而 Arias 烈度参数的权重较低, 仅占 23.3%, 因此本文选取 4 种不同的 V_{s30} 以涵盖 4 类场地 (图 8), 基于模型的预测结果探讨 PGA 和 V_{s_r} 变化的关系。

图 8 为 PGA 关于 V_{s_r} 变化关系。由图 8 可见, V_{s_r} 随 PGA 的增大下降的趋势, PGA 越大, V_{s_r} 下降越快。同时, V_{s30} 越小的松软场地受 PGA 影响越大, 下降幅度也越大。在以往的研究中普遍认为在坚硬的场地中仅会产生很小的非线性变化, 但在本文中 B 类场地在 PGA 较大时仍有一定的等效剪切波速比下降, 推测可能是因为数据库中 B 类场地数据所占比例较少, 且 V_{s30} 与场地整体土层情况仍有一定差异, 导致该网络模型预测结果在 V_{s30} 较高的场地中仍有一定程度的等效剪切波速比下降。

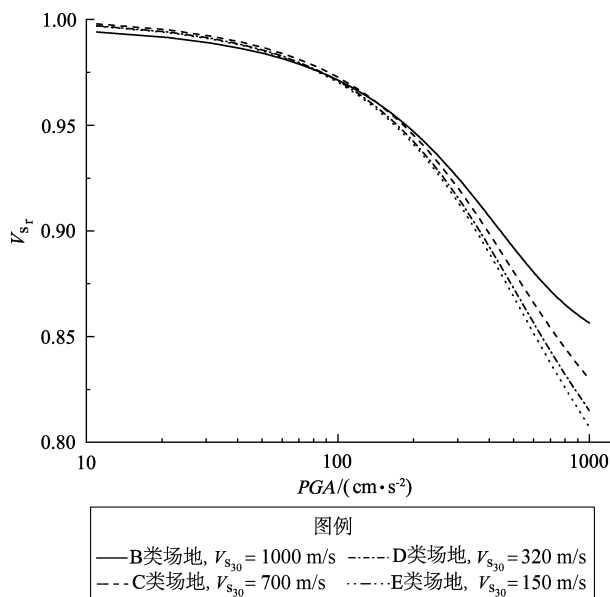


图 8 不同场地等效剪切波速比 V_{s_r} 随 PGA 的变化

Fig. 8 Variation of equivalent shear wave velocity ratio V_{s_r} with PGA in different sites

4 结论

本文使用日本 KiK-net 台网的 407 个台站记录到的 30 952 条记录, 提出了一种基于 BP 神经网络的场地等效剪切波速比变化预测模型。模型采用均

方误差函数以及 Adam 优化算法, 包含 3 个输入参数、5 个隐藏神经元和 1 个输出参数。输入参数为加速度峰 PGA 、Arias 烈度 I_a 及场地剪切波速度 V_{s30} , 输出为场地等效剪切波速比 V_{s_r} , 得到以下结论:

(1) 神经网络模型可以在不构建复杂函数回归关系的情况下, 预测场地的剪切波速变化情况。本文选取的包含不同场地类型的 6 个台站, 通过使用 BP 神经网络对 6 个台站的场地剪切波速比的预测曲线可知, BP 网络模型预测曲线相对光滑, 未出现过拟合现象。相较于使用最小二乘法回归所得的剪切波速比函数曲线, BP 神经网络模型的相关系数较高, 该神经网络模型残差对于各输入变量整体呈现出无偏特性, 在大部分软硬场地中均有较好的预测性能。

(2) 由 BP 神经网络模型预测曲线可知, PGA 为 $50 \sim 100$ cm/s^2 时, 多数场地开始出现非线性变化, 剪切波速开始发生变化; $PGA > 100$ cm/s^2 时, 场地发生显著的非线性变化, 剪切波速开始发生较快变化。 PGA 达到 175 cm/s^2 左右时, B 类场地剪切波速下降 5%, PGA 达到约 140 cm/s^2 时, D、E 类场地剪切波速下降 5%。

(3) 模型敏感性分析表明, PGA 在该神经网络模型中占据着较高的权重, 为场地等效剪切波速比变化的最主要控制参数。该神经网络模型捕捉到场地等效剪切波速比随 PGA 的增大下降的趋势, 而较为松软的 D、E 类场地受 PGA 影响更大, 下降的幅度也更大。

(4) 在数据较少的 B、E 类场地中, 基于数据驱动神经网络模型存在一定的训练风险, 是后续研究中需要讨论的一个关键问题。

本文使用了日本 KiK-net 台网提供的地震动数据, 在此表示感谢。

参考文献:

- 董凯月. 2020. 基于深度神经网络的地下地震动参数预测研究[D]. 哈尔滨: 哈尔滨工业大学.
- Dong K Y. 2020. Study on the prediction of underground motion parameters based on deep neural network[D]. Harbin: Harbin Institute of Technology. (in Chinese)
- 刘启方, 陈长龙. 2022. 基于移动窗解卷积法的 2011 年日本东北 $M_w 9.0$ 大地震场地非线性时变识别[J]. 地震学报, 44(1): 96-110.

- Liu Q F, Chen C L. 2022. Identification of the temporal changes of site non-linearity during 2011 M_w 9.0 Tohoku earthquake by moving time window deconvolution method[J]. *Acta Seismologica Sinica*, 44(1): 96 – 110. (in Chinese)
- 苗雨, 施洋, 王苏阳, 等. 2018. 基于竖向台阵地震记录的非线性场地反应研究[J]. *自然灾害学报*, 27(6): 51 – 58.
- Miao Y, Shi Y, Wang S Y, *et al.* 2018. Assessing nonlinear soil behavior using vertical array data; A case at TCGH16 station from KiK – Net in Japan[J]. *Journal of Natural Disasters*, 27(6): 51 – 58. (in Chinese)
- 苗雨, 施洋, 张昊, 等. 2021. 基于地震观测记录的场地竖向非线性性质[J]. *北京工业大学学报*, 47(7): 669 – 679.
- Miao Y, Shi Y, Zhang H, *et al.* 2021. Investigating vertical nonlinearity of site using KiK – net seismic data[J]. *Journal of Beijing University of Technology*, 47(7): 669 – 679. (in Chinese)
- 万永革, 李鸿吉. 1995. 人工神经网络在地球物理中的应用综述[J]. *国际地震动态*, (1): 9 – 14.
- Wan Y G, Li H J. 1995. Overview of the application of artificial neural networks in Geophysics[J]. *Progress in Earthquake Sciences*, (1): 9 – 14. (in Chinese)
- 张亚沛. 2019. 基于 KIK – NET 数据库的土层特性识别及地下地震动幅值特性研究[D]. 哈尔滨: 哈尔滨工业大学.
- Zhang Y P. 2019. Research on identification of soil characteristics and amplitude characteristics of underground motion based on KiK – Net database[D]. Harbin: Harbin Institute of Technology. (in Chinese)
- Alavi A H, Gandomi A H. 2011. Prediction of principal ground-motion parameters using a hybrid method coupling artificial neural networks and simulated annealing [J]. *Computers & Structures*, 89(23 – 24): 2176 – 2194.
- Benito B, Herraiz M. 1997. An approach to the measurement of the potential structural damage of earthquake ground motions[J]. *Earthquake Engineering and Structural Dynamics*, 26: 79 – 92.
- Beresnev I A, Wen K L. 1996. Nonlinear soil response—A reality? [J]. *Bulletin of the Seismological Society of America*, 86(6): 1964 – 1978.
- Chin B H, Aki K. 1991. Simultaneous study of the source path and site effects on strong ground motion during the 1989 Loma Prieta earthquake; a preliminary result on pervasive nonlinear site effects[J]. *Bulletin of the Seismological Society of America*, 81(5): 1859 – 1884.
- Chousianitis K, Del G V, Kalogeras I, *et al.* 2014. Predictive model of Arias intensity and Newmark displacement for regional scale evaluation of earthquake-induced landslide hazard in Greece [J]. *Soil Dynamics and Earthquake Engineering*, 65(4): 11 – 29.
- Chousianitis K, Del G V, Sabatakakis N, *et al.* 2016. Assessment of earthquake-induced landslide hazard in Greece; From Arias intensity to spatial distribution of slope resistance demand [J]. *Bulletin of the Seismological Society of America*, 106(1): 174 – 188.
- Derras B, Bard P Y, Cotton F. 2014. Towards fully data driven ground-motion prediction models for Europe [J]. *Bulletin Earthquake Engineering*, 12(1): 495 – 516.
- Dhanya J, Raghukanth S T G. 2017. Ground motion prediction model using artificial neural network [J]. *Pure and Applied Geophysics*, 175(3): 1035 – 1064.
- Dhanya J, Raghukanth S T G. 2020. Neural network-based hybrid ground motion prediction equations for Western Himalayas and North – Eastern India [J]. *Acta Geophysica*, 172(3): 762 – 781.
- Garson G D. 1991. Interpreting neural-network connection weights [J]. *AI Expert*, 6: 47 – 51.
- Gevery M, Dimopoulos I, Lek S. 2003. Review and comparison of methods to study the contribution of variables in artificial neural network models [J]. *Ecological Modelling*, 160(3): 249 – 264.
- Ghofrani H, Atkinson G M, Goda K. 2013. Implications of the 2011 M_w 9.0 Tohoku Japan earthquake for the treatment of site effects in large earthquakes [J]. *Bulletin of Earthquake Engineering*, 11(1): 171 – 23.
- Kerb T, Ting S B. 2005. Neural network estimation of ground peak acceleration at stations along Taiwan high-speed rail system [J]. *Engineering Applications of Artificial Intelligence*, 18(7): 857 – 866.
- Kingma D P, Ba J. 2014. Adam: A method for stochastic optimization [C]. ICLR, arXiv preprint arXiv:1412.6980.
- Regnier J, Cadet H, Bonilla L F, *et al.* 2013. Assessing nonlinear behavior of soils in seismic site response; Statistical analysis on Kik-net strong-motion data [J]. *Bulletin of the Seismological Society of America*, 103(3): 1750 – 1770.
- Rubinstein J L. 2011. Nonlinear site response in medium magnitude earthquakes near Parkfield California [J]. *Bulletin of the Seismological Society of America*, 101(1): 275 – 286.
- Wang H Y, Jiang W P, Wang S Y, *et al.* 2019. In situ assessment of soil dynamic parameters for characterizing nonlinear seismic site response using KiK – net vertical array data [J]. *Bulletin of Earthquake Engineering*, 17(5): 2331 – 2360.
- Wu C, Peng Z, Benzon Y. 2010. Refined thresholds for non-linear ground motion and temporal changes of site response associated with medium – size earthquakes [J]. *Geophysical Journal International*, 182(3): 1567 – 1576.

Research on Prediction of Site Equivalent Shear Wave Velocity Change Based on BP Neural Network

SU Wenhao, LIU Qifang

(*Suzhou University of Science and Technology, Key Laboratory of Structure Engineering of Jiangsu Province, Suzhou 215009, Jiangsu, China*)

Abstract

In this paper, a total of 30952 records from 407 stations of the Japanese KiK-net is used to propose a prediction model for the change of equivalent shear wave velocity ratio based on BP neural network. The model adopts the mean square error function and the Adam optimization algorithm, consists of three inputs, five hidden neurons and one output. The input parameters are Peak Ground Acceleration (PGA), Arias intensity (I_a) and site $V_{s_{30}}$. The output parameter is site equivalent shear wave velocity ratio (V_s). The research shows that the residual error of the network model is unbiased for each input variable, and has good prediction performance in many kinds of sites. Compared with the function curve of the traditional least-square method, the neural network model has a relatively better performance. In the prediction curve of the network model, the shear wave velocity of the site of Class B decreases by 5% when the PGA reaches about 175 cm/s^2 , and the shear wave velocity of the sites of Class D and E decreases by 5% when the PGA reaches about 140 cm/s^2 . The nonlinear threshold of most sites is between $50 \sim 100 \text{ cm/s}^2$. PGA occupies a high weight in the network model and is the main controlling parameter of the site equivalent shear wave velocity change. The network model captures that the equivalent shear wave velocity ratio of the site has a downward trend with the increase of PGA . At the same time, it shows that the Class D and E sites are greatly affected by PGA , and the declining range is larger.

Keywords: neural network; equivalent shear wave velocity; site nonlinearity; parameter prediction; peak ground acceleration