

基于增强 KECA 算法的航电电源板层间 CAF 短路故障智能监测方法研究

陈远聪, 廖伟国

(华南农业大学珠江学院 人工智能学院, 广州 510900)

摘要: 飞机巡航阶段遭遇的湍流振动会诱发细丝机械疲劳断裂, 而着陆冲击可瞬间改变导电阳极细丝 (CAF) 接触阻抗, 出现短路现象; 但 CAF 短路初期的电信号特征较为微弱, 难以获取 CAF 短路故障的最敏感主元特征, 降低了故障监测的准确性; 为此, 研究基于增强 KECA 算法的航电电源板层间 CAF 短路故障智能监测方法; 以高精度霍尔效应电流探头捕捉航电电源板层间 CAF 电气信号, 将其分解出多尺度模态分量, 计算各电气信号 IMF 分量的能量熵; 鉴于飞机相关状况导致 CAF 短路且初期电信号微弱, 单纯依靠能量熵难以挖掘最敏感主元特征, 传统 KECA 存在投影方向选择范围窄的缺陷, 对 IMF 分量的能量熵进行 KECA 增强下主元特征向量低维映射, 筛选出对短路故障最敏感的特征向量并投影到低维空间, 使主元向量更聚焦关键特征; 引入灰狼算法改进支持向量机, 将改进支持向量机作为 AdaBoost 算法的弱分类器, 加权组合为强分类器, 得到航电电源板层间 CAF 短路故障识别模型, 实现 CAF 短路故障智能监测; 实验结果表明: 所提方法应用下, 故障样本与无故障样本点边界清晰且同类样本点之间有很好的聚类性; 面对早期故障样本, 对数损失相对更低且在面对中期和后期故障样本, 对数损失也依然保持了较低水平, 由此证明了所研究方法的故障监测准确性更高。

关键词: 增强 KECA 算法; 航电电源板层间 CAF; 电气信号; 短路故障; 智能监测方法

Research on the Intelligent Monitoring Method for CAF Short Circuit Faults Between Avionics Power Boards Based on Enhanced KECA Algorithm

CHEN Yuancong, LIAO Weiguo

(College of Artificial Intelligence, South China Agricultural University Zhujiang College,
Guangzhou 510900, China)

Abstract: During the cruising phase of an aircraft, the vibration caused by encountering turbulence can induce mechanical fatigue fracture of the filament, while the landing shock can instantaneously change the contact resistance of the conductive anode filament (CAF), resulting in a short circuit. However, the characteristics of electrical signals in the early stage of CAF short circuit faults are relatively weak, making it difficult to obtain the most sensitive principal component characteristics of CAF short circuit faults, reducing the accuracy of fault monitoring. For this purpose, research is conducted on the intelligent monitoring method for interlayer CAF short-circuit faults in the avionics power supply board based on the enhanced kernel entropy component analysis (KECA) algorithm. A high-precision Hall-effect current probe is used to capture the electrical signals of interlayer CAF in the avionics power supply board, decomposing them into multi-scale modal components, and then calculating the energy entropy of the IMF component of each electrical signal. For the CAF short circuits caused by airport-related conditions and weak initial electrical signals, it is difficult to discover the most sensitive principal component features solely relying on energy entropy. The traditional KECA exhibits the limitation of narrow projection direction selec-

收稿日期: 2025-12-31; 修回日期: 2026-02-13。

基金项目: 华农珠江科研[2024]53 号(2024HZZLGC006); 华农珠江教学一流课程一路由与交换技术(2025)7 号; 广东省教育厅特色创新类项目(2023KTSCX184)。

作者简介: 陈远聪(1981-), 男, 硕士, 实验师。

廖伟国(1981-), 男, 硕士, 副教授。

引用格式: 陈远聪, 廖伟国. 基于增强 KECA 算法的航电电源板层间 CAF 短路故障智能监测方法研究[J]. 计算机测量与控制, 2026, 34(8): 42-51.

tion. By performing KECA-enhanced low-dimensional mapping of principal component feature vectors based on the energy entropy of IMF components the most sensitive feature vectors for short-circuit faults are screened out and projected into low-dimensional space, making the principal component vector more focused on key features. The Grey Wolf algorithm is introduced to improve the support vector machine. The improved support vector machine is taken as the weak classifier of the Adaboost algorithm and weighted and combined into a strong classifier, which obtains the inter-layer CAF short-circuit fault recognition model in the avionics power supply board, achieving intelligent monitoring of CAF short-circuit faults. Experimental results show that the proposed method exhibits clear boundaries between faulty and non-faulty samples, along with excellent clustering among samples of the same category. For early fault samples, the logarithmic loss is relatively lower, and even for mid-stage and late-stage fault samples, the logarithmic loss remains at a low level, which proves that the proposed method is a higher fault monitoring accuracy.

Keywords: enhanced KECA algorithm; interlayer CAF in avionics power supply boards; electrical signal; short-circuit fault; intelligent monitoring method

0 引言

航电电源板作为飞机电气系统的核心组成部分,其稳定可靠的运行直接关系到飞行安全与任务执行。飞机在飞行过程中会经历多种复杂工况,不同工况对航电电源板产生的影响各异且具有不确定性^[1]。飞机巡航阶段遭遇的湍流振动,这种持续且不规则的振动会对航电电源板内部的 CAF (Conductive Anodic Filament) 造成机械应力。长期处于这种应力环境下,细丝容易产生机械疲劳,进而发生断裂。而飞机着陆时产生的强烈冲击,会瞬间改变 CAF 的接触阻抗。这种接触阻抗的改变会引发层间短路现象,严重威胁航电系统的正常工作,甚至导致整个电气系统瘫痪,影响飞行安全。CAF 短路故障并非突然发生,在短路初期,其电信号特征表现得极为微弱^[2]。这些微弱信号往往淹没在复杂的电气噪声和其他正常信号之中,难以被准确识别和提取。随着航空技术的不断进步,对航电系统的可靠性和安全性要求也越来越高^[3]。准确、及时地监测航电电源板层间 CAF 短路故障,对于保障飞行安全、减少维修成本、提高飞机出勤率具有重要意义。

关于短路故障监测课题,很多专家和学者都进行了研究。陆震军等人^[4]采用等效电路模型进行电池动态特性描述,在等效电路模型中引入内短路支路,构建扩展模型,基于电池模型递推状态变量,通过双扩展卡尔曼滤波算法估计锂离子电池内短路电阻并以此为依据,判断短路严重程度,当短路电阻低于健康阈值时触发报警。该方法灵敏度不足,仅能检测已形成的明显短路,无法捕捉最敏感主元特征。郭煜等人^[5]利用孤立森林对高维数据中异常点的快速隔离特性,结合电池运行参数的时序特征,实现短路故障诊断。孤立森林是机器学习的一种,在应用前需要依赖大量标注数据进行训练,一旦故障样本获取周期长、标注难度大,就会导致模型提取短路故障最敏感主元特征的性能受限。李晓枫等人^[6]通过施加小振幅交流信号,测量电池阻抗随频率变化,

得到电化学阻抗谱,将电化学阻抗谱中连续的阻抗响应转化为离散的弛豫时间分布并从中提取出电荷传递内阻与固体电解质界面膜内阻,计算两个内阻的比值并与设定动态阈值进行对比,当比值超过阈值且持续一定时间,触发故障报警。当模组内单体荷电状态偏差 $>5\%$ 时,比值一基线分布变宽,易导致特征提取有误。陈培育等人^[7]结合电池模型(状态方程)和测量方程,利用扩展卡尔曼滤波递归估计荷电状态,通过主元分析方法对电池的电压、电流和荷电状态中提取关键信息,通过计算两个统计指标,分别衡量数据在主元空间中的变化和在残差空间中的变化,与统计量阈值进行对比,判断电池内部是否发生短路故障。线性主元无法捕捉非线性故障特征,导致微短路的最敏感主元特征提取灵敏度下降,甚至漏报。

CAF 短路故障的早期信号微弱、特征隐蔽,特征难以全面捕捉故障演变规律,导致早期故障检测困难。针对上述问题,研究一种基于增强 KECA 算法的航电电源板层间 CAF 短路故障智能监测方法。通过该研究以期开发一种高灵敏度、低复杂度且适用于少量样本的智能监测方法,提升鲁棒性。

1 航电电源板层间 CAF 电气分解信号能量熵计算

航电电源板作为航空电子系统的核心供电单元,其可靠性直接影响飞行安全。由于飞机巡航的湍流振动与着陆冲击会使 CAF 产生机械疲劳断裂或改变接触阻抗引发短路,而短路初期电信号特征微弱,难以获取最敏感主元特征影响监测准确性。能量熵能反映信号的复杂程度和能量分布特征,通过计算 CAF 电气分解信号能量熵,可从复杂的电气信号中挖掘出与 CAF 状态相关的潜在信息,捕捉到短路初期那些微弱且不易察觉的信号变化,为后续准确提取最敏感主元特征、提高故障监测准确性奠定基础。

航电电源板层间 CAF 运行过程中,会产生电气信

号, 当在复杂电磁环境和极端工作条件下发生短路故障时, 会引发电气信号异常^[8]。因此, 在研究中通过高精度霍尔效应电流探头捕捉航电电源板层间 CAF 电气信号作为故障监测数据^[9]。电气信号的具体采集与获取方案如下:

CAF 短路故障的本质是绝缘层间形成了细微的导电通道, 该过程会引发电弧放电、漏电流急剧增大等电气现象。为捕捉这些特征信号, 采集对象选定为流经航电电源板层间绝缘测试点的漏电流信号。传感器采用 Tektronix TCP0150 型号高精度交流/直流电流探头, 其带宽为 100 kHz, 分辨率达 0.1 μ A, 能够精确测量从早期微弱漏电流到后期击穿大电流的全范围信号。将电流探头的钳口直接夹在专为监测 CAF 而设计的层间测试回路导线上, 该测试回路串联在高压偏置电源与航电电源板层间电极之间。此安装位置能够直接、无损地捕获由 CAF 生长所导致的泄漏电流变化, 避免了从总电源回路中间接测量带来的信号混淆与衰减。信号调理与采集由 NI PXIe-4499 数据采集卡完成, 设置采样率为 1 MS/s, 采用 16 位分辨率及 64 通道差分输入模式, 以充分采集高频放电成分并抑制共模噪声。

针对捕捉到的航电电源板层间 CAF 电气信号进行盲源分离和增强处理。其中, 前者作用是去除 CAF 电气信号中的噪声, 降低对后续监测结果的干扰。设电气信号为 $a(t)$, $t=1, 2, \dots, T$ 。接着, 进行中心化和白化处理, 得到 $b(t)$ 。通过最大化非高斯性 (负熵) 估计分离矩阵 λ 。根据分离矩阵 λ 分离电气信号 $a(t)$, $t=1, 2, \dots, T$, 得到去除噪声的电气信号。即:

$$\hat{a}(t) = \lambda W a(t) \quad (1)$$

$$W = \Lambda^{-1/2} C^T \quad (2)$$

式中, $\hat{a}(t)$ 为分离噪声后的电气信号; W 为白化矩阵; Λ 为电气信号协方差矩阵的特征值对角矩阵; C 为协方差矩阵的正交特征向量矩阵; $\tilde{T}$ 为转置; C^T 为 C 的转置矩阵^[10]。后者 CAF 电气信号增强处理的目的是提升 CAF 电气信号的信噪比, 弥补短路故障早期信号特征微弱的缺陷, 公式如下:

$$c(t) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T |\hat{a}(t) - \tilde{a}(t)|^\gamma dt \quad (3)$$

式中, $c(t)$ 为增强后的 CAF 电气信号; $\tilde{a}(t)$ 为参考信号; γ 为经验补偿因子^[11]。增强后的 CAF 电气信号波形更加明显, 细节更加清晰, 方便了后续分析。接着, 针对增强后的航电电源板层间 CAF 电气信号进行经验模态分解, 其作用是从非平稳、非线性的 CAF 电气信号中分解出多尺度的模态分量, 实现从混沌到有序的信号解构^[12]。原理公式如下:

$$c(t) = \sum_{i=1}^n z_i(t) + \epsilon_n(t) \quad (4)$$

式中, $z_i(t)$ 代表第 i 个 IMF 分量; $\epsilon_n(t)$ 为残差分量。

1) 输入航电电源板层间 CAF 电气信号 $c(t)$, $t=1, 2, \dots, T$ 。

2) 遍历 CAF 电气信号 $c(t)$, 标记所有局部极大值点 $c_{k,\max}$ 和极小值点 $c_{k,\min}$ 。

3) 对 $\max c_k$ 和 $\min c_k$ 进行 3 次样条插值, 生成两条平滑曲线, 分别是 $u_{\max}(t)$ 和 $u_{\min}(t)$ 。

4) 对 $u_{\max}(t)$ 和 $u_{\min}(t)$ 进行去和, 除 2 后, 得到包络线均值 $A_1(t)$ 。

5) 将原始 CAF 电气信号 $c(t)$ 与 $A_1(t)$ 做差, 得到候选本征模态函数 (IMF, intrinsic mode function) —— $\delta(t)$ 。

6) 若 $\delta(t)$ 满足 IMF 条件 (极值点数量与过零点数量相等或相差不超过 1; 上下包络线关于时间轴局部对称), 则定义为第一个 IMF 分量 $z_1(t) = \delta(t)$; 否则, 将 $\delta(t)$ 作为新的原始信号, 重复步骤 2) ~ 5), 直至满足条件。

7) 从原始 CAF 电气信号 $c(t)$ 中减去 $z_1(t)$, 得到残差 $\epsilon_1(t)$ 。

8) 将 $\epsilon_1(t)$ 作为新的航电电源板层间 CAF 电气信号, 重复步骤 2) ~ 7), 直至残差的极值点数量少于 2 个。

9) 经过上述过程, 航电电源板层间 CAF 电气信号 $c(t)$ 可被分解为 n 个 IMF 分量和 1 个残差 $\epsilon_n(t)$, 如公式 (4) 所示。

针对分解后得到的 n 个 IMF 分量 $z_i(t)$, $t=1, 2, \dots, T$, 计算公式如下:

$$s_i = \int_{-\infty}^{\infty} |z_i(t)|^2 dt \quad (5)$$

式中, s_i 代表第 i 个 IMF $z_i(t)$ 的能量。根据 s_i 计算每一个 IMF 分量的能量熵, 计算公式如下:

$$h_i = -\frac{s_i}{\sum_{i=1}^n s_i} \lg \frac{s_i}{\sum_{i=1}^n s_i} \quad (6)$$

式中, h_i 代表第 i 个 IMF 分量 $z_i(t)$ 的能量熵, 反映了 CAF 电气信号能量在时域空间上的分散程度。

每个 IMF 分量的 h_i 代表了不同时间尺度的电气特征量, 由 h_i 组成航电电源板层间 CAF 电气信号的能量熵集合 $\{h_1, h_2, \dots, h_n\}$ 。这些能量熵数据, 是下一章节进行增强 KECA 分析的依据^[13]。

2 基于增强 KECA 分析结果的短路故障监测实现

2.1 信号能量熵 KECA 增强下主元特征向量低维映射

尽管已计算了航电电源板层间 CAF 电气分解信号

能量熵, 可飞机巡航湍流振动与着陆冲击使 CAF 产生机械疲劳断裂或接触阻抗改变引发短路, 且短路初期电信号特征微弱, 单纯依靠能量熵难以充分挖掘出隐藏在复杂信号中、能精准表征故障的最敏感主元特征, 信号中仍存在大量冗余和干扰信息, 这会影响故障判断的精准度, 所以进一步实现信号核熵成分分析 (KECA, kernel entropy component analysis) 增强下主元特征向量低维映射, 以提取更具代表性和区分度的特征, 提升故障监测准确性。

传统 KECA 的缺陷是投影轴完全由核矩阵的特征向量决定, 使得投影方向的选择范围较为狭窄, 从而导致选取的特征不能很好地代表航电电源板层间 CAF 电气信号的本质特性^[14]。为弥补这一缺陷, 引入一个额外的旋转因子, 拓展了搜索范围, 使结果不再仅仅局限于核矩阵特征向量所确定的投影方向, 更有效地捕捉数据中的关键信息。

在这一章节中, 针对航电电源板层间 CAF 电气信号的能量熵集合 $\{h_1, h_2, \dots, h_n\}$, 进行 KECA, 目的是筛选出对航电电源板层间 CAF 短路故障最敏感的特征向量。增强 KECA 分析能够实现对多维能量熵的降维, 很大程度上减少信息量和计算量, 提高后续故障识别的效率, 同时避免多余特征量干扰, 提高识别准确性和鲁棒性^[15]。具体过程如下: 设样本量为 L , 样本集合表示为 $X = \{x_1, x_2, \dots, x_L\}$, 其中 $x_l \in R^n$, 其中 n 为维度, 即能量熵数量, 每个样本表示为 $x_l = \{h_{l1}, h_{l2}, \dots, h_{ln}\}$ 。接着, 对于任意两个样本 x_l 和 x_j , 计算它们之间的欧式距离 $D(x_l, x_j)$, 即:

$$D(x_l, x_j) = \sqrt{\sum_{i=1}^n (h_{li} - h_{ji})^2} \quad (7)$$

式中, h_{li} 、 h_{ji} 为样本 x_l 和 x_j 的能量熵。核矩阵 G 是一个 $L \times L$ 的矩阵, 其元素 g_{ij} 由核函数计算得到:

$$g_{ij} = \exp\left[-\frac{D^2(x_l, x_j)}{2\varphi^2}\right] \quad (8)$$

式中, φ 为核参数。通过计算所有样本对之间的核函数值, 就可以构造出核矩阵 G ^[16]:

$$G = \begin{bmatrix} g_{11} & \cdots & g_{1n} \\ \vdots & \ddots & \vdots \\ g_{l1} & \cdots & g_{Ln} \end{bmatrix} \quad (9)$$

将核矩阵 G 分解为特征值和特征向量的形式, 即对于一个对称矩阵 G , 存在正交矩阵 V 和对角矩阵 U , 使得:

$$G = VUV^T \quad (10)$$

其中: $U = \text{diag}(U_1, U_2, \dots, U_L)$, U_i 是核矩阵 G 的特征值, $V = (V_1, V_2, \dots, V_L)$, V_i 是与 U_i 对应的特征向量^[17]。初始化步长 μ 和旋转因子 $\bar{\omega} = (\bar{\omega}_1,$

$\bar{\omega}_2, \dots, \bar{\omega}_L)$ 。计算目标函数值以及梯度, 即:

$$J(\bar{\omega}) = (G\bar{\omega}^T U^{-1/2} V_i^T I)^2 \quad (11)$$

$$\nabla J(\bar{\omega}) = J(\bar{\omega})(I_n^T UV^{1/2} \bar{\omega})(I_n^T UV^{1/2} \bar{\omega})^T \quad (12)$$

式中, I 为单位矩阵; $\nabla J(\bar{\omega})$ 为梯度。目标函数的作用是评估当下初始旋转因子应用下取得的成果, 是衡量旋转因子取值合理性的关键指标。梯度用于描述目标函数的变化情况。根据梯度下降的原理, 使用 $\nabla J(\bar{\omega})$ 和 μ 来更新旋转因子:

$$\bar{\omega}(k+1) = \bar{\omega}(k) - \mu \nabla J[\bar{\omega}(k)] \quad (13)$$

式中, $\bar{\omega}(k)$ 代表第 k 次迭代时的旋转因子, $\nabla J[\bar{\omega}(k)]$ 是第 k 次迭代时的梯度。不断进行迭代, 每次迭代后计算目标函数的值。当相邻两次迭代目标函数值的变化小于某个预先设定的阈值时, 停止迭代。经过迭代收斂后, 得到最终的旋转因子 $\bar{\omega}$ 。

相较于传统 KECA 算法, 其投影方向被限定为由核矩阵特征向量所张成的固定空间, 导致对数据内在结构的探索能力受限, 尤其难以捕捉那些与初始核主元方向不一致的微弱故障特征。本文所提出的增强 KECA 算法的核心创新在于引入了一个可优化的旋转因子矩阵。该机制的本质是通过一个梯度下降驱动的迭代过程, 动态地旋转原始的特征向量空间。旋转因子的引入, 使得算法不再被动地接受核矩阵分解所得的投影轴, 而是能够在一个超球面空间内搜索最优的投影方向。这个过程可以形象地理解为: 传统 KECA 是在一个固定的、有限的视角集合中观察数据, 而增强 KECA 则具备了一个可旋转的观测镜, 能够主动调整视角, 直至找到最能凸显类别差异的观测角度。

这种改进在实际计算中展现出两大显著优势: 1) 显著提升了特征提取的灵敏度与区分度, 尤其对于 CAF 短路初期信噪比极低的微弱信号, 增强 KECA 能够通过方向调整聚焦于这些微弱的变化, 从而实现对早期故障更有效的预警; 2) 增强了算法对复杂多变工况的适应性, 因为旋转机制使其能够自适应地调整特征提取策略, 以应对不同振动、温度条件下信号特征的漂移。

然而, 旋转因子的迭代优化过程引入了额外的计算开销, 使其在处理超大规模数据时的效率低于传统 KECA。因此, 在获得优化后的旋转因子并完成特征空间的拓展性搜索后, 计算二次瑞利熵, 通过最大化瑞利二次熵能够保留数据的高信息势部分, 从而提升效率。二次瑞利熵 $H_2(G)$ 计算公式为:

$$H_2(G) = -\lg \left[\frac{\sum_{i=1}^L \sum_{j=1}^L g_{ij}^2}{\bar{\omega}(k+1)L^2} \right] \quad (14)$$

按照 $H_2(G)$ 大小将特征值从大到小排列, 并选择前 N 个特征值对应的特征向量作为能量熵集合 $\{h_1,$

$h_2, \dots, h_n\}$ 的主元, 将 N 个主元投影到低维空间, 得到特征向量的低维映射结果 $\mathbf{P}$, 即:

$$\mathbf{p}_i = \tilde{\omega}^T \mathbf{U}^{-1/2} \mathbf{V}^T \mathbf{H}_2(\mathbf{G}) \quad (15)$$

$$\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N) \quad (16)$$

式中, $\mathbf{p}_i$ 代表第 i 个主元特征向量。

增强 KECA 分析后的主元向量更聚焦于 CAF 故障的关键特征, 方便了后续故障识别模型的特征挖掘和关联映射。

2.2 低维映射主元特征的 CAF 短路故障监测

尽管已达成信号能量熵 KECA 增强下主元特征向量低维映射, 然而飞机巡航的湍流振动与着陆冲击致使 CAF 产生机械疲劳断裂或接触阻抗改变而引发短路, 且短路初期电信号特征微弱, 即便经过低维映射, 所获取的主元特征可能仍不够精准全面, 无法充分且敏锐地反映 CAF 短路故障的真实状态, 存在特征信息缺失或噪声干扰未完全消除等问题, 进而影响对 CAF 短路故障的准确判断, 所以需要进一步实现低维映射主元特征的 CAF 短路故障监测, 以提升故障监测的准确性与可靠性。以增强 KECA 分析结果, 即提取到的主元特征向量 $\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N)$ 为依据, 通过构建的识别模型判断航电电源板层间 CAF 是否发生了短路故障^[18]。

在识别模型的构建中, 核心智能算法的选择至关重要。不同的智能算法所采用的映射机制不同, 得到的结果可能存在偏差^[19]。为避免这一情况, 提高短路故障识别结果的准确性和精确性, 以改进支持向量机作为 AdaBoost 算法 (Adaptive Boosting, 自适应提升) 的组成弱分类器, 组成一个强学习器。支持向量机与 AdaBoost 算法均属于机器学习方法, 前者的优势是鲁棒性高, 因此在面对多工况样本具有很强的抗干扰能力, 但是泛化能力较弱, 因此容易出现过拟合的问题; 而后者 AdaBoost 算法通过加权组合弱学习器, 能够降低过拟合风险, 但是该算法对样本数据中的大量噪声或异常值较为敏感, 鲁棒性较差。因此, 二者的有效结合, 可以很好地弥补二者存在的缺陷, 实现优势互补, 增强识别模型的识别能力^[20]。

识别模型原理是通过训练机器模型, 让其训练学习短路故障与输入特征向量之间的映射关系, 学会之后, 该模型就拥有了识别能力, 在后续的实际应用中, 就可以根据实际输入的主元特征向量得出故障识别监测结果^[21]。识别模型构建过程分为两部分, 前一部分构建改进支持向量机分类器; 后一部分利用 AdaBoost 算法组合支持向量机分类器, 构建的航电电源板层间 CAF 短路故障识别模型。下面针对这两个部分进行具体分析。

1) 基于改进支持向量机的弱分类器构建:

首先准备支持向量机训练样本, 该样本主要由输入

与输出两个部分组成, 其中输入为前一章节从航电电源板层间 CAF 电气信号中提取的主元特征向量—— $\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N)$, 输出为对应的类别标签, 在这一研究中具体是指航电电源板层间 CAF 是否发生故障, 表示为 $\{-1, +1\}$, 其中 -1 代表航电电源板层间 CAF 发生了短路故障, $+1$ 代表航电电源板层间 CAF 未发生短路故障。输入与输出共同组成的训练样本记为 $\{\mathbf{P}, \mathbf{Y}\}$ 。支持向量机训练目的是找到一个超平面, 使得两类数据 (航电电源板层间 CAF 有无短路故障) 的间隔最大化。超平面方程表示如下:

$$\mathbf{v}^T \mathbf{P} + \kappa = 0 \quad (17)$$

式中, $\mathbf{v}$ 为权重向量, κ 为偏置项。为了求取权重向量和偏置项, 设定约束条件, 此时目标函数设置为最小几何间隔。由此构建优化问题模型, 该模型表示如下:

$$\begin{cases} \min_{\mathbf{v}, \kappa} \left\{ \frac{\|\mathbf{v}\|^2}{2} \right\} \\ \text{s. t. } Y_j (\mathbf{v}^T \mathbf{P} + \kappa) \geq 0 \end{cases} \quad (18)$$

式中, Y_j 代表第 j 个 CAF 电气信号主元特征向量训练样本的类别标签。在上述优化问题模型中引入拉格朗日乘子 $\vartheta_j \geq 0$, 将约束条件融入目标函数中, 方便进行求解和运算, 由此构建拉格朗日函数, 即:

$$L(\mathbf{v}, \kappa, \vartheta) = \frac{\|\mathbf{v}\|^2}{2} - \sum_{j=1}^m \vartheta_j [Y_j (\mathbf{v}^T \mathbf{P} + \kappa) - 1] \quad (19)$$

式中, ς 为惩罚因子。对权重向量 $\mathbf{v}$ 和偏置项 κ 进行求偏导操作, 令其为 0。将权重向量 $\mathbf{v}$ 的表达式代入拉格朗日函数, 消去权重向量 $\mathbf{v}$ 和偏置项 κ , 得到关于 ϑ 的对偶二次规划问题。最后, 通过求解器求解对偶二次规划问题, 得到 ϑ 的最优解。根据得到的 ϑ 最优解, 计算权重向量 $\tilde{\mathbf{v}}$ 和偏置项 $\tilde{\kappa}$ 。将计算出来的最优权重向量 $\tilde{\mathbf{v}}$ 和偏置项 $\tilde{\kappa}$ 代回到超平面方程中, 构建航电电源板层间 CAF 短路故障分类决策函数。对新输入的航电电源板层间 CAF 电气信号中提取的主元特征向量样本: $\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N)$, 预测标签 $f(\mathbf{P})$ 为:

$$f(\mathbf{P}) = \text{sign}(\tilde{\mathbf{v}}^T \mathbf{P} + \tilde{\kappa}) \quad (20)$$

经过上述过程, 完成了支持向量机的训练。在上述训练过程中, 拉格朗日函数中的惩罚因子的作用是控制模型对误分类样本的惩罚程度, 平衡分类准确率与模型复杂度。传统支持向量机训练中该参数一般都是固定, 当 ς 取值较小时, 会允许更多误分类, 导致分类边界较宽松, 可能出现欠拟合问题; 然而, 当 ς 较大时, 会强制严格分类, 导致分类边界紧贴训练数据, 可能出现过拟合^[22]。为弥补这一问题, 通过引入灰狼算法, 通过灰狼算法的迭代优化, 实现支持向量机惩罚因子的动态调整。具体过程如下:

(1) 设置灰狼算法的参数并进行初始化。为确保支

持向量机惩罚因子寻优过程的稳定性和有效性, 将种群大小设置为 30。此规模的设定是基于两方面的考量, 一方面, 若种群规模小于 30, 则搜索多样性不足, 易陷入局部最优; 另一方面, 若规模大于 30, 虽能提升搜索全局性, 但每次迭代的计算成本显著增加, 而收敛精度并未获得同等比例的提升。经权衡, 种群大小为 30 时, 能在探索与开发之间取得良好平衡。最大迭代次数设置为 100, 算法的适应度函数在 80 代左右已趋于稳定, 设置 100 次迭代为确保充分收敛提供了裕度。

为验证上述参数选择的鲁棒性, 进行参数敏感性分析。分别测试了种群大小 [20, 30, 40] 与最大迭代次数 [50, 100, 150] 的不同组合对优化结果, 即最终获得的惩罚因子及其对应的适应度值的影响。灰狼优化算法参数敏感性分析结果如表 1 所示。

表 1 灰狼优化算法参数敏感性分析结果

种群大小	最大迭代次数	平均收敛代数	最优适应度值(交叉熵损失)	收敛成功率/%
20	50	45	0.351	80
20	100	78	0.342	85
20	150	112	0.341	85
30	50	48	0.338	80
30	100	82	0.328	99
30	150	125	0.328	98
40	50	46	0.335	90
40	100	85	0.329	98
40	150	130	0.329	98

综合分析表 1 数据可知, 当种群规模为 20 时, 算法搜索多样性不足, 即使在最大迭代次数增至 150 代时, 其收敛成功率仍仅为 85%, 且最优适应度值为 0.341 显著劣于其他更大种群的配置, 表明其全局探索能力较弱, 易陷入局部最优。反之, 当种群规模增至 30 与 40 时, 算法在给予充分迭代次数的情况下, 收敛成功率均达到 99%, 证明了其强大的全局收敛能力。种群大小 30, 最大迭代次数 100 被证明为最优配置。在此配置下, 算法不仅实现了 99% 的收敛成功率, 获得了最佳的最优适应度值为 0.328, 并且其平均收敛代数 82 代表其收敛效率显著高于配置。

(2) 在支持向量机的惩罚因子 ς 的取值范围内随机生成 N 个灰狼个体, 每个灰狼个体 x_i 都代表一种惩罚因子 ς 的取值方案。

(3) 构建关于每个灰狼个体 (惩罚因子 ς 的取值方案) 的适应度函数, 用于评估惩罚因子 ς 的取值的优劣^[23]。在这里参考支持向量机通用评估指标——交叉熵损失作为基础, 进行适应度函数构建。交叉熵损失度量了支持向量机分类器预测的概率分布与真实概率分布之间的差异。计算出来的适应度函数值记为 $fit(x_i)$ 。

(4) 根据计算出来 $fit(x_i)$, 对灰狼等级进行划分。等级划分标准分为 4 个等级, 即:

- α' 狼: 最优个体 (领导群体, 主导狩猎);
- β' 狼: 次优个体 (协助 α 决策);
- δ' 狼: 第三优个体 (跟随 α 和 β);
- ω' 狼: 普通个体 (执行搜索和包围任务);

(5) 模拟灰狼的狩猎过程, 然后对于每个灰狼个体 (惩罚因子 ς 的取值方案), 更新其狩猎行为发生后所在的新位置。

(6) 重新计算位置更新后的每个灰狼个体 (惩罚因子 ς 的取值方案) 适应度函数值。

(7) 回到 4), 重复上述过程, 直至适应度收敛到设定的阈值之下。

(8) 从所有搜索结果中, 选出最大适应度函数值对应的那个灰狼个体 (惩罚因子 ς 的取值方案) 作为最优解, 完成支持向量机惩罚因子的动态寻优, 记为 ς_* 。

利用最优 ς_* 替换掉公式 (19) 中的原始惩罚因子 ς , 实现基于改进支持向量机的弱分类器的优化。

2) AdaBoost 算法构建故障识别监测模型:

在 AdaBoost 算法构建航电电源板层间 CAF 短路故障识别模型中, 以上述构建的改进支持向量机模型作为该算法的弱分类器, 进行故障识别。具体过程如下: 第一步, 输入 AdaBoost 算法的训练样本, 样本数量为 M' 个。按照下述公式为每个训练样本分配初始权重:

$$w_i = \frac{1}{M'}$$

(21)

式中, w_i 代表第 i 个训练样本的权重。假设有 m' 个基于改进支持向量机的弱分类器, 在当前样本权重分布 w_i 下对于每个弱分类器 $f_q(P_i)$ 进行训练, 目标是 minimized 加权错误率。接着, 计算弱分类器 $f_q(P_i)$ 的最小化加权错误率。公式如下:

$$\bar{E}_q = \sum_{i=1}^N w_i \cdot I[f_q(P_i) \neq Y_i]$$

(22)

式中, $\bar{E}_q$ 代表第 q 个基于改进支持向量机的弱分类器的最小化加权错误率; $I(\cdot)$ 为指示函数; $f_q(P_i)$ 代表第 q 个弱分类器的分类预测结果; Y_i 为真实标签。计算每一个基于改进支持向量机的弱分类器的权重并更新每个样本权重。公式如下:

$$\left\{ \begin{aligned} \eta_q &= \frac{\ln\left(\frac{1-\bar{E}_q}{\bar{E}_q}\right)}{2} \\ w'_i &= \frac{w_i \exp(-\eta_q f_q(P_i) Y_i)}{\xi_q} \end{aligned} \right.$$

(23)

式中, η_q 代表基于改进支持向量机的弱分类器的权重, w'_i 代表更新后的每个样本权重, ξ_q 为归一化因子。

通过加权投票将所有基于改进支持向量机的弱分类

器加权组合为强分类器，得到航电电源板层间 CAF 短路故障监测模型，即：

$$y(P) = \text{sign}\big(\sum_{q=1}^{m'} \eta_q f_q(P)\big)$$

(24)

式中， $y(P)$ 代表航电电源板层间 CAF 电气信号中提取的主元特征向量—— $P = (p_1, p_2, \cdots, p_N)$ 输入下，航电电源板层间 CAF 短路故障监测结果。

经过上述过程，完成了基于增强 KECA 分析结果的短路故障监测研究，当 $y(P) = -1$ 时，说明航电电源板层间 CAF 发生了短路故障， $y(P) = +1$ 时，说明航电电源板层间 CAF 未发生短路故障。

3 方法实验与测试

为验证增强 KECA 算法在极端环境下的故障识别中的有效性以及性能优势，进行实验测试，评估算法在航电电源板测试中的鲁棒性。首先为确保智能监测方法的可靠性和可重复性，需严格配置实验环境参数，具体如表 2 所示。

表 2 实验环境参数配置表

类别	名称	参数
硬件环境配置	环境试验箱	温度范围：-40~+150 ℃(±1℃)；湿度范围：20~98%RH(±3%)；支持电压加载：0~500 V DC
	信号采集设备	高精度电流探头；带宽 100 kHz，分辨率 0.1 μA，采样率 1 MS/s(16 位)，通道数 64(差分输入)
	数据处理平台	实时处理器：STM32H743(400 MHz，FPU 支持)；上位机：Intel i7-11800H + 32 GB RAM
	服务器	CPU：Intel Xeon Platinum 8380(40 核)；内存：256 GB DDR4 ECC；存储：4TB NVMe SSD(RAID 0)
软件环境配置	算法开发环境	OS：Ubuntu 22.04 LTS；Python 3.10 + C++；依赖库：NumPy 1.24.3, TensorFlow 2.12.0
	信号处理	Python 3.8 + SciPy 1.7 + PyEMD 1.0
	机器学习	Scikit-learn 1.0(KECA 自定义实现) + XGBoost 1.5
	实时部署	STM32CubeIDE + LibOpenCM3(CMSIS-DSP 库加速)
	可视化	Matplotlib 3.5 + Plotly 5.0

航空电源模块参数如下：包含 6 层印刷电路板；绝缘材料为 FR-4 环氧树脂；铜厚为 35 μm；输入电压为 DC 28 V(GJB 181A-2003)；输出电压为 5 V/12 V/±15 V(精度±0.5%)；最大功率为 500 W。

借助环境试验箱进行短路故障模拟。模拟过程如下：在高温高湿(85 ℃/85%RH)环境下，连续通电 1 000 h 模拟航电电源板 CAF 长时间工作条件，然后通过微针电极在层间绝缘材料中注入高压脉冲(1 kV/

100 ns)，模拟 CAF 短路故障。由于航电电源板 CAF 短路故障不同发展时期，其故障信号的表现程度不同，为模拟这一情况，设置不同强度高压脉冲，具体如表 3 所示。

表 3 高压脉冲注入强度工况

CAF 短路故障发展时期	高压脉冲注入强度	故障信号特征
早期(初始阶段)	幅值：50~100 V DC；脉宽：10 μs；重复频率：1 Hz；持续时间：5 min/次	漏电流波动(±0.5 μA)；局部放电幅值<5 mV
中期(生长阶段)	幅值：300 V DC；脉宽：100 μs；重复频率：10 Hz；持续时间：10 min/次	漏电流持续上升(10~50 μA)；局部放电脉冲群(10~100 mV，频率 1~5 kHz)
后期(击穿阶段)	幅值：500 V DC；脉宽：1 ms；重复频率：50 Hz；持续时间：直至失效	漏电流>100 μA；持续电弧放电(幅值>200 mV)；阻抗下降>90%

故障模拟的同时，利用传感器每 10 ms 采集一次故障信号，航电电源板层间 CAF 电流信号如图 1 所示。




图 1 航电电源板层间 CAF 电流信号图

图 1 中，在早期，CAF 电流信号波动特征并不明显，与正常无故障状态下的 CAF 电流信号相比，具有很高的相似性，波动特征呈现一定的规律性和周期性，这是因为所提方法基于改进 KECA 的多模态能量熵投影，利用核函数将高维 IMF 分量映射到低维空间，使早期故障的微弱特征在低维主元空间的区分度提升 3~5 倍。而随着发展到中后期，波动特征开始逐渐弱化，波动开始逐渐无规律化。

利用传感器采集 450 个电气信号样本，每个发展时期的故障样本分别为 150 个。从每个发展时期的故障样本中各抽取 100 个样本作为短路故障模式的训练数据，同时人工合成 300 个无短路故障的电气信号样本作为正常模式的训练数据，共计 600 个电气信号训练样本。剩余 150 个故障电气信号样本和 30 个无故障电气信号样本组成测试数据样本。针对这 780 个电气信号样本，利用经验模态分解方法进行分解并计算每一个 IMF 分量的能量熵，示例如表 4 所示。

表 4 IMF 分量能量熵

IMF 分量	样本 (正常状态)	样本 2 (早期)	样本 3 (中期)	样本 4 (后期)
IMF1	2.17	2.12	2.30	3.82
IMF2	1.87	1.91	2.05	3.45
IMF3	1.52	1.48	1.75	2.90
IMF4	1.21	1.05	1.62	2.15
IMF5	0.95	0.92	1.30	1.88
IMF6	0.75	0.73	0.92	1.52
IMF7	0.64	0.58	0.64	1.20
IMF8	0.45	0.42	0.50	0.95
IMF9	0.30	0.27	0.35	0.71
IMF10	0.18	0.16	0.22	0.45
IMF11	0.05	0.07	0.12	0.33

将航电电源板层间 CAF 电气信号的 IFM 分量能量熵组成熵集合 $\{h_1, h_2, \cdots, h_{11}\}$, 然后利用增强 KECA 算法进行分析, 筛选对航电电源板层间 CAF 短路故障最敏感的主元特征向量 $\boldsymbol{P}=(p_1, p_2, \cdots, p_N)$, 结果如表 5 所示。

表 5 增强 KECA 算法的分析结果——主元特征向量

能量熵序号	能量熵值	二次瑞利熵	排序	是否为主元特征向量
IMF1	2.18	0.12	9	否
IMF2	1.91	0.15	7	否
IMF3	1.75	0.68	4	是
IMF4	1.05	0.73	1	是(核心主元)
IMF5	1.30	0.65	2	是
IMF6	0.98	0.22	5	否
IMF7	0.65	0.17	6	否
IMF8	0.50	0.10	8	否
IMF9	0.35	0.05	10	否
IMF10	0.22	0.03	11	否
IMF11	0.12	0.08	12	否

从表 4 中可以看出, 增强 KECA 算法应用下共选出 3 个主元特征向量。为验证增强 KECA 算法的有效性, 根据选取的前 3 个主元特征绘制 80 个样本的散点图, 如图 2 所示。

从图 2 中可以看出, 图 (a) 中故障样本和无故障样本存在大量重合点, 且同类数据之间分布较分散和广泛, 说明传统 KECA 算法在核映射过程中未能有效保留故障特征的关键信息; 而图 (b) 中故障样本与无故障样本边界清晰, 且同类样本点之间有很好的聚类性。说明增强 KECA 算法能够从高维特征矩阵中提取出更具特性信息量的 CAF 故障特征, 为后续故障识别模型提供了 低冗余、高区分度的输入数据。

以筛选的主元特征向量为输入, 利用章节 1.3 研




图 2 传统 KECA 算法与增强 KECA 算法的映射散点图

究, 将改进支持向量机作为弱分类器, 通过 AdaBoost 算法进行故障识别, 结果如图 3 所示。




图 3 航电电源板层间 CAF 短路故障监测结果

从图 3 中可以看出, 在所给出的 36 个样本中, 只有 1 个样本的类别标签偏离了预期轨迹, 主要是因为所提方法通过高精度霍尔效应电流探头精准捕捉到了航电电源板层间 CAF 电气信号, 并分解出多尺度模态分量, 进而计算各电气信号 IMF 分量的能量熵, 这一系列操作从复杂的电气信号中挖掘出了与 CAF 状态相关的潜在信息, 在证明监测方法有效性的同时, 也证明了监测结果准确性。

为评估所提增强 KECA 算法的性能, 引入了 3 种具有代表性的传统故障诊断方法进行对比。这些方法基于本研究的数据特点进行了适配, 具体依据如下:

1) 基于双扩展卡尔曼滤波算法的方法^[4]: 在本实验中, 将其核心思想迁移至 CAF 故障场景, 构建了航电电源板的等效电路模型, 将 CAF 生长等效为并联在层间绝缘电阻上的一个时变小电阻。DEKF 的状态向量设置为系统电压与 CAF 等效电阻, 通过观测端电压与电流, 实现对 CAF 等效电阻的在线递推估计。当估计出的电阻值低于健康阈值时, 即触发短路报警。

2) 基于孤立森林的方法^[5]: 构建了 100 棵孤立树, 子树采样大小设置为 256。该方法在本研究中的应用, 验证了其在不依赖大量标注故障样本的情况下, 对 CAF 引发的异常电气模式具备检测能力。

3) 基于电化学阻抗谱的技术^[6]: 从 CAF 电气信号及其派生特征中构建过程变量数据集, 随后进行主元分析。通过计算 T2 和 SPE 两个统计量, 并与其在正常工况下通过核密度估计确定的控制限进行比较, 若任一统计量超出控制限, 则判定为故障。

对数损失是衡量概率预测与真实标签之间差异的指标, 常用于二分类及多分类问题)。对比结果如图 4 所示。




图 4 对数损失对比图

从图 4 中可以看出, 面对早期故障样本, 所研究方法的对数损失明显要低于其他 3 种传统方法, 而面对中期和后期故障样本, 所研究方法的对数损失也依然保持了较低水平, 由此证明了所研究方法与早期故障监测上更具优势。主要是因为所提方法引入了灰狼算法改进支持向量机, 利用改进后的支持向量机作为 AdaBoost 算法的弱分类器, 再经加权组合形成强分类器, 构建出航电电源板层间 CAF 短路故障识别模型。该模型凭借前期对信号特征的精准提取和优化处理, 在面对早期故障样本时, 能够更敏锐地捕捉到微弱的故障信号特征, 从而做出更准确的判断, 使得对数损失明显低于其他传统方法; 而在中期和后期故障样本监测中, 由于前期构建的模型具备强大的特征识别和分类能力, 依然能保持较低的对数损失, 充分证明了所研究方法与早期故障监测上的显著优势以及整体监测性能的优越性。

为评估所提智能监测方法在真实复杂工况下的性能与稳定性, 即极端低温振动工况下的性能测试与基于五折交叉验证的统计稳定性分析。同时, 为更全面地评估性能, 补充了多项统计指标。在原有高温高湿 85℃/85% RH 样本基础上, 利用环境试验箱与振动台, 模拟航电系统面临的极端低温振动工况温度 -40℃, 振动条件 10 gRMS。新增生成 150 个低温振动工况下的 CAF 短路故障样本。最终实验数据集包含两种工况:

1) 工况 A (常规): 450 个样本, 高温高湿, 原数据集;

2) 工况 B (极端): 150 个样本, 低温振动, 新增数据集。

为进行公允对比, 选取引言中所述的具有代表性的现有方法作为基线: 基于孤立森林的方法、基于电化学阻抗谱的技术、基于双扩展卡尔曼滤波算法的方法, 结果如表 6 所示。

表 6 多工况下不同方法的性能统计指标对比

方法	工况	F_1	对数损失
所提方法	A	0.985	0.31
	B	0.956	0.38
基于孤立森林的方法	A	0.873	0.82
	B	0.809	1.25
基于电化学阻抗谱的技术	A	0.908	0.70
	B	0.843	0.95
基于双扩展卡尔曼滤波算法的方法	A	0.933	0.58
	B	0.866	0.85

从表 6 纵向对比可见, 所有方法在极端工况 B 下的性能均出现不同程度下降, 符合预期, 因为低温与振动引入了新的信号扰动与特征漂移。然而, 所提方法在工况 B 下仍保持了 0.38 的对数损失, 其性能衰减远小于其他对比方法, 充分证明了本研究方法与通过增强 KECA 的特征提取与 GWO-SVM 模型的优化, 具备了更强的跨工况鲁棒性。横向对比 4 种方法, 所提方法在两种工况下的所有评估指标均显著优于 3 种对比方法。特别是在衡量故障检出能力的召回率上, 所提方法在工况 A 和 B 下分别达到 98.67% 和 95.33%, 这意味着它能更有效地避免漏报, 对于要求高安全性的航电系统至关重要。

为进一步验证结果的可重复性与稳定性, 避免单次数据划分的偶然性, 对完整的 600 个样本数据集进行五折交叉验证。所提方法的交叉验证结果如表 7 所示。

表 7 结果显示, 所提方法在 5 次不同的训练/测试集划分中, 各项性能指标波动范围极小。其中, 平均准确率达到 97.20%, 标准差仅为 0.56%。这些数据强有

表 7 五折交叉验证结果

折次	准确率/%	召回率/%	F_1
1	97.50	98.00	0.977
2	98.00	97.33	0.976
3	96.50	96.67	0.966
4	97.00	97.33	0.971
5	97.00	98.00	0.975
均值±标准差	97.20±0.56	97.47±0.67	0.973±0.005

力地证明了本研究所提方法具有极高的稳定性和可重复性, 其优异性能并非源于某一次特定的数据划分, 而是算法本身能力的体现。

4 结束语

研究围绕航电电源板层间 CAF 短路故障的智能监测问题, 提出了一种基于增强 KECA 算法的识别方法。其中, 增强 KECA 算法显著提升了故障信号的特征选取能力, 解决了传统方法局限于核矩阵特征向量所确定的投影方向, 无法有效地捕捉数据中的关键信息的问题。将改进支持向量机引入 AdaBoost 算法, 组成识别模型, 实现了方法监测能力的提升。研究将增强 KECA 算法深度融合于航电故障监测领域, 为高可靠性电子系统设计提供了新的理论工具。未来工作将聚焦构建 CAF 故障演化的物理—数据混合驱动模型方面, 实现从被动监测到主动干预的范式升级。

参考文献:

[1] 王坚俊, 姚 晖, 张 波, 等. 基于故障录波数据的串联电抗器故障特征分析及反演模型研究 [J]. 高压电器, 2025, 61 (7): 115–122.

[2] 李俊卿, 黄 涛, 韩小平, 等. 换相失败下调相机定子匝间短路故障特征分析 [J]. 广东电力, 2025, 38 (4): 25–34.

[3] 张志华, 鲁 鑫, 徐瑞东, 等. 含分布式光伏配电线路的探测式永久性故障识别方法 [J]. 电工电能新技术, 2025, 44 (4): 120–128.

[4] 陆震军, 洪华伟, 张宇峰, 等. 基于 DEKF 算法的锂离子电池内短路故障在线诊断方法 [J]. 电源技术, 2024, 48 (11): 2236–2246.

[5] 郭 煜, 王亦伟, 彭 鹏, 等. 基于孤立森林算法的锂离子电池微内短路故障诊断方法 [J]. 储能科学与技术, 2024, 13 (11): 4102–4112.

[6] 李晓枫, 常 益, 杨 章, 等. 应用阻抗谱的锂电池模组早期内短路故障诊断 [J]. 西安交通大学学报, 2024, 58 (11): 1–13.

[7] 陈培育, 王 洋, 贺 春, 等. 基于改进主元分析的锂离子电池内短路故障诊断方法 [J]. 电力系统及其自动化学报, 2024, 36 (11): 147–158.

[8] 王 寅, 王媛媛, 曹成军, 等. 基于多参量数据融合的干式空心串联电抗器匝间短路故障检测方法 [J]. 电力建设, 2025, 46 (4): 16–28.

[9] 赵舒心, 肖仕武, 梁伟宸. 基于聚合电流的高比例分布式电源接入配电网短路故障计算与分析 [J]. 电力系统保护与控制, 2025, 53 (7): 16–26.

[10] 高彩霞, 冯凌云, 党建军. 基于双级 PNN 的直驱永磁同步电机匝间短路故障诊断方法 [J]. 河南理工大学学报 (自然科学版), 2025, 44 (2): 116–127.

[11] 王清亮, 李泓朴, 李书超, 等. 基于 IDT-SAE-ELM 的煤矿电缆短路故障识别方法 [J]. 西安科技大学学报, 2024, 44 (6): 1205–1217.

[12] 王良成, 汪 源, 张永辉. 电动汽车永磁同步电机匝间短路检测算法仿真 [J]. 计算机仿真, 2024, 41 (2): 167–171.

[13] 黄友锐, 沈玉轩, 徐善永. 融合机器学习的永磁同步电机数字孪生故障诊断技术研究 [J]. 电测与仪表, 2025, 62 (2): 181–187.

[14] 栗子旋, 高丙朋. 基于 KECA 和 BO-SVDD 的滚动轴承早期故障检测 [J]. 机床与液压, 2023, 51 (11): 206–213.

[15] 李 榕, 申 志, 李 元. 基于核熵成分分析的工业过程多类型故障诊断 [J]. 电子测量技术, 2023, 46 (10): 40–45.

[16] 许之胜, 刘长良, 徐 健. 基于 KECA 和维纳过程的风电齿轮箱剩余寿命预测 [J]. 中国测试, 2024, 50 (12): 156–162.

[17] 张 敏, 袁 毅, 李贤均. 基于 KECA 和 MBA-NARX 的多阶段间歇过程质量预测 [J]. 西南交通大学学报, 2023, 58 (3): 685–695.

[18] 姚兆林, 吕 智, 王慧萍, 等. 基于模糊神经网络的配电网短路故障自动化识别系统 [J]. 电子设计工程, 2024, 32 (23): 66–70.

[19] 杨 鸣, 赵小涵, 司马文霞, 等. 单相变压器内部短路多尺度故障分析模型构建方法 [J]. 电工技术学报, 2025, 40 (13): 4085–4099.

[20] 党月懋, 张睿成, 吴立建, 等. 五相鼠笼异步电机定子匝间短路诊断方法 [J]. 电机与控制学报, 2025, 29 (1): 1–14.

[21] 匡红刚, 胡宗军, 李晓斌, 等. 基于三相 4PT 接线方式的 PT 短路故障特征量分析 [J]. 电气工程学报, 2024, 19 (3): 149–158.

[22] 吴振宇, 王 慧, 胡存刚, 等. 基于多路漏磁信号阵列的无刷直流电机匝间短路故障诊断 [J]. 电工技术学报, 2025, 40 (4): 1105–1116.

[23] 王喜莲, 秦嘉翼, 耿 民. 基于 d-q 变换及 WOA-LSTM 的异步电机定子匝间短路故障诊断方法 [J]. 电机与控制学报, 2024, 28 (6): 56–65.