

基于改进神经网络的铁轨抗压强度预测研究

尹轶

(国能黄大铁路有限责任公司, 山东 东营 257000)

摘要: 为了提高铁轨抗压强度预测精度和效率, 提出基于改进神经网络的铁轨抗压强度预测方法。通过经验模态分解方法提取铁轨振动信号; 通过小波分解对铁轨振动信号实行降噪处理; 结合线性回归和模糊度函数改进神经网络, 获取更有效的隶属度函数, 构建铁轨抗压强度预测模型; 基于FCM算法通过离散化处理进行振动信号属性约简, 并完成铁轨抗压强度的预测。实验结果表明, 所提方法的铁轨抗压强度预测结果误差低于2 MPa, 预测时间在25 min左右, 提高了预测精度和预测效率, 具有较好的实际应用价值。

关键词: 改进神经网络模型; 抗压强度预测; 铁轨; 经验模态分解; 小波分解; 属性约简

中图分类号: TP183 文献标识码: A 文章编号: 1003-7241(2025)01-0065-06

Research on the Iron Rail Compressive Stress Inspection Based on Improvement of Neural Networks

YIN Yi

(Guoneng Huangda Railway Co., Ltd., Dongying 257000 China)

Abstract: In order to improve the accuracy and efficiency of railway track compressive strength prediction, an improved neural network based railway track compressive strength prediction method is proposed. The rail vibration signal is extracted by empirical mode decomposition. The noise of rail vibration signal is reduced by wavelet decomposition. Combined with linear regression and fuzzy function, the neural network is improved to obtain more effective membership function, and a prediction model of railway track compressive strength is constructed. Based on FCM algorithm, attribute reduction of vibration signal is carried out through discretization processing, and the compressive strength of rail is predicted. The experimental results show that the prediction error of the rail compressive strength of the proposed method is less than 2 MPa, and the prediction time is about 25 min, which improves the prediction accuracy and prediction efficiency, and has good practical application value.

Keywords: improved neural network model; prediction of pressure resistance; railroad track; experience modular decomposition; wavelet decomposition; attribute reduction

0 引言

随着铁路的高速发展, 铁路交通成为人们出行的便利选择。列车运行中长期的振动使得桥墩和支座不可避免地产生一定残余变形, 引起铁轨的几何不平顺, 容易造成列车脱轨事故。因此, 为了保障铁路安全运行, 需要及时对铁轨状态进行检测, 而铁轨抗压强度的智能预测是检测的基础。检修人员可以根据自动化的预测结果, 对强度低的铁轨进行及时检测^[1-2]。因此研究铁轨抗压强度的自动预测方法, 具有重要意义。

吴贤国等人首先收集了待检材料数据特征样本; 其次, 通过重要度衡量数据特征, 去除重要性较低的特征; 最后, 将数据输入至基于随机森林的神经网络模型完成抗压强度的检测^[3]。该方法存在检测精度较低的问题。

张研等人首先通过主成分分析降维提取到的材料信息特征; 其次构建相关向量机并以此实行抗压强度的预测^[4]。该方法存在检测时间长的问题。赵宏良等人首先使用活化能公式和度时积公式构建三种抗压强度的预测模型; 其次, 采用电子扫描和数据回归法修正预测误差问题, 并对其实行检测^[5]。该方法存在整体检测精度不佳, 不适合实际应用的问题。

上述研究方法没有考虑到纵连式无砟轨道横向变形时产生的振动信号在转换为量纲化参数时容易产生混乱映射, 提取的信号特征存在非线性与模糊化的错误, 造成强度预测精度较低, 预测时间延长。为了解决上述方法中存在的问题, 提出基于改进神经网络的铁轨抗压强度预测研究。创新性地结合线性回归和模糊度函数改进神经网络模型, 解决模型参数模糊和非线性等问题, 从而提高预测精度; 基于FCM算法通过离散化处理对模型样本

*基金项目: 国家能源有限公司总部科技项目 (5700-202227228A-1-1-ZN)

收稿日期: 2023-11-02

进行属性约简,提高预测效率。

1 铁轨振动信号提取

安装传感器设备现场采集铁轨信号。为了在无线振动信号较为微弱的情况下保证传输,搭建 ZigBee 无线网络作为近距离通信方式,连接 GPRS 网络作为远距离通信方式。现场测量仪器将数据传输至 ZigBee/GPRS 网关,通过 ZigBee 协调器将数据封装发送到移动网络。

通过经验模态分解方法对铁轨振动信号实行提取^[6-7]。经验模态分解即通过原始振动信号的局部特征实行自适应分解的方法,其满足两个条件:

- (1) 任意一定的局部峰值包络线的均值为0;
- (2) 整个数据段内的零交叉点数量与极值点数量差为0或者小于1。

可通过分解出的振动信号分辨率信息的分辨率表达描述振动信号能量分布及时间联合分布情况,即信息特征可通过频带能量表达,故提取铁轨振动信号的不同尺度下的 IMF 能量占比来表达铁轨振动信号信息特征。

首先采用经验模态分解方法分解 $x(y)$ 原始铁轨振动信号,其公式如下:

$$x(y) = \sum_{o=1}^n v_o(y) + t(y) \tag{1}$$

式中, $v_o(y)$ 表示 IMF 分量函数, $t(y)$ 表示残余函数。

计算 IMF 分量能量 E_o , 其公式如下:

$$E_o = \int_{-\infty}^{+\infty} |v_o(y)|^2 dt, o=1,2,\dots,n \tag{2}$$

计算振动信号特征向量 E , 即通过振动信号能量比构建向量,其公式如下:

$$E = \left(\sum_{o=1}^n |E_o|^2 \right)^{\frac{1}{2}} \tag{3}$$

振动信号越复杂,越容易因经验模态分解算法的终止筛选及振动信号长度等因素,让分解后的分量振动信号数量远超于原始铁轨振动信号实际分量,出现虚假分量问题。虚假分量的产生影响了时频谱分析及振动信号特征提取的精确度^[8]。

因此需根据虚假分量的方差贡献率与实际分量的相关性剔除虚假分量,其相关性系数 $x_h(o)$ 公式如下:

$$x_h(o) = \frac{1}{N} \sum_{k=1}^n x(k) \cdot v_o(k+v) \tag{4}$$

式中, N 表示振动信号长度, v 表示间隔时间, $x(k)$ 表示筛选函数, k 表示第 k 个振动信号分量。

IMF 分量因子的重要性可根据方差贡献率衡量,其值大小与因子重要性成正比,方差贡献率 $mseb(o)$ 公式如下^[9]:

$$mseb(o) = \frac{\left\{ \frac{1}{N} \sum_{k=1}^n v_o(k)^2 - \left[\frac{1}{N} \sum_{o=0}^N v_o(k) \right]^2 \right\}}{\sum_{k=1}^n v_o(k)^2 - \left[\frac{1}{N} \sum_{o=0}^N v_o(k) \right]^2} \tag{5}$$

根据计算出的方差贡献率及分量相关系数来选择铁轨振动信号的 IMF 分量,完成铁轨振动信号的提取。

2 铁轨振动信号降噪

采用小波分解方法对上节提取到的铁轨振动信号实行降噪处理^[10]。

噪声振动信号及待提取振动信号在经小波分解后的分辨率不同,且待提取振动信号较噪声振动信号的幅值较大,故可通过阈值算法实现振动信号去噪处理。

含噪振动信号公式如下:

$$s(l) = g(l) + \psi_r(t), l=0,1,\dots,n,n-1 \tag{6}$$

式中, $s(l)$ 表示含噪振动信号, $g(l)$ 表示原始振动信号, ψ 表示噪声强度, $\psi_r(t)$ 表示噪声振动信号。

对其实行小波分解,其原理如图 1 所示。




图 1 小波分解原理

小波即为一种长度有限均值为 0 的一段振动信号区域的波,其公式如下:

$$\int_{-\infty}^{+\infty} \varphi(y) = 0, |\zeta(e)|^2 |\xi|^{-1} dt < +\infty \tag{7}$$

式中, $\varphi(y)$ 表示振动信号基本小波, $\zeta(e)$ 表示尺度函数。平移基本小波 $\zeta_{s,v}(y)$, 得到公式如下:

$$\zeta_{s,v}(y) = s^{-0.5} \zeta\left(\frac{y-v}{s}\right), s > 0, v \in T \tag{8}$$

式中, v 表示平移量, s 表示尺度值, $\zeta_{s,v}(y)$ 表示小波基函数序列。

离散小波变换 $E_g(m,n)$ 公式如下:

$$E_g(m,n) = a^{-\frac{m}{2}} \int_{-\infty}^{+\infty} g(y) \bar{\varphi}(x) f \xi \tag{9}$$

式中, $\bar{\varphi}(x)$ 表示共轭函数, E 表示离散系数, $g(m,n)$ 表示振动信号, a 表示尺度参数, $g(y)$ 表示离散小波逆变换。

进一步推导出离散小波逆变换 $g(y)$ 公式如下:

$$\begin{cases} g(y) = \sum_{m+n} < g \\ \zeta_{m,n} > \zeta_{m,n}(y) = \frac{1}{S} \sum_{m,n} E_g(m,n) \zeta_{m,n}(y) \end{cases} \tag{10}$$

式中, S 表示小波的上限界,其值大于 0,对分解后的振动

信号实行小波重构。

基于此,完成铁轨振动信号的去噪处理。

3 基于改进神经网络的预测方法设计

将去噪后的铁轨振动信号输入至改进神经网络模型中完成铁轨抗压强度的检测。

结合线性回归和模糊度函数改进神经网络模型,根据线性回归改进模型参数模糊和非线性等问题,采用模糊度函数作为多种数据的规则,获取更有效的隶属度函数,建立出精度更高的铁轨抗压强度的改进神经网络检测模型^[11]。基于FCM算法对输入模型的样本通过离散化处理进行属性约简,提高预测效率。将离散化的属性样本输入到线性回归与模糊度函数神经网络模型中,选择隶属度函数的最优参数,计算铁轨的综合抗压强度,实现预测铁轨预测。

3.1 线性回归函数

线性回归函数即在确定性模型场合通过最小化及误差均方来获取输入数据和输出数据的最佳函数,其公式如下:

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n + i \quad (11)$$

式中, Y 表示输出数据, X 表示输入数据, i 表示干扰项, β 表示模型参数。

模糊线性回归可以为模型数据的确定性及层次多样时提供概率规范的回归方法,其公式如下:

$$Y = S_0 + S_1 X_1 + \dots + S_n X_n \quad (12)$$

式中, S 表示包含独立参数与因果不确定关联的对称模糊数,可用 $s=(t, v)$ 表达,其中 t 表示函数中心值, v 表示中心值的跨度。

隶属度函数 $v_s(x)$ 公式如下:

$$v_s(x) = Z\left(\frac{x-t}{v}\right) \quad (13)$$

式中, Z 表示用于约束模糊数的对称参考函数,呈递减趋势。

最终得到线性方程的隶属度函数 $v_{Y_k}(Y_o)$ 公式如下:

$$v_{Y_k}(Y_o) = Z\left(\frac{Y_k - (t_o + \sum_{o=1}^n t_o x_{ok})}{V_o + \sum_{o=1}^n V_o |x_{ok}|}\right) \quad (14)$$

式中, k 表示隶属集合数量, o 表示输入数量。

使用对称参考函数 $z(x)$ 公式如下:

$$z(x) = \max(0, 1 - |x|) \quad (15)$$

式中,对称参考函数 $z(x)$ 在 $(0, 1)$ 中递减。

可转换模糊回归方程为线性优化问题,其公式如下:

$$\begin{cases} K = \min \left\{ m v_o + \sum_m \sum_n^{k=1} \sum_{o=1}^{o=1} v_o |x_{ok}| \right\} \\ y_k \geq t_o + \sum_{o=1}^{o=1} t_o x_{ok} - (1-j) \left(v_o + \sum_{o=1}^{o=1} v_o |x_{ok}| \right) \\ y_k \leq t_o + \sum_{o=1}^{o=1} t_o x_{ok} + (1-j) \left(v_o + \sum_{o=1}^{o=1} v_o |x_{ok}| \right) \\ V_o \geq 0 (o = 1, 2, \dots, n) \end{cases} \quad (16)$$

式中, K 表示目标优化函数, j 表示设定阈值。

进一步推导出模糊线性回归方程,即为线性规划问题,其公式如下:

$$Y = S_0 + S_1 C_1 + S_2 C_2 + S_3 C_3 + S_4 C_4 \quad (17)$$

最终求得模糊度 $G(M^j)$ 公式如下:

$$G(M^j) = \sqrt{(v_o^j)^2 + (v_1^j)^2 + \dots + (v_n^j)^2} \quad (18)$$

3.2 改进神经网络模型

改进神经网络检测模型结构如图2所示。




图2 改进神经网络结构图

其前三层为输入层,第四层为结合模糊推理模型的隐藏层,第五层为输出层。

在第一层内,隶属度可通过节点获取,根据获取的隶属度函数模糊化输入信号,其公式如下:

$$\begin{cases} P_{o,1} = v_{A_o}(x_1) \\ P_{o,1} = v_{B_o}(x_2) \\ P_{o,1} = v_{C_o}(x_3) \\ P_{o,1} = v_{D_o}(x_4) \end{cases} \quad (19)$$

式中, P 表示节点, $v(x)$ 表示梯形隶属度函数。

在第二层内,可计算出前提模糊集,并完成输入信号的代数积转换输出,其激励强度规则的节点输出公式如下:

$$P_{o,2} = v_{A_o}(x_1) v_{B_o}(x_2) v_{C_o}(x_3) v_{D_o}(x_4) = e_o \quad (20)$$

式中, e_o 表示神经元的权重参数。

在第三层内,归一化隶属度函数各条规则的激励强度,其公式如下:

$$P_{o,3} = \bar{e}_o = \frac{e_o}{e_1 + e_2 + e_3 + e_4} \quad (21)$$

式中, $e_1 + e_2 + e_3 + e_4$ 表示上一层的总权重。

在第四层内,计算自适应节点的模糊规则,公式如下:

$$P_{o,4} = \bar{e}_o (A_o x + w_o y + t_o) \quad (22)$$

式中, \bar{e}_o 表示上一层参数, $\{A_o, w_o, y, t_o\}$ 表示每个规则的后续参数。

在第五层内, 模糊模型的输出公式如下:

$$P_{o,s} = \sum_o \bar{e}_o g_o = \frac{\sum_o e_o g_o}{\sum_o e_o} \quad (23)$$

其中, 隶属度函数选用高斯隶属度函数, 其公式如下:

$$v_{A_o}(x) = \left(-\frac{(x - v_o)^2}{2\zeta_o^2} \right) \quad (24)$$

式中, ζ 表示高斯噪声, v_o 表示中心值跨度。

计算隶属度函数的最优参数, 使模糊推理模型达到最优输出。

基于此, 完成结合线性回归与模糊度函数的神经网络模型构建, 并通过其完成铁道抗压强度的检测。

3.3 基于FCM的连续属性离散化

铁轨抗压强度受到不同材料和环境的影响, 同时不同因素之间存在非线性、不确定性、随机性等特点。需要对输入模型的样本通过离散化处理进行属性约简。

将属性分为 m 类 ($2 \leq m \leq n$), 则第 i 类属性的聚类中心为:

$$v_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (25)$$

式中, u_{ij} 为任意特征点 x_j 中第 j 类的隶属度^[12]。

则任意特征点 x_j 中第 j 类的隶属度 u_{ij} 为:

$$u_{ij} = \frac{1}{\sum_{j=1}^m \left(\frac{\|x_j - v_i\|}{\|x_j + v_i\|} \right)^{2(m-1)}} \quad (26)$$

隶属度矩阵 U 的离散目标函数为:

$$J_m(U) = \sum_{i=1}^m \sum_{j=1}^n u_{ij}^m \|x_j - v_i\|^2 \quad (27)$$

式中, $m > 1$ 为影响 U 离散化程度的指数权重。

可用隶属度最大化原则对样本集进行离散化, 哪一个聚类中心的隶属度最大, 即将其相对应的离散属性值作为样本的最优离散度。

3.4 铁轨抗压强度预测实现

将离散化的属性样本输入到线性回归与模糊度函数神经网络模型中, 选择隶属度函数的最优参数, 建立预测铁轨预测模型。

根据动载激振原理和按质阻弹模拟原理, 耦合铁轨与路基的同步振动, 计算铁轨的抗压强度:

$$K = \frac{P}{A} + mw^2 \quad (28)$$

式中, P 为激振力, A 为振幅, M 为参振质量, W 为振动角频率。

按照图3流程完成预测。




图3 预测流程

根据图3所示流程, 将参数样本输入模型中, 完成铁轨抗压强度预测。

4 实验与分析

为了验证基于改进神经网络的铁轨抗压强度预测研究方法的整体有效性, 对其完成如下测试。

在测试软件搭建实验模型, 选用 CRTSⅢ型轨道板作为实验对象, 其包含不同龄期的 P4925、P4853、P5600、P4856 四种板型铁轨。

4.1 铁轨振动信号提取

本系统在某市地铁路段安装传感器设备采集铁轨信号, 安装情况如图4所示。



(a) 检测传感器 (b) ZigBee 节点传输模块

图4 现场硬件设备安装

ZigBee 终端节点采用美国德州仪器的 CC2530。铁轨检测传感器型号为久泰铁路轨道智能型 BJLF-2。

硬件设备安装完成后, 设置上位机 500 ms 一次定时发送采集指令。传感器 X 方向的波动范围为 $4.823^\circ - 4.824^\circ$, Y 方向的波动范围为 $1.996^\circ - 1.998^\circ$ 。考虑传感器存在安装偏差, 将波动范围控制在 $0 - 0.001^\circ$ 之间。

采集的部分振动信号 IMF 分量如图5所示。

采用小波分解方法对上节提取到的铁轨振动信号实行降噪处理。将信号特征频率强度系数作为测试指标。设 $G_k (k=1, 2, \dots, N)$ 为频率幅值, GD_j 为信号特征频率倍频 j 的幅值, 强度系数 D_g 计算公式如下:

$$D_g = \frac{\sum_{j=1}^3 GD_j}{\sum_{k=1}^N G_k} \quad (29)$$




图5 振动信号提取

去噪前后信号强度系数结果如图6所示。




图6 去噪前后结果对比

由图6可知,去噪后信号强度明显提高,在噪声强度最大时,强度系数仍高于0.1,证明本文方法信号去噪效果较好。

将上节中FCM 离散化后的属性数据导入 Rosetta 软件中进行约简操作,提取出对地铁抗压强度有影响的主要因素。整理后得到的六个主要属性因素参数为:{混凝土制作材料配比,地铁比表面积,激振力,振动角频率,列出加速度、倾角变化}。将六个主要属性的信号样本输入到训练模型中进行训练。

4.2 模型训练参数


在网络的训练开始前,首先要把环境变量清空,然后使用 Matlab 中的 newff 函数来建立一个新的神经网络。通过一系列测试和实验后选择以下训练参数:根据6个属性样本,设定输入层共6个节点。隐含层中设置12个神经元。算法迭代最高为10次。学习率数值是0.01。而输出层的节点只有一个分量,即抗压强度预测结果。将参数设置好之后开始进行训练。

4.3 测试结果分析


(1) 预测精度

采用所提方法、基于随机森林预测方法(文献[3])、基于PCA-RVM模型预测方法(文献[4])对其实行抗压强


度检测,其结果如图7所示。




(a) P4925 版型误差



(b) P4853 版型误差



(c) P5600 版型误差



(d) P4856 版型误差

图7 三种方法的误差对比

基于随机森林预测方法的抗压强度检测在P4925 版型中,较真实抗压强度值的误差小,但在其他三类版型中,其抗压强度检测误差大,不能满足所有版型铁轨检测;基于PCA-RVM模型预测方法的抗压强度检测结果与真实抗压强度值相比,误差较大,检测精确度不佳;所

提方法在四种版型中的抗压强度检测值与真实抗压强度值最接近,误差最小,均低于2 MPa,表明所提方法的抗压强度检测精度更高。

(2) 检测时间

采用所提方法、基于随机森林预测方法、基于PCA-RVM模型预测方法对其完成抗压强度检测,记录每种版型所有龄期的板材检测时间之和,所用时间如图8所示。

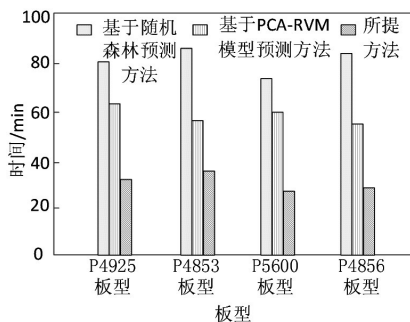


图8 三种方法所用时间

分析图8可知,基于随机森林预测方法的抗压强度检测时间最长,高达80 min;基于PCA-RVM模型预测方法的抗压强度检测时间在60 min左右;所提方法的抗压强度检测时间最短,在25 min左右,不及基于随机森林预测方法和基于PCA-RVM模型预测方法的一半,表明所提方法的抗压强度检测效率高。

通过上述实验可知,所提方法在信号提取环节,使用经验模态分解方法准确的提取到了铁轨信号的分量特征,为抗压强度的检测确立基础;并通过小波分解方法去除铁轨信号噪声,降低了噪声干扰,进一步提高了检测精确度;最后通过线性回归算法及模糊度函数对神经网络模型的改进,建立了自适应模糊神经网络检测模型,大大提高了抗压强度检测的精度及降低了检测时间。

5 结束语

铁轨的抗压强度预测是铁路安全领域研究的重点内容之一,如何用自动方法代替人工检测是未来研究的重点,

因此提出基于改进神经网络的铁轨抗压强度预测研究方法。首先,提取铁轨信号;其次,对其实行去噪处理;最后,通过模型对其完成抗压强度检测。测试结果证明,本文方法在抗压强度检测精度和效率上具有技术优势,为铁轨的安全检测研究提供了新的思路,具有实际应用价值。

参考文献:

- [1] 汪恩良,田雨,刘兴超,等.基于WOA-BP神经网络的超低温冻土抗压强度预测模型研究[J].力学学报,2022,54(4):1145-1153.
- [2] 张驰,郭媛,黎明.神经网络模型发展及应用综述[J].计算机工程与应用,2021,57(11):57-69.
- [3] 吴贤国,刘鹏程,陈虹宇,等.基于随机森林的高性能混凝土抗压强度预测[J].混凝土,2022,1(1):17-20,24.
- [4] 张研,廖逸夫,王鹏鹏,等.THM作用下砂岩三轴抗压强度预测的PCA-RVM模型[J].矿业研究与开发,2020,40(11):52-58.
- [5] 赵宏良,马士宾,杨志伟,等.基于成熟度的二灰稳定碎石抗压强度预测方法[J].中国粉体技术,2022,28(1):76-86.
- [6] 马媛,陈友兴,李鹏,等.经验模态分解火箭发动机多界面粘结检测特征信号提取技术[J].宇航材料工艺,2021,51(1):90-93.
- [7] 杨录,王慧敏,梁星雨.基于倒谱与经验模态分解的盐敏大鼠血压信号特征提取方法[J].中国测试,2020,46(6):61-66.
- [8] 何定桥,王鹏军,杨军.深度神经网络在EMD虚假分量识别中的应用[J].工程力学,2021,38(S1):195-201.
- [9] 马斌,张泽,赵钊.基于相关性方差贡献率的高坝泄洪振动数据级融合方法[J].水利水电科技进展,2020,40(2):36-41,75.
- [10] 余浩,庄池杰,曾嵘,等.提高暂态电压测量精度的自适应小波去噪方法[J].高电压技术,2020,46(6):2139-2147.
- [11] 王海龙,柏皓博,赵岩,等.基于傅里叶分解-小波包分析的爆破信号去噪方法[J].爆破,2021,38(2):37-44.
- [12] 王瀚伦,雷加坤,康信,等.基于似然BP算法的区域供电能效差异变化趋势预测方法[J].自动化技术与应用,2024,43(4):177-181.

作者简介:尹轶(1986-),男,本科,工程师,研究方向:铁道工程。

(上接第44页)

多目标负荷优化分配[J].工程热物理学报,2020,41(1):29-38.

[8] 杨宏强,孙瑜,杜伟.燃煤发电厂智能DCS的功能设计与应用[J].热力发电,2020,49(3):100-106.

[9] 黄守军,杨俊.发电成本垂直差异电力市场概率发电①——基于大用户电量偏好视角[J].管理科学学报,2020,23(6):18-43.

[10] 晏建军,崔晓波,罗凯明,等.基于多模型预测控制的火电机深度调峰一次调频控制策略[J].锅炉技术,2020,51(6):12-17.

[11] 杨寅平,曾沅,秦超,等.面向深度调峰的火电机组灵活性改造规划模型[J].电力系统自动化,2021,45(17):79-88.

[12] 徐静,杨德岭.基于PSO-BP模型的差速器装配密封质量预测[J].森林工程,2024,40(5):134-144.

[13] 杨军亭,张自强,王栋,等.基于配电网全域大数据的负荷智能预测模型[J].自动化技术与应用,2024,43(7):54-57,116.

作者简介:黄常抒(1979-),男,本科,工程师,研究方向:发电厂继电保护、自动化技术管理。

通信作者:龙建平(1981-),男,本科,高级工程师,研究方向:电厂性能计算、环保监测等厂网侧应用软件。