

文章编号:1007-5321(2021)01-0124-07

DOI:10.13190/j.jbupt.2020-118

损伤声发射信号小波包神经网络特征识别方法

齐添添¹, 陈 尧¹, 何才厚^{1,2}, 龙盛蓉¹, 李秋锋¹

(1. 无损检测技术教育部重点实验室 南昌航空大学, 南昌 330063;
2. 江西省特种设备检验检测研究院鹰潭分院, 鹰潭 335000)

摘要: 在材料损伤的检测和评价时,为了在大量接收信号中识别有效声发射信号,提出了一种基于小波包特征提取的损伤声信号神经网络识别方法,首先利用小波包全局分解的优势,准确提取非平稳信号的特征信息,建立相应特征向量,对有效声发射信号和干扰噪声信号进行表征;然后根据特征向量和识别输出要求,建立了 3 层结构的反向传播神经网络对信号进行分析和识别,滤除噪声信号,保留有效声发射信号;最后,在玻璃钢复合材料的声发射实验中,采集了 400 组信号对该方法进行验证,准确性达到 97.5%,能够满足工程需要。

关键词: 声发射检测;小波包分解;特征向量;BP 神经网络;信号识别

中图分类号:TH87

文献标志码:A

A Wavelet Packet Neural Network Feature Recognition Method for Damage Acoustic Emission Signals

QI Tian-tian¹, CHEN Yao¹, HE Cai-hou^{1,2}, LONG Sheng-rong¹, LI Qiu-feng¹

(1. Key Laboratory of Nondestructive Testing, Nanchang Hangkong University, Nanchang 330063, China;
2. Yingtan Branch of Special Equipment Inspection and Research Institute of Jiangxi, Yingtan 335000, China)

Abstract: In the testing and evaluation of material damage, in order to identify effective acoustic emission (AE) signals among a large number of received signals, a neural network recognition method based on wavelet packet feature extraction is proposed. Firstly, the advantage of wavelet packet global decomposition is used to accurately extract the feature information from non-stationary signals, so, the corresponding feature vectors are established to characterize effective AE signals and interfering noise signals. Then, according to feature vectors and recognition output requirements, a three-layer back propagation neural network is established to analyze and identify signals, which could filter out noise signals and retain effective AE signals. Finally, 400 sets of AE signals are collected in the experiment of glass fiber reinforced plastics to verify the method. The collected AE signals are identified with an accuracy of 97.5%, which can meet requirements of engineering.

Key words: acoustic emission testing; wavelet packet decomposition; feature vector; back propagation neural network; signal recognition

收稿日期:2020-08-14

基金项目:国家自然科学基金项目(11764030,51705232);江西省自然科学基金项目(20192BAB216026);江西省质监局科技计划项目(GZJKE201810)

作者简介:齐添添(1995—),女,硕士生。

通信作者:李秋锋(1976—),男,教授,E-mail:qiufenglee@163.com。

近年来,声发射(AE, acoustic emission)检测快速发展,已成为一种新兴的无损检测手段。该检测方法类似于以超声波信号为对象的检测法,但是声发射检测中的超声波实际是材料因外力作用而出现损伤时释放出来的应力波,因此其检测原理与其他无损检测方法有本质区别,它是一种被动的动态检测方法^[1-2]。

在声发射检测过程中,材料损伤释放的应力波能力通常比较微弱,在信号采集时一般会设置阈值,但阈值设置过高,可能检测不到微弱的声发射信号而造成漏检;而阈值设置过低,机械振动、摩擦等噪声信号就会“趁虚而入”,这些干扰噪声信号与声发射信号在时域上相近,都属于非平稳随机信号,很难直接辨别和区分,这将极大地影响对有效损伤声发射信号的识别和评价,极易造成误检。因此,在对采集信号做进一步分析前,对有效声发射信号进行识别并去除干扰噪声信号是十分必要的^[3-4]。于等^[5]将经验模态与阈值降噪结合,使用 Wavelet-EMD 方法对声发射信号进行降噪,虽然信噪比有所改善,信号降噪效果也较为稳定,但是其主要是针对检测信号中的混叠噪声进行抑制,而无法判断检测信号本身是否为有效声发射信号,对损伤声源进行准确的定位定量评价仍然存在一定影响。

小波包分解是一种能够对各类非平稳随机信号进行有效处理的现代时频分析和处理方法,是小波分解的推广^[6]。通过小波包变换可将采集的信号分解为多个二维参量(时间、位置)和频率,实现信号在不同频带、不同时刻的特征分解,小波包分解具有很强的时频局部化分解能力,为提取和识别损伤类型提供了保障。目前小波包分解广泛应用于语言、图像、地震、机械振动等领域^[7]。Bianchi 等^[8]应用小波包变换分析裂纹的演变并识别此类事件,将其与噪声进行区分;梁等^[9]采用 Db5 小波基处理,获得了声发射信号能量分布结果。

目前使用较多的反向传播神经网络(BPNN, back propagation neural network)属于多层前向反馈网络,在模式识别、预测评估等方面应用非常广泛。因神经网络识别方法具有良好的非线性映射特征和学习记忆性,使其可适用于较复杂材料结构中的声发射信号识别。利用 BPNN 中的信号识别可区分干扰噪声信号和有效声发射信号,利用适当的模式和参数设置,有助于提高识别率。Sachse 等^[10]使用神经网络分析处理声发射信号,这是神经网络第一次

在声发射信号分析中应用;Bhat 等^[11]模拟多种类型噪声及夹杂在碳纤维复合材料检测信号中的噪声,并完成对其进行神经网络分类识别。

声发射检测信号是一种典型的非平稳随机信号,根据实际需要提出了一种基于小波包特征提取的损伤声发射信号神经网络识别方法。该方法是采用小波包分解方法对目标信号进行特征分解,根据有效声发射信号与干扰噪声在不同频带上的特征,建立特征向量对这 2 类信号进行表征;然后利用 BPNN 的智能识别能力,通过特征向量对 2 类信号进行分类,从而去除干扰噪声信号,保留有效声发射信号,最终实现对声发射源的有效识别和评价。

1 小波包分解方法

1.1 小波包分解原理

小波包变换在小波变换的基础上发展而来,同时也是小波变换的推广。小波包分解实际是对小波分解进行改进,将信号高频分量和低频分量都进行分解,比小波变换划分更加精细和全面,更能体现出信号全频率特点,特征向量能够自适应选择频带,具有时频局部化特点,特征与频谱对应,从而提高信号的时频分辨率^[12]。

图 1 所示为 3 层小波包分解树结构,图中 $S_{0,0}$ 为分解前的原始信号; $S_{i,j}$ 为第 i 层(即尺度数)第 j 个节点对应的分解信号,这些分解信号与原始信号的关系为

$$\begin{aligned} S_{0,0} &= S_{1,0} + S_{1,1} = S_{2,0} + S_{2,1} + S_{2,2} + S_{2,3} = \\ &= S_{3,0} + S_{3,1} + S_{3,2} + S_{3,3} + S_{3,4} + S_{3,5} + S_{3,6} + S_{3,7} \end{aligned} \quad (1)$$

其中:节点数 j 为偶数表示经过低通滤波系数 $g(k)$ 分解得到的低频成分信号,反之, j 为奇数则表示经过高通滤波系数 $h(k)$ 分解得到的高频成分信号。高通和低通滤波系数需要满足正交关系:

$$g(k) = (-1)^k h(1-k) \quad (2)$$




图 1 信号 3 层小波包分解树

在不同分解层计算得到的分解信号可通过逐层

计算得到:

$$S_{i+1,2j}(n) = \sum_k g(k-2n)S_{i,j}(k) \quad (3)$$

$$S_{i+1,2j+1}(n) = \sum_k g(k-2n)S_{i,j}(k) \quad (4)$$

这样分解将在各层产生 2 个序列,对低频信号和低频信号都要进行分解,使信号的低频和低频分辨率都得到提高.按照上述方式分解,信号在第 i 层小波包分解后,将得到 2^i 个特征信号,每个特征信号与相应频率段相匹配.

小波包变换的核心部分就是小波基,选取合适的小波基有利于准确提取声发射信号的特征,适用声发射信号的离散小波且为紧支性的小波基有:Db 小波基、Symlets 小波基和 Coiflets 小波基^[8].选用 Db 小波基对声发射信号进行小波包变换,以相关系数作为衡量信号逼近能力的选取标准,消失矩为 4 时,分解特征与信号具有良好的相关性,根据接收的声发射信号频率范围选取适合的小波分解层数.因此,选用 Db4 小波基对声发射信号进行 5 层小波包分解.

1.2 特征向量构建

每次小波包分解都是将信号频带进行划分,并得到相应子频带的信号成分,这样原信号的特征信息也就在各子频带信号中.对于各类信号在频域中特征可以通过各个频带的能量进行分析和识别.因此在信号进行小波包分解后,可以将分布在不同频带内的能量分布特征作为信号识别的重要依据.

根据帕塞瓦尔(Parseval)定理,一个信号 $d(t)$,其时域总能量与频域总能量是相等的,即

$$\int_{-\infty}^{\infty} d^2(t) dt = \int_{-\infty}^{\infty} D(f) df \quad (5)$$

其中: t 为时间, f 为频率, $D(f)$ 为信号的频域能量.利用这个能量特性,采用小波包能量法提取声发射信号特征^[12].对于小波包分解,只是将信号高频成分和低频成分分离出来,在信号形式上发生了变化,但是分解前后的总能量始终保持相等^[13].如果将声发射信号进行小波包分解至第 i 层,则各子频带信号能量为

$$E_{ij} = \int |S_{i,j}(t)|^2 dt = \sum_{k=1}^n |x_{i,j}(k)|^2 \quad (6)$$

其中: $x_{i,j}(k)$ 为 $S_{i,j}$ 的长度为 n 的离散信号, E_{ij} 为 $S_{i,j}$ 的能量.那么信号总能量为

$$E = \sum_{j=0}^{2^i-1} E_{ij} \quad (7)$$

则特征向量 T 为

$$T = [t_1, t_2, \dots, t_{2^i}] = \left[\frac{E_{i0}}{E}, \frac{E_{i1}}{E}, \dots, \frac{E_{i(2^i-1)}}{E} \right] \quad (8)$$

每个信号的特征向量中包含 2^i 个特征值,实际就是各频带信号的能量占比,不同信号的特征都可以用该特征向量进行表征.

2 反向传播神经网络建立

神经网络可解决声源信号识别的问题,也可以克服人为干预和效率低的问题^[14].神经网络分为监督学习和无监督学习 2 种训练方式,结合声发射信号特点和小波包分解特征向量表征方式,建立有监督学习的 BPNN 对信号进行模式识别^[15].

为了实现对有效声发射信号的识别,采用如图 2 所示的 3 层 BPNN 模型对信号的小波包特征向量分类和识别.该 BPNN 由输入层、若干中间层(隐含层)和输出层组成,3 层网络即可完成输入层与输出层的非线性映射.

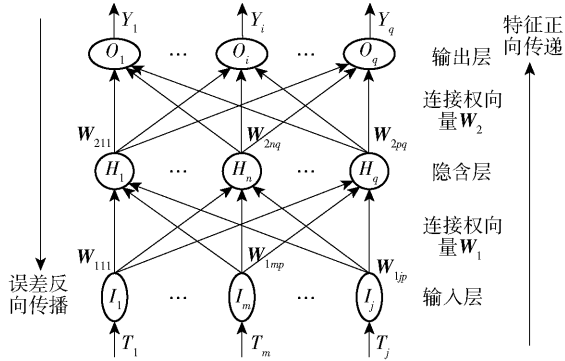


图2 BPNN 的拓扑结构

BPNN 学习过程由特征正向传递和误差反向传播两部分组成,由网络模型正向传递至隐含层,计算神经元的输出值,再传递给输出层进行判断,若未达到期望输出,则将误差沿着原路径反向传播,向输入层返回误差信号,作为权值和阈值修正依据,直至误差低于预设目标阈值,训练结束,BPNN 的具体建立步骤如下.

2.1 确定 BPNN 各层节点数

1) 输入层节点数

输入层节点数由输入的特征向量维数决定,用向量描述信号特征,将需要区分的 2 类信号进行小波包分解至第 5 层,可以得出含 32 个特征值的特征

向量作为网络的输入数据,因此,确定输入层节点数 N 为 32.

2) 输出层节点数

研究目的是对有效声发射信号和干扰噪声信号进行识别,期望输出的类别为有效声发射信号 1、干扰噪声信号 2 两类,仅需 2 种输出结果,因此,输出层节点数 M 为 2.

3) 隐含层结构

采用 3 层 BPNN,即仅有一个隐含层,实现非线性映射关系. 隐含层节点数为

$$P = \sqrt{N + M} + m \tag{9}$$

其中:因 N 和 M 分别为输入层节点数和输出层节点数,且 $1 < m < 10$. 故隐含层节点数 P 取值范围为 $[6,15]$. 经计算,该 BPNN 误差最小时隐含层节点数为 8.

2.2 确定激活函数、选择初始权值

采用 S 型对数函数作为隐含层和输出层的激活函数. 初始权值选 $(0,1)$ 范围内的随机数,初始权值由 BPNN 根据条件随机选择.

2.3 选取学习率、循环次数和期望误差

学习率的大小会影响训练网络权值变化量、训练时间和收敛速度. 在分类识别中,学习率的选取范围为 $(0.01,1)$,设置学习率为 0.1. BPNN 训练的期望误差为 0.01,最大循环迭代次数为 1 000 次.

3 实验过程与分析

3.1 实验系统与试块准备

实验采用声发射监测 GFRP 试块拉伸试验过程. 试块拉伸试验在 WDW-50 型计算机控制的电子万能试验机上进行,该试验机最大载荷值为 100 kN,可以满足实验要求. 在拉伸试验中,采用 PCI-2 型声发射系统进行监测,该系统由 4 块 PCI 卡实现 8 通道数据采集,并利用 AEWin 软件对信号进行采集和处理控制. 实验中使用的是 R80D 声发射传感器,其中心频率为 800 kHz,有效接收带宽为 0.1 ~ 1 MHz.

GFRP 试块是用 430 号树脂和玻璃纤维编织制成,采用 $0^\circ/90^\circ$ 交叉铺层方式,在 $170\text{ }^\circ\text{C}$ 、5 MPa 的高温高压环境下固化 2 小时完成. 拉伸试块尺寸均按 $240\text{ mm} \times 50\text{ mm} \times 3\text{ mm}$ 切割而成. 拉伸试验中,为了防止夹具压应力太大,造成试块两端被破坏,在试块两端固定了铝片. 同时在试块中间的两侧都预置了 10 mm 缺口,以确保应力集中在试块中央,更

易在目标区域产生损伤而发出声发射信号,便于采集有效声发射信号.

3.2 信号采集过程

拉伸实验开始前,将声发射传感器安装在试块上,并在试验机上用夹具固定好试块,前置放大器设置为 40 dB. 然后启动试验机,为了采集环境干扰噪声信号,先不启动拉伸加载,同时将声发射仪器的采集信号通道阈值设定为 0 dB,开启声发射仪器开始采集噪声信号,共采集了 200 组噪声信号,图 3 所示为其中一个噪声信号的归一化波形.




图 3 环境干扰噪声信号波形

在采集噪声信号时发现幅值多次达到 45 dB,因此在开始拉伸加载前将阈值设定到 50 dB. 启动拉伸加载至试块上时,拉伸速度设置为 1 mm/min,同时开启声发射仪器开始采集超过阈值的声发射信号. 为了更准确的采集到有效声发射信号,仅将预置缺陷附近出现的声发射信号作为有效声发射信号,也同样采集了 200 组有效声发射信号,图 4 所示为采集到的其中一个有效声发射信号的归一化波形.




图 4 有效声发射信号波形

3.3 信号特征向量提取

根据小波包分解原理,对接收到的 400 组信号

进行处理,采用 Db4 小波包 5 层分解,按式(8)计算出每组信号的 32 个能量占比特征值,每个特征值对应为该信号在有效带宽内分解的信号频段,组成该信号的能量特征分布,并形成特征向量 T 对该信号特征进行表征。

图 5 所示为环境干扰噪声信号的小波包分解能量特征分布。由图可知,该噪声信号特征表现为:能量主要集中在前 5 个频率区间,在第 1 个频率区间能量最高;且频带覆盖范围较窄,干扰信号的主要频率范围为 $0 \sim 156.2 \text{ kHz}$ 。




图 5 环境干扰噪声信号能量特征分布

图 6 所示为有效声发射信号的小波包分解能量特征分布。由图可知,有效声发射信号特征表现为:能量主要集中在第 2 至第 9 个频率区间,该区间信号能量占总能量的 95% 以上,特别是在第 2 至第 5 个频率区间能量较高,第 6 至第 9 个频率区间能量相对较低,第 13 至第 15 个频率区间仍有较低能量,说明有效声发射信号的频率主要集中在 $0 \sim 300 \text{ kHz}$ 之间,有少数高频信号成分可达到 400 kHz ,信号覆盖的有效频带长度较宽。




图 6 有效声发射信号能量特征分布

采用 5 层分解的小波包特征向量可以更为精细地对声发射信号进行划分,基于小波包分解特征提

取的声发射信号向量特征有明显区分。环境干扰噪声信号频率更集中在低频段,而有效声发射信号覆盖的频率段更宽。

为观察该方法对其他噪声的适应性,在实验过程中,采集夹具与试块处出现的摩擦噪声信号,该信号也属于无效干扰信号。提取的 1 个摩擦噪声信号波形如图 7 所示。将该摩擦噪声信号进行小波包分解,其能量特征分布如图 8 所示。




图 7 摩擦噪声信号波形




图 8 摩擦噪声信号能量特征分布

对比图 5 和图 8 可知,环境干扰噪声和摩擦噪声虽然属于不同类型的干扰噪声信号,但是小波包分解提取的能量特征向量非常相似:能量均主要集中在前 5 个频率区间,且第 1 个频率区间能量最高,因此,该识别方法对多种类型的噪声识别具有适应性。

3.4 神经网络训练和识别

采用 BPNN 对小波包分解获得的声发射信号特征向量进行模式识别,对干扰噪声信号及有效声发射信号进行分类。建立 BPNN 后,从实验采集的 200 组干扰噪声信号和 200 组有效声发射信号中,选取 360 组作为 BPNN 的训练样本,其余 40 组作为测试样本验证 BPNN 识别的准确性。

图 9 所示为 BPNN 的训练误差曲线,由图可知,大约经过 51 步迭代训练后,误差降低至期望误差以下。




图 9 BPNN 训练误差曲线

BPNN 训练完成后,将 40 组测试样本的小波包分解特征向量依次输入 BPNN 中进行识别,图 10 所示为 BPNN 识别结果与实际信号类型的对比。




图 10 预测信号与实际信号对比

3.5 实验结果分析

由图 10 可知,在 40 组检测样本中,仅有 1 组(第 8 组)样本识别结果出现错误,采用 BPNN 对声发射信号进行识别的准确率达到 97.5%。

从整个实验过程来看,小波包分解对提取信号特征非常有效,采用各个分解频段内能量占比作为特征值,可以通过能量分布情况对信号进行有效表征;采用的 BPNN 具有较强的学习能力与识别能力,仅需较少的训练迭代次数就能达到期望误差,同时也能够准确地识别出信号类型,能够满足工程需求。

在对实验结果分析过程中发现,结果中仍然存在对有效声发射信号的错误识别。为了进一步提高识别的准确率,可以从以下 2 个方面进行改进:①增加 BPNN 训练样本,可以更准确地把握各类信号

特征,避免出现类似信号特征的错误识别;②优化信号的特征向量,进一步统计 2 类信号的关键特征信息,更有针对性地进行训练,提高信号识别的准确性。

4 结束语

根据声发射检测过程需要,提出了损伤声发射信号的小波包神经网络特征识别方法,实现了对有效声发射信号的准确识别,消除了干扰噪声信号对损伤检测与评价的影响,得出如下结论。

1)通过小波包分解,将信号按照频段划分和分解,分析不同频段的分解信号能量占比和分布情况,发现不同类型的信号存在一定差异,可通过能量分布特征形成的特征向量有效表征不同的信号类型。

2)建立 BPNN 后,将特征向量作为输入值,经过实验数据训练后,该 BPNN 的识别准确率较高。实验结果表明,该 BPNN 不仅训练速度快,而且对干扰噪声和玻璃钢损伤声发射信号的识别准确率达到 97.5%。

参考文献:

- [1] Mecrory J P, Al-Jumaili S K, Crivelli D, et al. Damage classification in carbon fibre composites using acoustic emission: A comparison of three techniques[J]. Composites Part B: Engineering, 2015, 68: 424-430.
- [2] Wei Xinchun, Chen Yao, Lu Chao, et al. Acoustic emission source localization method for high-speed train bogie[J]. Multimedia Tools and Applications, 2020, 79: 14933-14949.
- [3] 李昕, 罗更生, 龙盛蓉, 等. 钢板声发射时间反转聚焦增强定位方法[J]. 仪器仪表学报, 2016, 37(8): 1792-1799.
Li Xin, Luo Gengsheng, Long Shengrong, et al. Location method of acoustic emission by time reversal focusing and enhancing for steel plate[J]. Chinese Journal of Scientific Instrument, 2016, 37(8): 1792-1799.
- [4] 齐添添, 陈尧, 李昕, 等. 基于时间反转的玻璃钢复合板材声发射源定位方法[J]. 仪器仪表学报, 2020, 41(6): 208-217.
Qi Tiantian, Chen Yao, Li Xin, et al. AE source location method based on time reversal for GFRP plate[J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 208-217.
- [5] 于金涛, 赵树延, 王祁. 基于经验模态分解和小波变换声发射信号去噪[J]. 哈尔滨工业大学学报, 2011,

- 43(10): 88-92.
- Yu Jintao, Zhao Shuyan, Wang Qi. De-noising of acoustic emission signals based on empirical mode decomposition and wavelet transform[J]. Journal of Harbin Institute of Technology, 2011, 43(10): 88-92.
- [6] 蒋佳伟, 胡以怀, 柯赞, 等. 基于小波包特征提取和模糊熵特征选择的柴油机故障分析[J]. 振动与冲击, 2020, 39(4): 273-277, 298.
- Jiang Jiawei, Hu Yihuai, Ke Yun, et al. Fault diagnosis of diesel engines based on wavelet packet energy spectrum feature extraction and fuzzy entropy feature selection[J]. Journal of Vibration and Shock, 2020, 39(4): 273-277, 298.
- [7] 陈世平, 王振忠, 俞辉, 等. 改进小波包多阈值去噪法及其工程应用[J]. 中国机械工程, 2017, 28(20): 2414-2419.
- Chen Shiping, Wang Zhenzhong, Yu Hui, et al. Improved wavelet packet multi threshold denoising method and its engineering applications[J]. China Mechanical Engineering, 2017, 28(20): 2414-2419.
- [8] Bianchi D, Mayrhofer E, Groschl M, et al. Wavelet packet transform for detection of single events in acoustic emission signals[J]. Mechanical Systems & Signal Processing, 2015, 64: 441-451.
- [9] 梁晓敏, 周伟, 庞艳荣, 等. 基于小波分析的复合材料层间损伤声发射行为[J]. 玻璃钢/复合材料, 2014, (8): 44-48.
- Liang Xiaomin, Zhou Wei, PangYanrong, et al. Acoustic emission behavior on interlaminar damage of composite based on wavelet analysis[J]. Fiber Reinforced Plastics/Composites, 2014, (8): 44-48.
- [10] Sachse W, Grabec I. Intelligent processing of acoustic emission signals[J]. Materials Evaluation, 1992, 50: 826-832.
- [11] Bhat C, Bhat M, Murthy C. Acoustic emission characterization of failure modes in composites with ANN[J]. Composite Structures, 2003, 61(3): 213-220.
- [12] 郭飞, 张培伟, 张大海, 等. 基于小波包能量特征向量的光纤布拉格光栅低速冲击定位[J]. 振动与冲击, 2017, 36(8): 184-189.
- Guo Fei, Zhang Peiwei, Zhang Dahai, et al. Localization of low-velocity impact by using fiber Bragg grating sensors based on wavelet packet energy eigenvector[J]. Journal of Vibration and Shock, 2017, 36(8): 184-189.
- [13] Lu Jiyun, Wang Bangfeng, Liang Dakai. Wavelet packet energy characterization of low velocity impacts and load localization by optical fiber Bragg grating sensor technique[J]. Applied Optics, 2013, 52: 2346-2352.
- [14] 宁方立, 韩鹏程, 段爽, 等. 基于改进 CNN 的阀门泄漏超声信号识别方法研究[J]. 北京邮电大学学报, 2020, 43(3): 38-44.
- Ning Fangli, Han Pengcheng, Duan Shuang, et al. Research on identification method of valve leakage ultrasonic signal based on improved CNN[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(3): 38-44.
- [15] 蒋芳, 张南飞, 胡艳军, 等. 基于 BP 神经网络的 CSI 无源目标分类方法[J]. 北京邮电大学学报, 2020, 43(1): 40-45.
- Jiang Fang, Zhang Nanfei, Hu Yanjun, et al. BP neural network based CSI device-free target classification method[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(1): 40-45.