

DOI:10.3969/j.issn.1003-5060.2024.06.009

基于 Bi-LSTM 的浅层地下双孔洞探测技术

梁靖^{1,2}, 张红^{1,2}, 叶晨³, 周立成^{1,2}, 刘泽佳^{1,2}, 汤立群^{1,2}

(1. 华南理工大学土木与交通学院, 广东广州 510641; 2. 华南理工大学亚热带建筑科学国家重点实验室, 广东广州 510641; 3. 广州市高速公路有限公司, 广东广州 510289)

摘要: 文章探究一种基于深度学习的浅层地下孔洞探测技术, 以应对地下孔洞给桩基施工安全所造成的严重威胁。基于浅层地震反射波法的原理, 采用基础施工过程中的桩锤激震作为激励源, 通过在探测区域地表上布置少量加速度传感器采集孔洞反射信号, 并将反射信号作为深度学习的输入, 以输出孔洞信息, 建立一种新型的智能孔洞探测方法。结果表明, 双向长短期记忆神经网络 (bidirectional long short-term memory neural network, Bi-LSTM) 的预测模型对于地下双孔洞的工况具有较高的识别准确率, 在容许误差为 2 m 的情况下, 孔洞位置和直径的预测准确率可达 95.3%。该研究验证了基于深度学习的多孔洞探测技术的可行性, 有望为施工前期土层地质状况的评估提供技术保障。

关键词: 地下孔洞探测; 桩锤激震; 深度学习; 双向长短期记忆神经网络 (Bi-LSTM); 有限元仿真

中图分类号: U442.2 **文献标志码:** A **文章编号:** 1003-5060(2024)06-0778-06

Shallow underground double-hole detection technology based on Bi-LSTM

LIANG Jing^{1,2}, ZHANG Hong^{1,2}, YE Chen³,
ZHOU Licheng^{1,2}, LIU Zejia^{1,2}, TANG Liqun^{1,2}

(1. School of Civil Engineering and Transportation, South China University of Technology, Guangzhou 510641, China; 2. State Key Laboratory of Subtropical Building Science, South China University of Technology, Guangzhou 510641, China; 3. Guangzhou Expressway Co., Ltd., Guangzhou 510289, China)

Abstract: This paper explores a shallow underground hole detection technology based on deep learning to deal with the serious threat of underground holes to the safety of pile foundation construction. Based on the principle of shallow seismic reflection wave method, and taking the pile hammer shock in the foundation construction process as the excitation, a new intelligent hole detection method is established by placing a small number of acceleration sensors on the surface of the detection area to collect the hole reflection signal, and take the reflected signal as the input of deep learning to output the hole information. The results show that the bidirectional long short-term memory neural network (Bi-LSTM) prediction model has a high recognition accuracy for the working conditions of underground double holes. When the tolerance error is 2 m, the accuracy of hole location and diameter prediction can reach 95.3%. This study verifies the feasibility of multi-hole detection technology based on deep learning, and is expected to provide technical support for the assessment of soil geological conditions in the pre-construction period.

Key words: underground hole detection; pile hammer shock; deep learning; bidirectional long short-term memory neural network (Bi-LSTM); finite element simulation

收稿日期: 2021-05-18; 修回日期: 2021-06-21

基金项目: 国家自然科学基金资助项目 (11972162); 广州市科技计划资助项目 (201903010046)

作者简介: 梁靖 (1995—), 男, 江西上饶人, 华南理工大学硕士生;

周立成 (1987—), 男, 广东汕头人, 博士, 华南理工大学副教授, 硕士生导师, 通信作者, E-mail: cticzhou@scut.edu.cn.

0 引言

地下孔洞是指岩溶区地下水或地表水的活动对土层产生潜蚀作用及崩解作用所形成的地下空间,是对工程建设最具威胁性的地质现象之一^[1]。在未探明桩位地下孔洞的情况下进行桩基施工,易发生漏浆、埋钻、塌孔等事故^[2]。发展高效、准确的地下孔洞探测技术,可为桩基础施工提供安全保障。

目前,初勘阶段常采用浅层地震反射波法、高密度电法等探测范围较大的手段进行摸查。详勘阶段多用超前钻探的方式进行取芯,或采用弹性波计算机层析扫描(computer tomography, CT)、管波等方法探测钻孔周围一定范围内的地下孔洞的发育情况。其中,超前钻探^[3]是最常用的探测手段,但是钻探直径极小,单一钻孔易发生漏判,若要保证精度则会导致成本较高。浅层地震反射波法^[4]探测范围大,常作为钻探的先行手段,其通过向地面施加一个冲击力,使介质质点发生弹性振动并以应力波的形式在介质中传播,应力波在传播过程中遇到波阻抗界面时产生反射,即可利用反射波的强度、频谱、相位、波长、旅时等信息进行桩位附近的孔洞探测。然而,该方法需使用炸药或大型激振设备作为激励源,因此其应用存在局限性。

传统探测方法存在探测面积小、成本高、设备要求高等问题,而浅层地震反射波法对孔洞的探测需将地震信号处理为二维图像,数据分析准确度依赖人工观察,需要丰富的领域知识或专家经验。鉴于此,文献^[5]以桩基础施工锤击作为激励源,发展一种基于浅层机器学习的地下单孔洞智能识别技术,通过捕捉孔洞地震反射波信号即可实现较大范围的地下浅层单孔洞量化识别。然而,浅层机器学习方法依赖于特征工程,在面对存在多个地下孔洞的工况时,孔洞之间的相互影响给特征工程带来了极大挑战。

近年来,深度学习以其强大的特征学习能力引领了机器学习领域的一次重要革命,在地质勘查方面,已有研究人员利用相关技术进行了应用探索。文献^[6]在超前钻探的基础上选择不同的钻进参数组合,通过神经网络对地层进行识别,基于多参数的地层识别准确率达到 78%,并认为可将循环神经网络应用到地层识别的任务中;文献^[7]利用卷积神经网络与深度回归森林实现在地震波信号转换后的二维图像中孔洞体的图形识别

及基于地质图形的孔洞体积预测。

因此,本文进一步引入深度学习,建立一种无需提取人工特征并能实现自适应特征学习的地下双孔洞智能探测方法。

1 浅层地下双孔洞智能探测方法

本文结合深度学习所提出的双孔洞智能探测方法如图 1 所示,其具体步骤如下。

1) 在一定空间范围内建立双孔洞随机分布的有限元模型库,并计算地表振动响应数据。

2) 选取地表加速度响应数据的有效数据段,与孔洞信息标签进行组合形成响应数据集。

3) 构建深度神经网络模型,使用数据集训练和测试模型,优化网络结构,以提高网络泛化能力,从而实现双孔洞的量化预测。

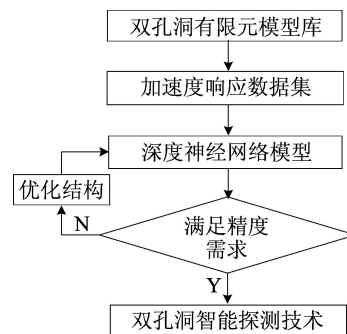


图 1 基于深度学习的双孔洞识别方法

2 有限元模型库及响应数据集

深度学习需大量数据作为学习样本,而实测数据成本高,数据规模难以满足深度学习训练要求。因此,本方法将借助有限元仿真建立数据库。首先,建立了包含不同孔洞位置和大小双孔洞有限元模型库;其次,筛选模型计算所得的加速度响应信号,并将信号和孔洞大小、位置的标签一一对应组成加速度响应数据集。

2.1 模型基本参数

本文运用 ABAQUS 有限元软件进行建模,土体用尺寸为 30 m×30 m×30 m 的立方体进行模拟,土体本构采用经典的 Mohr-Coulomb 本构模型^[8],其本构参数见表 1 所列。

为模拟应力波在半无限空间土层中的传播过程,本文采用无限单元的形式设定边界条件,选择无限单元类型 CIN3D8 单元来定义土层模型的无限边界,内部使用有限元单元 C3D10M,有限元与无限元连接处的单元为 C3D8R,以实现不同界面

的耦合。用以激发地震波的桩锤模型采用直径为 1.5 m、高度为 0.75 m、总质量为 4 t 的钢块,并从距离地表 1 m 的高度自由下落锤击土层进行激发。当传感器布设半径过大时,加速度信号变弱、易受噪声干扰、精度降低;当布设半径过小时,探测面积小、效率低。

计算结果表明,将传感器布置半径确定 10 m 时,可以较好平衡上述矛盾,而在圆周上均匀分布 6 个加速度传感器可以充分利用孔洞反射波的有效信息。因此,本文采用的传感器布置方案是以 10 m 为半径的圆周上每 60° 布置 1 个加速度传感器,以获取地表加速度信号。

表 1 土体本构参数

密度/ (kg/m^3)	杨氏模量/ MPa	泊松比	内摩擦角/ ($^\circ$)	剪胀角/ ($^\circ$)
1 710	11.6	0.38	24.47	0

2.2 双孔洞有限元模型数据库


在确定模型基本参数后,需批量建立双孔洞随机分布的模型库。双孔洞有限元模型图如图 2 所示。

孔洞参数示意图如图 2a 所示,假设每一个模型中存在 2 个相互独立的球形孔洞,每个孔洞由洞顶的三维坐标 (X, Y, Z) 及孔洞直径 D 进行描述,为更好地区分 2 个孔洞,将洞顶坐标与激震中心直线距离 S 较小的孔洞称为孔洞 1,相距较大的孔洞称为孔洞 2。

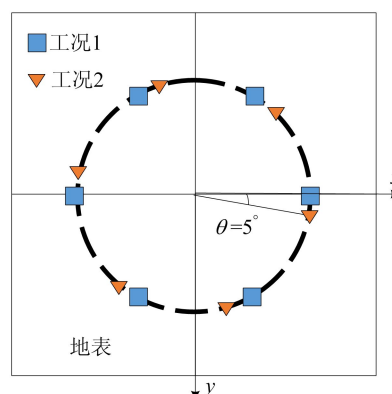
双孔洞相关参数共 8 个,分别为孔洞 1 (X_1, Y_1, Z_1, D_1) 和孔洞 2 (X_2, Y_2, Z_2, D_2) 。考虑到本技术的探测能力,每个基准模型的孔洞洞顶坐标中 X, Y 在 $-10 \sim 10$ m 范围内取随机数;孔洞顶部到地表的垂直距离 Z 在 $2 \sim 8$ m 范围内取随机数;孔洞直径 D 在 $4 \sim 8$ m 范围内取随机数。共取 100 组随机数组合建立基准模型。

每个基准模型中,在半径为 1 m 的圆周上每 5° 输出 1 次地表加速度响应时程曲线,每个基准模型共输出 72 个位置的时程响应。按照传感器的布设方式,每 6° 取 1 条响应数据组合成 1 个数据样本,如图 2b 所示。

通过旋转方位角 θ ,即将 6 个传感器的位置顺时针旋转 5° ,并取 1 个数据样本,等效于孔洞绕 Z 轴逆时针旋转 5° 的新工况,每个基准模型可等效为 72 种工况,100 个基准模型的工况总数共计 7 200 种。



(a) 传感器布置方案及孔洞参数示意图



(b) 单个模型的多种工况等效原理图

图 2 双孔洞有限元模型

2.3 地表振动响应信号的分析与选取

不同于传统的机器学习算法的性能依赖于特征工程,深度学习算法具备自动学习数据层次特征的能力。对所采集的地表振动响应数据进行筛选,尽可能保留足够的敏感特征,减少地表纵波及表面波干扰,以提高预测模型性能。不同孔洞地表加速度响应曲线如图 3 所示。

由图 3a 可知,第 1 个峰值所表示的地表纵波出现在 0.09 s 左右,瑞利波出现在 0.25 s 左右,而在地表纵波与瑞利波之间包含了孔洞反射波信号,并且随着孔洞位置下移,孔洞初始反射波信号出现在 0.10~0.20 s 的范围内。为保证脉冲激励作用下响应时程信号的完整性,本文采用的采样时间为 $0 \sim 0.30$ s,步长为 1 ms。

随机选取的双孔洞地表振动响应曲线如图 3b 所示,由于多个孔洞之间相互影响,传感器会优先接收到来自距离更近的孔洞的反射信号,如果进行简单的特征工程易造成信息的缺失,难以有效预测孔洞的位置和大小,因此本文倾向于保留更多原始数据中的有效信息。

地表纵波总是最先被传感器所捕捉,而瑞利波的较大峰值可能会对数据造成影响,从而干扰

网络的性能,因此本文以地表纵波以及瑞利波为标的,选取地表纵波之后、瑞利波之前的数据,对应图中 0.09~0.24 s 的数据段,时间步长为 1 ms,共计 150 个数据点,并将其作为深度学习算法的输入。

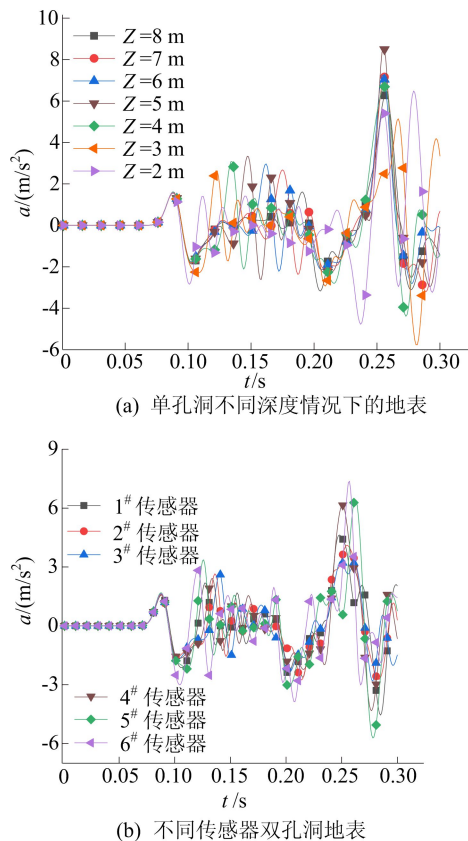


图 3 不同孔洞地表加速度响应曲线

3 基于深度学习的双孔洞预测模型

3.1 双向长短期记忆神经网络

深度学习^[9]的基础方法是人工神经网络,能对输入的数据进行从低级到高级的特征提取。循环神经网络(recurrent neural network, RNN)将 $t-1$ 时刻的输出作为 t 时刻的输入的一部分,使其能在序列化数据中进行特征的提取。在 RNN 的基础上,长短期记忆神经网络模型^[10] (long short-term memory neural network, LSTM)通过定义单元状态以及增加输入门、遗忘门和输出门 3 种门结构,使自循环的权重能够浮动,避免 RNN 中梯度消失或者梯度爆炸的问题,且通过 Sigmoid 函数在区间 $(0, 1)$ 中的取值来控制门的开关状态以有效实现较长序列的特征表达。有学者在 LSTM 的结构上进行了优化分别发展了其简化版本门控神经网络 (gated recurrent unit,

GRU)和特征提取能力得到加强的双向长短期记忆神经网络^[11] (bidirectional LSTM, Bi-LSTM)。

Bi-LSTM 结构如图 4 所示, $W_1, W_2, W_3, W_4, W_5, W_6$ 为权重系数。Bi-LSTM 具有前向、后向 2 个 LSTM 网络,双中间层结构共同提取特征并在输出层将提取到的特征向量进行拼接组合,以此达到更为全面的特征信息表达。加速度响应时程信号是基于时序的数据,数据序列性质的表达对于孔洞探测具有十分重要的意义。因此,本文将采用 Bi-LSTM 发展多孔洞智能探测技术。




图 4 双向长短期记忆神经网络结构

3.2 双孔洞预测模型结构

基于深度堆叠的 Bi-LSTM 所构建的预测模型结构如图 5 所示,模型参数见表 2 所列,所有参数及函数均为多次试验所确定的较优组合,训练轮次为 300 轮,其训练过程与一般神经网络相同。

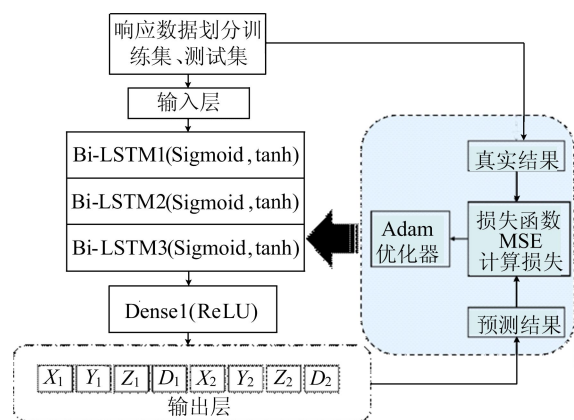


图 5 双孔洞预测模型结构

表 2 双孔洞预测模型参数

层名	通道数	单元数	Dropout	循环 Dropout
输入层	6			
Bi-LSTM1	6	512	0.2	0.2
Bi-LSTM2	6	256	0.2	0.2
Bi-LSTM3	6	128	0.2	0.2
Dense1	1	64	0.2	
输出层	8	1		

神经网络类需以张量作为输入,故本文数据输入形式为每批次传入 32 个由 6 个长度为 150 的向量所组成的矩阵,每个矩阵对应 6 个加速度传感器及每个传感器输出的 150 个数据点。

3.3 性能指标和容许误差

由于已有部分成熟算法可以进行序列数据的学习和预测,故有必要将 Bi-LSTM 与全连接神经网络(fully connected neural network, FCNN)、RNN、GRU、LSTM 等进行对比,用作对比的各类网络只对其核心模块进行替换,并对所有超参数进行针对性优化。本文选择在回归问题中最为常用的平均绝对误差(mean absolute error, MAE),作为网络性能的比较参数。

$$E_{MA} = \frac{1}{m} \sum_{i=1}^m |x^{(i)} - y^{(i)}| \quad (1)$$

其中: m 为每批次样本量; $x^{(i)}$ 为实际值; $y^{(i)}$ 为神经网络预测值。

作为回归算法,神经网络的预测值与实际值很难恰好相等,考虑到工程应用中允许存在一定的误差,故引入容许误差,并对平均绝对误差较小的网络结构从工程应用价值角度进行比较研究。假设预测出其中一个孔洞洞顶位置坐标为 (X_p, Y_p, Z_p) 、孔洞直径为 D_p ,而孔洞的实际洞顶坐标为 (X_r, Y_r, Z_r) ,实际直径为 D_r ,容许误差为 r ,当满足以下方程组时,即可认为预测准确。

$$\begin{cases} X_r - r \leq X_p \leq X_r + r, \\ Y_r - r \leq Y_p \leq Y_r + r, \\ Z_r - r \leq Z_p \leq Z_r + r, \\ D_r - r \leq D_p \leq D_r + r, \end{cases} \quad (2)$$

进一步可采用准确率对其工程实用性进行表征。假定在测试集中预测准确的工况数为 N_c ,测试集总工况数为 N_{total} ,则准确率 A_{cc} 为:

$$A_{cc} = \frac{N_c}{N_{total}} \quad (3)$$

4 结果与讨论

4.1 双孔洞预测平均绝对误差

数据集包含 7 200 种工况的样本数据,随机抽取其中的 1 000 个样本组成测试集,剩余的数据以 9 : 1 的比例划分为训练集及验证集,训练集包含 5 580 个样本,验证集包含 620 个样本。

双孔洞预测模型 300 轮次训练的损失变化图如图 6 所示。图 6 中:train_loss 代表训练集总损失;val 表示各参数验证集损失。训练初始阶段,各参数损失快速下降,随后损失值趋于平稳,训练

集以及验证集上损失差距小且没有随着训练轮次的增加而变大,因此在网络训练过程中数据的特征得到有效提取,并未发生过拟合和欠拟合的情况。

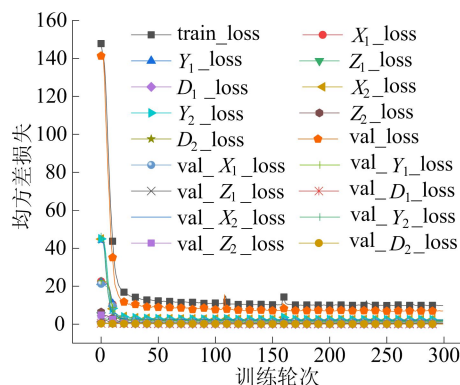


图 6 训练集及验证集训练轮次损失变化

使用不同结构的神经网络对双孔洞的 8 个描述参数进行预测,并计算 E_{MA} ,每种算法分别训练 3 次并取平均值,以评价各个模型的性能,结果见表 3 所列。在 8 个参数预测的 E_{MA} 中,LSTM 明显优于 RNN 及 GRU,而 FCNN 在本任务中未能从训练数据中学到相关特征,无法满足任务需求。相较于单向的 LSTM,Bi-LSTM 整体的平均绝对误差值减小了 28.3%,在预测结果中各个参数的 E_{MA} 表现均更为出色,故此 Bi-LSTM 可以更有效地从加速度信号中提取数据特征,面对孔洞探测任务具有更小的误差和更好的稳定性。

表 3 双孔洞预测平均绝对误差

输出层	FCNN	RNN	GRU	LSTM	Bi-LSTM
X_1	2.89	1.44	1.09	0.57	0.43
Y_1	3.00	1.43	1.15	0.58	0.46
Z_1	1.03	0.82	0.38	0.23	0.15
D_1	0.47	0.49	0.27	0.25	0.12
X_2	4.37	1.40	1.43	0.70	0.52
Y_2	4.36	1.39	1.47	0.69	0.56
Z_2	1.46	1.21	0.51	0.23	0.17
D_2	0.47	0.46	0.38	0.28	0.12
合计	18.05	8.64	6.68	3.53	2.53

进一步对 Bi-LSTM 层数进行探究,Bi-LSTM 循环体层数预测平均绝对误差结果见表 4 所列。从表 4 可以看出,包含 1 层 Bi-LSTM 的神经网络从原始数据中提取有效特征的能力有限;增加 Bi-LSTM 的层数,其性能较单层循环体网络在各个参数上均有显著提升,整体 E_{MA} 减少了 32.4%;网络性能在 Bi-LSTM 层数为 3 层时达到

峰值,较单层 Bi-LSTM 的 E_{MA} 值下降达 51.3%;增至4层时,由于模型过于复杂,其泛化能力有所降低,发生了较为明显的过拟合现象。因此,Bi-LSTM 循环体为3层时模型的性能达到最优。

表4 Bi-LSTM 循环体层数预测平均绝对误差

输出层	1层	2层	3层	4层
X_1	0.84	0.56	0.43	0.77
Y_1	0.85	0.64	0.46	0.74
Z_1	0.39	0.23	0.15	0.32
D_1	0.35	0.20	0.12	0.33
X_2	0.98	0.70	0.52	0.81
Y_2	1.01	0.74	0.56	0.86
Z_2	0.42	0.24	0.17	0.28
D_2	0.35	0.20	0.12	0.31
合计	5.19	3.51	2.53	4.42

4.2 工程实用性

使用式(2)、式(3)对 RNN、LSTM、Bi-LSTM 的孔洞探测性能进行工程意义上的表征和比较研究,不同容许误差的准确率见表5所列。

表5 双孔洞预测准确率 %

循环体结构	$r=1\text{ m}$	$r=2\text{ m}$
RNN	2.7	33.6
LSTM	73.2	90.3
Bi-LSTM	84.8	95.3

由表5可知,RNN 难以满足双孔洞探测的需求。LSTM 在应对双孔洞探测任务方面具备相应的能力,容许误差 $r=2\text{ m}$ 时,准确率在 90.0% 以上,其探测能力可以满足实际工程中的部分需求。在 Bi-LSTM 方面, $r=1\text{ m}$ 时,8 个参数探测准确率高达 84.8%;而 $r=2\text{ m}$ 时,准确率更是达到 95.3%,较之 LSTM 分别高出 11.6% 和 5.0%,显而易见,Bi-LSTM 相比于其他算法更适用于地下多孔洞探测的任务。

5 结 论

本文基于深度学习提供一种自适应特征学习

的双孔洞智能探测方法,并验证该技术的工程应用潜力,主要结论如下。

1) 深度学习可以自适应提取响应数据的内在特征,避免了进行复杂的特征工程。

2) Bi-LSTM 相较于 RNN、GRU、LSTM 具有更低的预测平均绝对误差和更高的预测准确率,当容许误差为 1、2 m 时,8 个参数预测准确率可分别达到 84.8%、95.3%,其精度能够满足双孔洞探测的工程需求。

[参 考 文 献]

- [1] 万志清,秦四清,李志刚,等. 土洞形成的机理及起始条件[J]. 岩石力学与工程学报,2003,22(8):1377-1382.
- [2] 闫双斌. 桩基荷载下溶洞顶板稳定性研究[D]. 长沙:中南大学,2013.
- [3] 姜凯华. 复杂岩溶地区超前钻在桩基施工中的应用[J]. 中国城市经济,2011(30):263-265.
- [4] 甘伏平,马祖陆,喻立平. 岩溶地区复杂条件下的浅层地震方法应用研究[J]. 地质与勘探,2005,41(3):75-78.
- [5] 陈敬松,周立成,李浩祖,等. 一种基于桩锤激震和 k 近邻算法的地下溶洞探测方法:CN 111551985A[P]. 2020-08-18.
- [6] 房昱纬,吴振君,盛谦,等. 基于超前钻探测试的隧道地层智能识别方法[J]. 岩土力学,2020,317(7):344-353.
- [7] 任海洋. 基于深度学习方法的溶洞体识别及定量计算[D]. 成都:电子科技大学,2019.
- [8] HUDSON J A, HARRISON J P. Engineering rock mechanics[M]. Oxford:Elsevier,1997:158-373.
- [9] 张军阳,王慧丽,郭阳,等. 深度学习相关研究综述[J]. 计算机应用研究,2018,35(7):1921-1928.
- [10] GRAVES A. Supervised sequence labelling with recurrent neural networks[J]. Studies in Computational Intelligence,2012,385:1-131.
- [11] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks,2005,18(5/6):602-610.

(责任编辑 吴 亮)