

融合多尺度时频域特征的电力电子 电路软故障诊断

贺江涛¹, 姜媛媛^{1,2*}

(1. 安徽理工大学 电气与信息工程学院, 安徽 淮南 232001;

2. 安徽理工大学 环境友好材料与职业健康研究院, 安徽 芜湖 241003)

Fusion of Multi-Scale Time-Frequency Domain Features for Soft Fault Diagnosis of Power Electronic Circuits

HE Jiangtao¹, JIANG Yuanyuan^{1,2*}

(1. School of Electrical and Information Engineering, Anhui University of Science and Technology,
Huainan 232001, China;

2. Institute of Environmentally-Friendly Materials and Occupational Health,
Anhui University of Science and Technology, Wuhu 241003, China)

Abstract: [Objective] Power electronic components in DC motor systems are prone to soft faults under prolonged high-frequency switching operation. To address the problems in soft fault diagnosis, including insufficient fusion of time-frequency domain features and low recognition accuracy, this paper proposes a fault diagnosis method based on the LSTM-CAM-Transformer model by combining the long short-term memory (LSTM) network and the multi-scale time-frequency domain cross-attention mechanism (CAM). [Methods] Firstly, the collected fault signal was preprocessed, and the parameters of the variational mode decomposition (VMD) algorithm were optimized using the Rime optimization algorithm (RIME), which accurately obtained the optimal combination of the decomposition modals K and the penalty factor α , and effectively removed the noise and interference components in the signal. Then, the 5-dimensional time domain parameters and 5-dimensional frequency domain parameters of each intrinsic modal function were extracted, which were used as the feature vectors for fault diagnosis. Finally, a multi-scale time-frequency domain CAM was utilized to strengthen the information interaction between the time domain and frequency domain of the feature vectors, allowing the model to further mine the time-frequency domain features of the signals. [Results] The model proposed in this paper was compared with the other four models to verify its superiority. The experimental results showed that compared with the other four models, the LSTM-CAM-Transformer model proposed in this paper has the fastest convergence

speed, better stability and generalization, and outperforms the other four models in diagnostic accuracy, F1 score, loss value and recall. [Conclusion] The LSTM-CAM-Transformer model proposed in this paper effectively solves the problem of insufficient fusion of time-frequency domain features in the traditional method by integrating the signal preprocessing strategy of RIME-based improved VMD signal preprocessing strategy with the CAM time-frequency feature enhancement mechanism, which provides an efficient and reliable new method for the soft fault diagnosis of the power electronic equipment in the DC motor system.

Key words: variational mode decomposition; DC motor; long short-term memory network; time-frequency domain features; soft fault diagnosis

摘 要: [目的] 直流电机系统中的电力电子器件在长期高频开关工作下易发生软故障。针对软故障诊断中存在的时频域特征融合不足、识别准确率低等问题, 本文将长短期记忆(LSTM)网络和多尺度时频域交叉注意力机制(CAM)相结合, 提出了一种基于 LSTM-CAM-Transformer 模型的故障诊断方法。[方法] 首先, 对采集到的故障信号进行预处理, 采用霜冰优化算法(RIME)对变分模态分解(VMD)参数进行寻优, 精准得到最优分解模态数 K 和惩罚因子 α 的组合, 有效去除信号中的噪声与干扰成分。然后, 提取各个本征模态函数的 5 维时域参数和 5 维频域参数, 将其作为故障诊断的特征向量。最后, 利用多尺度时频域 CAM 增强特征向量在时域和频域之间的信息交

互,使模型进一步挖掘信号的时频域特征。【结果】将本文所提模型和其他四种模型进行对比以验证其优越性。试验结果表明,相较于其他四种模型,本文所提 LSTM-CAM-Transformer 模型收敛速度最快,稳定性和泛化性更强,且在诊断准确率、F1 分数、损失值和召回率上的表现均优于其他四种模型。【结论】本文所提 LSTM-CAM-Transformer 模型通过融合基于 RIME 改进的 VMD 信号预处理策略与 CAM 时频特征增强机制,有效解决了传统方法中时频域特征融合不足的难题,为直流电机系统中电力电子设备的软故障诊断提供了一种高效可靠的新方法。

关键词: 变分模态分解;直流电机;长短期记忆网络;时频域特征;软故障诊断

0 引言

在电机系统中常常需要电力电子电路来驱动电机、控制负载等,电力电子电路的稳定运行直接关系到整个机械系统的可靠性和效率。然而,电力电子电路常常受到内外部多种因素的干扰,容易发生故障,从而影响系统的正常运行。因此,及时准确地诊断故障原因至关重要。电力电子电路的故障类型可分为硬故障与软故障两种。目前已有多种故障诊断方法^[1-2],但大多数侧重于电路的硬故障诊断^[3]。相比之下,软故障虽不会立即导致电路功能丧失,但可能在持续工作中演变为硬故障,进而引发更严重的后果。因此,进行电力电子电路的软故障诊断,对于维持电机系统正常运行至关重要^[4]。

电力电子故障诊断关键在于提取故障信号特征并进行故障分类。在特征提取方面,文献[5]采用基于时变滤波改进的经验模态分解(Empirical Mode Decomposition, EMD)对振动信号进行分解,并采用相关系数法计算本征模态函数(Intrinsic Mode Function, IMF)与原始信号的相关性,但模态混叠和端点效应会影响信号特征的提取。文献[6]采用快速集合经验模态分解(Fast Ensemble Empirical Mode Decomposition, FEEMD)来处理信号,尽管该方法将信号分解为平稳的固有模态分量和残差分量,消除噪声成分并保留了信号的完整性,但是端点效应依然存在。变分模态分解(Variational Mode Decomposition, VMD)是一种高效且稳定的信号分解方法,能够有效解决

模态混叠和端点效应的难题,其较强的鲁棒性和抗干扰能力能够有效反映信号特征^[7]。

在选取信号特征方面,文献[8]分析了滚珠丝杠电机电流的时域信号,虽然取得了不错的效果,但是电路故障信号通常具有非平稳特性(如突变、脉冲噪声等),而只分析时域信号难以有效提取此类特性。文献[9]将振动信号转换到频域,以正常信号振幅平均值作为高频信号的阈值确定频率最高值来获取频谱信号,并将其作为模型的特征参数,但频域参数仅描述信号的频率成分,缺乏时间维度信息,不能反映频率特征随时间的变化。因此,本文使用融合时频域特征作为特征参数,从而多尺度、多维度地描述信号特性,帮助诊断多种复杂故障^[10]。

近年来,深度学习在时间序列分析及计算机视觉等领域取得了重要进展。其中,长短期记忆(Long Short-Term Memory, LSTM)网络因其能够捕捉长期依赖关系,而被广泛应用于各类任务中^[11]。然而,由于序列计算的递归特性,LSTM 网络在处理长序列时容易受到效率和并行化能力的限制。Transformer 模型作为一种全新的序列建模架构模型,摒弃了传统的递归机制,通过自注意力机制(Self-Attention Mechanism, SAM)实现了全局信息的高效捕获^[12]。

综上所述,本文首先基于霜冰优化算法(Rime Optimization Algorithm, RIME)对 VMD 参数进行寻优;然后采用优化后的 VMD 对故障信号进行分解得到 IMF,并提取 IMF 的 10 维时频域参数作为特征向量^[13];最后使用 LSTM-交叉注意力机制(Cross-Attention Mechanism, CAM)-Transformer 模型进行诊断。试验结果验证了本文所提方法的可行性和有效性。

1 理论基础

1.1 VMD

VMD 是一种自适应且非递归的信号分解方法,旨在将复杂的非固定频率信号分解为多个 IMF。该方法通过最小化信号与一组基函数之间的距离来实现,同时通过引入约束条件来确保分解结果的稳定性和物理可解性^[14]。约束变分问题的表达式为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \right\|_2^2 \right\}$$

$$\text{s. t. } f(t) = \sum_k u_k(t) \quad (1)$$

式中: u_k 为第 k 个 IMF 分量; ω_k 为第 k 个 IMF 的中心频率; $\delta(t)$ 为狄拉克函数; $f(t)$ 为原始信号。

Dragomiretskiy 等^[15]通过引入拉格朗日乘子 λ 和二次惩罚项 α 将式(1)转化为无约束的优化问题。扩展后的拉格朗日表达式为

$$L(u_k, \omega_k, \lambda) =$$

$$\alpha \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \right\|_2^2 +$$

$$\left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (2)$$

式中: $L(\cdot)$ 为拉格朗日函数。

式(2)中等式右边的三项分别为梯度函数的 L2 范数、二次惩罚项以及拉格朗日乘子项。其中,第一项主要用于评估带宽,其余两项用于确保重构约束。

VMD 在分解的过程中,分解模态数 K 和惩罚因子 α 两个参数需预先根据经验设置。 K 设置太小,可能无法捕获信号中的所有重要成分,导致信息丢失;而 K 设置较大,虽然可以提高频率分辨率,更好地捕获信号中的细微变化,但可能引入冗余信息,增加计算复杂度,同时可能使得模态之间的正交性和稳定性变差。 α 设置过大,可能会导致模态过于平滑,造成欠拟合;而 α 设置过小,可能导致模态过分灵活,产生过拟合现象^[16]。因此,研究 K 和 α 在不同情况下的自适应优化,对于提升 VMD 的效率和结果具有关键意义。

1.2 RIME

RIME 是一种新型启发式优化算法。该算法模拟霜冰中软霜和硬霜的生长过程,设计了软霜搜索策略与硬霜穿刺机制,并改进了元启发式算法的选择机制,引入了正贪婪选择策略以避免局部最优解^[17]。本文将灰狼优化 (Grey Wolf Optimization, GWO) 算法、鲸鱼优化算法 (Whale Optimization Algorithm, WOA)、麻雀搜索算法 (Sparrow Search Algorithm, SSA)、蜣螂优化 (Dung Beetle Optimization, DBO) 算法^[18]与 RIME 进行对比。RIME 融入冰火双阶段使其更具适应性,

其多尺度扰动也能提高系统的搜索鲁棒性^[19]。霜粒位置更新表达式为

$$R_{mn}^{\text{new}} = R_{\text{best},n} + s_1 \varphi [h(Ub_{mn} - Lb_{mn}) + Lb_{mn}] \cos \theta,$$

$$s_2 < E \quad (3)$$

$$\theta = \frac{\pi t}{10T} \quad (4)$$

$$\varphi = 1 - \left(\frac{\varepsilon t}{T} \right) / \varepsilon \quad (5)$$

$$E = \sqrt{t/T} \quad (6)$$

式中: R_{mn}^{new} 为第 m 个时间的第 n 个霜粒更新后的位置; $R_{\text{best},n}$ 为最优候选解的第 n 个霜粒位置; s_1 和 s_2 为随机数; $\cos \theta$ 为粒子的运动方向; φ 为影响环境的因素; h 为黏附度; Ub_{mn} 、 Lb_{mn} 分别为解空间的上、下界; t 为当前迭代次数; T 为最大迭代次数; ε 为阶跃函数的段数。

1.3 RIME-VMD 提取时频域特征

RIME-VMD 利用 RIME 算法较强的全局搜索能力以及高效的参数更新机制来确认 VMD 的最优参数组合 $[K, \alpha]$ 。在电力电子电路中通常使用 VMD 方法来分解电压信号,并从中提取 IMF 的信息熵和排列熵等作为电路故障的关键特征向量^[20],但对时域参数与频域参数的研究相对较少。因此本文进行相关研究,时频域参数设置及其表达式如表 1 所示。表 1 中, $q_1 \sim q_5$ 为时域参数; $q_6 \sim q_{10}$ 为频域参数; N 为数据点数; x_i 为时域信号数据; $\bar{x}$ 为时域信号数据均值; σ 为时域信号的标准差; f_i 为第 i 个频率分量的频率值; $P(f_i)$ 为 f_i 归一化概率密度; f_c 为第 c 个频率分量的频率值; $X(f_i)$ 为第 i 个频率分量的幅度值; $\text{Re}[X(f)]^2$ 、 $\text{Im}[X(f)]^2$ 分别为余弦分量、正弦分量的强度。将时域参数和频域参数结合使用可以提高故障识别的准确性。

2 模型设计

2.1 LSTM 网络

LSTM 网络利用输入门、遗忘门和输出门来选择性地忘记和保留重要信息^[21]。输入门更新信息,遗忘门选择旧细胞中的一部分信息忘记,输出门控制着下一阶段的信息更新量。这种门控结构避免了多级反向传播后梯度消失和梯度爆炸的问题^[22]。LSTM 网络结构如图 1 所示。

表 1 时频域参数及其表达式

Tab. 1 Time-frequency domain parameters and its formulas

时域参数名称	表达式	频域参数名称	表达式
标准差	$q_1 = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$	频谱熵	$q_6 = -\sum_{i=1}^N P(f_i) \log P(f_i)$
均方根值	$q_2 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	均方根带宽	$q_7 = \sqrt{\frac{\sum_{i=1}^N (f_i - f_c)^2 \cdot X(f_i) ^2}{\sum_{i=1}^N X(f_i) ^2}}$
偏度	$q_3 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\sigma^3}$	中心频率	$q_8 = \frac{\sum_{i=1}^N f_i \cdot X(f_i) ^2}{\sum_{i=1}^N X(f_i) ^2}$
能量	$q_4 = \sum_{i=1}^N x_i^2$	频谱能量	$q_9 = \sum_{i=1}^N X(f_i) ^2$
自相关系数	$q_5 = \frac{\sum_{i=1}^{N-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^N (x_i - \bar{x})^2}$	幅度谱最大值	$q_{10} = \max \{ \sqrt{\text{Re}[X(f)]^2 + \text{Im}[X(f)]^2} \}$




图 1 LSTM 网络结构图

Fig. 1 LSTM network structure diagram

LSTM 网络的相关表达式如式 (7) ~ 式 (12) 所示。

遗忘门 f_t 为

$$f_t = \sigma \{ \mathbf{w}_f [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{j}_f \} \quad (7)$$

输入门 i_t 为

$$i_t = \sigma \{ \mathbf{w}_i [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{j}_i \} \quad (8)$$

当前输入的单元状态 $\tilde{c}_t$ 为

$$\tilde{c}_t = \tanh \{ \mathbf{w}_c [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{j}_c \} \quad (9)$$

当前时刻的单元状态 c_t 为

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (10)$$

输出门 o_t 为

$$o_t = \sigma \{ \mathbf{w}_o [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{j}_o \} \quad (11)$$

最终输出 h_t 为

$$h_t = o_t \circ \tanh(c_t) \quad (12)$$

式中: σ 为 sigmoid 激活函数; $[\mathbf{h}_{t-1}, \mathbf{x}_t]$ 为前一时时刻输出 $\mathbf{h}_{t-1}$ 和当前时刻时输入 $\mathbf{x}_t$ 的组合矩阵; $\mathbf{w}_f, \mathbf{j}_f$ 分别为遗忘门的权重矩阵、偏置矩阵; $\mathbf{w}_i, \mathbf{j}_i$ 分别为输入门的权重矩阵、偏置矩阵; $\mathbf{w}_c, \mathbf{j}_c$ 分别为输出门的权重矩阵、偏置矩阵; $\mathbf{w}_o, \mathbf{j}_o$ 分别为单元状态的权重矩阵、偏置矩阵; c_{t-1} 为上一时刻单元状态; $\circ$ 为 Hadamard 积运算。

2.2 CAM

为了提升模型对时间序列中时域与频域信息的深度挖掘能力, 本文提出了一种结合 CAM 的设计, 以提升时频域间的信息交互能力。通过引入 CAM 和 SAM 动态捕捉序列中各个数据点之间的关系。序列中各个数据点之间的相关性会随着时间序列的变化而变化, 进而为时间序列分类任务提供了有效的判别信息。最终, 模型将通过捕捉这些相关性信息来进行更加精确的预测。图 2 以频域到时域为例展示了 CAM 的结构。图 2 中, 下标 δ 为频域相关信息; 下标 β 为时域相关信息; $\mathbf{X}_\delta, \mathbf{X}_\beta$ 分别为时、频域输入特征; $\mathbf{W}_H, \mathbf{W}_P$ 和 $\mathbf{W}_V$ 为线性变换的权重矩阵; $\mathbf{H}_\delta = \mathbf{X}_\delta \mathbf{W}_H$ 为 $\mathbf{X}_\delta$ 的查询矩阵; $\mathbf{P}_\beta = \mathbf{X}_\beta \mathbf{W}_P, \mathbf{V}_\beta = \mathbf{X}_\beta \mathbf{W}_V$ 分别为 $\mathbf{X}_\beta$ 的值矩阵和键矩阵; d_k 为注意力机制中键的维度; $\mathbf{Y}_{\delta, \beta}$ 为融合了时频域信息的输出。

频域到时域的交叉注意力输出为




图2 CAM 结构

Fig. 2 CAM structure

$$CAM_{\delta-\beta}(X_{\delta}, X_{\beta}) = (H_{\delta} P_{\beta}^T / \sqrt{d_k}) V_{\beta} = [X_{\delta} W_H (X_{\beta} W_P)^T / \sqrt{d_k}] X_{\beta} W_V \quad (13)$$

最终的输出 $Y_{\delta, \beta}$ 通过时域和频域的交叉注意力以及各自注意力模块的结果进行堆叠得到:

$$Y_{\delta, \beta} = CAM_{\delta-\beta}(X_{\delta}, X_{\beta}) + CAM_{\beta-\delta}(X_{\beta}, X_{\delta}) + IMHA(X_{\delta}) + IMHA(X_{\beta}) \quad (14)$$

式中: $IMHA$ 为模态内的分层注意力输出。

交叉注意力融合模型的结构如图3所示。对于时域序列 $x_t \in \mathbf{R}^T$, 先将其划分成长度相等的子序列 $x_{t_l} \in \mathbf{R}^{N_l \times L}$, 其中 T 为序列的总长度, L 为子序列长度, $N_l = T/L$ 为子序列的数量^[23]。对每个子序列使用线性变换将其投影成长度为 D 的向量, 然后加入位置信息, 得到注意力模型的输入。 X_{β} 的计算过程为

$$X_{\beta} = [x_{t_1}^1 E, x_{t_1}^2 E, \dots, x_{t_{N_l}}^{N_l} E] + LE \quad (15)$$

式中: $x_{t_l}^i$ 为第 i 个子序列; E 为线性变换矩阵, $E \in \mathbf{R}^{L \times D}$; LE 为位置信息, $LE \in \mathbf{R}^{(N_l+1) \times D}$ 。

经过交互信息之后, 特征将通过一层自注意力模块进行自适应的特征融合, 随后被输入到Transformer网络中, 进一步进行特征处理和学习。

2.3 Transformer

Transformer 是一种基于 SAM 的深度学习架构^[24]。与传统的循环神经网络不同^[25], Transformer 能够并行处理整个输入序列的数据, 显著提高了模型的计算效率和训练速度, 特别适用于长序列建模任务。Transformer 的核心在于 SAM 和多头注意力机制。SAM 通过计算序列中每个词与其他所有词的相关性, 从而捕捉到重要的上下文关系; 多头注意力机制则在多




图3 交叉注意力融合模型结构

Fig. 3 Structure of the cross-attention fusion model

个注意力头上并行计算, 以获取不同层次和不同维度的特征信息^[26]。Transformer 架构如图4所示。




图4 Transformer 架构图

Fig. 4 Transformer architecture diagram

2.4 LSTM-CAM-Transformer 模型

处理时间序列任务中有短期依赖关系和长期依赖关系两大挑战。由于 LSTM 的强时序依赖关系和 Transformer 处理长序列时对全局依赖的捕捉能力^[27], 因此本文设计了一种基于 LSTM-CAM-Transformer 模型的故障诊断方法。

LSTM-CAM-Transformer 模型架构如图5所示。首先, 将 VMD 提取的时频域参数输入到 LSTM 网络层以提取时序特征, 为后续模块提供

丰富的时序信息。然后,CAM 模块将时域到频域和频域到时域的注意力机制的输出进行拼接,并通过全连接层融合。最后,将 CAM 模块融合的特征传入到 Transformer 编码器,生成各类别的预测概率,再通过 *Softmax* 激活函数将结果转换为故障分类概率分布,实现对输入数据的故障分类^[28]。




图 5 LSTM-CAM-Transformer 模型架构图
Fig. 5 LSTM-CAM-Transformer model architecture diagram

3 电力电子电路软故障诊断参数设定及流程

3.1 电路系统结构与软故障参数设定

本文以 UC3843 控制的 150 W Boost 电路为研究对象。Boost 电路是一种将输入低电压转换为输出高电压的转换电路。该电路的输入电压为 12 V,输出电压为 24 V,额定功率为 150 W,电阻功率为 50 W,负载为 100 Ω,电容 C_1 和 C_5 的容量为 1 000 μF。电路实物图、试验平台和电路原理图分别如图 6~图 8 所示。

在 DC-DC 电路中,电解电容的故障率高达 60%。因此,本文对电容 C_1 和 C_5 的参数衰退故障进行研究。在电容值衰减至标称值的 10% ~ 50% 过程中,定义 16 种故障模式。其中, f_{11} 为




图 6 电路实物图
Fig. 6 Physical diagram of the circuit



图 7 试验平台
Fig. 7 Test platform

正常模式; f_{12} 、 f_{13} 、 f_{14} 和 f_{21} 、 f_{31} 、 f_{41} 分别为 C_1 和 C_5 发生软故障;其余模式为 C_1 与 C_5 均发生软故障。电容故障参数的设定如表 2 所示。

表 2 电容故障参数设定 Tab. 2 Setting of capacitor fault parameters			
故障模式	C_1 、 C_5 电容值/μF	C_1 、 C_5 退化程度/%	故障类别
f_{11}	988,916	0~10,0~10	1
f_{12}	988,887	0~10,10~20	2
f_{13}	988,653	0~10,30~40	3
f_{14}	988,554	0~10,40~50	4
f_{21}	864,916	10~20,0~10	5
f_{22}	864,887	10~20,10~20	6
f_{23}	864,653	10~20,30~40	7
f_{24}	864,554	10~20,40~50	8
f_{31}	655,916	30~40,0~10	9
f_{32}	655,887	30~40,10~20	10
f_{33}	655,653	30~40,30~40	11
f_{34}	655,554	30~40,40~50	12
f_{41}	546,916	40~50,0~10	13
f_{42}	546,887	40~50,10~20	14
f_{43}	546,653	40~50,30~40	15
f_{44}	546,554	40~50,40~50	16




图 8 Boost 电路原理图

Fig. 8 Schematic diagram of Boost circuit

3.2 故障诊断流程

本文选取了 4 个测试点的电压信号作为故障诊断信号,分别为输入电压(1 号测试点)、输出电压(2 号测试点)、MOS 管漏极电压(3 号测试点)以及 MOS 管源极电压(4 号测试点)。在每类电容软故障模式下,针对这 4 个测点分别采集 50 组数据,诊断流程如图 9 所示。




图 9 故障诊断流程

Fig. 9 Fault diagnosis process

4 试验与分析

4.1 试验环境

使用第三章 DC-DC 升压电路的故障数据来验证所提诊断方法的可行性。测试软件环境为 Windows10 64 位, 配备 32 GB RAM, 试验基于 PyTorch 框架在 PyCharm 平台上进行。硬件环境包括一个 AMD Ryzen r5 7500F CPU 和一个 4060

T 8 GB GPU。将 Cross Entropy 作为损失函数, Adam 作为优化器, 学习率设为 0.000 1, 每组试验迭代 100 次数。

4.2 试验分析

4.2.1 优化算法的收敛性对比

本文基于 RIME 对 VMD 的参数 K 、 α 进行寻优, 得到最优参数组合为 $K = 10$ 、 $\alpha = 1\ 500$ 。为了验证 RIME 的优越性, 将其与 GWO、WOA、SSA 和 DBO 4 种优化算法进行对比。所有优化算法的种群大小设置为 30, 最大迭代次数为 100, 适应度函数使用均方误差。5 种算法的适应度曲线如图 10 所示。




图 10 适应度曲线

Fig. 10 Fitness curves

由图 10 可知, 相较于其他 4 种算法, RIME 在

机制设计上融合了“火阶段全局跳出”与“冰阶段局部精调”的双阶段策略,同时通过多尺度扰动机制提升了搜索多样性与稳定性。在 VMD 参数优化中,RIME 不仅表现出更快的收敛速度和更低的均方误差,还具有更高的适应性与迁移能力,显著提升了信号分解质量与后续故障诊断性能。

4.2.2 不同 VMD 参数对比

为了深入探讨不同 VMD 参数对故障诊断结果的影响,本文设计了 $K=6、7、8、9、10$ 和 $\alpha=1\ 500、2\ 000$ 共 10 组对比试验,其中 $K=10,\alpha=1\ 500$ 为 RIME 算法优化 VMD 得到的最优参数组合。试验结果如表 3 所示。

表 3 不同 VMD 参数设置下的故障诊断结果对比

Tab. 3 Comparison of fault diagnosis results with different VMD parameter settings		
参数设置	准确率/%	损失值
$K=6,\alpha=1\ 500$	97.48	0.076 5
$K=6,\alpha=2\ 000$	97.70	0.071 3
$K=7,\alpha=1\ 500$	98.23	0.053 0
$K=7,\alpha=2\ 000$	97.89	0.066 5
$K=8,\alpha=1\ 500$	98.52	0.039 8
$K=8,\alpha=2\ 000$	98.32	0.478 6
$K=9,\alpha=1\ 500$	97.62	0.072 4
$K=9,\alpha=2\ 000$	99.01	0.031 4
$K=10,\alpha=1\ 500$	99.91	0.020 3
$K=10,\alpha=2\ 000$	98.92	0.037 8

由表 3 可知,人为设置的 VMD 参数在准确率和损失值上存在一定的波动性,基于 RIME 优化的 VMD 的故障诊断准确率最高,为 99.91%。试验结果证明了 RIME 优化 VMD 参数的合理性。

4.2.3 消融试验对比

为深入探究 LSTM-CAM-Transformer 模型中各组件的有效性及其对模型性能的贡献,本文设计了一系列消融试验,并选取诊断准确率、F1 分数(F1-Score)、损失值和召回率(Recall)作为评定性能指标,对 LSTM、LSTM-CAM、LSTM-Transformer 以及 LSTM-CAM-Transformer 4 种模型进行对比分析。试验结果如表 4 所示。

由表 4 可知,LSTM 模型的准确率为 54.95%,F1-Score 为 0.463 4,损失值为 1.192 6,Recall 为 0.495 8。引入 CAM 后,LSTM-CAM 模型的准确率

提升至 56.87%,性能有所改善。LSTM-CAM-Transformer 模型的性能最优,其准确率高达 99.91%,F1-Score 为 0.985 1,损失值仅为 0.020 3,Recall 为 0.994 7,该结果验证了本文所设计的多模块融合模型架构的优越性与有效性。

表 4 消融试验结果对比

Tab. 4 Comparison of ablation test results				
模型名称	准确率/%	F1-Score	损失值	Recall
LSTM	54.95	0.463 4	1.192 6	0.495 8
LSTM-CAM	56.87	0.512 2	1.091 8	0.549 5
LSTM-Transformer	98.23	0.965 4	0.037 1	0.974 2
LSTM-CAM-Transformer	99.91	0.985 1	0.020 3	0.994 7

4.2.4 模型对比

为了进一步验证本文所提 LSTM-CAM-Transformer 模型的优越性,将 LSTM、门控循环单元(Gated Recurrent Unit, GRU)、卷积神经网络(Convolutional Neural Networks, CNN)-LSTM、CNN-Transformer、LSTM-Transformer 与本文所提 LSTM-CAM-Transformer 模型进行对比。试验环境保持不变。模型对比结果如图 11 所示。




图 11 模型对比结果

Fig. 11 Model comparison results

由图 11 可知,加入 CAM 模块之后,LSTM-CAM-Transformer 模型比 LSTM-Transformer 模型的收敛速度更快,在第 20 轮训练时准确率已经达到了 99%,此时 LSTM-Transformer 模型才达到 95%。与其他模型相比,LSTM-CAM-Transformer 模型的表现更优。

4.2.5 数据划分对比试验

为了评估不同训练集和验证集划分比例对模型性能的影响,本文将训练集和验证集划分比例分别设置为 1:9、3:7 和 7:3。试验结果如图 12 所示。

由图 12 可知,随着训练集占比的减少,各个模型的准确率都有所下降。GRU 模型从 53.81% 下降到 42.21%,CNN-LSTM 模型从 76.41% 下降到 74.51%,LSTM 模型从 54.95% 下降到 42.49%,CNN-Transformer 模型从 74.55% 下降到 73.21%,而 LSTM-CAM-Transformer 模型准确率从 99.91% 下降到 99.26%,仅下降了 0.7%,其他模型下降均超过 1%。由此可见本文所提 LSTM-CAM-Transformer 模型的稳定性和泛化性更强。




图 12 不同数据划分比例下试验结果对比

Fig. 12 Comparison of test results with different data division ratios

4.2.6 可视化分析

在模型训练中,采用均匀流形逼近与投影 (Uniform Manifold Approximation and Projection, UMAP) 技术将特征数据映射到二维空间,以可视化特征聚类的演化和特征分布。可视化结果如图 13 所示。




图 13 UMAP 特征可视化结果

Fig. 13 UMAP feature visualization results

由图 13 可知,在模型初始阶段,特征图像的分布较为混乱,特征离散程度较高。随着模型对特征的处理,特征的提取和聚合使得分布更加均匀,聚类情况显著改善。结果表明,LSTM-CAM-Transformer 分类模型在故障特征提取方面发挥着重要作用,使得特征表达更加集中充分。

4.2.7 特征提取方法对比

为验证融合时频域参数对电子电路软故障诊断的优越性,基于 Boost 电路软故障试验数据,将原始信号通过 VMD 分解后提取时频域特征,并将其与直接从时域、频域以及通过 VMD 提取的时域、频域特征进行对比分析。试验结果如表 4 所示。

表 4 不同特征提取方法的准确率对比
Tab. 4 Accuracy of different methods for each model

模型名称	准确率/%				
	时域 参数	频域 参数	VMD- 时域	VMD- 频域	VMD- 时频域
GRU	25.12	12.91	41.55	50.41	53.81
LSTM	24.21	13.26	42.79	51.68	54.95
CNN-Transformer	28.12	14.42	73.18	73.61	74.55
CNN-LSTM	28.39	18.72	58.55	70.42	76.41
LSTM-CAM-Transformer	95.31	30.15	99.11	98.92	99.91

由表 4 可知,在各模型中,使用 VMD 提取 IMF 时频域特征得到的故障分类准确率高与其他四种特征提取方法,验证了本文所提融合时频域参数方法的优越性。

5 结语

针对电力电子电路软故障诊断存在的时频域特征融合不足、不易诊断等问题,本文提出了一种基于 LSTM-CAM-Transformer 模型的故障诊断方法,主要结论如下。

(1)通过 RIME 对 VMD 的分解模态数 K 和惩罚因子 α 两个参数进行优化,获得最优的参数组合,避免了人工选择 VMD 参数的局限,从而提高了分解效率和性能。

(2)采用基于 RIME 优化的 VMD 算法对故障信号分解,并提取时频域特征,相较于传统方法,这种方法能更好地融合时频域特征,获得更加全面的故障信息。

(3)所提 LSTM-CAM-Transformer 模型在故障诊断中表现出较高的诊断准确率,相比于 GRU、LSTM、CNN-Transformer 和 CNN-LSTM 等模型有明显优势。试验结果验证了本文方法的可行性,为电机系统中电力电子电路的软故障诊断提供了一种新的思路和解决方案。

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

贺江涛进行了方案设计、试验研究、内容总结与论文撰写,姜媛媛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。

The scheme design, content summary, experiment study and paper writing were carried out by He Jiangtao. The manuscript was reviewed and revised by Jiang Yuanyuan. All authors have read and approved the final version of the manuscript for submission.

参考文献

[1] KHAN S S, WEN H Q. A comprehensive review of fault diagnosis and tolerant control in DC-DC converters for DC microgrids [J]. IEEE Access, 2021, 9: 80100-80127.

[2] ZHANG H, REN H, YI C Z, et al. Ripple-based matrix modeling and cross-coupling effect analysis of double-input DC-DC Boost converters [J]. Science China Technological Sciences, 2022, 65(8): 1878-1890.

[3] 杨静, 崔江, 周凡. 基于电流位置关系的 DSEG 整流器开路故障诊断算法[J]. 电机与控制应用, 2024, 51(6): 44-55.

YANG J, CUI J, ZHOU F. Open-circuit fault diagnosis algorithm of DSEG rectifier based on current position relation [J]. Electric Machines & Control Application, 2024, 51(6): 44-55.

[4] 邱建琪, 沈佳晨, 史涔激, 等. 基于残差卷积网络的多传感器融合永磁同步电机故障诊断[J]. 电机与控制学报, 2024, 28(7): 25-33.

- QIU J Q, SHEN J C, SHI C W, et al. Fault diagnosis of multi-sensor fusion permanent magnet synchronous motor based on residual convolutional neural network [J]. *Electric Machines and Control*, 2024, 28(7): 25-33.
- [5] 臧旭, 张甜瑾, 邵心悦, 等. 基于时变滤波经验模态分解和 SSA-LSSVM 的变压器内部机械故障诊断方法[J]. *电机与控制应用*, 2023, 50(9): 49-56.
- ZANG X, ZHANG T J, SHAO X Y, et al. A transformer internal mechanical fault diagnosis method based on TVFEMD and SSA-LSSVM [J]. *Electric Machines & Control Application*, 2023, 50(9): 49-56.
- [6] 饶鸿江, 何永泰, 彭洁, 等. 基于 FEEMD-NTEO 的风电场送出线路故障定位[J]. *电机与控制应用*, 2024, 51(1): 106-115.
- RAO H J, HE Y T, PENG J, et al. Fault location of wind farm transmission line based on FEEMD-NTEO [J]. *Electric Machines & Control Application*, 2024, 51(1): 106-115.
- [7] LI H, LIU T, WU X, et al. An optimized VMD method and its applications in bearing fault diagnosis [J]. *Measurement*, 2020, 166: 108185.
- [8] 段洪春, 伍星, 王贵勇. 电流时域同步平均残差特征统计的滚珠丝杠故障定位方法研究[J/OL]. *机械科学与技术*, 2023-09-13. <https://doi.org/10.13433/j.cnki.1003-8728.20230282>
- DUAN H C, WU X, WANG G Y. Research on fault localization method of ball screw based on current time-domain synchronous averaging residual feature statistics [J/OL]. *Mechanical Science and Technology for Aerospace Engineering*, 2023-09-13. <https://doi.org/10.13433/j.cnki.1003-8728.20230282>.
- [9] 田野, 陈姚节, 张莉, 等. 频域特征提取联合双流 CNN 的轴承故障诊断方法[J]. *噪声与振动控制*, 2024, 44(4): 167-173+295.
- TIAN Y, CHEN Y J, ZHANG L, et al. Bearing fault diagnosis based on frequency-domain feature extraction and joint dual-stream CNN [J]. *Noise and Vibration Control*, 2024, 44(4): 167-173+295.
- [10] 郭家豪, 欧阳晖, 刘振兴. 基于 APSO-SSVM 的异步电动机转子故障诊断[J]. *电机与控制应用*, 2023, 50(10): 91-99.
- GUO J H, OUYANG H, LIU Z X. Rotor fault diagnosis of asynchronous motor based on APSO-SSVM [J]. *Electric Machines & Control Application*, 2023, 50(10): 91-99.
- [11] 陈文杰, 崔江. 基于 LSTM 的航空发电机整流电路诊断技术[J]. *电机与控制应用*, 2023, 50(4): 85-90
- CHEN W J, CUI J. Diagnosis technology of aero-generator rectifier circuit based on LSTM [J]. *Electric Machines & Control Application*, 2023, 50(4): 85-90.
- [12] 黄星华, 吴天舒, 杨龙玉, 等. 一种面向旋转机械的基于 Transformer 特征提取的域自适应故障诊断[J]. *仪器仪表学报*, 2022, 43(11): 210-218.
- HUANG X H, WU T S, YANG L Y, et al. Domain adaptive fault diagnosis based on transformer feature extraction for rotating machinery [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(11): 210-218.
- [13] 郭昱君, 王爱元, 姚晓东. 基于 BP 神经网络和小波包能量熵的异步电动机故障诊断[J]. *电机与控制应用*, 2022, 49(10): 53-59.
- GUO Y J, WANG A Y, YAO X D. Fault diagnosis of asynchronous motor based on BP neural network and wavelet packet energy analysis [J]. *Electric Machines & Control Application*, 2022, 49(10): 53-59.
- [14] DIBAJ A, ETTEFAGH M M, HASSANNEJAD R, et al. Fine-tuned variational mode decomposition for fault diagnosis of rotary machinery [J]. *Structural Health Monitoring*, 2020, 19(5): 1453-1470.
- [15] DRAGOMIRETSKIY K, ZOISSO K. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [16] 张帅, 丁俊华, 丁雪兴, 等. 基于 IA-VMD 的浮环密封声发射信号降噪与特征提取[J]. *振动与冲击*, 2024, 43(4): 222-229.
- ZHANG S, DING J H, DING X X, et al. Noise reduction and feature extraction of acoustic emission signals from floating ring seals based on IA-VMD [J]. *Journal of Vibration and Shock*, 2024, 43(4): 222-229.
- [17] XUE J K, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization [J]. *The Journal of Supercomputing*, 2023, 79: 7305-7336.
- [18] SU H, ZHAO D, HEIDARI A A, et al. RIME: A

- physics-based optimization [J]. Neurocomputing, 2023, 532: 183-214.
- [19] 刘潇, 沈泽俊, 张立新, 等. 基于梯度加权类激活热力图的卷积神经网络故障诊断模型鲁棒性分析[J]. 科学技术与工程, 2023, 23(17): 7326-7334.
- LIU X, SHEN Z J, ZHANG L X, et al. Robustness analysis of convolutional neural network fault diagnosis model based on gradient-weighted class activation map [J]. Science Technology and Engineering, 2023, 23(17): 7326-7334.
- [20] 陈演斐, 凌志豪, 李志新, 等. 基于参数优化 VMD 和多尺度模糊熵的星-三角接法 FS-PMM 匝间短路故障诊断方法[J]. 电机与控制应用, 2024, 51(6): 31-43.
- CHEN Z F, LING Z H, LI Z X, et al. Fault diagnosis of inter-turn short circuit fault in star-delta connection FS-PMM based on parameter optimization VMD and multi-scale fuzzy entropy [J]. Electric Machines & Control Application, 2024, 51(6): 31-43.
- [21] ZHAO Y M, CHEN Z Y, DONG Y Q, et al. An interpretable LSTM deep learning model predicts the time-dependent swelling behavior in CERCER composite fuels [J]. Materials Today Communications, 2023, 37: 106998.
- [22] WANG D K, ZHAO L Z, HAO T X, et al. Multiple sequence long and short memory network model for corner gas concentration prediction on coal mine workings [J]. ACS Omega, 2022, 7(42): 37980-37987.
- [23] 刘可真, 梁玉平, 代莹皓, 等. 基于 CNN-ISSA-GRU 模型的短期负荷预测方法[J]. 电机与控制应用, 2022, 49(8): 79-86.
- LIU K Z, LIANG Y P, DAI Y H, et al. Short-term load forecasting method based on CNN-ISSA-GRU model [J]. Electric Machines & Control Application, 2022, 49(8): 79-86.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//31st Conference on Neural Information Processing Systems, Long Beach, 2017.
- [25] ARUNKUMAR K E, KALAGA D V, KUMAR CH M S, et al. Forecasting of COVID-19 using deep layer recurrent neural networks (RNNs) with gated recurrent units (GRUs) and long short-term memory (LSTM) cells [J]. Chaos Solitons and Fractals, 2021, 146: 110861.
- [26] 王春雷, 张建林, 李美惠, 等. 结合卷积 Transformer 的目标跟踪算法[J]. 计算机工程, 2023, 49(4): 281-288+296.
- WANG C L, ZHANG J L, LI M H, et al. Object tracking algorithm combining convolution and transformer [J]. Computer Engineering, 2023, 49(4): 281-288+296.
- [27] KHALIL M M Y, WANG Q X, CHEN B, et al. Cross-modality representation learning from transformer for hashtag prediction [J]. Journal of Big Data, 2023, 10(1): 148.
- [28] 赵金涛, 郭凯凯, 高雄, 等. 基于电流矢量分析的 PMSM 系统开路故障诊断方法[J]. 电机与控制应用, 2025, 52(1): 64-73.
- ZHAO J T, GUO K K, GAO X, et al. Open-circuit fault diagnosis method for PMSM systems based on current vector analysis [J]. Electric Machines & Control Application, 2025, 52(1): 64-73.

收稿日期:2025-03-08

收到修改稿日期:2025-05-12

作者简介:

贺江涛(2001-),男,硕士研究生,研究方向为电力电子系统故障诊断,1072233935@qq.com;

*通信作者:姜媛媛(1982-),女,博士,教授,研究方向为电力电子系统故障诊断,jyyLL672@163.com。