

DOI: 10.19783/j.cnki.pspc.250250

基于多模态三支路异构融合的逆变器开路故障诊断研究

刘伟¹, 王澜¹, 易冠群²

(1. 东北石油大学电气信息工程学院, 黑龙江 大庆 163318; 2. 国网信息通信产业集团有限公司, 北京 102211)

摘要: 针对逆变器开路故障, 提出了一种基于 GAF-RP-LSTM-Transformer 的三支路异构融合的诊断方法。首先, 采用互补集合经验模态分解与相位随机技术(complementary ensemble empirical mode decomposition with phase randomization technique, CEEMD-PRT)算法处理逆变器输出电流信号, 提取局部故障特征。并通过格拉姆角场(Gramian angular field, GAF)和递归图(recurrence plot, RP)变换将一维时序信号转换为二维图像, 充分利用时序信号中的全局趋势特征(GAF)和非线性动力学特征(RP)。为弥补传统一维特征提取在空间相关性表征上的不足, 利用长短期记忆(long short-term memory, LSTM)网络提取时序数据的动态特征, 利用 GAF-RP-Transformer 双支路模型提取二维图片的空间特征。为实现一维时序特征与二维空间特征间多维信息的融合, 提出了全新的异构特征融合模块, 通过多模态图像的互补性, 增强模型对故障细微差异的捕捉能力。实验结果表明, 所提模型在测试集上的分类准确率达到 99.3%, 显著优于其他对比模型, 并能在不同噪声干扰下保持较高的诊断准确性。特别是在 30 dB 和 20 dB 噪声下, 准确率下降幅度较小, 表明该方法具有较强的鲁棒性。仿真验证了 GAF-RP-LSTM-Transformer 三支路异构融合模型在逆变器故障诊断中的有效性与优越性。

关键词: 逆变器开路故障诊断; 多模态三支路异构融合模型; CEEMD-PRT 算法; 异构特征融合

Research on open-circuit fault diagnosis of inverters based on multi-modal three-branch heterogeneous fusion

LIU Wei¹, WANG Lan¹, YI Guanqun²

(1. School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China;

2. State Grid Information & Telecommunication Group Co., Ltd., Beijing 102211, China)

Abstract: A three-branch heterogeneous fusion diagnostic method based on GAF-RP-LSTM-Transformer is proposed for inverter open-circuit faults. First, the output current signals are processed to extract localized fault characteristics through complementary ensemble empirical mode decomposition and phase randomization techniques (CEEMD-PRT). Then, the one-dimensional temporal signals are converted into two-dimensional images via Gramian angular field (GAF) and recurrence plot (RP) transformations, effectively leveraging global trend features (GAF) and nonlinear dynamic characteristics (RP) embedded in the temporal sequences. To overcome the limitations of conventional one-dimensional feature extraction in spatial correlation representation, a long short-term memory (LSTM) network is employed to capture dynamic temporal features, while a dual-branch GAF-RP-Transformer model extracts spatial features from the two-dimensional images. To enable multidimensional fusion of temporal and spatial characteristics, a novel heterogeneous feature fusion module is proposed, leveraging the complementarity of multi-modal images to enhance the model's ability to capture subtle fault differences. Experimental results demonstrate that the proposed model achieves a classification accuracy of 99.3% on the test sets, significantly outperforming comparative models while maintaining high diagnostic accuracy under varying noise conditions. In particular, under 30 dB and 20 dB noise levels, the accuracy degradation remains small, indicating strong robustness. Simulation results validate the effectiveness and superiority of the GAF-RP-LSTM-Transformer three-branch heterogeneous fusion framework in inverter fault diagnosis.

This work is supported by the National Natural Science Foundation of China (No. 62473096).

Key words: inverter open-circuit fault diagnosis; multi-modal three-branch heterogeneous fusion model; CEEMD-PRT algorithm; heterogeneous feature fusion

基金项目: 国家自然科学基金项目资助(62473096)

0 引言

在“双碳”战略驱动下，电力系统逐步向可再生能源转型，风电、光伏装机占比显著提升。逆变器作为新能源并网核心设备，其运行状态直接影响电网暂态稳定性与动态调节能力^[1-3]。逆变器主要故障包括开路故障与短路故障：开路故障引发输出电流畸变及二次故障风险，短路故障导致过电流与设备损坏。当前短路故障的检测与熔断技术较为成熟，而开路故障因隐蔽性强，诊断技术仍需深化研究^[4]。绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)器件因长期承受电热应力，成为逆变器故障高发部件。实时监测其运行状态可早期识别故障隐患，及时采取保护措施，从而提升系统可靠性^[5-7]。因此研究逆变器开路故障检测技术，对保障新能源并网安全与电力系统稳定运行具有重要意义。

在逆变器故障诊断领域，主要技术方法包括信号处理、机器学习及深度学习等^[8-10]。近年来，深度学习逐渐成为研究热点：文献[11]提出基于自适应正则化系数的卷积神经网络(convolutional neural network, CNN)实现故障分类，通过分析逆变器拓扑结构构建模型并优化参数；文献[12]融合遗传算法(genetic algorithm, GA)、蚁群算法(ant colony optimization, ACO)与反向传播(back propagation, BP)网络，结合快速傅里叶变换(fast Fourier transform, FFT)提取电流特征；文献[13]采用小波包分析与量子神经网络处理桥臂电压信号。上述方法均基于一维信号特征提取，存在模态单一、动态-空间特征融合不足的局限。

为提升特征空间表达能力，部分研究尝试引入图像化处理：文献[14]通过经验模态分解(empirical mode decomposition, EMD)将一维信号转换为二维形式，结合二维卷积神经网络(two dimensional convolutional neural network, 2D-CNN)进行诊断；文献[15]利用 FFT 预处理后的相电流数据输入 2D-CNN 提取特征。然而，现有方法仍局限于单一模态，未能有效融合时序动态特征与多模态图像的互补优势，导致复杂故障模式表征能力不足。

近年来，以注意力机制为核心的 Transformer 模型^[16]因其长距离依赖捕捉能力，在自然语言处理(natural language processing, NLP)、语音识别及计算机视觉(computer vision, CV)领域^[17-19]表现突出。多支路并行模型作为新兴架构，可通过并行处理多源信息提升计算效率。但基于 Transformer 与多支路异构模型的协同设计在故障诊断领域尚未充分探索。

本文提出 GAF-RP-LSTM-Transformer 三支路异构融合模型。将时序动态特征(LSTM 支路)、全局趋势特征(GAF-Transformer支路)与非线性动力学特征(RP-Transformer 支路)深度融合，弥补单一模态的信息偏差。不同支路提取的时序与空间特征如果直接拼接进行特征融合，可能会因维度不匹配或序列信息丢失而导致诊断模型的性能下降。在此基础上，本文提出一种全新的异构特征融合模块，通过对不同模态的特征进行 1×1 卷积相乘处理实现跨模态交互，并结合自注意力机制动态分配权重，筛选关键特征。这种融合方式突破了传统方法的限制，全面捕捉故障关键信息，能有效提升诊断的准确性与鲁棒性。为逆变器故障诊断提供了更高精度的解决方案。

1 逆变器开路故障类型分析

1.1 并网逆变器的工作原理

本文以电压源型逆变器作为研究对象，采用三相桥式拓扑结构，其中包含 6 个 IGBT 开关器件，通过 LCL 型滤波器对逆变器输出的交流电流进行滤波处理，使输出的正弦波波形更加平稳光滑，LCL 型滤波器具有滤波效果良好、体积小、损耗小以及适应性广等特点^[20]。三相并网逆变器主电路的拓扑结构图如图 1 所示。

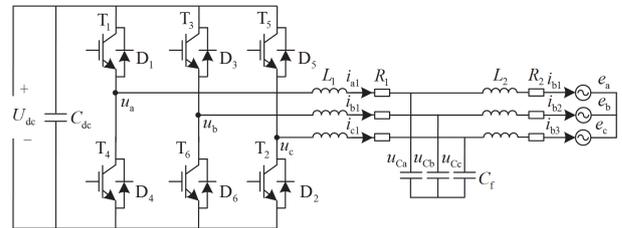


图 1 三相逆变器拓扑结构原理图

Fig. 1 Schematic diagram of three-phase inverter topology

1.2 逆变器故障类型分析

根据电压源型三相两电平逆变器拓扑结构特征，其 IGBT 模块、续流二极管及驱动电路构成主要故障源，这些组件的失效可能引发连锁反应，导致系统稳定性显著降低。在功率器件短路情况下，可将其切换至开路故障模式，考虑到在实际工作中，3 个或更多开关管同时发生故障的概率较低，因此本研究重点分析单管或双管开路故障。

逆变器工作状态分为正常状态、单个 IGBT 开路、同一相的两个 IGBT 开路、同半桥的两个 IGBT 开路及交叉的两个 IGBT 开路 5 类。表 1 系统化归纳了逆变器的 5 类典型故障类型，为逆变器故障机理分析与诊断提供明确分类依据。

表 1 逆变器故障类型

Table 1 Fault types of inverter

故障编号	故障状态	故障开关管	故障标签
G1	正常状态	无 IGBT 开路	1
G2	单个 IGBT 开路	IGBT1	2
		IGBT2	3
		IGBT3	4
		IGBT4	5
		IGBT5	6
		IGBT6	7
G3	同一相的	IGBT1, IGBT4	8
	两个 IGBT 开路	IGBT3, IGBT6	9
G4	同半桥的两个 IGBT 开路	IGBT2, IGBT5	10
		IGBT1, IGBT3	11
		IGBT1, IGBT5	12
		IGBT3, IGBT5	13
		IGBT4, IGBT6	14
		IGBT2, IGBT4	15
		IGBT2, IGBT6	16
		IGBT1, IGBT6	17
G5	交叉的两个 IGBT 开路	IGBT3, IGBT4	19
	IGBT 开路	IGBT4, IGBT5	20
		IGBT2, IGBT3	21
		IGBT5, IGBT6	22

2 基于多模态三支路异构融合的逆变器故障诊断方法

2.1 基于 CEEMD-PRT 算法的数据处理

对原始电流信号进行互补集合经验模态分解 (complementary ensemble empirical mode decomposition, CEEMD), 并结合相位随机化技术(phase randomization technique, PRT)进行处理。CEEMD-PRT 算法通过自适应分解机制, 将非平稳时序信号转化为本征模态函数(intrinsic mode function, IMF), 提取局部故障特征, 通过相关系数法计算每个 IMF 与相位随机化信号之间的皮尔逊相关系数, 量化其相关性。并筛选出相关系数高的分量进行信号重构, 最后生成一维时序数据集, 结果如图 2 所示。皮尔逊相关系数计算方法如下。

用 ρ_k 来表示 IMF 分量 $I_k(t)$ 与相位随机化信号 $\hat{x}(t)$ 的相关系数, 其计算公式如式(1)所示。

$$\rho_a = \frac{\sum_{t=1}^T (I_a(t) - \bar{I}_a)(\hat{x}(t) - \bar{x})}{\sqrt{\sum_{t=1}^T (I_a(t) - \bar{I}_a)^2} \cdot \sqrt{\sum_{t=1}^T (\hat{x}(t) - \bar{x})^2}} \quad (1)$$

式中: T 为信号长度; \bar{x} 为 $\hat{x}(t)$ 的平均值; \bar{I}_a 为 $I_a(t)$ 的平均值。将 $|\rho_a|$ 从大到小进行排序, 筛选相关系数大于 0.2 的前 a 个 IMF 分量。

将筛选后的 IMF 分量进行叠加, 得到重构信号 $\hat{X}(t)$, 如式(2)所示。

$$\hat{X}(t) = \sum_{k \in S} I_k(t) \quad (2)$$

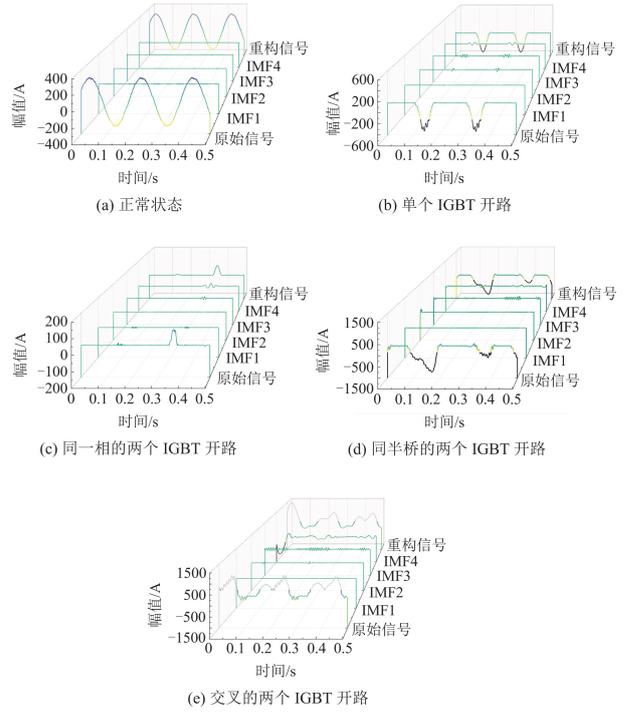


图 2 CEEMD-PRT 分解图

Fig. 2 CEEMD-PRT decomposition diagram

2.2 格拉姆角场变换

格拉姆角场(Gramian angular field, GAF)利用极坐标矩阵将一维序列数据转换为二维图像, 保持故障电流信号与格拉姆矩阵中时间序列的相关性, 其中每个元素实际上是角度的三角函数值。

GAF 图像的生成流程如下: 首先, 对原始时域信号进行归一化处理, 将其压缩到区间[-1,1]内; 然后, 将归一化后的数据从笛卡尔坐标系转换为极坐标系, 在此过程中将时间序列信息嵌入到坐标点中; 接着, 使用余弦函数 $f(x) = \cos(x)$ 分析转换后的数据之间的时序相关性; 最后, 生成 $m \times m$ 维的 GAF 矩阵, 其中 m 为数据中的采样点数, 进而形成特征更加集中的二维图像^[21]。

1) 缩放转换。通过最小-最大定标器将原始的一维时间序列 $X = \{X_1, X_2, \dots, X_n\}$ 归一化到在区间上的时间序列 \tilde{X}_i , $\tilde{X}_i = \{\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_n\}$ 。缩放公式为

$$\tilde{x}_i = \frac{[x_i - \max(X)] + [x_i - \min(X)]}{\max(X) - \min(X)} \quad (3)$$

式中: x_i 表示原始序列中的第 i 个数据点; \tilde{x}_i 表示归一化后的第 i 个数据点。一维时间序列由 n 个跨度相等的时间戳 t 和对应的测量数据 x 组成。

2) 极坐标转换。将缩放后的一维时间序列 \tilde{X}_i 的值映射为角度 θ_i , 时间映射为 r_i , 转换后得到在极坐标上的时间序列, 如式(4)所示。

$$\begin{cases} \theta_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X}_i \\ r_i = \frac{t_i}{A}, t_i \in A \end{cases} \quad (4)$$

式中: A 是用作极坐标空间的正则化因子的常数。

3) 生成格拉姆矩阵: 一维时间序列经上述转换后, 通过计算每两点之间的三角弦函数之和的三角函数值或者三角弦函数之差的三角函数值, 利用角度透视来识别不同时间间隔之间的时间相关性。基于三角弦函数之和的格拉姆矩阵为 \mathbf{G}_{GASF} , 基于三角弦函数之差的格拉姆矩阵为 \mathbf{G}_{GADF} , 其公式分别为

$$\mathbf{G}_{\text{GASF}} = \begin{bmatrix} \cos(\theta_1 + \theta_1) & \cdots & \cos(\theta_1 + \theta_n) \\ \cos(\theta_2 + \theta_1) & \cdots & \cos(\theta_2 + \theta_n) \\ \vdots & & \vdots \\ \cos(\theta_n + \theta_1) & \cdots & \cos(\theta_n + \theta_n) \end{bmatrix} = \quad (5)$$

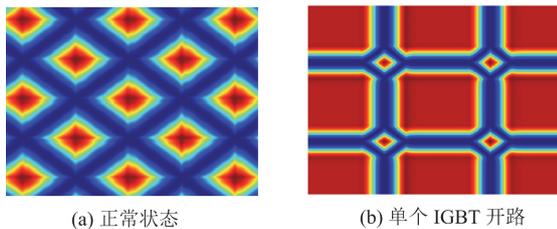
$$\mathbf{G}_{\text{GADF}} = \begin{bmatrix} \sin(\theta_1 - \theta_1) & \cdots & \sin(\theta_1 - \theta_n) \\ \sin(\theta_2 - \theta_1) & \cdots & \sin(\theta_2 - \theta_n) \\ \vdots & & \vdots \\ \sin(\theta_n - \theta_1) & \cdots & \sin(\theta_n - \theta_n) \end{bmatrix} = \quad (6)$$

式中: \tilde{X} 为经过归一化处理后的时间序列数据; \mathbf{I} 为单位行向量。格拉姆矩阵对一维时间序列的时间信息进行编码, 这样信号的时间依赖性可以得到保留。

根据表 1, 不同故障类型的 GAF 变换如图 3 所示, 该变换将时间相关性编码为二维空间相位关系。

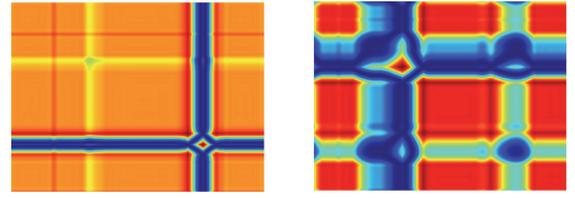
2.3 递归变换

递归图(recurrence plot, RP)作为非线性动力学分析工具, 其原理是基于相空间重构理论, 采用相空间重构技术将时序数据转换至高维空间, 实现系



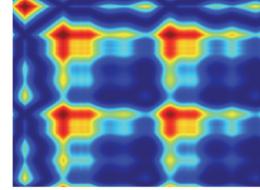
(a) 正常状态

(b) 单个 IGBT 开路



(c) 同一相的两个 IGBT 开路

(d) 同半桥的两个 IGBT 开路



(e) 交叉的两个 IGBT 开路

图 3 GAF 变换图

Fig. 3 GAF transformation diagram

统递归特性与动态演变的可视化表征。该方法通过计算重构轨迹中点与点之间的相似性, 刻画系统的周期性与稳定性, 实现对时间序列复杂性的特征增强和可视化分析^[22]。

1) 归一化处理。首先对给定的一维时域信号进行归一化操作, 通常是将其转换到 $[-1, 1]$ 区间。在逆变器故障诊断中, 通过式(3)实现归一化。

2) 相空间重构。依据嵌入理论选取合适的延迟时间 τ 和嵌入维度 m , 进行相空间重构。重构后的向量表达式为

$$\mathbf{X}_i = [\bar{x}_i, \bar{x}_{i+\tau}, \dots, \bar{x}_{i+(m-1)\tau}], i = 1, 2, \dots, N \quad (7)$$

$$N = n - (m-1)\tau \quad (8)$$

3) 计算距离与生成递归矩阵: 计算重构后相空间内两点 X_i 和 X_j 的距离 D_{ij} , 如式(9)所示。

$$D_{ij} = \|X_i - X_j\| \quad (9)$$

接着选取合适阈值 ε , 得到递归矩阵 $\mathbf{R}(i, j)$, 如式(10)所示。

$$\mathbf{R}(i, j) = H(\varepsilon - D_{ij}) \quad (10)$$

其中为 $H(\cdot)$ 为 Heaviside 函数, 即

$$H(r) = \begin{cases} 1, r > 0 \\ 0, r \leq 0 \end{cases} \quad (11)$$

4) 绘制递归图

以 i 为横坐标, j 为纵坐标绘制 $\mathbf{R}(i, j)$, 形成递归图。其值为 0 或 1, 用黑白图形象刻画时间序列, $\mathbf{R}(i, j) = 0$ 时坐标 (i, j) 显示为白点, $\mathbf{R}(i, j) = 1$ 时坐标 (i, j) 显示为黑点。根据表 1, 不同故障类型的 RP 变换如图 4 所示, 通过点密度与分布模式反映系统稳定性。

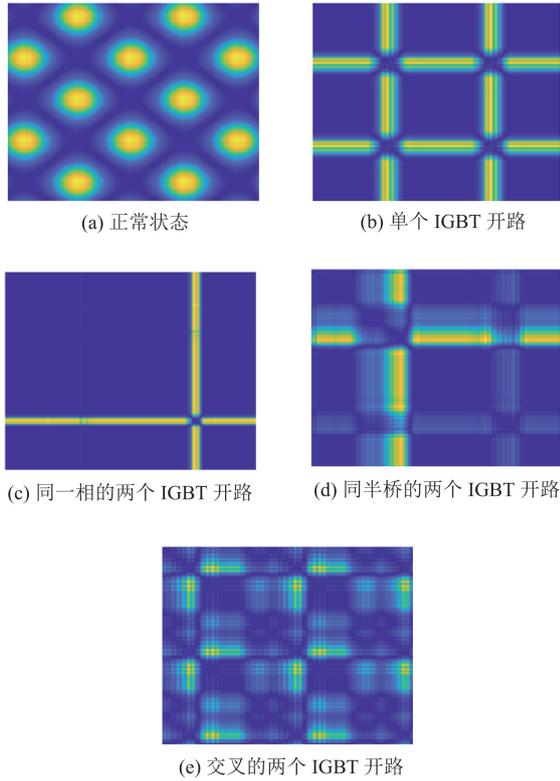


图 4 RP 变换图

Fig. 4 RP Transformation diagram

2.4 基于 GAF-RP-LSTM-Transformer 的三支路异构融合模型

为了优化模型的特征提取能力, 本文提出了 GAF-RP-LSTM-Transformer 三支路异构融合模型, 该模型通过 3 种不同的输入方式提取到 3 种不同模态的特征信息, 使其在保留二维网络更强的空间特征提取能力的同时, 能有效地提取一维时序信息, 增强特征的表达能力, 使提取到的特征更加丰富和全面。通过异构特征融合模块对不同模态的特征信息进行深度融合, 可以有效提高诊断模型分类的准确率。该方法在深层特征提取的同时, 还能避免梯度消失和梯度爆炸的问题, 进一步提升了三相逆变器故障诊断的稳定性和泛化能力。基于 GAF-RP-LSTM-Transformer 三支路异构融合的逆变器故障诊断模型如图 5 所示。

1D-LSTM 支路通过 LSTM 网络提取一维时序波形特征, 充分捕捉时序数据中的动态变化信息, 提升了特征提取的效果。LSTM 网络结构如图 6 所示。

1D-LSTM 支路利用 LSTM 提取时序特征。假设输入序列为 $X = \{x_1, x_2, \dots, x_t\}$, 其中 $x_t \in \mathbf{R}^{d_{in}}$; \mathbf{R} 表示实数集, d_{in} 表示输入维度, LSTM 的公式如下所述^[23-24]。

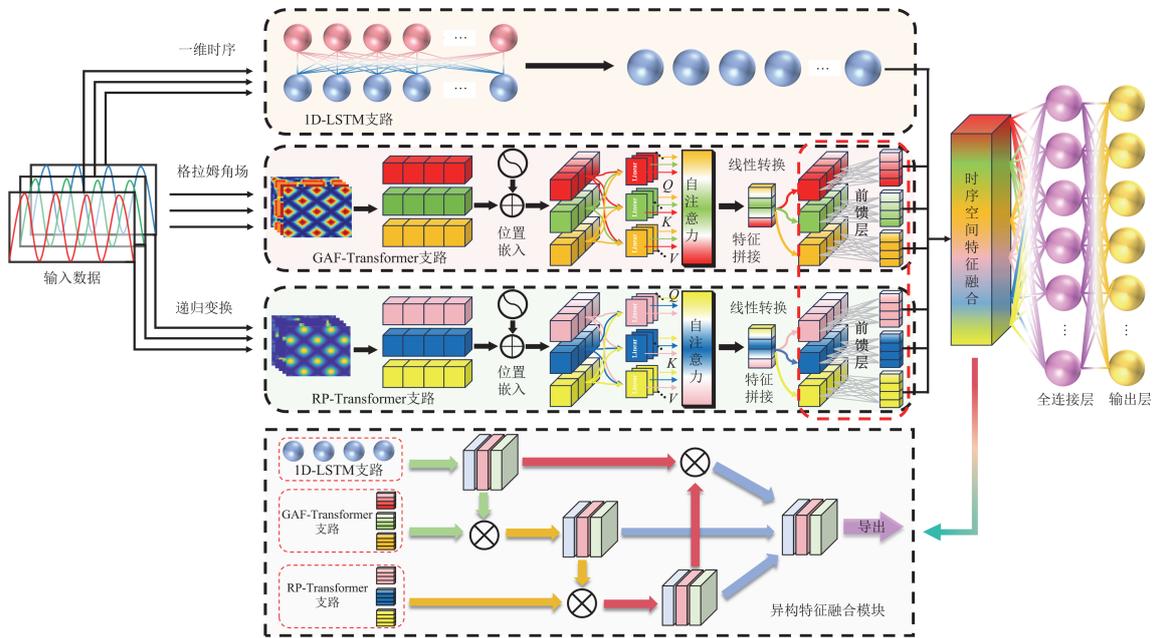


图 5 GAF-RP-LSTM-Transformer 三支路异构融合故障诊断模型

Fig. 5 Fault diagnosis model of GAF-RP-LSTM-Transformer triple-branch heterogeneous fusion

1) 记忆单元

LSTM 引入了记忆单元的概念, 用一个单独的状态 C_t 来传递和存储信息, 其允许 LSTM 更灵活地

保留和遗忘信息。记忆单元的更新计算式为

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (12)$$

式中: C_t 表示当前细胞状态; f_t 表示遗忘门的输出

结果； C_{t-1} 表示前一个细胞状态； i_t 表示输入门的输出结果； \tilde{C}_t 表示将当前细胞的输入信号 X_t 和前一个细胞的输出 H_{t-1} 的状态信息进行整合的状态量。

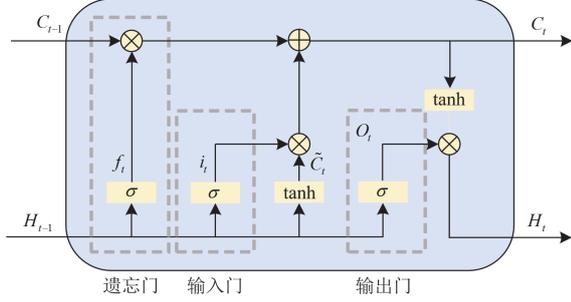


图 6 LSTM 神经网络结构示意图

Fig. 6 Schematic diagram of LSTM neural network structure

2) 遗忘门

遗忘门的主要作用是控制是否要从记忆单元中遗忘信息。输入信号 X_t 与上一个细胞的输出 H_{t-1} 相结合，再经过 sigmoid 的非线性处理，得到遗忘门的输出 f_t 。遗忘门的更新公式为

$$f_t = \sigma(W_f \cdot [H_{t-1}, x_t] + b_f) \quad (13)$$

式中： σ 表示 sigmoid 激活函数； W_f 表示遗忘门的权重矩阵； b_f 表示偏置向量。

3) 输入门

输入门的主要作用是控制新输入信息对记忆单元的更新。输入门的更新计算式为

$$i_t = \sigma(W_i \cdot [H_{t-1}, x_t] + b_i) \quad (14)$$

$$\tilde{C}_t = \tanh(W_c \cdot [H_{t-1}, x_t] + b_c) \quad (15)$$

式中： W_i 表示输入门的权重矩阵； W_c 表示候选向量的权重矩阵； b_i 、 b_c 均表示偏置向量； \tanh 表示双曲正切激活函数。

4) 输出门

输出门的作用是控制从记忆单元输出到隐藏状态的信息。输出门的更新计算公式为

$$o_t = \sigma(W_o \cdot [H_{t-1}, x_t] + b_o) \quad (16)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (17)$$

式中： o_t 表示输出门的输出结果； W_o 表示候选向量的权重矩阵； b_o 表示偏置向量； h_t 表示隐藏层输出值。

GAF-Transformer 支路利用 Transformer 结构提取全局特征，将一维时序波形转换为二维 GAF 图像，实现了全局趋势的捕捉，提供了丰富的角度信息。RP-Transformer 支路同样采用 Transformer 结构，该支路将一维时序波形转换为二维 RP 图像，揭示出时间序列中的非线性动力学特征，增强了故障识别的准确性。GAF-RP-Transformer 模型结构图如图

7 所示。

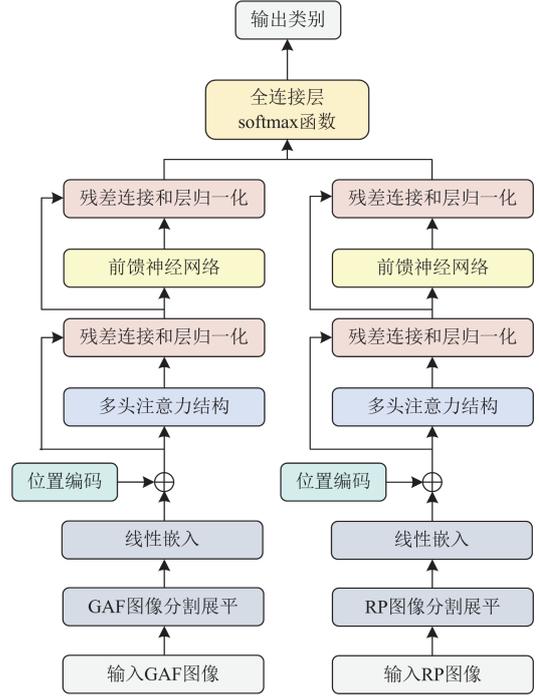


图 7 GAF-RP-Transformer 模型结构图

Fig. 7 Schematic diagram of GAF-RP-Transformer model structure

将两种图片分别输入到 Transformer 中进行特征提取，首先嵌入特征向量，并与其相对位置关系进行叠加，通过线性变换标记特征在时间维度上的先后顺序，并利用并行的自注意力计算，得到多个参数独立的“表示子空间”，扩展了模型专注于不同特征的能力。

假设输入特征为 $F \in \mathbf{R}^{T \times d_m}$ ，自注意力机制的计算公式为

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (18)$$

式中： Q 、 K 、 $V \in \mathbf{R}^{T \times d_k}$ 分别表示查询、键和值； d_k 表示键的维度。多头注意力的输出为

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) W^O \quad (19)$$

式中： $\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$ ， W_i^Q 、 W_i^K 、 $W_i^V \in \mathbf{R}^{d_k \times d_m}$ 是投影矩阵； $W^O \in \mathbf{R}^{hd_k \times d}$ 是输出投影矩阵， d_o 是单支路输出特征维度。

不同支路提取的时序与空间特征如果直接拼接进行特征融合，可能会因维度不匹配或序列信息丢失而导致诊断模型的性能下降。在此基础上，本文提出一种全新的异构特征融合模块，通过对不同模

态的特征进行 1×1 卷积相乘处理, 实现一维特征与二维特征间多维信息的融合, 并且在保留序列信息的同时增强全局与局部特征的互补性。异构特征融合模块如图8所示。

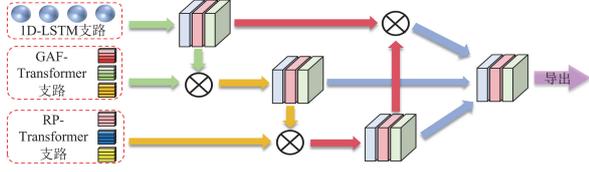


图8 异构特征融合模块

Fig. 8 Heterogeneous feature fusion module

在特征融合阶段, 由于 1×1 卷积不改变空间维度, 在减少计算量的同时可以提取跨模态的关联特征, 所以将1D-LSTM、GAF-Transformer和RP-Transformer这3个支路的特征信号分别进行卷积相乘, 使其两两交互融合, 最后再将3个支路输出的结果进行整体 1×1 卷积, 其步骤如下所述。

1) 1D-LSTM支路的一维特征经一维卷积后与GAF-Transformer支路的二维空间特征相乘, 实现时序信息与全局空间特征的加权融合, 将时序信息嵌入到GAF的全局趋势特征中, 强化时序与空间的关联。

$$F_{IG} = C_{1D}(F_{ID}, F_{GAF}; W_{IG}, b_{IG}) \quad (20)$$

式中: F_{IG} 表示LSTM与GAF支路交互特征; C_{1D} 表示一维卷积操作; F_{ID} 表示1D-LSTM支路的输出特征, $F_{ID} \in \mathbf{R}^{T \times d_h}$, d_h 是LSTM隐藏层的维度; F_{GAF} 表示GAF-Transformer支路的输出特征, $F_{GAF} \in \mathbf{R}^{T \times d_o}$; W_{IG} 是卷积核, $W_{IG} \in \mathbf{R}^{k \times d_h \times d_o}$, k 是卷积核大小; b_{IG} 是偏置项, $b_{IG} \in \mathbf{R}^{d_o}$ 。

2) GAF-Transformer支路的二维特征卷积后与RP-Transformer支路的二维特征相乘, 融合全局趋势(GAF)与局部非线性模式(RP), 捕捉复杂的时序与空间的动态。

$$F_{GR} = C_{1D}(F_{GAF}, F_{RP}; W_{GR}, b_{GR}) \quad (21)$$

式中: F_{GR} 表示GAF与RP支路交互特征; F_{RP} 表示RP-Transformer支路的输出特征, $F_{RP} \in \mathbf{R}^{T \times d_o}$; W_{GR} 是卷积核, $W_{GR} \in \mathbf{R}^{k \times d_h \times d_o}$; b_{GR} 是偏置项, $b_{GR} \in \mathbf{R}^{d_o}$ 。

3) RP-Transformer支路的二维特征卷积后与1D-LSTM支路的一维特征相乘, 将局部非线性特征反馈到时序特征中, 增强模型对突变或周期性事件的敏感性。

$$F_{IR} = C_{1D}(F_{ID}, F_{RP}; W_{IR}, b_{IR}) \quad (22)$$

式中: F_{IR} 表示LSTM与RP支路的交互特征; W_{IR} 是卷积核, $W_{IR} \in \mathbf{R}^{k \times d_h \times d_o}$; b_{IR} 是偏置项, $b_{IR} \in \mathbf{R}^{d_o}$ 。

4) 最后使用 1×1 卷积对拼接后的特征进行通道整合和降维, 将多支路特征映射到统一表征空间, 避免维度爆炸。

$$F_C = \text{Concat}(F_{IG}, F_{IR}, F_{GR}) \in \mathbf{R}^{T \times 3d_o} \sqrt{b^2 - 4ac} \quad (23)$$

$$F_f = C_{1D}(F_C; W_f, b_f) \in \mathbf{R}^{T \times d_f} \quad (24)$$

式中: F_C 表示多模态特征拼接结果; F_f 表示最终融合特征; W_f 是卷积核, $W_f \in \mathbf{R}^{k \times 3d_o \times d_f}$, d_f 是最终输出的特征维度; b_f 是偏置项, $b_f \in \mathbf{R}^{d_f}$ 。

通过充分利用一维和二维特征的互补性, 不仅提高了模型对输入数据的表达能力, 还促进了不同特征之间的信息传递和协同作用, 为逆变器开路故障诊断带来了更为丰富和多样化的特征表示, 能够进一步提高模型分类准确性和泛化能力。

图5中的异构图像特征融合模块在以下方面实现了突破:

1) 通过卷积点乘强制不同支路特征进行局部交互, LSTM与GAF支路的交互可关联时序动态与全局趋势, 而GAF与RP支路的交互则可整合线性与非线性特征。

2) 拼接后的多模态特征经整体卷积压缩为低维判别性特征, 同时自注意力机制动态调整各模态贡献度。

3) 相较于传统串联或简单拼接融合, 本方法通过卷积交互与注意力加权, 从算法层面解决了多模态特征冗余与冲突问题。

3 逆变器故障诊断实验验证

3.1 实验数据采集

本文通过Matlab/Simulink平台搭建电压源型三相两电平并网逆变器仿真模型, 通过改变单个和两个IGBT的通断来模拟1种正常类型和21种故障类型。采样信号为逆变器输出的A相电流信号, 采样频率为50 kHz。每种故障类型采集4.12 s的故障数据, 即每相电流采集206 000个故障数据点。由于在0.1 s时控制故障发生, 故障发生瞬间波形会有微小变化, 电流信号的周期为0.02 s, 为得到较好的故障数据, 舍弃前面0.12 s的数据, 获得长度为20万的22组故障数据。将每组20万个数据点的每2000个数据点作为一个样本, 每种故障类型为100个样本, 22种故障类型一共有2200个样本, 将其命名为原始数据集, 以便后续数据处理及图片转换操作, 并将2200个样本按照8:2的比例随机分配为

训练集与测试集, 原始训练集 1760 个样本, 原始测试集 440 个样本。

3.2 数据预处理

为实现多模态数据的高效利用, 对仿真故障数据实施三阶段处理:

1) 对原始电流信号进行 CEEMD-PRT 处理, 有效提取局部故障特征, 生成一维时序数据集并标注标签。

2) 将一维时序样本转换为 GAF 与 RP 二维图像, 每组样本生成两种图像共 4400 张, 标注对应故障标签, 形成二维图像数据集。

3) 将处理后的一维时序数据及二维图像按 8:2 的比例随机划分为训练集与测试集。训练阶段采用多模态三支路异构融合模型进行特征学习, 通过性能反馈优化模型参数, 最终基于独立测试集验证故障分类准确率, 实现设备状态精准识别。

3.3 故障诊断训练流程图

基于 GAF-RP-LSTM-Transformer 三支路异构融合的逆变器故障诊断整体流程图如图 9 所示, 步骤 1 为数据集的采集, 步骤 2 为数据集的处理, 步骤 3 为 GAF-RP-LSTM-Transformer 三支路异构融合诊断模型训练, 具体流程如下。

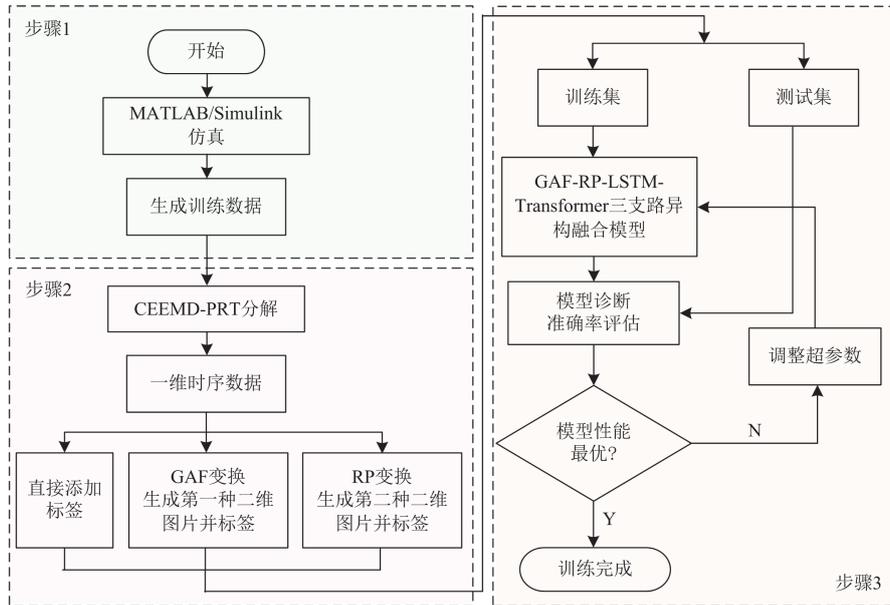


图 9 GAF-RP-LSTM-Transformer 三支路异构融合模型训练流程图

Fig. 9 Training flow chart of GAF-RP-LSTM-Transformer three-branch heterogeneous fusion model

步骤 1: 利用 MATLAB/Simulink 搭建三相并网逆变器模型, 通过控制开关管的导通与关断, 模拟出 1 种正常状态和 21 种不同的故障状态, 将采集到的 A 相输出电流作为原始数据, 并将其按照 8:2 的比例随机分配为训练集与测试集。

步骤 2: 对原始数据集采用 CEEMD-PRT 算法进行数据处理生成一维时序数据集。对一维时序数据集进行 GAF 变换和 RP 变换, 生成二维 GAF 数据集和二维 RP 数据集, 构建出全局与局部互补的多模态数据集。

步骤 3: 构建 GAF-RP-LSTM-Transformer 三支路异构融合模型, 将上述 3 种不同方式生成的一维时序数据集、二维 GAF 数据集和二维 RP 数据集分别输入到模型的 3 个不同通道中, 进行迭代训练, 将训练集与测试集同时输送至网络中, 模型收敛后利用测试集进行效果测试。如果测试效果不理想,

则需要调整神经网络中的超参数, 重新进行模型训练, 直至测试结果满足一定要求, 表示此时诊断模型训练完毕。然后将测试集上的预测结果与真实值进行对比, 计算模型的准确率等评估指标, 最终实现对三相逆变器开路故障的诊断。

4 实验结果分析

4.1 模型参数与训练结果

该模型采用 Adam 优化器, 其初始学习率设定为 0.001, 批量大小固定为 10。损失函数选用交叉熵损失函数以优化分类性能, 隐藏层激活函数采用负斜率系数为 0.1 的 LeakyReLU, 以缓解梯度消失问题。训练集和测试集划分比例为 8:2, 整个训练过程持续 100 个完整周期, 确保模型充分收敛。其测试集的混淆矩阵如图 10 所示。

由图 10 可见, 该模型的测试集混淆矩阵只有 3

个样本诊断不准确, 其中交叉的 IGBT5、IGBT6 开路故障有 2 个样本被诊断为同半桥的 IGBT1、IGBT3 开路故障; 交叉的 IGBT1、IGBT2 开路故障有 1 个样本被诊断为交叉的 IGBT2、IGBT3 开路故障。仿真结果表明, GAF-RP-LSTM-Transformer 三支路异构融合模型对逆变器开路故障具有优越的诊断能力。

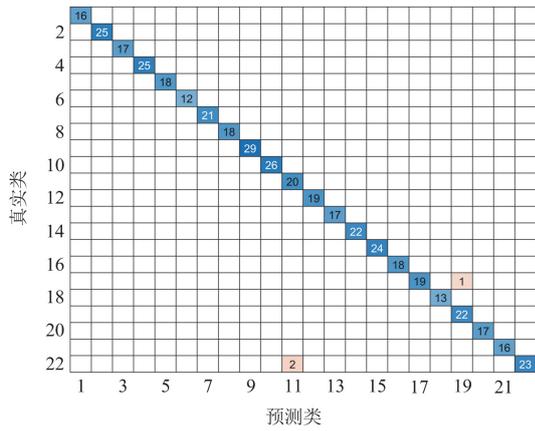


图 10 测试集混淆矩阵

Fig. 10 Test set confusion matrix

由图 11 可知, 在迭代 100 次后, 模型达到收敛状态。训练集分类准确率约收敛至 99.7%, 损失值约收敛至 0.003; 测试集分类准确率约收敛至 99.3%, 损失值约收敛至 0.007。

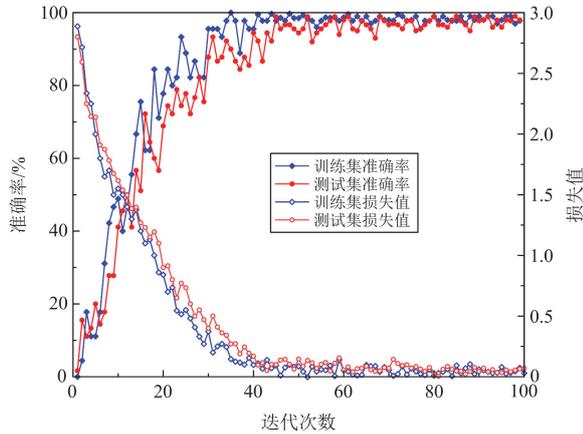


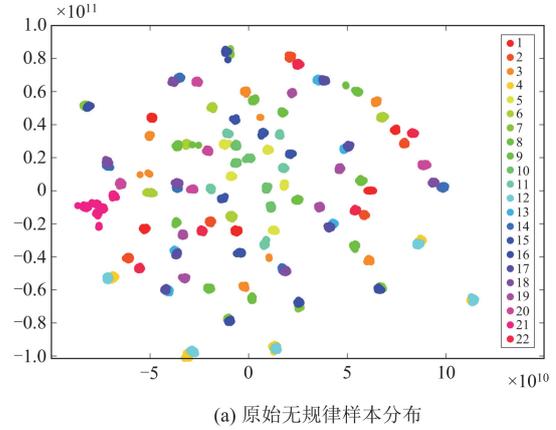
图 11 GAF-RP-LSTM-Transformer 三支路异构融合模型的训练过程

Fig. 11 Training process of GAF-RP-LSTM-Transformer triple-branch heterogeneous fusion model

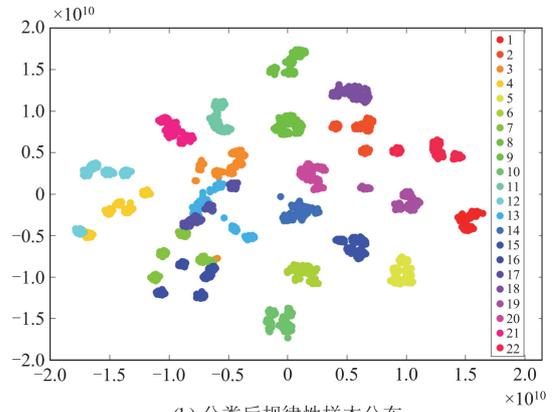
4.2 特征可视化

为验证模型分类性能, 采用 t 分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)算法将高维特征降维映射至低维空间, 通过保留数

据拓扑结构实现特征可视化。如图 12 所示, 二维投影结果中横纵坐标仅表示数据点间的相对距离, 点聚集程度反映特征相似度及提取能力。



(a) 原始无规律样本分布



(b) 分类后规律性样本分布

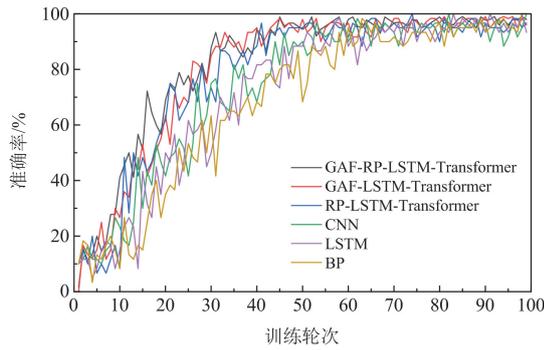
图 12 t-SNE 特征可视化

Fig. 12 t-SNE feature visualization

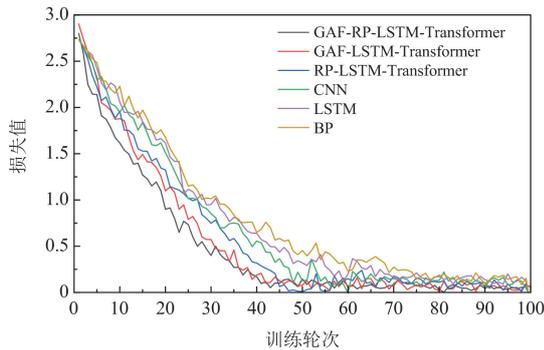
图 12(a)显示原始样本分布无规律, 不同故障信号特征向量集中于中间区域且重叠严重, 表明原始特征区分度低; 图 12(b)为经 GAF-RP-LSTM-Transformer 三支路异构融合模型处理后的样本分布, 各类故障特征向量在小区域内高度聚集且无重叠, 类内紧凑性显著提升, 验证了模型通过融合图像处理与时空特征提取, 实现了故障特征的有效解耦与精准分类, 充分体现了其优越的异构特征表达与模式识别性能。

4.3 不同模型训练效果对比

为评估本文提出的 GAF-RP-LSTM-Transformer 三支路异构融合模型训练策略的优势性, 本文采用对比研究方法, 选取 GAF-LSTM-Transformer 模型、RP-LSTM-Transformer 模型、CNN、LSTM 以及 BP 神经网络模型这 5 种深度学习模型进行性能测试对比, 图 13 为各模型的准确率曲线和损失值曲线。



(a) 准确率对比曲线



(b) 损失值对比曲线

图 13 各模型的训练过程对比

Fig. 13 Comparison of training processes of various models

根据图 13 可知, GAF-RP-LSTM-Transformer 三支路异构融合模型测试集准确率为 99.30%, GAF-LSTM-Transformer 模型测试集准确率为 97.65%, RP-LSTM-Transformer 模型测试集准确率为 97.21%, CNN 测试集准确率为 96.30%, LSTM 测试集准确率为 95.90%, BP 测试集准确率为 95.14%, 表明 GAF-LSTM-Transformer 三支路异构融合模型对逆变器开路故障具有优越的诊断能力。

4.4 鲁棒性分析

本研究选取信噪比为 10 dB、20 dB、30 dB、40 dB 的高斯白噪声构建测试集, 输入至各方法预训练最优模型进行验证。基于三相电流信号特性, 设定共模与差模两种干扰模式: 共模干扰通过向 A、B、C 三相同步注入相同强度噪声实现, 差模干扰则对 A、B 两相施加相位相反的噪声信号并保持 C 相无噪状态。通过计算两种噪声场景下诊断准确率的均值(如表 2 所示), 综合评估各模型在复杂噪声环境中的鲁棒性。不同噪声条件下各模型的诊断准确率对比结果如图 14 所示。

从表 2 中的数据能够看出, 在不同的噪声干扰下, 各个模型的诊断准确率存在差异。当面对 40 dB 的噪声干扰时, 本文所提出的方法准确率可达到

表 2 不同噪声干扰下多模型准确率对比

Table 2 Accuracy comparison of multi-model algorithms in noise-contaminated environments

模型算法	准确率/%			
	10 dB	20 dB	30 dB	40 dB
GAF-RP-LSTM-Transformer	93.96	97.96	98.24	98.62
GAF-LSTM-Transformer	92.83	93.38	95.86	96.13
RP-LSTM-Transformer	91.76	92.26	94.60	95.95
CNN	89.84	91.34	93.53	94.61
LSTM	89.17	90.87	93.26	94.37
BP	87.62	89.23	92.17	93.82

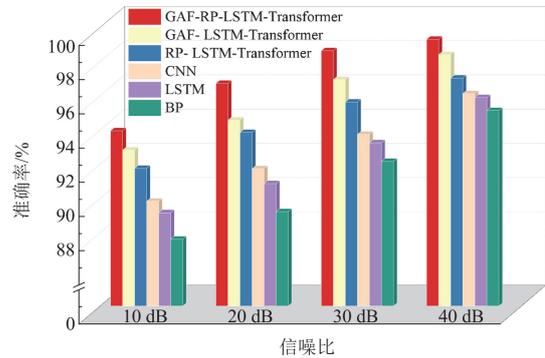


图 14 不同噪声条件下各模型的准确率对比

Fig. 14 Accuracy comparison of models under different noise conditions

98.62%, 高于其他对比模型。随着信噪比的降低, 各模型的准确率均出现下降。在面对 30 dB 噪声干扰时, 其诊断准确率为 98.24%, 相较于 40 dB 仅降低了 0.38%; 而在面对 20 dB 噪声干扰时, 模型准确率仍保持在 97.96%, 较 40 dB 噪声干扰时仅下降 0.66%; 并且在 10 dB 的强噪声条件下, 模型准确率仍保持 93.96%, 较 GAF-LSTM-Transformer、RP-LSTM-Transformer、CNN、LSTM 及 BP 网络分别提升 0.77%、2.2%、4.12%、4.79%和 6.34%, 验证了特征融合机制对模型鲁棒性的增强作用。综上所述, 本文提出的 GAF-RP-LSTM-Transformer 三支路异构融合模型在面对噪声干扰时, 依旧能够保持较高的诊断分类水平, 这表明该模型能够很好地抑制噪声, 具有较好的诊断鲁棒性。

5 结论

针对逆变器开路故障诊断问题, 本研究提出了一种基于 LSTM-GAF-RP-Transformer 三支路异构融合的逆变器开路故障诊断方法, 通过结合时序动态特征与多模态图像特征, 充分发挥了图像化处理在特征空间扩展与非线性表征上的优势。本研究的

主要结论如下。

1) 实验表明, GAF 图像对全局趋势的捕捉与 RP 图像对局部动力学的解析具有强互补性,二者融合有效克服了单一模态特征的局限性,为复杂噪声环境下的高精度诊断提供了可靠支撑。

2) 实验结果表明,所提模型在测试集上的分类准确率达到 99.30%。在特征可视化方面,经 t-SNE 可视化后,该方法类间分离性良好,类内紧凑性良好,充分发挥了强大的图像处理能力,对逆变器故障诊断识别率较高。与其他对比模型相比,本文所提方法在训练集中分类准确率表现优越。

3) 本文提出的 GAF-RP-LSTM-Transformer 融合模型在强噪声环境下表现出卓越的诊断鲁棒性。其在 10 dB、20 dB、30 dB、40 dB 噪声干扰下的准确率分别达到 93.96%、97.96%、98.24%、98.62%。相比现有模型,该架构展现出更优的抗噪声干扰能力和稳定性。

针对三相并网逆变器的开路故障诊断问题,虽然提出的基于多模态三支路异构融合模型的故障诊断方法具有一定的有效性和可行性,但仍有需要进一步完善的地方,今后可以围绕以下工作展开研究:

1) 当前方法依赖单一电流信号与固定负载仿真数据,未来可考虑融合电压、温度等多传感器数据构建多物理场诊断框架,并在动态负载、电网波动等真实场景验证适应性。

2) 模型的推理速度可能在低性能设备上不满足实时性要求。未来可考虑轻量化设计优化计算效率,开发更高效的转换算法,利用并行化优化策略和硬件加速方法,提升大规模数据流的处理效率。

参考文献

- [1] 陈怡薇,徐永海,袁敞,等. 基于切换调制策略的 ANPC 三电平逆变器开路故障诊断方法研究[J]. 电力系统保护与控制, 2025, 53(2): 27-37.
CHEN Yiwei, XU Yonghai, YUAN Chang, et al. Research on open-circuit fault diagnosis method of ANPC three-level inverter based on switching modulation strategy[J]. Power System Protection and Control, 2025, 53(2): 27-37.
- [2] 马铭遥,凌峰,孙雅蓉,等. 三相电压型逆变器智能化故障诊断方法综述[J]. 中国电机工程学报, 2020, 40(23): 7683-7699.
MA Mingyao, LING Feng, SUN Yarong, et al. Review of intelligent fault diagnosis methods for three-phase voltage-mode inverters[J]. Proceedings of the CSEE, 2020, 40(23): 7683-7699.
- [3] SHARMA J, SUNDARABALAN C K, BALASUNDAR C. Proportionate normalized least mean M-estimate controlled shunt converter for load balancing in distribution grid[J]. Protection and Control of Modern Power Systems, 2025, 10(1): 52-63.
- [4] 申皓澜,唐欣,罗毅飞,等. 基于 CNN 的三相逆变器开路故障诊断及其样本条件分析[J]. 国防科技大学学报, 2022, 44(6): 163-172.
SHEN Haolan, TANG Xin, LUO Yifei, et al. Open-circuit fault diagnosis for three-phase inverters based on CNN and analysis of its sample conditions[J]. Journal of National University of Defense Technology, 2022, 44(6): 163-172.
- [5] 刘述喜,刘科,王乾蕴,等. 基于模态时频图与 Resnet-BiGRU 模型的 MMC 子模块开路故障诊断[J]. 电力系统保护与控制, 2025, 53(2): 73-88.
LIU Shuxi, LIU Ke, WANG Qianyun, et al. Open-circuit fault diagnosis of MMC sub modules based on modal time-frequency diagrams and the Resnet-BiGRU model[J]. Power System Protection and Control, 2025, 53(2): 73-88.
- [6] 阳同光,沈兵. 模块化多电平换流器 IGBT 模块失效机理和状态监测研究综述[J]. 电力系统保护与控制, 2023, 51(4): 174-187.
YANG Tongguang, SHEN Bing. Review of failure mechanism and state monitoring technology for modular multilevel converter IGBT modules[J]. Power System Protection and Control, 2023, 51(4): 174-187.
- [7] 韩素敏,郑书晴,何永盛. 基于粗糙集贪心算法的逆变器开路故障诊断[J]. 电力系统保护与控制, 2020, 48(17): 122-130.
HAN Sumin, ZHENG Shuqing, HE Yongsheng. Open circuit fault diagnosis for inverters based on a greedy algorithm of a rough set[J]. Power System Protection and Control, 2020, 48(17): 122-130.
- [8] 董唯光,王宁,张周卫,等. 基于 MTF-CNN 的三相光伏并网逆变器 IGBT 故障诊断[J/OL]. 电源学报: 1-12[2025-03-23]. <https://link.cnki.net/urlid/12.1420.tm.20240830.1626.002>
DONG Weiguang, WANG Ning, ZHANG Zhouwei, et al. Open circuit diagnosis of three-phase PV grid-connected photovoltaic inverter IGBT based on MTF-CNN[J/OL]. Journal of Power Supply: 1-12[2025-03-23]. <https://link.cnki.net/urlid/12.1420.tm.20240830.1626.002>
- [9] 韩素敏,高静利,赵国帅,等. 采用超螺旋滑模观测器的并网逆变器开路故障诊断[J]. 电力系统及其自动化学报, 2025, 37(3): 120-128.
HAN Sumin, GAO Jingli, ZHAO Guoshuai, et al. Open-circuit fault diagnosis of grid-connected inverter with super-twisting sliding mode observer[J]. Proceedings of the CSU-EPSA, 2025, 37(3): 120-128.
- [10] 姬鑫,陈超波,张彬彬,等. 基于 Prony 算法的三电平逆变器开路故障诊断方法[J]. 电测与仪表, 2023, 60(8):

- 97-104.
JI Xin, CHEN Chaobo, ZHANG Binbin, et al. Open-circuit fault diagnosis method of three-level inverter based on Prony algorithm[J]. *Electrical Measurement & Instrumentation*, 2023, 60(8): 97-104.
- [11] 陈旺斌, 孟献蒙, 程凡永, 等. 基于卷积神经网络的光伏逆变器故障诊断[J]. *湖南工业大学学报*, 2021, 35(1): 25-30.
CHEN Wangbin, MENG Xianmeng, CHENG Fanyong, et al. Fault diagnosis of photovoltaic inverter based on convolution neural network[J]. *Journal of Hunan University of Technology*, 2021, 35(1): 25-30.
- [12] 赵丹阳, 董唯光, 高锋阳. 一种改进卷积神经网络的逆变器故障诊断[J]. *电源学报*, 2020, 18(3): 124-132.
ZHAO Danyang, DONG Weiguang, GAO Fengyang. Improved inverter fault diagnosis based on convolutional neural network[J]. *Journal of Power Sources*, 2020, 18(3): 124-132.
- [13] WEN Long, LI Xinyu, GAO Liang, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(7): 5990-5998.
- [14] 丁毅, 何怡刚, 李兵, 等. 基于小波包和量子神经网络的逆变器故障诊断[J]. *重庆理工大学学报(自然科学)*, 2021, 35(4): 152-158.
DING Yi, HE Yigang, LI Bing, et al. Fault diagnosis of three-level inverter based on quantum neural network and wavelet packet analysis[J]. *Journal of Chongqing University of Technology (Natural Science)*, 2021, 35(4): 152-158.
- [15] 孙权, 于翔海, 李宏胜, 等. 基于二维卷积神经网络的BLDCM驱动系统故障检测方法[J]. *电源学报*, 2022, 20(1): 180-187.
SUN Quan, YU Xianghai, LI Hongsheng, et al. Fault detection method for BLDCM drive system based on 2D-CNN[J]. *Journal of Power Supply*, 2022, 20(1): 180-187.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [17] ZHAO Q, CAI X, CHEN C, et al. Commented content classification with deep neural network based on attention mechanism[C]// 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), March 25-26, Chongqing, China: 2016-2019.
- [18] YANG B, TU Z, WONG D F, et al. Modeling localness for self-attention networks[C]// 2018 Conference on Empirical Methods in Natural Language Processing, October 29-November 1, 2018, Brussels, Belgium: 4449-4458.
- [19] 周海成, 石恒初, 曾令森, 等. 基于关系超图增强 Transformer 的智能站二次设备故障诊断研究[J]. *电力系统保护与控制*, 2024, 52(12): 123-132.
ZHOU Haicheng, SHI Hengchu, ZENG Lingsen, et al. Fault diagnosis of an intelligent substation secondary device based on a relational hypergraph-enhanced Transformer[J]. *Power System Protection and Control*, 2024, 52(12): 123-132.
- [20] 郭亮, 迟颂, 施文. 计及多重开关事件的高频电压源逆变器实时仿真[J]. *河北大学学报(自然科学版)*, 2019, 39(5): 547-553.
GUO Liang, CHI Song, SHI Wen. Real-time simulation of high-frequency voltage inverters with multiple switching event[J]. *Journal of Hebei University (Natural Science Edition)*, 2019, 39(5): 547-553.
- [21] LÜ C, HUO Z, CHENG X, et al. Distributed optical fiber sensing intrusion pattern recognition based on GAF and CNN[J]. *Journal of Light Wave Technology*, 2020, 38(15): 4174-4182.
- [22] 黄冬梅, 吴志浩, 孙园, 等. 基于VAE预处理和RP-2D CNN的不平衡负荷数据类型辨识方法[J]. *电力系统及其自动化学报*, 2022, 34(10): 66-72, 80.
HUANG Dongmei, WU Zhihao, SUN Yuan, et al. Data type identification method for imbalanced load based on VAE preprocessing and RP-2D CNN[J]. *Proceedings of the CSU-EPSA*, 2022, 34(10): 66-72, 80.
- [23] 王义国, 林峰, 李琦, 等. 基于TCN-LSTM模型的电网电能质量扰动分类研究[J]. *电力系统保护与控制*, 2024, 52(17): 161-167.
WANG Yiguo, LIN Feng, LI Qi, et al. Classification of power quality disturbances in a power grid based on the TCN-LSTM model[J]. *Power System Protection and Control*, 2024, 52(17): 161-167.
- [24] 赵宇洋, 徐慧慧, 田云飞, 等. 基于融合注意力机制自编码器的配网光伏逆变器故障检测[J]. *智慧电力*, 2024, 52(11): 1-7.
ZHAO Yuyang, XU Huihui, TIAN Yunfei, et al. Fault detection in photovoltaic inverters in distribution networks based on autoencoder integrated with attention mechanism[J]. *Smart Power*, 2024, 52(11): 1-7.

收稿日期: 2025-03-11; 修回日期: 2025-05-15

作者简介:

刘伟(1971—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为智能监测与诊断系统、可再生能源与智能控制; E-mail: 442780146@qq.com

王澜(2000—), 女, 硕士研究生, 研究方向为智能控制。E-mail: 1240492800@qq.com

(编辑 周金梅)