Hans汉斯

基于小波分析与神经网络的电子设备故障诊断

杨 好¹,李军成^{1*},杨 磊²

¹湖南人文科技学院数学与金融学院,湖南 娄底 ²曲阜特霓电子科技有限公司,山东 曲阜

收稿日期: 2024年5月10日; 录用日期: 2024年6月11日; 发布日期: 2024年6月30日

摘要

电子设备在长期运行过程中由于受到各种因素的影响,不可避免地会出现故障。如何对电子设备的故障 进行有效诊断具有重要的应用价值。为提高电子设备故障的诊断精度,本文提出了一种基于小波分析和 RBF神经网络的电子设备故障诊断方法,该方法首先利用小波分析提取故障样本的小波系数,然后利用 RBF神经网络训练小波系数实现故障诊断。基于MATLAB的仿真实验结果表明,所提出的方法是一种有 效的电子设备故障诊断方法。

关键词

小波分析,RBF神经网络,电子设备,故障诊断

Electronic Device Fault Diagnosis Based on Wavelet Analysis and Neural Network

Hao Yang¹, Juncheng Li^{1*}, Lei Yang²

¹Colege of Mathematics and Finance, Hunan University of Humanities, Science and Technology, Loudi Hunan ²Qufu Teni Electronic Technology Co., Ltd., Qufu Shandong

Received: May 10th, 2024; accepted: Jun. 11th, 2024; published: Jun. 30th, 2024

Abstract

Electronic devices are inevitably prone to malfunctions during long-term operation due to various factors. How to effectively diagnose faults in electronic devices has important application value. To improve the accuracy of electronic device fault diagnosis, this paper proposes a method based on wavelet analysis and RBF neural network for electronic device fault diagnosis. This method first uses wavelet analysis to extract the wavelet coefficients of fault samples, and then uses RBF

*通讯作者。

neural network to train wavelet coefficients for fault diagnosis. The simulation experiment results based on MATLAB show that the proposed method is an effective method for diagnosing electronic device faults.

Keywords

Wavelet Analysis, RBF Neural Network, Electronic Device, Fault Diagnosis

Copyright © 2024 by author(s) and Hans Publishers Inc. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). <u>http://creativecommons.org/licenses/by/4.0/</u>

CC ① Open Access

1. 引言

随着制造业的飞速发展,电子设备的内部构造变得越来越复杂,这导致设备发生故障的几率也相应 增加。一旦电子设备出现故障,企业将面临重大的经济损失。一般情况下,电子设备的故障并不会直接 显现,而是需要通过分析相关数据来进行判断,这无疑增加了电子设备的维修时间难度。若能提前对电 子设备的故障进行诊断,不仅能保障电子设备的安全稳定运行,而且还可延长电子设备的使用寿命,使 得企业的运行成本得到有效控制。因此,对电子设备的故障进行有效诊断一直都是重要的研究课题。

目前,国内外已有许多学者利用不同数学模型诊断电子设备故障,取得了较为丰富的研究成果。例如,文献[1]给出了一种基于小波分析和神经网络的传感器故障诊断方法;文献[2]提出了一种 BP 神经网络的故障诊断模型;文献[3]使用卷积神经网络提取振动信号特征,利用 EEMD 和近似熵构建信号特征向量,并通过训练 BP 神经网络创建了水电机组故障识别器;文献[4]提出了一种基于时间频率分析(时频分析)的故障诊断方法;文献[5]为了精确地识别变转速电机轴承的故障,提出了一种优化的时频分析策略; 文献[6]使用自动编码器对模拟电路的初始故障信号进行降噪处理,然后将处理后的信号输入到深度信念 网络中以提取特征;文献[7]为了有效地检测电子电路中的问题,研发了一种故障检测系统;文献[8]提出 了一种基于小波分析的电磁阀故障诊断方法;文献[9]针对航空电子设备故障诊断问题,采用了聚类方法 构建了多个模型,并开发了一个实用的故障诊断系统;文献[10]提出了一种 MCKD 方法,该方法结合了 粒子群优化算法,能够更准确、更高效地诊断设备的运行状态;文献[11]提出了一种创新的基于序列平均 变化率的灰色诊断模型;文献[12]采用动态贝叶斯网络作为主要工具识别出故障征兆并获取相关训练数据; 文献[13]采用加权灰色关联分析,提出了一种改进的复杂电子设备故障诊断方法;文献[14]运用短时傅立 叶变换(STFT)和连续小波变换(CWT)进行机电系统故障诊断等。

综合分析上述文献发现,利用不同数学模型诊断电子设备故障各有优势,但有些数学模型的诊断精 度还可进一步提高。例如,利用单一的小波分析模型或神经网络模型对电子设备故障进行诊断虽然能取 得较好的效果,但其诊断精度可能并不令人满意。为此,本文将考虑结合小波分析模型和神经网络模型 的优点,构建一种适用于电子设备故障诊断的组合模型,以期提高电子设备的诊断精度,为电子设备的 故障诊断提供一种新选择。

2. 预备知识

2.1. 小波分析的基本原理及其 MATLAB 实现

小波分析[1]是一种强大的信号处理技术,它的核心原理在于将复杂的信号分解成不同尺度的频率成

分,以便于进行精细的时频分析和特征提取。这种方法的关键在于多尺度分析,它仅对信号的低频部分 进行进一步的细分,而对高频部分则不作进一步处理。下面简要介绍小波多分辨率分析。

函数 $f(t) \in L^2(R)$ 的连续小波变换定义为:

$$WT_{f}(\alpha,\tau) = \left(f(t),\phi_{\alpha,\tau}(t)\right) = \frac{1}{\sqrt{\alpha}} \int f(t)\phi^{*}\left(\frac{t-\tau}{\alpha}\right) dt$$
(1)

式中, $\alpha(\alpha \neq 0)$ 为尺度因子; τ 为平移因子。

在式(1)中令 $\alpha = \alpha_0^j$, $\tau = k \alpha_0^j \tau_0$, 得离散小波变换为:

$$WT_f(j,k) = WT_f(j\alpha_0^j, k\alpha_0^j\tau_0) = (f(t), \phi_{j,k}(t)) = \int_{-\infty}^{\infty} f(t)\phi_{j,k}^*(t)dt$$
(2)

式中, j为尺度指标; k为平移指标; $WT_{f}(j,k)$ 为离散小波系数。

通常情况下,离散化参数可取为 $\alpha_0 = 2$, $\tau_0 = 1$,此时得二进离散小波变换为:

$$d_{j,k} = \left(f(t), \phi_{j,k}(t)\right) = \int_{-\infty}^{\infty} f(t) 2^{-\frac{j}{2}} \phi\left(2^{-j}t - k\right) dt$$
(3)

式中, *d*_{*j,k}为二进离散小波变换系数,小波分析的放大倍数* 2^{-*j*} 会随着尺度指标 *j* 改变,这也是小波分析的多分辨率特性。</sub>

利用 MATLAB 进行小波分析的步骤为:

Step 1: 准备工作。确保已经将"Wavelet Toolbox"工具箱添加到 MATLAB 的路径中,可使用 "waveletdenoise"等函数进行小波分析,且准备好需要分析的数据。

Step 2: 选择小波基函数。MATLAB 的小波函数库中有许多不同类型的小波基函数可供选择,如 Haar 小波、Daubechies 小波、Symlet 小波等。

Step 3:执行小波变换。使用"wavedec"函数执行小波变换,将时间序列数据转换为小波系数。该函数的参数包括时间序列数据、小波基函数和分解层数,调用格式为:

[C, L] = wavedec(signal, level, "waveletname")

其中, "signal"是需要分解的信号, "level"是分解的层数, "waveletname"是选择的小波基函数的名称。"C"是一个包含近似系数和细节系数的向量, "L"是一个向量, 包含近似系数和细节系数对应的长度。

Step 4:提取近似系数和细节系数。使用 "appcoef"函数提取近似系数, "detcoef"函数提取细节系数,调用格式为:

ca = appcoef(C, L, "waveletname", level); %提取近似系数

cd = detcoef(C, L, level);%提取细节系数

其中, "C"和"L"是"wavedec"函数的输出, "waveletname"是小波基函数的名称, "level"是提取系数的层数。

2.2. RBF 的基本原理及其 MATLAB 实现

神经网络[15]是一种基于人工智能的高效模型,它通过自动学习数据,实现对数据的深度分析和诊断。 神经网络可以被视为一个由众多神经元模型相互连接构成的复杂网络,具有强大的学习、模式识别和诊 断能力。神经网络由输入层、隐藏层和输出层三个结构组成。神经网络的组成结构如图1所示。

这里主要介绍 RBF 神经网络。RBF 神经网络[16]是一种模拟人脑结构和学习机制的先进算法。其核 心理念在于采用径向基函数作为隐藏层的激活函数,每个输入特征均拥有独立的径向基中心。在训练过 程中,RBF 网络着重调整网络中心和半径,力求最小化网络输出与实际输出之间的差异,从而提升诊断 精度和整体性能。



Figure 1. Composition structure of neural networks 图 1. 神经网络的组成结构

RBF 神经网络学习算法需要求解的参数有三个:基函数的中心向量 *W*、方差 σ 以及隐含层到输出层的权值。根据选取的径向基函数中心的方法不同,**RBF** 神经网络有不同的学习方式。

RBF 神经网络学习方法由两个阶段组成:一是自组织学习阶段,此阶段为无导师学习过程,求解隐藏层基函数的中心向量与方差;二是有导师学习阶段,此阶段求解隐藏层到输出层之间的权值。

RBF 神经网络的可表示为:

$$y = \sum \omega_i \varphi \left(\left\| x - c_i \right\| \right) \tag{4}$$

式中, y 为网络的输出; ω_i 为第 i 个 RBF 神经元的权重; $\varphi(||x-c_i||)$ 为径向基函数,它表示输入向量 x 与第 i 个神经元的中心 c_i 之间的欧氏距离 $||x-c_i||$ 的径向对称函数; Σ 表示对所有 RBF 神经元进行求和。

径向基函数 φ 通常选择高斯函数,其表达式为:

$$\delta(\mathbf{r}) = e^{\left(-r^2/(2|\sigma^2)\right)} \tag{5}$$

式中, δ 为输入向量x与神经元中心 c_i 之间的欧氏距离; σ 为高斯函数的宽度参数,它决定了函数的形状和宽度。

RBF 神经网络是一种三层前馈网络,其输入层将输入向量 *x* 传递给隐藏层,隐藏层使用径向基函数 对输入进行变换并计算输出值,输出层将隐藏层的输出进行线性组合得到最终输出 *y*。通过调整权重 *ω*, 和 中心 *c*, **RBF** 神经网络可以学习并逼近任意非线性函数。

在 MATLAB 中训练和使用 RBF 神经网络的步骤为:

Step 1: 准备数据。准备输入数据矩阵 "X"和目标输出数据矩阵 "T"。

Step 2: 创建 RBF 网络。使用 "newrb" 或 "newrbe" 函数创建一个 RBF 神经网络,调用规则为: net = newrb(X, T, GOAL, SPREAD, MN, DF);

其中, "X"为输入数据矩阵, "T"为目标输出数据矩阵, "GOAL"为网络性能目标, "SPREAD" 为径向基函数的扩展速度, "MN"为神经元数量的最小值, "DF"为分布密度函数。

Step 3: 训练网络。使用"train"函数训练 RBF 网络,调用格式为:

$$[net, tr] = train(net, X, T);$$

其中, "net"为待训练的 RBF 神经网络, "X"为输入数据矩阵, "T"为目标输出数据矩阵, "tr"为

训练记录信息。

Step 4: 测试网络。使用"sim"函数测试训练好的网络的性能,调用格式为:

Y = sim(net, Xtest);

其中, "net"为训练好的 RBF 神经网络, "Xtest"为测试输入数据矩阵, "Y"为网络的预测输出。 Step 5: 使用网络进行分析。使用训练好的 RBF 神经网络对新数据进行分析,调用格式为:

prediction = sim(net, newdata);

其中, "net"为训练好的 RBF 神经网络, "newdata"为新输入数据, "prediction"为网络的输出。

3. 基于小波分析与神经网络的电子故障诊断方法

为精确高效地对电子设备故障进行诊断,本文结合小波分析和神经网络模型的优点,构建出适用于 电子设备故障诊断的组合模型。利用该组合模型进行电子设备故障诊断的基本流程如图2示。



Figure 2. Basic process of using composite models for electronic device fault diagnosis 图 2. 利用组合模型进行电子设备故障诊断的基本流程

3.1. 数据预处理

为了使得故障样本数据被限定在一定的范围内,从而消除奇异样本数据导致的不良影响,需将收集 到的电子设备故障样本数据进行归一化预处理。由于电子设备故障样本数据是离散的,一般不符合正态 分布,故使用最小-最大归一化方法进行数据与处理。最小-最大归一化的计算公式为:

$$y = (x - \min) / \max - \min$$
 (6)

其中, y 为标准化后的数据; x 为原数据; min 为数据最小值; max 为数据最大值。

3.2. 对故障样本数据进行小波分析提取小波系数

小波分析能够通过对故障信号的分解,提取出蕴含故障特征的小波系数。这些系数独一无二地反映 了故障的类型、程度和潜在的发展趋势。因此,小波分析不仅捕捉到了隐藏在复杂信号中的关键信息, 还为故障的早期识别、预警和精准修复提供了有力支持。它可以大大提升电子设备故障样本数据分析的 准确性和效率。

使用 MATLAB 对电子设备故障样本数据进行小波分析并提取小波系数的主要步骤为:

Step 1: 准备故障样本数据。导入归一化后的电子设备故障样本数据。

Step 2:选择小波函数。选择一个合适的小波函数作为基函数。由于 Daubechies 小波具有紧支撑性、 对称性和正交性等特点,并且能够有效地进行多分辨率分析,故 Daubechies 小波可以更加准确地提取故 障特征、识别故障类型并预测故障发展趋势,从而为电子设备的故障诊断和预防性维护提供有力支持。 因此,本文选取 Daubechies 小波作为基函数。

Step 3:进行小波分解。将归一化后的电子设备故障样本数据、Daubechies 小波和尺度参数作为输入。 本文将尺度参数设置为 2,也就是对故障样本数据进行小波分解的层数为 2。

Step 4:提取小波系数。从小波系数矩阵中提取需要的小波系数。本文提取的小波系数为近似系数、 第一层细节系数和第二层细节系数。

3.3. 用神经网络诊断故障类型

RBF 神经网络的核心思想是通过训练样本集来建立一个模型,该模型能够将输入特征映射到输出类 别或故障类型上。在电子设备故障诊断中,这意味着可以将监测到的样本数据作为输入向量 *x*,通过 **RBF** 神经网络进行处理和分析,最终输出诊断结果,即故障类型或异常状态。

利用 MATLAB 通过 RBF 神经网络进行故障诊断的主要步骤为:

Step 1:数据导入。将故障样本数据的小波系数导入。

Step 2: 创建 RBF 神经网络。使用"newrb"函数创建 RBF 神经网络。

Step 3: 训练 RBF 神经网络。使用故障样本数据的小波系数训练 RBF 神经网络。

Step 4:测试 RBF 神经网络。使用测试数据对训练好的 RBF 神经网络进行测试。

Step 5: 使用 RBF 神经网络进行故障诊断。将待诊断的设备数据输入到训练好的 RBF 神经网络中, 神经网络将输出对应的故障类型。

4. 仿真实验

文献[2]以某电子设备为诊断对象,给出了 6 个测试点 10 个板卡故障的样本数据,如表 1 所示,其中 V_i/V (i = 1, 2, 3, 4)表示四个时间段的电压。

编号	V1/V	V2/V	V3/V	V4/V	故障类型
1	10.253	14.135	10.624	11.311	MA-1
2	0.536	14.782	0.325	0.259	MA-2
3	5.126	8.395	13.698	14.687	MB-1
4	0.568	4.865	9.658	14.568	MB-2
5	14.325	11.459	0.265	5.368	MC-1
6	13.684	12.084	0.657	4.865	MC-2
7	13.956	13.652	9.657	11.527	MD
8	9.576	12.651	12.357	0.826	ME
9	5.367	4.795	12.657	0.264	MF
10	14.965	10.532	4.976	9.853	MG
11	5.013	14.965	10.021	4.986	正常

Table 1. Fault sample data 表 1. 故障样本数据

由于表 1 的数据量太少,不利于 RBF 神经网络训练。为此,本文将表 1 中的电压数据分别扩大 1.5 倍和缩小 0.5 倍,得到故障的模拟数据如表 2 所示。

对表1与表2中的数据进行归一化处理,结果如表3所示。

将表 3 中的数据用 MATLAB 进行小波分析,提取近似系数、第一层细节系数和第二层细节系数, 其中第一层细节系数有两个,第二节细节系数有一个,结果如表 4 所示。

将表 4 中的前 25 组数据用于训练 RBF 神经网络, 剩余 8 组数据用于检验故障诊断的准确度。剩余 8 组数据的故障诊断检验结果如表 5 所示。

由表 5 可知, RBF 神经网络的诊断准确率达到了 75%, 表现良好。在具体样本中, 编号 26、28、29、 30、32 和 33 的诊断结果完全正确, 这进一步印证了 RBF 神经网络在处理特定数据集时的有效性。然而,

编号 27 和编号 31 的诊断结果错误,这可能源于多种因素,如网络训练不足、数据中存在噪声或样本分 布不平衡等。

Table	2. Simulated data of faults
表 2.	故障的模拟数据

编号	V1/V	V2/V	V3/V	V4/V	编号	V1/V	V2/V	V3/V	V4/V
12	15.3795	21.2025	15.936	16.9665	23	5.1265	7.0675	5.312	5.6555
13	0.804	22.173	0.4875	0.3885	24	0.268	7.391	0.1625	0.1295
14	7.689	12.5925	20.547	22.0305	25	2.563	4.1975	6.849	7.3435
15	0.852	7.2975	14.487	21.852	26	0.284	2.4325	4.829	7.284
16	21.4875	17.1885	0.3975	8.052	27	7.1625	5.7295	0.1325	2.684
17	20.526	18.126	0.9855	7.2975	28	6.842	6.042	0.3285	2.4325
18	20.934	20.478	14.4855	17.2905	29	6.978	6.826	4.8285	5.7635
19	14.364	18.9765	18.5355	1.239	30	4.788	6.3255	6.1785	0.413
20	8.0505	7.1925	18.9855	0.396	31	2.6835	2.3975	6.3285	0.132
21	22.4475	15.798	7.464	14.7795	32	7.4825	5.266	2.488	4.9265
22	7.5195	22.4475	15.0315	7.479	33	2.5065	7.4825	5.0105	2.493

Table 3. Normalized data 表 3. 归一化后的数据

编号	V1/V	V2/V	V3/V	V4/V	故障类型	编号	V1/V	V2/V	V3/V	V4/V	故障类型
1	0.4536	0.6275	0.4702	0.5010	MA-1	18	0.9322	0.9118	0.6432	0.7689	MD
2	0.0182	0.6565	0.0088	0.0058	MA-2	19	0.6378	0.8445	0.8247	0.0497	ME
3	0.2239	0.3704	0.6080	0.6523	MB-1	20	0.3549	0.3165	0.8449	0.0119	MF
4	0.0196	0.2122	0.4269	0.6469	MB-2	21	1.0000	0.7021	0.3286	0.6564	MG
5	0.6361	0.5076	0.0061	0.2347	MC-1	22	0.3311	1.0000	0.6677	0.3293	正常
6	0.6073	0.5356	0.0236	0.2122	MC-2	23	0.2239	0.3109	0.2322	0.2476	MA-1
7	0.6195	0.6059	0.4269	0.5107	MD	24	0.0062	0.3254	0.0015	0.0000	MA-2
8	0.4233	0.5610	0.5479	0.0312	ME	25	0.1090	0.1823	0.3011	0.3232	MB-1
9	0.2347	0.2090	0.5613	0.0060	MF	26	0.0069	0.1032	0.2106	0.3206	MB-2
10	0.6647	0.4661	0.2172	0.4357	MG	27	0.3151	0.2509	0.0001	0.1145	MC-1
11	0.2188	0.6647	0.4432	0.2176	正常	28	0.3008	0.2649	0.0089	0.1032	MC-2
12	0.6833	0.9442	0.7082	0.7544	MA-1	29	0.3069	0.3000	0.2105	0.2524	MD
13	0.0302	0.9877	0.0160	0.0116	MA-2	30	0.2087	0.2776	0.2710	0.0127	ME
14	0.3387	0.5584	0.9148	0.9813	MB-1	31	0.1144	0.1016	0.2778	0.0001	MF
15	0.0324	0.3212	0.6433	0.9733	MB-2	32	0.3295	0.2302	0.1057	0.2149	MG
16	0.9570	0.7644	0.0120	0.3550	MC-1	33	0.1065	0.3295	0.2187	0.1059	正常
17	0.9139	0.8064	0.0384	0.3212	MC-2						

编号	近似 系数	细节 系数 1a	细节 系数 1b	细节 系数 2	故障 类型	编号	近似 系数	细节 系数 1a	细节 系数 1b	细节 系数 2	故障 类型
1	1.0262	-0.1230	-0.0218	0.0549	MA-1	18	1.6281	0.0144	-0.0889	0.2160	MD
2	0.3447	-0.4513	0.0021	0.3301	MA-2	19	1.1784	-0.1462	0.5480	0.3040	ME
3	0.9273	-0.1036	-0.0313	-0.3330	MB-1	20	0.7641	0.0272	0.5890	-0.0927	MF
4	0.6528	-0.1362	-0.1556	-0.4210	MB-2	21	1.3436	0.2106	-0.2318	0.3586	MG
5	0.6923	0.0909	-0.1616	0.4515	MC-1	22	1.1641	-0.4730	0.2393	0.1671	正常
6	0.6894	0.0507	-0.1334	0.4536	MC-2	23	0.5073	-0.0615	-0.0109	0.0275	MA-1
7	1.0815	0.0096	-0.0593	0.1439	MD	24	0.1666	-0.2257	0.0011	0.1651	MA-2
8	0.7817	-0.0974	0.3654	0.2026	ME	25	0.4578	-0.0518	-0.0156	-0.1665	MB-1
9	0.5055	0.0182	0.3927	-0.0618	MF	26	0.3207	-0.0681	-0.0778	-0.2106	MB-2
10	0.8919	0.1404	-0.1545	0.2390	MG	27	0.3403	0.0454	-0.0809	0.2257	MC-1
11	0.7722	-0.3153	0.1595	0.1114	正常	28	0.3389	0.0254	-0.0667	0.2268	MC-2
12	1.5451	-0.1845	-0.0327	0.0825	MA-1	29	0.5349	0.0049	-0.0296	0.0720	MD
13	0.5228	-0.6771	0.0031	0.4952	MA-2	30	0.3850	-0.0487	0.1826	0.1013	ME
14	1.3966	-0.1554	-0.0470	-0.4995	MB-1	31	0.2470	0.0091	0.1964	-0.0310	MF
15	0.9851	-0.2042	-0.2333	-0.6315	MB-2	32	0.4402	0.0702	-0.0772	0.1196	MG
16	1.0442	0.1362	-0.2425	0.6772	MC-1	33	0.3803	-0.1577	0.0798	0.0557	正常
17	1.0400	0.0760	-0.2000	0.6804	MC-2						

Table 4. Wavelet coefficients 表 4. 小波系数

Table 5. Fault diagnosis test results 表 5. 故障诊断检验结果

编号	RBF	诊断故障	实际故障
26	4.467	MB-2	MB-2
27	6.1969	MC-2	MC-1
28	6.7419	MC-2	MC-2
29	7.3042	MD	MD
30	8.4776	ME	ME
31	10.9565	MG	MF
32	10.0514	MG	MG
33	11.5465	正常	正常

5. 结语

电子设备在持续运行过程中常常面临各种故障的挑战。因此,如何快速、准确地对电子设备的故障 进行诊断具有重要的应用价值。本文提出了一种基于小波分析和RBF神经网络的电子设备故障诊断方法, 该方法结合了小波分析与神经网络在数据分析中的优点,能有效地实现电子设备故障诊断。利用 MATLAB 进行仿真实验,结果表明,本文提出的方法在对电子设备进行故障诊断时具有较高的准确率, 具有较高的应用价值。

基金项目

曲阜特霓电子科技有限公司横向课题"电子设备数据的分析与可视化"资助。

参考文献

- [1] 李子凡, 叶志锋, 王彬. 基于小波分析和神经网络的传感器故障诊断[J]. 机械制造与自动化, 2023, 52(4): 196-201.
- [2] 王秋彦, 鞠建波, 金鑫. 优化的 BP 神经网络在电子设备故障诊断中的应用[J]. 现代电子技术, 2010, 33(3): 147-149, 153.
- [3] 孙文昊, 胡志平, 肖志怀, 等. 基于一维卷积神经网络与近似熵特征融合的水电机组故障诊断[J]. 中国农村水利水电, 2024(2): 199-204.
- [4] 张坤. 传感器故障诊断方法研究及其在机械振动监测的应用[D]: [硕士学位论文]. 南京: 东南大学, 2021.
- [5] 赵旭荣. 基于时频分析的矿井提升机故障诊断研究[J]. 企业科技与发展, 2023(8): 40-43.
- [6] 郭爱军, 鞠晨. 基于深度信念网络的模拟电路故障诊断[J]. 自动化技术与应用, 2023, 42(2): 76-80.
- [7] 王新渝. 基于时频分析的变转速滚动轴承早期故障诊断方法研究[D]: [硕士学位论文]. 北京: 北京信息科技大学, 2023.
- [8] 王钦惠, 胡向宇, 崔梧玉, 孙迎萍. 基于小波分析的电磁阀在轨实时诊断[J]. 真空与低温, 2021, 27(3): 292-295.
- [9] 叶盆燕. 基于聚类方法的航空电子设备故障诊断[D]: [硕士学位论文]. 成都: 电子科技大学, 2021.
- [10] 栗龙强, 刘永强, 廖英英. 基于粒子群优化 MCKD 的轴承故障诊断方法[J]. 轴承, 2020(6): 45-50.
- [11] 王翠竹. 时域平均降噪方法改进及其系统实现[D]: [硕士学位论文]. 舟山: 浙江海洋大学, 2021.
- [12] 周德新,蒋红菊. 基于动态贝叶斯网络的机载电子设备故障诊断[J]. 计算机测量与控制, 2014, 22(3): 656-658, 666.
- [13] 丛晓,陈勇,张光轶. 基于序列平均变化率的灰色模型故障预测方法[J]. 中国电子科学研究院学报, 2021, 16(10): 1034-1037.
- [14] Luczak, M. (2024) Machine Fault Diagnosis through Vibration Analysis: Continuous Wavelet Transform with Complex Morlet Wavelet and Time-Frequency RGB Image Recognition *via* Convolutional Neural Network. *Electronics*, 13, Article 452. <u>https://doi.org/10.3390/electronics13020452</u>
- [15] 金秋. 神经网络在小样本数据集的研究及应用[D]: [硕士学位论文]. 成都: 电子科技大学, 2020.
- [16] 刘敏, 闫霞, 张利男, 等. 基于粗糙集和 RBF 神经网络的工业机器人故障诊断[J]. 机械工程与自动化, 2023(1): 146-148.