

基于改进经验小波变换的永磁同步电机故障 诊断策略

钱轶群¹, 张孜乐^{2*}, 杨依林¹, 张宇磊¹, 于天佑², 周荔丹²

(1. 国网上海长兴供电公司, 上海 201913;

2. 上海交通大学 电子信息与电气工程学院, 上海 200240)

Fault Diagnosis Strategy for Permanent Magnet Synchronous Motors Based on Improved Empirical Wavelet Transform

QIAN Yiqun¹, ZHANG Zile^{2*}, YANG Yilin¹, ZHANG Yulei¹, YU Tianyou², ZHOU Lidan²

(1. State Grid Shanghai Changxing Electric Power Supply Company, Shanghai 201913, China;

2. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University,
Shanghai 200240, China)

Abstract: [Objective] Permanent magnet synchronous motor (PMSM) is widely used in wind power generation and electric vehicles due to its high power factor, simple structure and good dynamic performance. However, PMSM may experience phase loss faults during operation due to reasons such as drive failure or loose stator winding connections. When operating with phase loss, the PMSM generates noise and vibration, leading to a reduction in output power. Prolonged phase loss operation can also damage electrical equipment, making accurate fault diagnosis crucial for ensuring the normal operation of the equipment. [Methods] This paper proposed a fault diagnosis strategy based on an improved empirical wavelet transform (IEWT) and categorical boosting (CatBoost) algorithm, and applied it to the phase loss fault diagnosis of six-phase PMSM. First, the basic principle of the IEWT algorithm was introduced. The IEWT algorithm performed spectral segmentation on the Welch power spectrum, effectively suppressing modal aliasing compared to the empirical wavelet transform (EWT) algorithm. Then, the PMSM fault signal was decomposed using the IEWT to obtain the modal components. The energy moments of each modal component were used to characterize the fault signal and construct a fault classification dataset. Finally, based on an arithmetic optimization algorithm, 80%

of the dataset was used as a training set to tune the hyperparameters of the CatBoost algorithm. Suitable hyperparameters were selected to build a CatBoost fault classification model, which was compared with other traditional classification models. [Results] Experimental results show that the fault diagnosis strategy based on IEWT and CatBoost algorithm effectively suppresses the erroneous segmentation phenomenon caused by large side lobes near the main frequency in the traditional EWT algorithm, improving fault classification accuracy. Compared to traditional classification models, the CatBoost multi-classification model can more accurately identify fault types, demonstrating balanced classification performance for each fault category. It has stronger generalization ability and performs well under different fault conditions. [Conclusion] The experimental results validate the feasibility and effectiveness of the proposed fault diagnosis strategy for six-phase PMSM phase loss fault diagnosis, providing support for future six-phase PMSM fault-tolerant control and comprehensive fault detection technologies.

Key words: phase loss fault; fault diagnosis; improved empirical wavelet transform ;CatBoost algorithm

摘要: [目的] 永磁同步电机(PMSM)因其功率因数高、结构简单和动态性能好等优势在风力发电、电动汽车领域得到广泛应用。然而,PMSM 在运行过程中由于驱动器损坏、定子绕组接线松动等原因可能会导致缺相故障,PMSM 缺相运行时会产生噪声和振动,导致输出功率降低,并且长时间缺相运行会损坏电气设备,因此对其进行

基金项目: 国网上海市电力公司科技项目资助 (5209KZ230005)

Funded by State Grid Shanghai Electric Power Company Technology Project (5209KZ230005)

准确的故障诊断对于保障设备的正常运行至关重要。

【方法】本文提出了一种基于改进经验小波变换 (IEWT) 和分类提升 (CatBoost) 算法的故障诊断策略, 并将其应用于六相 PMSM 缺相故障诊断。首先, 介绍了 IEWT 算法的基本原理, IEWT 算法在 Welch 功率谱曲线上进行频谱分割, 相较于经验小波变换 (EWT) 算法, 能有效抑制模态混叠; 然后, 对 PMSM 故障信号进行 IEWT 分解得到各个模态分量, 利用各个模态的能量矩表征故障信号, 构建故障分类数据集; 最后, 基于算数优化算法, 取数据集的 80% 作为训练集对 CatBoost 算法进行超参数调优, 选择合适的超参数构建 CatBoost 故障分类模型, 并与其他传统分类模型进行对比。**【结果】**试验结果表明, 本文所提基于 IEWT 和 CatBoost 算法的故障诊断策略有效抑制了传统 EWT 算法中因主频附近旁瓣过大导致的错误分段现象, 提高了故障分类的准确率。与传统分类模型相比, CatBoost 多分类模型能够更加准确地识别故障类别, 且在每种故障类别上的分类性能表现均衡, 泛化能力更强, 在不同的故障工况下均有良好表现。**【结论】**试验结果验证了本文所提故障诊断策略在六相 PMSM 缺相故障诊断上的可行性和有效性, 为后续六相 PMSM 容错控制以及综合故障检测技术提供了支撑。

关键词: 缺相故障; 故障诊断; 改进经验小波变换; CatBoost 算法

0 引言

永磁同步电机 (Permanent Magnet Synchronous Motor, PMSM) 凭借其功率因数高、动态性能优的特点, 被广泛应用于制造业、交通运输业以及可再生能源发电行业, 其工况好坏直接影响着整个系统的性能^[1]。缺相故障是 PMSM 常见的电气故障, 通常表现为相绕组与电源断开, 从而导致磁场畸变, 使剩余健康相中产生不平衡电流, 引起较大的电磁转矩脉动^[2]。如果不能及时诊断出缺相类别, 并采取补救措施, 可能会对整个系统造成二次伤害。因此, 对 PMSM 进行有效的状态监测和故障诊断必不可少。

目前, 电机的故障诊断策略大致可划分为解析模型法、信号分析法以及数据驱动法三种^[3]。基于模型的故障诊断通过分析系统的冗余成分来优化系统硬件, 如文献[4]提出一种统一模型用于 PMSM 故障诊断, 但精确的输入输出模型通常难以建立。基于信号分析的故障诊断是通过对测量信号进行时域或频域的特征提取, 然后对比健

康系统的特征做出诊断决策, 如文献[5]利用频率跟踪算法在时域提取幅值和初相角, 实时计算故障指示器和初相角差值, 实现了 PMSM 定子绕组故障和开关管故障类型的判别。但此方法对系统动态的输入关注较少, 在未知输入扰动或不平衡条件下诊断性能可能会下降。基于数据驱动的故障诊断从大量历史数据出发, 将各种人工智能技术应用到工业过程中, 如文献[6]根据不同故障情况下的转矩, 提出一种基于反向传播 (Back Propagation, BP) 神经网络的异步电机传感器故障诊断方法。三种方法为 PMSM 系统的健康监测与故障诊断提供了多元化的解决方案。为了发挥各种故障诊断方法的优势, 实际工程应用中通常采用混合诊断策略。本文利用信号分析法获得 PMSM 的时频特征, 然后选择一种机器学习算法对故障数据集进行分析, 最终实现 PMSM 缺相故障诊断。

常用的信号分析法有快速傅里叶变换 (Fast Fourier Transform, FFT)^[7]、小波变换^[8]和经验模态分解^[9]等。经验小波变换 (Empirical Wavelet Transform, EWT)^[10]以经验模态分解和小波变换为基础, 是一种具有高时频分辨率且能够自适应地构造基函数的信号分析方法, 被广泛应用于医疗信号分析^[11]、地质勘探^[12]以及机械故障检测^[13]等领域。由于频谱泄露和噪声干扰, EWT 在频谱划分时可能检测不到最佳边界值, 导致出现模态混叠现象。现有的改进方式主要从两个角度出发, 一是改进频谱分段算法, 如文献[14]提出了一种基于可变阈值的广义 EWT 算法; 二是优化信号频谱, 如文献[15]提出了一种基于自适应频谱趋势的改进 EWT (Improved EWT, IEWT) 算法, 利用分段埃尔米特插值重新拟合信号频谱后, 再进行频谱划分。本文根据第二种改进方式, 提出了一种新的 IEWT 算法, 该算法利用 Welch 功率谱^[16]曲线代替 FFT 曲线, 在较为平滑的曲线上进行频谱分割, 获得了故障信号的时频特征。

目前, 机器学习分类算法主要分为单一分类算法和集成分类算法两大类。随着数据结构复杂、数据量大和数据质量参差不齐等问题愈加突出, 集成学习成为了大数据分析的强有力工具。集成学习主要分为并行和串行两种架构, 分别对应 Bagging 类算法和 Boosting 类算法^[17]。分类提

升(Categorical Boosting, CatBoost)算法是一种基于 Boosting 框架的开源机器学习算法,由 Yandex 公司于 2017 年提出,因其具有高模型精度和更快的预测速度而被广泛应用^[18]。

综上所述,本文将信号分析和数据驱动相结合,提出了一种基于 IEWT 和 CatBoost 算法的混合故障诊断策略,并将其应用于六相 PMSM 故障诊断。首先,对 IEWT 算法的基本原理进行分析;然后,对六相 PMSM 在故障工况下的故障信号进行分解,提取各分量系数的能量矩作为特征向量,构建 PMSM 故障特征集;最后,将故障特征集与标签组合训练 CatBoost 分类模型,通过算数优化算法(Arithmetic Optimization Algorithm, AOA)^[19]选择性能较好的模型保存,并与 BP 神经网络^[20]、支持向量机(Support Vector Machine, SVM)^[21]以及极限梯度提升(eXtreme Gradient Boosting, XGBoost)^[22]等主流算法进行对比。试验结果表明,本文所提方法整体分类准确率较高,且在每种故障类别上的分类性能表现均衡,能实现对 PMSM 缺相故障的诊断。

1 IEWT 算法

1.1 IEWT 算法基本原理

传统 EWT 算法频谱划分依据周期图法^[23],其原理简单,但容易出现频谱泄露现象,从而影响边界值检测算法的准确性。通过对信号进行分段、重叠,再加以不同的窗函数,可以实现对周期图法的优化,从而更清晰地描绘信号在不同频率处的功率分布,体现频域信息的同时又不易产生频谱泄露。

IEWT 算法主要包括 Welch 分解、频谱分段、小波滤波器组构造以及模态提取四个步骤。设故障信号为 $x(n)$,分解模态数为 N ,IEWT 算法的具体步骤如下。

(1) Welch 分解:将信号分成 L 段,利用窗函数 $w(n)$ 处理每段数据,并进行 FFT 求出每段功率,求平均后得到 Welch 功率谱 $\tilde{P}(\omega)$ 的表达式如式(1)所示:

$$\tilde{P}(\omega) = \frac{1}{M \cdot U \cdot L} \sum_{i=1}^L \left| \sum_{n=0}^{M-1} x_N^i(n) w(n) e^{-j\omega n} \right|^2 \quad (1)$$

式中: M 为每段的数据长度; U 为归一化因子。

(2) 频谱分段:利用局部最大值算法求取 $\tilde{P}(\omega)$,按降序排列的前 $N-1$ 个极大值点,对应 $N-1$ 个主频点。然后根据主频率确定原始边界集,取相邻两主频点的中点为实际频谱分割边界,得到 N 个连续区间。

(3) 小波滤波器组构造:分段确定后,根据 Littlewood-Paley 小波和 Meyer 小波构建经验尺度函数 $\hat{\varphi}_k(\omega)$ 和经验小波函数 $\hat{\psi}_k(\omega)$ ^[10]:

$$\hat{\varphi}_k(\omega) = \begin{cases} 1, & |\omega| \leq \omega_k - \tau_k \\ \cos\left\{\frac{\pi}{2}\beta\left[\frac{1}{2\tau_k}(|\omega| - \omega_k + \tau_k)\right]\right\}, & \omega_k - \tau_k < |\omega| \leq \omega_k + \tau_k \\ 0, & \text{其他} \end{cases} \quad (2)$$

$$\hat{\psi}_k(\omega) = \begin{cases} 1, & \omega_k + \tau_k < |\omega| \leq \omega_{k+1} - \tau_{k+1} \\ \cos\left\{\frac{\pi}{2}\beta\left[\frac{1}{2\tau_{k+1}}(|\omega| - \omega_{k+1} + \tau_{k+1})\right]\right\}, & \omega_{k+1} - \tau_{k+1} \leq |\omega| \leq \omega_{k+1} + \tau_{k+1} \\ \sin\left\{\frac{\pi}{2}\beta\left[\frac{1}{2\tau_k}(|\omega| - \omega_k + \tau_k)\right]\right\}, & \omega_k - \tau_k \leq |\omega| \leq \omega_k + \tau_k \\ 0, & \text{其他} \end{cases} \quad (3)$$

式中: $\beta(\cdot)$ 为取值范围为 $[0,1]$ 的任意函数,同文献[10]一致。 ω_k 为第 $k+1$ 个频谱区间的角频率; τ_k 为第 $k+1$ 个频谱区间的滤波器带宽。经验小波在边界集元素中起着带通滤波的作用。

(4) 模态提取:每段频谱区间对应一个本征模态函数(Intrinsic Mode Function, IMF),参照式(4)提取各分量。

$$\begin{cases} u_0(t) = W_u(0,t) \cdot \varphi_1(t) \\ u_k(t) = W_u(k,t) \cdot \psi_k(t), k = 1, \dots, N-1 \end{cases} \quad (4)$$

式中: $W_u(0,t)$ 为逼近系数; $W_u(k,t)$ 为细节系数; $\varphi_1(t)$ 、 $\psi_k(t)$ 分别为 $\hat{\varphi}_1(\omega)$ 、 $\hat{\psi}_k(\omega)$ 的时域表达式。

1.2 频谱分割效果对比

EWT 算法直接在 FFT 频谱上划分频段,当信号较弱或噪声较强时,信号在主瓣附近的幅值较大,干扰局部最大值算法寻找其他主频点,导致边界值集中在某一频段内,无法正确提取模态分量。

如图 1 所示,以同一段电流信号为例,分别采

用 EWT 算法和 IEWT 算法对其进行 5 段模态分解,对比频谱分割效果。由图 1(a)可知,EWT 算法因主频附近的旁瓣值过大错误划分出无效频段 1,导致后续频段 2 的两个特征频点中有一个未被划分。IEWT 算法在 Welch 功率谱曲线上进行频谱分割,如图 1(b)所示,其谱线更加平滑,频谱泄露现象较少。使用局部最大值算法求取极值点,不会被旁瓣值干扰,能够更加准确地定位特征频点,使得频谱分段更加准确,确保后续提取到正确的模态分量,有效抑制模态混叠。

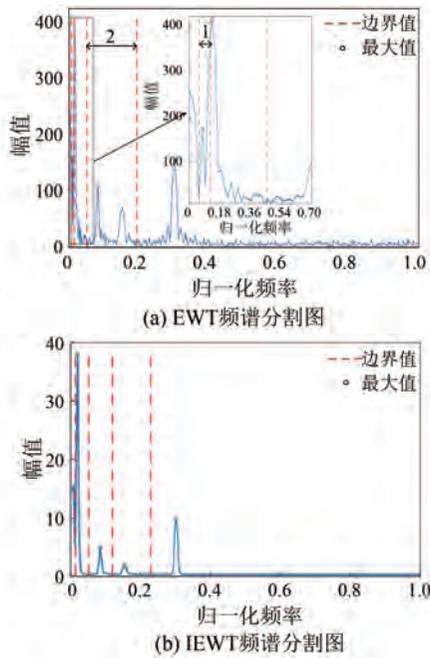


图 1 频谱分割效果对比

Fig. 1 Comparison of spectrum segmentation effects

1.3 特征提取

特征提取是机器学习算法的一个重要步骤。在地震信号研究中,信号经分解后常用均值、能量矩、变异系数、峰度和瑞丽熵等统计值来描述特征^[24]。由于电机故障信号没有地震信号复杂,因此仅选用各模态的能量矩来表征信号,以此反映各模态分量的能量沿时间轴的分布情况,具体的步骤如下。

(1) 计算能量矩:对故障信号进行 IEWT 分解,得到多个模态分量,各模态分量 c_j 的能量矩 E_j 表达式为

$$E_j = \sum_{i=1}^N (i \cdot \Delta t) |c_j(i \cdot \Delta t)|^2, j = 1, 2, \dots, k \quad (5)$$

式中: N 为采样点数; k 为模态分量的个数; Δt 为采样时间间隔。

(2) 归一化:对 E_j 进行最值归一化处理,如式(6)所示:

$$E'_j = \frac{E_j - \min(E_j)}{\max(E_j) - \min(E_j)}, j = 1, 2, \dots, k \quad (6)$$

(3) 构造故障特征向量:根据式(7)构造特征向量 \mathbf{V} ,若 m 个故障信号构成一组样本,则用于分类的特征矩阵可表示为 \mathbf{F} 。

$$\mathbf{V} = [E'_1 \quad E'_2 \quad \dots \quad E'_k]^T \quad (7)$$

$$\mathbf{F} = [\mathbf{V}_1 \quad \mathbf{V}_2 \quad \dots \quad \mathbf{V}_i], i = 1, 2, \dots, m \quad (8)$$

IEWT 算法可以在保留信号频域信息的同时较为精准地分离各个模态,有效抑制了传统 EWT 算法因频谱泄露导致的模态混叠现象。与此同时,利用各个模态的能量矩表征故障信号,构建故障分类数据集,为后续机器学习分类模型的构造提供了数据支持。

2 CatBoost 算法

2.1 CatBoost 算法原理

CatBoost 算法的核心是将弱分类器进行线性组合,是对梯度增强决策树算法的改进,其独特之处在于能自动处理类别特征,无需进行繁琐的编码,与其他主流改进算法相比,其类别型特征处理方法和排序提升机制更有效^[25]。

2.1.1 类别型特征处理方法

许多数据集包含类别型特征,常用的处理方法有独热编码、目标编码等。独热编码原理简单但面对高基数类别时,相应的特征维度和树的深度也会增加,模型会消耗更多的时间和计算资源。

目标编码是根据每个样本在整个数据集上的平均标签值替换类别,得到对应数据特征 $x_{i,k}$,如式(9)所示。但由于计算过程中使用了标签数据,当个例存在或测试集的特征分布与训练集不一致时,会导致标签泄露问题,即 $x_{i,k}$ 的值等于标签值。

$$x_{i,k} = \frac{\sum_{j=1}^n [x_{j,k} = x_{i,k}] \cdot Y_j}{\sum_{j=1}^n [x_{j,k} = x_{i,k}]} \quad (9)$$

式中: i, j 为行数; k 为列数; $[\cdot]$ 为艾弗森括号; Y_j 为标签值。

CatBoost 算法在目标编码的基础上提出了目标统计(Target Statistics, TS)编码方式。首先,在梯度增强过程中对 n 个样本进行多组随机排序,记当前给定序列为 $\sigma = (\sigma_1, \dots, \sigma_n)$;然后,在一定范围内计算具有相同类别的样本的平均标签值;最后,结合先验值 P ,根据式(10)将类别型特征转化成相应数值特征 $X_{\sigma_{p,k}}$ 。

$$X_{\sigma_{p,k}} = \frac{\sum_{j=1}^{P-1} [x_{\sigma_{j,k}} = x_{\sigma_{p,k}}] \cdot Y_{\sigma_j} + a \cdot P}{\sum_{j=1}^{P-1} [x_{\sigma_{j,k}} = x_{\sigma_{p,k}}] + a} \quad (10)$$

式中: a 为先验值权重。

通过 TS 编码,CatBoost 算法能够不占用预处理时间处理类别型特征,解决了目标编码的标签泄露问题。

2.1.2 排序提升机制

CatBoost 算法的另一个重要方面是排序提升机制。以往的梯度提升算法通常根据当前树模型的损失函数的梯度来决定下一颗树的结构和叶子节点值,但在模型累加过程中,每棵树都在同一样本上训练,这会导致逐点梯度估计存在偏差,模型出现过拟合。CatBoost 算法具有的排序提升机制缓解了这些问题,有效减少了梯度偏差,程序执行伪代码如图 2 所示。

```

Ordered boosting
Input:  $(X_i, Y_i)_{i=1}^n$ , Number of trees  $I$ 
1:  $M_i \leftarrow 0$  for  $i=1, \dots, n$ 
2: for iter  $\leftarrow 1$  to  $I$  do
3:   for  $i \leftarrow 1$  to  $n$  do
4:     for  $j \leftarrow 1$  to  $i-1$  do
5:        $g_j \leftarrow \frac{d}{da} \text{Loss}(y_j, a) \Big|_{a=M_i(X_j)}$ 
6:        $M \leftarrow \text{LearnModel}(X_j, g_j)$  for  $j=1, \dots, i-1$ 
7:        $M_i \leftarrow M_i + M$ 
8: return:  $M_1, \dots, M_n$ 

```

图 2 CatBoost 排序提升机制伪代码

Fig. 2 CatBoost ordered boosting mechanism pseudocode

图 2 中, $(X_i, Y_i)_{i=1}^n$ 为输入数据, X_i 为特征向量, Y_i 为标签值; I 为树的数量(即迭代次数); M_i 为样本 i 的当前预测值; Loss 为计算损失函数; a 为模型 $M_i(X_j)$ 的输出; y_j 为样本中的真实标签; g_j 为样本 j 的梯度; LearnModel 表示学习一个新

模型。

首先,对训练集进行随机排序,此序列与 TS 编码用到的序列一致;其次,从训练集中剔除样本,并训练一个单独的模型 $M_i(X_i)$;然后,针对排列在 X_i 之前的样本,计算其在 M_i 上损失函数的一阶梯度;最后,根据梯度训练得到提升模型 M ,并与原有模型累加,得到新的树模型 M_i ,进入下一轮迭代。此外,CatBoost 算法采用对称二叉树作为基分类器,有正则效果,预测速度极快,并且基于贪心策略将类别型特征进行交叉组合能够发挥特征的全部优势。

2.2 AOA

确定分类算法之后,选取合适的超参数可以使模型性能更加优秀,AOA 是一种基于种群的元启发式算法,由 Laith 于 2021 年提出,可以实现从一组候选方案中确定符合特定标准的最佳元素,并且能够在不计算导数的情况下解决优化问题。

AOA 优化 CatBoost 模型的具体流程如图 3 所示。图 3 中, C_iter 、 M_iter 分别为当前迭代次数、最大迭代次数; MOA 、 MOP 分别为数学加速器优化函数、概率函数; r_1 、 r_2 和 r_3 为 $[0, 1]$ 上的随机数。

AOA 优化过程包含初始化、探索和开发三个阶段。在初始化阶段,主要设置 AOA 参数和初始随机解;在探索阶段,使用具有大阶变化的乘法运算符或除法运算符探索整个空间,大步长寻找较为优越的位置;在开发阶段,使用更容易接近目标的加法运算符或减法运算符进行局部寻优并保持候选解的多样性。此外,算法的优异性能需在探索和开发之间取得适当平衡才能获得。

鉴于 CatBoost 算法能够高效处理类别特征,有效减少梯度偏差,所以选择该算法构建 PMSM 故障分类模型,并利用 AOA 探索最优超参数,从而获取最佳模型。

3 基于 IEWT 和 CatBoost 算法的六相 PMSM 缺相故障诊断

基于 IEWT 和 CatBoost 算法,本文提出了一种六相 PMSM 缺相故障诊断策略,如图 4 所示。该策略在电机驱动模块和控制模块的基础上增加信号分析和数据驱动结合的故障诊断模块,实现对故障的预测和识别;结合容错控制算法,增强了

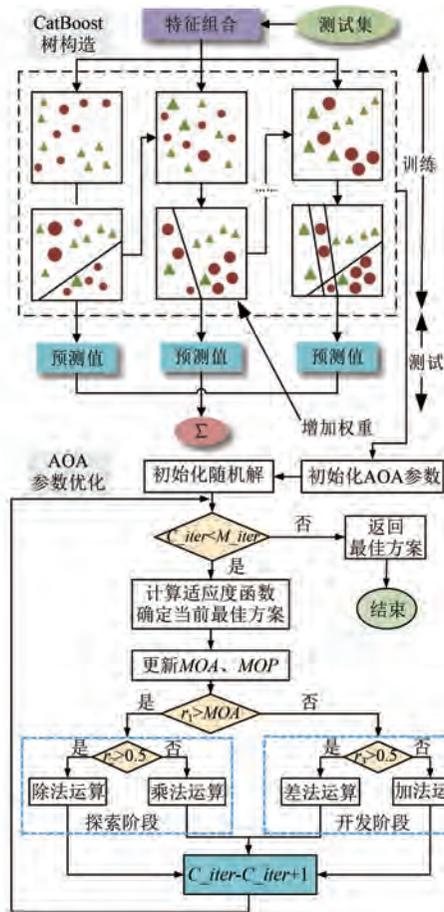


图 3 AOA 流程
Fig. 3 AOA flow

电机的运行可靠性、容错运行能力,提高了电机的能量转换效率。其中,故障诊断模块包含离线训练和在线识别两种模式。

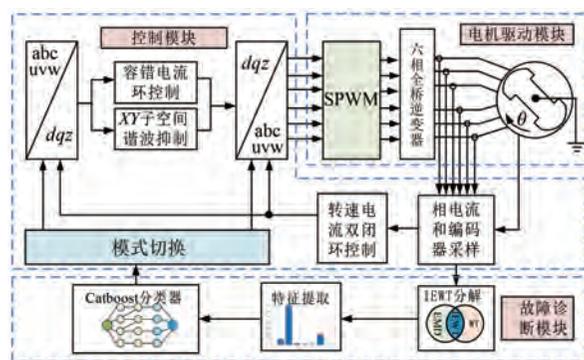


图 4 故障诊断策略
Fig. 4 Fault diagnosis strategy

(1) 离线训练

搭建故障切换模型,记录六相 PMSM 不同工况下的采样信号,每种工况对应的分类标签如表 1 所示。采用 IEWT 算法对采样信号进行分解,提

取子模态能量矩构造故障特征集,训练 CatBoost 分类器并保存最优模型。

表 1 分类标签
Tab. 1 Category label

工况类型	故障类型	分类标签
正常工况	无	0
故障工况	一相开路	1
	两相开路 30°	2
	两相开路 90°	3
	两相开路 120°	4
	两相开路 150°	5

(2) 在线识别

通过窗函数在线读取六相 PMSM 信号,经信号分解和特征提取后,调用离线状态下训练好的 CatBoost 模型,诊断故障类别,控制单元随之选择相应的容错控制方案,避免电机长时间缺相运行对系统造成二次伤害。

4 仿真及试验验证

基于 Matlab/Simulink 搭建六相 PMSM 故障切换模型,记录正常工况和五种故障工况下的 6 240 组故障信号。然后,通过在环硬件系统 RTU-BOX 试验平台,分析故障电流信号,验证 IEWT 算法的有效性。最后,在 Python 平台上训练并优化模型,验证 CatBoost 分类器的性能。试验平台如图 5 所示,PMSM 仿真参数如表 2 所示。

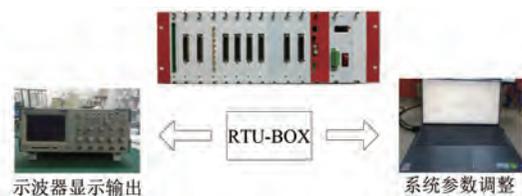


图 5 试验平台

Fig. 5 Experimental platform

表 2 仿真参数

Tab. 2 Simulation parameters

参数名称	参数值
永磁体磁链 ψ_m /Wb	1.33
极对数 p	3
定子 d 轴电感 L_d /H	0.039 3
定子 q 轴电感 L_q /H	0.039 3
转动惯量 J /($\text{kg}\cdot\text{m}^2$)	0.015
机械角速度 ω /($\text{rad}\cdot\text{s}^{-1}$)	150
额定功率 P_N /kW	20
定子绕组漏感 L_{all} /mH	1.75

4.1 IEWT 算法

为验证 IEWT 算法的有效性, 本文以 f 相开路时非故障相电流 i_a 为例进行信号分解, 如图 6 所示。六相 PMSM 在 t_1 时刻发生故障, t_2 时刻切换到容错运行状态。基于 Welch 功率谱曲线对信号进行 8 段 IEWT 分解, 频谱划分结果如图 7 所示。由图 7 可知, 该曲线能够较平滑地描绘信号在频域的功率大小, 且在寻找局部极大值时能够准确定位主峰, 合理划分频段。

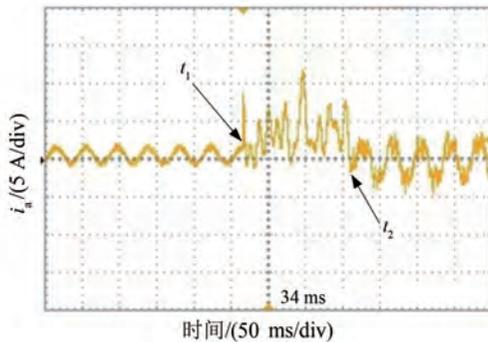


图 6 故障电流 i_a

Fig. 6 Fault current i_a

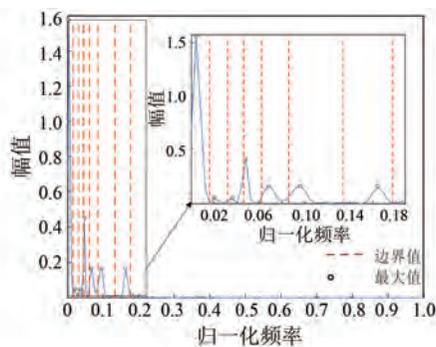


图 7 故障电流频谱划分

Fig. 7 Fault current spectrum segmentation

频段划分完成后, 构造相应小波滤波器组, 提取原始信号由低频到高频的 8 组模态分量 IMF1~IMF8。其中, IMF1 为信号的全局趋势; IMF2~IMF4 主要为低频分量; IMF5~IMF7 反映了故障过程的时频信息; IMF8 主要为高频噪声。IEWT 分解得到的模态分量可以很好地反映故障信号的发生时刻和故障频率的分布, 提取每个模态的能量矩表征原始信号, 从而判断电机处于何种工况。

4.2 CatBoost 分类器性能

针对六相 PMSM 开路的六种工况, 在负载转

矩 $3 \text{ N} \cdot \text{m} \sim 50 \text{ N} \cdot \text{m}$ 、参考转速 $100 \text{ rad/s} \sim 200 \text{ rad/s}$ 范围内设置 1 024 组参数, 采样六种故障信号(电机转速、电磁转矩以及 a、b、d 和 e 相定子电流), 共计 6 240 组样本。对每组样本进行 8 段 IEWT 分解并提取能量矩, 构造 $6\,240 \times 48$ 维输入数据集。CatBoost 学习目标选用“loss function: MultiLogloss”, 在 Python3.7 环境中构建模型, 计算机配置为 Intel i5-11320 和 16 GB RAM。

4.2.1 超参数优化

本文基于 AOA, 取输入数据集的 80% 作为训练集对 CatBoost 算法进行超参数调优。采用 5 折交叉验证方式分析指标准确率 (Accuracy, ACC), 根据指标大小选取模型最优取值, 如表 3 所示。相应训练过程中测试集和验证集上 ACC 的变化曲线如图 8 所示。由图 8 可知, 在迭代到 115 次时模型在验证集上的准确率最高。

表 3 超参数优化

Tab. 3 Hyperparameter optimization

超参数名称	优化范围	模型最优取值
迭代次数	[50, 300]	115
深度	[4, 10]	6
学习速率	[0.02, 0.2]	0.074
二次采样	[0.6, 1.0]	0.637
响应曲面	[0.6, 1.0]	0.894

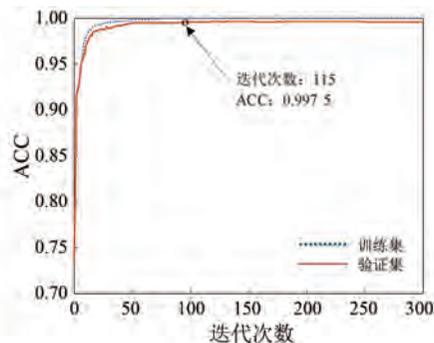


图 8 模型训练 ACC 曲线

Fig. 8 Model training ACC curves

调优前后验证集 ACC 对比如图 9 所示。由图 9 可知, 使用优化参数后, 模型在 5 折交叉验证的每一轮中验证集的分类准确率都得到了提升, AOA 使 CatBoost 分类器性能得到了改善。

4.2.2 不同分类算法对比

采用随机森林 (Random Forest, RF)、XGBoost 和 CatBoost 三种集成算法以及 SVM、BP 两种单一机器学习算法对同一故障数据集进行训练和预

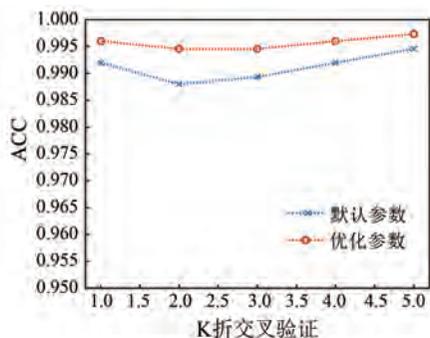


图 9 验证集 ACC 对比

Fig. 9 Comparison of validation set ACC

测,不同分类算法 ACC 对比如图 10 所示。RF、XGboost 和 CatBoost 的预测 ACC 分别为 0.989 6、0.989 5 和 0.994 3, SVM、BP 的预测 ACC 分别为 0.971 9、0.983 2, 可见集成算法的预测 ACC 比单一机器学习算法高。CatBoost 算法的预测 ACC 要优于其他四种分类算法,且在每种故障类别上的预测能力均衡,模型的泛化能力较强。

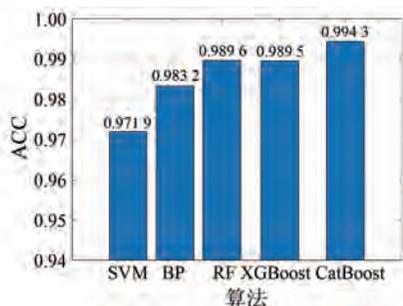


图 10 不同分类算法预测 ACC 对比

Fig. 10 Comparison of prediction ACC for different classification algorithms

5 结语

本文针对六相 PMSM 缺相故障诊断问题,提出了一种 IWET 算法来提取故障信号特征构建故障数据集,并将该数据集用于训练和优化 CatBoost 分类模型。该方法采用信号分析和数据驱动相结合的故障诊断策略,实现了六相 PMSM 缺相故障类型的有效识别。试验结果表明,IEWT 算法能够有效分离故障信号的模态,避免了传统方法中的模态混叠问题。与传统分类模型相比, CatBoost 分类模型能够更加准确地识别故障类型,且在每种故障类型上的分类性能表现均衡,泛化能力更强,为后续六相 PMSM 容错控制以及综合故障检测技术提供了支撑,为未来电机故障诊

断领域研究开辟了新途径。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

钱轶群进行了方案设计,张孜乐进行了内容总结与论文撰写,杨依林、张宇磊进行了试验研究,于天佑、周荔丹参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

Qian Yiqun carried out the scheme design. Zhang Zile carried out the content summary and paper writing. Yang Yilin and Zhang Yulei conducted experimental research. Yu Tianyou and Zhou Lidian participated in the review and revision of the paper. All authors have read the last version of the paper and consented for submission.

参考文献

- [1] HUANG S, LEI J Y, ZENG C, et al. Online rotor fault diagnosis of permanent magnet synchronous motors based on stator tooth flux [J]. IEEE Transactions on Industry Applications, 2021, 57 (3): 2366-2377.
 - [2] LI W L, FENG G D, LI Z, et al. Extended Kalman filter based inductance estimation for dual three-phase permanent magnet synchronous motors under the single open-phase fault [J]. IEEE Transactions on Energy Conversion, 2021, 37(2): 1134-1144.
 - [3] JUNG S M, PARK J S, KIM H W, et al. An MRAS-based diagnosis of open-circuit fault in PWM voltage-source inverters for PM synchronous motor drive systems [J]. IEEE Transactions on Power Electronics, 2013, 28(5): 2514-2526.
 - [4] 唐鸣, 王爱元, 朱振田. 多维度能量熵提取的不同负载下电机轴承故障诊断[J]. 电机与控制应用, 2023, 50(9): 63-69.
- TANG M, WANG A Y, ZHU Z T. Fault diagnosis of motor bearings with different loads based on multi-dimensional energy entropy extraction [J]. Electric Machines & Control Application, 2023, 50(9): 63-

- 69
- [5] HANG J, ZHANG J Z, CHENG M, et al. Detection and discrimination of open-phase fault in permanent magnet synchronous motor drive system [J]. *IEEE Transactions on Power Electronics*, 2015, 31(7): 4697-4709.
- [6] 丁小健,周健,梁超,等. 基于小波降噪和共振解调法的异步电机故障诊断方法[J]. *电机与控制应用*, 2020, 47(9): 106-110.
DING X J, ZHOU J, LIANG C, et al. A fault diagnosis method of asynchronous motor based on wavelet de-noising and resonance demodulation analysis [J]. *Electric Machines & Control Application*, 2020, 47(9): 106-110.
- [7] 王薇,殷勤业,姚博彬,等. 结合快速傅里叶变换和线性调频变换的快速波达方向估计[J]. *西安交通大学学报*, 2019, 53(12): 131-138+160.
WANG W, YIN Q Y, YAO B B, et al. A fast direction-of-arrival estimation algorithm based on fast Fourier transform and chirp transform [J]. *Journal of Xi'an Jiaotong University*, 2019, 53(12): 131-138+160.
- [8] 唐琛,杨剑,任兴,等. 基于小波变换的开关磁阻电机系统功率变换器故障诊断[J]. *电机与控制应用*, 2018, 45(9): 125-131.
TANG C, YANG J, REN X, et al. Fault diagnosis of power converter for switched reluctance motor system based on wavelet transform [J]. *Electric Machines & Control Application*, 2018, 45(9): 125-131.
- [9] 于春雨,张文韬,张庆海,等. 基于EMD-AR与改进宽度学习系统的滚动轴承故障诊断方法[J]. *中国电机工程学报*, 2023, 43(22): 8944-8955.
YU C Y, ZHANG W T, ZHANG Q H, et al. Fault diagnosis method of a rolling bearing on EMD-AR and improved broad learning system [J]. *Proceedings of the CSEE*, 2023, 43(22): 8944-8955.
- [10] GILLES J. Empirical wavelet transform [J]. *IEEE Transactions on Signal Processing*, 2013, 61(16): 3999-4010.
- [11] TRIPATHY R K, DASH S, RATH A, et al. Automated detection of pulmonary diseases from lung sound signals using fixed-boundary-based empirical wavelet transform [J]. *IEEE Sensors Letters*, 2022, 6(5): 1-4.
- [12] 程铁栋,易其文,吴义文,等. 改进 EWT_MPE 模型在矿山微震信号特征提取中的应用[J]. *振动与冲击*, 2021, 40(9): 92-101.
- CHENG T D, YI Q W, WU Y W, et al. Application of improved EWT_MPE model in feature extraction of mine micro-seismic signals [J]. *Journal of Vibration and Shock*, 2021, 40(9): 92-101.
- [13] 张文广,李浩瀚,蒯媛,等. 基于 EWT-DKELM 的控制系統执行器故障诊断方法研究[J]. *机电工程*, 2022, 39(4): 444-451.
ZHANG W G, LI H H, LIAN Y, et al. Fault diagnosis method of control system actuator based on EWT-DKELM [J]. *Mechanical and Electrical Engineering*, 2022, 39(4): 444-451.
- [14] THIRUMALA T, UMARIKAR A C, JAIN T. Estimation of single-phase and three-phase power-quality indices using empirical wavelet transform [J]. *IEEE Transactions on Power Delivery*, 2015, 30(1): 445-454.
- [15] LIU Y L, YUAN D, GONG Z, et al. Adaptive spectral trend based optimized EWT for monitoring the parameters of multiple power quality disturbances [J]. *International Journal of Electrical Power & Energy Systems*, 2023, 146: 108797.
- [16] 杨婧,程乃平,倪淑燕. Welch 算法在弱信号检测中的性能分析[J]. *计算机仿真*, 2020, 37(5): 235-240.
YANG J, CHENG N P, NI S Y. Performance analysis of Welch algorithm in weak signal detection [J]. *Computer Simulation*, 2020, 37(5): 235-240.
- [17] 杨剑锋,乔佩蕊,李永梅,等. 机器学习分类问题及算法研究综述[J]. *统计与决策*, 2019, 35(6): 36-40.
YANG J F, QIAO P R, LI Y M, et al. A review of machine-learning classification and algorithms [J]. *Statistics & Decision*, 2019, 35(6): 36-40.
- [18] 顾崇寅,徐潇源,王梦圆,等. 基于 CatBoost 算法的光伏阵列故障诊断方法[J]. *电力系统自动化*, 2023, 47(2): 105-114.
GU C Y, XU X Y, WANG M Y, et al. CatBoost algorithm based fault diagnosis method for photovoltaic arrays [J]. *Automation of Electric Power Systems*, 2023, 47(2): 105-114.
- [19] ABUALIGAH L, DIABAT A, MIRJALILI S, et al. The arithmetic optimization algorithm [J]. *Computer Methods in Applied Mechanics and Engineering*, 2021, 376: 113609.
- [20] 于聪,汤凯波,李哲,等. 基于 BP 神经网络与改

- 进 DS 证据融合的 GIS 设备局放故障识别[J]. 电气工程学报, 2023, 18(4): 361-369.
- YU C, TANG K B, LI Z, et al. GIS equipment fault identification based on BP neural network and improved DS evidence fusion [J]. Journal of Electrical Engineering, 2023, 18 (4): 361-369.
- [21] 刘可真, 姚岳, 赵现平, 等. 基于样本集成学习和 SO-SVM 的变压器故障诊断[J]. 电机与控制应用, 2023, 50(12): 21-31.
- LIU K Z, YAO Y, ZHAO X P, et al. Transformer fault diagnosis based on sample integration learning and SO-SVM [J]. Electric Machines & Control Application, 2023, 50(12): 21-31.
- [22] 汤占军, 孙润发. 基于多尺度模糊熵和 STOA-SVM 的风机轴承故障诊断[J]. 电机与控制应用, 2021, 48(12): 66-70.
- TANG Z J, SUN R F. Fan bearing fault diagnosis based on multi-scale fuzzy entropy and STOA-SVM [J]. Electric Machines & Control Application, 2021, 48(12): 66-70.
- [23] SUN Z Q, CHEN H C, CHEN Y P. Application of periodogram and Welch based spectral estimation to vortex frequency extraction [C]//2012 Second International Conference on Intelligent System Design and Engineering Application, Sanya, 2012.
- [24] KALRA M, KUMAR S, DAS B. Target detection on the basis of empirical wavelet transform using seismic signal [C]//2019 IEEE Bombay Section Signature Conference, Mumbai, 2019.
- [25] PROKHORENKOVA L, GUSEV G, VOROBAY A, et al. CatBoost: Unbiased boosting with categorical features [J]. arXiv, 2017.
-
- 收稿日期:2024-10-14
收到修改稿日期:2024-11-13
作者简介:
钱轶群(1995-),女,硕士,工程师,研究方向为新型电力系统,9420655542@qq.com;
*通信作者:张孜乐(1999-),男,硕士研究生,研究方向为电力电子在电力系统中的应用,zilezhang@sjtu.edu.com。