

文章编号: 1673-3193(2024)01-0058-08

基于可视图特征与CatBoost的转辙机故障诊断

杨喜旺^{1,2}, 王智超², 黄晋英³, 荆丽澄³, 王宇轩³

(1. 山西电子科技学院 信息与通信工程学院, 山西 临汾 041000;

2. 中北大学 计算机科学与技术学院, 山西 太原 030051; 3. 中北大学 机械工程学院, 山西 太原 030051)

摘要: 针对道岔转辙机转换油压信号难以提取有效的故障特征且传统的故障诊断方式效果差的问题, 本文提出一种基于可视图特征与CatBoost的道岔转辙机故障诊断方法。首先, 采用可视图算法将时域信号转换为复杂网络图。然后, 提取复杂网络图的5种统计特征, 即网络平均度、全局聚类系数、平均路径长度、传递性特征与网络图密度。最后, 通过CatBoost算法实现道岔转辙机故障诊断。将该方法分别与其它特征提取方法、故障分类算法进行比较。实验结果表明: 可视图特征能够更有效表征道岔转辙机的工作状态, CatBoost算法对道岔转辙机4种工作状态的诊断准确率达到97.5%, 验证了该方法的有效性和优越性。

关键词: 可视图特征; 道岔转辙机; CatBoost算法; 故障诊断

中图分类号: TP206

文献标识码: A

doi: 10.3969/j.issn.1673-3193.2024.01.008

引用格式: 杨喜旺, 王智超, 黄晋英, 等. 基于可视图特征与CatBoost的转辙机故障诊断[J]. 中北大学学报(自然科学版), 2024, 45(1): 58-65.

YANG Xiwang, WANG Zhichao, HUANG Jinying, et al. Fault diagnosis of switch machine based on visibility graph feature and CatBoost[J]. Journal of North University of China(Natural Science Edition), 2024, 45(1): 58-65.

Fault Diagnosis of Switch Machine Based on Visibility Graph Feature and CatBoost

YANG Xiwang^{1,2}, WANG Zhichao², HUANG Jinying³, JING Licheng³, WANG Yuxuan³

(1. School of Information and Communication Engineering, Shanxi Institute of Electronic Science and Technology,

Linfen 041000, China; 2. Data Science and Technology, North University of China, Taiyuan 030051, China;

3. School of Mechanical Engineering, North University of China, Taiyuan 030051, China)

Abstract: Aiming at the problem that it is difficult to extract effective fault features from oil pressure signals converted by turnout switch machine and the traditional fault diagnosis method is not effective, a fault diagnosis method turnout switch machine based on visibility graph features and CatBoost is proposed. Firstly, the visual graph algorithm is used to convert the time-domain signal into a complex network graph. Then, the five statistical features of complex network graphs are extracted (i. e., network average degree, global clustering coefficient, average path length, transitivity feature and network graph density). Finally, the fault diagnosis of turnout switch machine is realized by CatBoost algorithm. This method is compared with other feature extraction methods and fault classification algorithms. The experi-

收稿日期: 2023-03-29

基金项目: 山西省回国留学人员科研教研资助项目(2022-141); 山西省基础研究计划资助项目(202203021211096)

作者简介: 杨喜旺(1970—), 男, 副教授, 博士, 主要从事大数据算法与机械故障诊断方面的研究。

通信作者: 黄晋英(1971—), 女, 教授, 博士, 主要从事结构动力学分析、检测与控制、故障诊断与健康管理的研究。E-mail: jyhuang@nuc.edu.cn.

mental results show that the visibility graph feature can more effectively represent the working state of turnout switch machine. The diagnostic accuracy of CatBoost algorithm for four working states of turnout switch machine reaches 97.5%, which verifies its effectiveness and superiority.

Key words: visibility graph feature; turnout switch machine; CatBoost algorithm; fault diagnosis

针对铁路交通运输关键设备开展故障诊断与健康状态监测研究有着重要的意义。道岔转辙机作为一种被广泛应用的铁路设备,通常在复杂的工作条件下运行,若发生故障,会影响正常的铁路交通运输,从而造成严重的经济损失。因此,对铁路道岔转辙机设备开展故障诊断研究,能够有效降低设备的维护成本,保障设备正常运行^[1]。

道岔转辙机设备转换信号具有非平稳、非线性特性,难以通过提取时域、频域特征进行有效的诊断分析。许多学者对道岔转辙机故障诊断方法展开了研究。董昱等^[2]提出了一种基于小波分解的道岔转辙机设备的故障诊断方法,对信号进行小波包特征向量提取。Chen 等^[3]提出了一种基于能量的阈值小波(EBTW)的特征提取方法。孙永奎等^[4]基于小波包分解与多尺度排列熵实现了对转辙机声音信号的特征提取。然而,它们需要通过人工设定,无法保证提取特征的有效性。Kun 等^[5]提出了一种基于变分模式分解(VMD)和改进模糊聚类算法的新型转辙机故障诊断方法。该方法使用 VMD 对故障数据进行分解,提取分解信号各分量的奇异值作为故障特征,但是 VMD 分解中的相关参数同样需要人工设定。马丽等^[6]提出一种基于局部切空间排列和支持向量机(SVM)的故障诊断方法,该方法使用 EMD 算法对降维和消噪后的数据进行分解,提取分解后各分量的能量熵作为故障特征,通过 EMD 方法可以自适应地分解信号。然而,EMD 分解方法容易出现模态混叠的问题。魏文军等^[7]提出了一种基于 EEMD 多尺度样本熵的道岔转辙机故障诊断方法。曹源等^[8]通过 EEMD 将转辙机振动信号分解后,提取了重构信号的多尺度故障特征。赫婷等^[9]提出了一种非线性自适应正交经验模态分解(KPEMD)方法来提取分解信号的时域频域和能量熵特征,完成了转辙机关键部件柱塞泵的特征提取。EEMD 和 KPEMD 在一定程度上解决了模态混叠问题,但是 EEMD 相对于 EMD 复杂度增加,这会导致计算时间变长。池毅^[10]提出一种基于深度学习的道岔转辙机故障诊断方法。刘可兴等^[11]提出一种深度卷积降噪自编码器与双向

循环神经网络相结合的故障诊断方法。Cao 等^[12]提出了一种深度随机森林融合(DRFF)方法,对转辙机 3 个方向的振动信号进行融合,可以有效提高转辙机的故障诊断精度。付雅婷等^[13]利用经验模态分解将转辙机功率信号分解成多个本征模态函数信号,接着使用一维卷积神经网络(1DCNN)和长短期记忆神经网络(LSTM)提取特征。王瑞峰等^[14]使用一维卷积神经网络(1DCNN)和长短期记忆神经网络(LSTM)提取转辙机功率信号的特征。然而,深度学习模型存在计算量大且可解释性差等问题,限制了其应用。

针对传统信号分解算法难以保证提取特征的有效性以及深度学习模型可解释性差等问题,本文提出了一种基于可视图特征与 CatBoost 的转辙机故障诊断方法。首先,利用可视图分析技术将道岔转辙机设备转换油压信号转变为复杂网络图,并计算图对应的邻接矩阵与度矩阵。然后,通过邻接矩阵与度矩阵计算复杂网络图特征。最后,采用 CatBoost 实现道岔转辙机的故障识别与分类。本文不同于提取信号的时域、频域、时频域特征,而是将信号转换为复杂网络图,从而提取复杂网络图的统计特征,故提供了一种故障特征提取的新思路。

1 可视图算法

可视图算法是一种可以将时间序列转换为复杂网络的算法,该种算法简单易实现,运算速度快。可视图算法基本原理如下^[15]。

假设 (t_a, v_a) 和 (t_b, v_b) 是时间序列上的任意两点,若任一其它点 (t_c, v_c) ($t_a < t_c < t_b$)都满足

$$v_c < v_a + (v_b - v_a) \frac{t_c - t_a}{t_b - t_a}, \quad (1)$$

则 (t_a, v_a) 和 (t_b, v_b) 之间存在可视线。

如图 1 所示,可视图算法将图(a)中的时间序列数据转换为图(b)中相应的网络图谱。

图 1(a) 直方图表示时间序列中 5 个时间节点,其高度为对应的幅值。图 1(b) 网络图谱中连接表示原始时间序列中节点是否相互可视。图 1(c) 为时间序列转换后的图结构。




图1 可视图算法构建复杂网络

Fig. 1 Constructing a complex network with a viewable algorithm

2 图的基本概念与统计特征

2.1 图的表示

定义网络图为 $G=(V,E)$, 由节点集合 V 和边集合 E 组成。 $V=\{1,2,\dots,N\}$, N 为节点数量。部分节点之间存在相连的边, 这些边的集合表示为 E 。具体地, 取任意的两个节点为 $i,j \in V$, 则 $E=\{i,j,w_{ij}\}$, 其中, w_{ij} 为节点 i 与节点 j 之间边的权重。

通常, 定义 A 为邻接矩阵, 则 $N \cdot N$ 的 A 表示有 N 个节点的网络图, 其中 $A(i,j)=w_{ij}$ 。通常, A 由 0 和 1 两个元素组成, 1 表示两节点存在边连接, 0 表示两节点间无连接。同时, 定义一个度矩阵 $D=diag(d_1,d_2,\dots,d_N)$, 其中, d_i 为节点 i 的所有边权值的总和, 而 $diag()$ 将向量转变为对角矩阵。

2.2 图的统计特征

学者们针对复杂网络图提出了许多统计特征指标, 复杂网络图的节点和连边表示了许许多多的相互作用关系, 复杂网络本身的拓扑性质是对网络内在信息的反映。本文在此基础上, 对可视图网络平均度、全局聚类系数、平均路径长度、传递性特征

与网络图密度等 5 个特征指标进行提取^[16]。

网络图平均度定义为

$$K = \frac{1}{N} \sum_{i=1}^N d_i \quad (2)$$

全局聚类系数定义为

$$CC = \frac{\sum_{i=1}^n N_{\Delta}(i)}{\sum_{i=1}^n N_3(i)} \quad (3)$$

式中: $N_{\Delta}(i)$ 为与节点 i 相连的两节点相连的结构数目; $N_3(i)$ 为与节点 i 相连的两节点不相连的结构数目。

网络的平均路径长度定义为

$$L = \frac{2}{N(N+1)} \sum_{i < j} w_{ij} \quad (4)$$

传递性定义为网络中任意两个相连接的节点拥有共同的连接点的概率, 即

$$T = \frac{\sum_{i,j,k} w_{i,k} w_{j,k} w_{i,j}}{\sum_{i,j,k} w_{i,j} w_{j,k}} \quad (5)$$

网络密度定义为图中实际存在的连接数与理论上存在的最大边数之比, 其定义为

$$\rho = \frac{M}{\frac{1}{2} N(N-1)} \quad (6)$$

式中: M 为实际存在的边数。

3 CatBoost 故障分类算法

CatBoost 是一种改进的梯度提升树 (GBDT) 类算法。CatBoost 从两方面对 GBDT 算法进行了改进, 即处理标称属性和解决预测偏移的问题, 从而减少过拟合的发生^[17]。

GBDT 算法^[18]通过集成众多弱学习器, 不断迭代学习, 从而得到一个强学习器, 使分类的准确率提高。它采用的弱学习器为分类回归树 (CART)。

假设上一轮学习得到的强学习器为 $F^{t-1}(x)$, 损失函数为 $L(y, F^{t-1}(x))$, 则前轮次迭代是为了找到一个 CART 模型的弱学习器 h^t , 使当前轮次的损失函数达到最小值。当前轮次优化的目标函数为

$$h^t = \underset{h \in H}{\operatorname{argmin}} EL((y, F^{t-1}(x) + h(x))) \quad (7)$$

每一轮损失的近似值由目标函数的负梯度拟合, 所求取的梯度为

$$g^t(x, y) = \frac{\partial L(y, s)}{\partial s} |_{s = F^{t-1}(x)} \quad (8)$$

通常, 近似拟合 h' 的公式为

$$h' = \underset{h \in H}{\operatorname{argmin}} E(-g^t(x, y) - h(x))^2. \quad (9)$$

本轮次的最强学习器为

$$F^t(x) = F^{t-1}(x) + h^t. \quad (10)$$

CatBoost 算法是一种基于对称决策树的 GBDT 模型, 其最大的改进是支持直接输入类别型变量, 同时, 有效地解决了梯度偏差和预测偏移的问题, 从而降低了过拟合的发生性。

传统的提升(Boost)算法每个步骤中的梯度都由当前模型中相同的数据点来估计, 这样会造成梯度偏差, 从而造成过拟合。Catboost 使用下一棵对称决策树来拟合上一个模型的梯度, 通过生成 m 个随机排列的训练数据集样本, 针对每一个随机排列的样本 X , 训练一个单独的模型 N , 计算其梯度, 并且这个模型不依赖该样本的梯度进行更新。使用不同的排列来训练不同的模型, 不会造成模型过拟合, 也就解决了梯度偏差的问题。

预测偏移(Prediction shift)是由梯度偏差造成的。在经典的 GDBT 中, 使用相同的数据集求当前模型的梯度会导致梯度偏差, 进而导致模型过拟合。然而, CatBoost 将传统梯度估计方法替换为排序提升(Ordered boosting)的方法, 进而降低梯度估计的偏差, 提高模型的泛化能力。

在 CatBoost 算法中, 需要调节的参数很少, 其中重要的参数包括学习率、树的深度、树的数量等。

4 故障诊断流程

本文将采用国产某型电液式转辙机的转换油压数据进行故障诊断。首先, 通过可视图算法将道岔转辙机的油压转换数据转换为图网络。接着, 对网络图提取统计特征。最后, 使用 CatBoost 算法对特征样本进行故障分类。流程见图 2, 详细过程如下。

步骤 1: 通过道岔转辙机实验台采集正常状态、道岔卡阻不解锁、道岔卡阻不锁闭、转换过程中存在异常阻力等工况的转换油压数据。

步骤 2: 将总样本集按照 $a : b$ 的比例划分为训练集与测试集。

步骤 3: 将所有样本转换为可视图, 并求出每条样本的邻接矩阵与度矩阵。

步骤 4: 提取平均度、全局聚类系数、平均路径长度、传递性特征和网络密度等特征, 并对特征样本进行归一化处理。

步骤 5: 使用训练集全部的数据样本训练 CatBoost 模型。

步骤 6: 向 CatBoost 模型输入测试集样本数据, 模型输出对应的训练样本类型为对应的测试样本故障类型, 进而判断道岔转辙机的状态, 达到故障类型识别的目的。

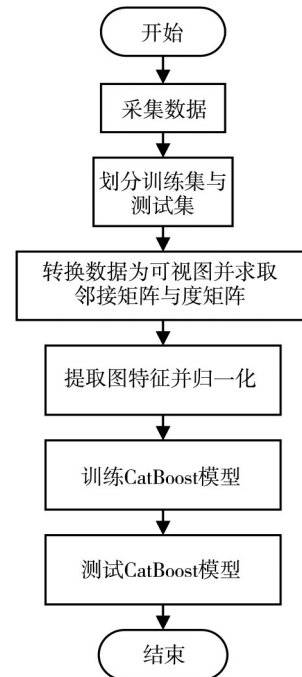


图 2 故障诊断流程图

Fig. 2 Trouble shooting flowchart

5 实验与结果分析

5.1 实验数据与采集

本实验数据通过使用某铁路局电务器材公司提供的某型电液式道岔转辙机故障模拟实验平台来获取, 转辙机故障实验平台如图 3 所示。



图 3 转辙机故障模拟实验台

Fig. 3 Switch machine fault simulation test bench

实验平台由某型电液式道岔转辙机主机、转辙机负机、监测微机 and 采集装置构成。根据实验需要,采集模型电液式转辙机常见4种工况的转换油压数据,分别为正常状态、道岔卡阻不解锁、道岔卡阻不锁闭、转换过程中存在异常阻力。正常工况下转换油压数据曲线如图4所示,该曲线大致可以分为5个阶段,依次为启动(T_1)、解锁(T_2)、转换(T_3)、锁闭(T_4)、接通表示(T_5),其余3种工况的转换油压数据曲线如图5所示。






图4 正常工况下转换油压曲线图


Fig. 4 Conversion oil pressure curve



(a) 道岔卡阻不解锁



(b) 道岔卡阻不锁闭



(c) 转换过程存在异常阻力

图5 道岔卡阻不解锁、道岔卡阻不锁闭、转换过程中存在异常阻力工况下的转换油压曲线图

Fig. 5 Conversion oil pressure curves under Turnout jam do not lock, Turnout jam not locked, Abnormal resistance in the conversion process

数据的精度为0.1 MPa,采样频率为50 Hz,每个样本的长度为700,每种工况下采集样本2500个,将样本按照7:3的比例划分为训练集和测试集,实验采集的4种工况以及样本数量说明详见表1。

表1 道岔转辙机工况

Tab. 1 Working conditions of turnout switch machine

工况编号	工况代码	工况名称	训练样本数	测试样本数
0	c_0	正常	1750	750
1	c_1	道岔卡阻不解锁	1750	750
2	c_2	道岔卡阻不锁闭	1750	750
3	c_3	转换过程中存在异常阻力	1750	750

5.2 故障特征提取

采用步骤2~步骤4对数据样本进行特征提取,分别对所有的数据样本提取平均度 f_1 、全局聚类系数 f_2 、平均路径长度 f_3 、传递性 f_4 与网络图密度 f_5 。表2为5种可视图统计特征在4种工况下的均值与方差。

从表2可以看出,平均度 f_1 、传递性 f_4 以及网络图密度 f_5 在正常 c_0 工况下最小,在道岔卡阻不锁闭 c_2 工况最大。全局聚类系数 f_2 、平均路径长度 f_3 在道岔卡阻不锁闭 c_2 工况下最小,全局聚类系数 f_2 在正常 c_0 工况下最大,平均路径长度 f_3 在道岔卡阻不解锁 c_1 工况下最大。这说明在不同工况下,每种统计特征之间存在较为明显的差异,并且每种特征的方差都较小,各工况下每项

特征在数值上较为稳定。

表 2 特征均值与方差表

Tab. 2 Tab. of characteristic mean and variance

工况	f_1		f_2		f_3		f_4		f_5	
	均值	方差	均值	方差	均值	方差	均值	方差	均值	方差
c_0	9.4	3.9	1.18	0.04	3.08	0.13	0.31	0.005	0.095	0.000 3
c_1	16.0	5.8	1.04	0.06	3.30	0.18	0.42	0.010	0.132	0.001 0
c_2	17.4	4.3	0.90	0.04	2.73	0.21	0.51	0.014	0.176	0.002 1
c_3	11.1	5.0	1.12	0.06	3.21	0.15	0.36	0.015	0.125	0.001 6

5.3 故障诊断仿真实验

本文通过python编写 CatBoost 故障诊断模型,模型的损失函数为对数损失函数,学习率为 0.01,同时,通过测试集数据对树的深度与树的数量两项重要参数值的设定进行测试。在图 6 中,树的深度在 6 时达到最优准确率。在图 7 中,树的数量为 100 左右时,准确率曲线达到最优且收敛。因此,设置树的深度为 8,树的数量为 100。




图 6 树的深度与准确率的关系

Fig. 6 The relationship between tree depth and accuracy rate




图 7 树的数量与准确率的关系

Fig. 7 The relationship between number of trees and accuracy rate

完成参数设定之后,使用训练集样本特征训练 CatBoost 模型。模型训练的损失曲线如图 8 所示,可以看出模型训练损失值收敛速度快,且训练迭代完成时的数值极低。模型完成训练之后,在测试集测试时的模型准确率为 97.5%,证明模型在转辙机故障诊断中的有效性与准确性。




图 8 训练损失曲线

Fig. 8 Training loss curve

5.4 实验对比

表 3 为提取转辙机转换油压信号的时域特征、频域特征、时频域特征、可视图特征的诊断结果。时域特征包括均值、峰值、方根幅值、方差、有效值、峰度、峭度和裕度等 8 个特征。频域特征包括重心频率、平均频率、均方根频率、频率标准差和功率谱熵等 4 个特征。时频域为小波分解后的系数特征与能量特征。由表可知,可视图特征提取方法明显优于其它特征提取方法,从而体现出可视图特征在转辙机故障特征提取中的优越性。

表 3 不同特征诊断结果

Tab. 3 Diagnostic results of different characteristics

特征提取方法	准确率/%
时域特征	88.7
频域特征	92.3
时频域特征	94.1
可视图特征	97.5

表 4 为 BP 神经网络^[19]、SVM^[20]、XGBoost^[21]、CatBoost 等分类算法在可视图特征

下的测试集故障诊断准确率。可以看出CatBoost算法的故障诊断准确率高於其它几种常见分类模型的,比SVM与BP神经网络等经典模型诊断准确率高0.5%以上,而比同为GBDT类算法的XGBoost高0.3%。

表4 不同模型诊断结果

Tab. 4 Diagnostic results of different models

诊断模型	准确率/%
SVM	96.9
BP神经网络	96.3
XGBoost	97.2
CatBoost	97.5

6 结论

本文结合可视图算法、复杂网络图特征以及CatBoost算法,针对铁路道岔转辙机难以提取有效的故障信号特征与传统故障诊断方法诊断准确率低等问题,提出了一种基于可视图特征和CatBoost的道岔转辙机故障诊断方法。通过实验验证,得出以下结论:

1) 可视图算法可以有效将转辙机时域信号转换为复杂网络图,通过网络图节点的度与节点间的边等信息,更好地展现出不同故障的特征。

2) 复杂网络图的5种特征可以较为准确地表征出转辙机的故障特征,有利于保证下一步故障诊断模型的诊断效果。

3) 将CatBoost模型应用于转辙机故障诊断,较好地实现了转辙机不同工作状态的识别分类,与传统的模型相比较,拥有较高的准确率。

参考文献:

[1] 程伟鸷,王海东,梁宇. 铁路道岔转辙机故障分析与故障诊断监测系统研究[J]. 中国铁路, 2018(7): 43-47. CHENG Weizhi, WANG Haidong, LIANG Yu. Research on fault analysis and fault diagnosis monitoring system of railway switch machine [J]. China Railway, 2018(7): 43-47. (in Chinese)

[2] 董昱,赵媛媛,林海香. 基于小波分析的电动转辙机动作电流的分析研究[J]. 兰州交通大学学报, 2012, 31(6): 39-43. DONG Yu, ZHAO Yuanyuan, LIN Haixiang. The analysis and research of electric switch machine operating current based on wavelet analysis [J]. Journal of Lanzhou Jiaotong University, 2012, 31(6): 39-43. (in Chinese)

[3] CHEN Q Y, GEMMA N, CLIVE R, et al. Improved fault diagnosis of railway switch system using energy-

based thresholding wavelets (EBTW) and neural networks [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.

[4] 孙永奎,曹源,李鹏,等. 基于小波包分解多尺度排列熵及2阶特征选择的转辙机故障诊断方法[J]. 中国铁道科学, 2023, 44(3): 178-188. SUN Yongkui, CAO Yuan, LI Peng, et al. A fault diagnosis method of switch machine based on wavelet packet decomposition, multi-scale arrangement entropy and second-order feature selection [J]. China Railway Science, 2023, 44(3): 178-188. (in Chinese)

[5] KUN S Y, HE T, WU Y C. Research on fault diagnosis method of switch machine based on KFCM [J]. Journal of Physics: Conference Series, 2021, 1972(1): 012029.

[6] 马丽,安志龙. 基于局部切空间排列和支持向量机的S700k转辙机齿轮组故障诊断模型[J]. 青海交通科技, 2019(4): 80-84. MA Li, AN Zhilong. Fault diagnosis model of S700K point machine gear set based on local tangent space arrangement and Support vector machine [J]. Qinghai transportation technology, 2019(4): 80-84. (in Chinese)

[7] 魏文军,刘新发. 基于EEMD多尺度样本熵的S700K转辙机故障诊断[J]. 中南大学学报(自然科学版), 2019, 50(11): 2763-2772. WEI Wenjun, LIU Xinfa. Fault diagnosis of S700k point machine based on EEMD multi-scale sample entropy [J]. Journal of the Central South University (Science Edition), 2019, 50(11): 2763-2772. (in Chinese)

[8] 曹源,宋迪,胡小溪,等. 基于改进时域多尺度散布熵与支持向量机的转辙机故障诊断[J]. 电子学报, 2023, 51(1): 117-127. CAO Yuan, SONG Di, HU Xiaoxi, et al. Fault diagnosis of switch machine based on improved time-domain multi-scale dispersion entropy and support vector machine [J]. Acta Electronica Sinica, 2023, 51(1): 117-127. (in Chinese)

[9] 赫婷,黄晋英,胡孟楠,等. 基于KPEMD与INFO-SVM的柱塞泵故障诊断[J]. 中北大学学报(自然科学版), 2023, 44(3): 216-221. HE Ting, HUANG Jinying, HU Mengnan, et al. Fault diagnosis of piston pump based on KPEMD and INFO-SVM [J]. Journal of North University of China (Natural Science Edition), 2023, 44(3): 216-221. (in Chinese)

[10] 池毅. 基于深度学习的道岔故障智能诊断方法研究[D]. 兰州: 兰州交通大学, 2021.

- [11] 刘可兴, 黄海于. 基于 DCDAE-BiLSTM 模型的转辙机故障诊断方法研究[J]. 铁道通信信号, 2021, 57(8): 87-91.
LIU Kexing, HUANG Haiyu. Research on switch machine fault diagnosis method based on DCDAE-BiLSTM model[J]. Railway Communication Signal, 2021, 57(8): 87-91. (in Chinese)
- [12] CAO Y, YUAN S J, YONG K S, et al. The fault diagnosis of a switch machine based on deep random forest fusion. [J]. IEEE Intelligent Transportation Systems Magazine, 2022, 15 (1): 437-452.
- [13] 付雅婷, 温世明, 杨辉, 等. 基于多通道输入和 1DCNN-LSTM 的道岔转辙机故障诊断[J]. 铁道学报, 2023(11): 98-106.
FU Yating, WEN Shiming, YANG Hui, et al. Fault diagnosis of turnout switch machine based on multi-channel input and 1DCNN-LSTM[J]. Journal of the China Railway Society, 2023(11): 98-106. (in Chinese)
- [14] 王瑞峰, 李扬. 基于 1DCNN-BiLSTM 组合模型的 S700K 转辙机故障诊断[J]. 电子测量与仪器学报, 2022, 36(11): 193-200.
WANG Ruifeng, LI yang. Fault diagnosis of S700K switch machine based on 1DCNN-BiLSTM combined model[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 193-200. (in Chinese)
- [15] 许红红. 基于可视图网络的脑电信号研究[D]. 南京: 南京邮电大学, 2020.
- [16] 郭建民. 时间序列复杂网络建网方法的性能分析及应用研究[D]. 天津: 天津大学, 2016.
- [17] DHANANJAY B, JAYARAMAN S. Analysis and classification of heart rate using CatBoost feature ranking model[J]. Biomedical Signal Processing and Control, 2021, 68(16): 102610.
- [18] 曹颖超. 改进的 GDBT 迭代决策树分类算法及其应用[J]. 科技视界, 2017(12): 105.
CAO Yingchao. Improved GDBT iterative decision tree classification algorithm and its application[J]. Science and Technology Vision, 2017(12): 105. (in Chinese)
- [19] 谢宇希, 颜拥军, 李翔, 等. 基于 BP 神经网络的核探测器故障诊断方法研究[J]. 原子能科学技术, 2021, 55(10): 1857-1864.
XIE Yuxi, YAN Yongjun, LI Xiang, et al. Research on fault diagnosis method of nuclear detector based on BP neural network [J]. Atomic Energy Science and Technology, 2021, 55(10): 1857-1864. (in Chinese)
- [20] 肖雅静. 基于支持向量机的滚动轴承故障诊断与预测方法研究[D]. 北京: 中国矿业大学(北京), 2019.
- [21] 姜少飞, 邬天骥, 彭翔, 等. 基于 XGBoost 特征提取的数据驱动故障诊断方法[J]. 中国机械工程, 2020, 31(10): 1232-1239.
JIANG Shaofei, WU Tianji, PENG Xiang, et al. Data-driven fault diagnosis method based on XGBoost feature extraction [J]. China Mechanical Engineering, 2020, 31(10): 1232-1239. (in Chinese)