

基于PSA引导双分支神经网络特征融合的同步电机故障诊断

李俊卿¹,苑浩¹,黄涛¹,张承志²,何玉灵³,张波¹

(1. 华北电力大学 电力工程系,河北保定 071003; 2. 国网濮阳供电公司,河南濮阳 457000;
3. 华北电力大学 机械工程系,河北保定 071003)

摘要:针对单一传感器信号在同步电机故障诊断中精度不高的问题,提出了1种基于金字塔切分注意力机制(PSA)的神经网络模型。首先,将三相电流信号和振动信号作为双分支输入到卷积神经网络进行特征提取,之后通过特征融合层将提取的信号特征进行融合。其次,添加PSA注意力机制捕获不同尺度的空间信息来丰富特征空间。最后,通过输出层输出诊断结果。实验表明所提模型能够显著提升同步电机故障诊断的准确率。

关键词:同步电机; PSA注意力机制; 双分支特征融合; 故障诊断; 神经网络

中图分类号:TM341

文献标志码:A

DOI:10.20204/j.sp.2024.12007

Fault Diagnosis of Synchronous Motor Based on PSA Guided Double Branch Neural Network Feature Fusion

LI Junqing¹, YUAN Hao¹, HUANG Tao¹, ZHANG Chengzhi², HE Yuling³, ZHANG Bo¹

(1. Department of Electric Power Engineering, North China Electric Power University, Baoding 071003, China;
2. State Grid Puyang Power Supply Company, Puyang 457000, China; 3. Department of Mechanical Engineering,
North China Electric Power University, Baoding 071003, China)

Abstract: Targeting the problem of poor accuracy of single sensor signal in synchronous motor fault diagnosis, the paper proposes a pyramid split attention (PSA) based neural network model. Firstly, the three-phase current signal and vibration signal are input into the convolutional neural network as two branches for feature extraction, and the extracted signal features are fused through the feature fusion layer. Secondly, the spatial information of different scales is captured with PSA attention mechanism to enrich the feature space. Finally, the diagnosis results are output through the output layer. The experiments show that the proposed model can significantly improve the accuracy of the synchronous motor fault diagnosis.

Key words: synchronous motor; PSA attention mechanism; dual branch feature fusion; fault diagnosis; neural network

0 引言

同步电机是电力系统中重要的旋转设备^[1],它能够运行在发电机、调相机或电动机的模式下。定子匝间短路故障是同步电机常见的故障类型之一,主要是由于定子绕组在电磁、热的作用下发生绝缘破坏降低其绝缘性能,且长时间的运行会进一步扩大短路范围,甚至烧毁绕组,被迫停机^[2],对电机及其所在电网的稳定运行构成威胁。因此,研究定子

基金项目:国家自然科学基金资助项目(52177042)

Project Supported by the National Natural Science Foundation of China (52177042)

匝间短路的故障诊断方法,提高故障诊断的准确率,对电力系统的稳定运行具有重要的现实意义。

随着数据处理和人工智能技术的发展,在传统故障诊断方法的基础上,基于机器学习的故障诊断方法在电机领域得到应用。其一般步骤是对提取的故障信号进行处理和转换,将提取到的故障特征信号输入到故障分类模型用于故障诊断^[3-4]。但在诊断过程中依据专业判断和经验起着至关重要的作用。同时对数据的质量和规模具有显著的依赖度,限制了传统故障诊断方法在不同情况下的灵活性和适应能力。近年来,伴随着人工神经网络研究的深入,深度学习在故障诊断领域的应用越来越广泛。其可以提供从数据输入到故障诊断决策的端到端解决方

案,减少了对中间步骤的依赖。文献[5]提出了1种基于一维卷积神经网络(One-dimensional-Convolutional Neural Networks, 1D-CNN)的暂态稳定性评估方法,该方法充分发挥了自动提取时间序列特征的能力。利用1D-CNN提取故障特征,相较于传统的故障特征提取方法,1D-CNN在处理时间序列信号时能够捕捉序列中的局部依赖关系,同时计算效率也更高。

长短期记忆网络(Long Short-term Memory, LSTM)具有长序列学习能力,在处理序列数据具有很大优势而得到广泛使用^[6]。但在应用过程中也表现出一定的局限性,例如无法完全捕捉时间序列的某些模式、难以捕捉长期依赖关系。文献[7]通过在神经网络模型中加入双向长短期记忆网络(Bidirectional Long Short-term Memory, BiLSTM),实现了从正向和反向2个维度捕捉序列信息的能力,这有助于更精确地识别序列数据中的相互依赖性,从而增强了模型的识别和判断能力。在神经网络模型中加入注意力机制,可以通过关注输入序列信号中的特定部分改善长距离依赖问题,进而提高模型的性能。文献[8]提出了1种利用多头注意力机制进行信息融合,并结合了自注意力机制的CNN的诊断方法。该方法能够有效地集中于轴承故障的特征信号,提高了故障识别的准确性。现有方法大多是将单一电流信号或者单一振动信号作为输入,提取单一信号不同维度的特征进行融合。此类方法受传感器自身精度和可靠性影响,在数据采集过程中存在误差和不确定性,同时也无法全面反映监测对象的真实状态。

本文提出一种将多传感器信号进行特征融合并引入注意力机制的模型,该模型将三相电流信号和振动信号经1D-CNN提取特征后进行融合,金字塔切分注意力机制(Pyramid Split Attention, PSA)对融合特征的重要性加权。对比实验表明,所提方法较单一电流信号输入和单一振动信号输入准确率有了很大的提升。

1 相关理论及模型原理

1.1 定子匝间短路振动特性分析

同步电机作为一个整体,绕组故障会引起气隙磁场变化。因此会在转子径向上产生不平衡的磁拉力。当发电机正常运行时气隙磁势 $f_z(\alpha, t)$ 的表达式^[9]为:

$$f_z(\alpha, t) = F_s \cos(\omega t - p\alpha) + F_r \cos\left(\omega t - p\alpha + \psi + \frac{\pi}{2}\right) \quad (1)$$

定子匝间短路故障时气隙磁势 $f_g(\alpha, t)$ 的表达式^[10]为:

$$f_g(\alpha, t) = F_{s+} \cos(\omega t - p\alpha) + F_{s-} \cos(\omega t + p\alpha) + F_{s3} \cos(3\omega t - p\alpha) + F_r \cos\left(\omega t - p\alpha + \psi + \frac{\pi}{2}\right) + F_{r2} \cos 2\left(\omega t - p\alpha + \psi + \frac{\pi}{2}\right) \quad (2)$$

式中: F_{s+} 为正序定子磁动势幅值; F_{s-} 为负序定子磁动势幅值; F_{s3} 为定子三次谐波磁动势幅值; F_r 为转子磁动势幅值; F_{r2} 为转子二次谐波磁动势幅值; p 为极对数; ω 为角频率; f 为电频率; α 为定子机械角度; ψ 为发电机内功率因数角。

当发生定子匝间短路时,同步电机转子所受到的X轴、Y轴的不平衡磁拉力 F_x 、 F_y 表示式为:

$$\begin{cases} F_x = \frac{\partial W}{\partial X} = \frac{RL}{2} \int_0^{2\pi} \frac{\partial \Lambda}{\partial X} f_g^2(\alpha, t) d\alpha \\ F_y = \frac{\partial W}{\partial Y} = \frac{RL}{2} \int_0^{2\pi} \frac{\partial \Lambda}{\partial Y} f_g^2(\alpha, t) d\alpha \end{cases} \quad (3)$$

式中: W 为气隙磁场能量; R 为定子内圆半径; L 为气隙轴向长度; Λ 气隙单位面积磁导。

定子是空心壳体结构,由于单位面积的电磁力为脉振力,这种脉振力同时作用在壳体结构的定子内圆面将会引起定子弹性圆柱壳体的振动,计算此脉振电磁力采用的是电磁力的磁密计算法^[10]。

发电机气隙磁密 $B(\alpha, t)$ 表达式为:

$$B(\alpha, t) = \Lambda(\alpha, t) f(\alpha, t) \quad (4)$$

作用在定子内圆表面的脉振电磁力为:

$$q(\alpha, t) = \frac{B^2(\alpha, t)}{2\mu_0} \quad (5)$$

式中: μ_0 为真空磁导率。

综上所述,当发生定子匝间短路时会引起定转子振动特性的变化。因此,可将振动作为本文所提方法的输入量进行同步电机的故障诊断。

1.2 卷积神经网络

与传统机器学习故障诊断的特征提取方法相比,CNN能够更有效地处理海量的原始数据,自动提取数据中的特征信息^[11-14]。本文采用的1D-CNN可自动提取原始信号中的特征,能最大限度地保留原始信号的关键特征,并且通过局部卷积操作和参数共享机制,使模型的参数数量显著减少,模型结构大幅简化,从而提高故障诊断的时效。其网络主要结构包括卷积层、池化层、全连接层、输出层如图1所示。

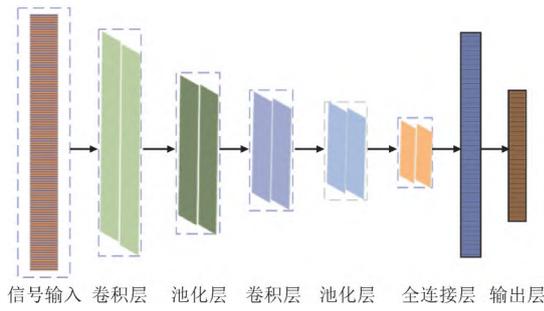


图1 CNN模型结构

Fig.1 Structure of CNN model

卷积层是CNN的核心组成部分,其主要任务是通过卷积计算进行特征提取。池化层的主要功能是减少数据维度,从而加速计算过程,本文采用最大池化实现这一目的。处理完卷积层和池化层的数据随后被送入全连接层,得到想要的分类结果。CNN卷积操作过程的数学表达式为:

$$y_i^l = f(w_i^l * y^{l-1} + b_i^l) \quad (6)$$

式中: y_i^l 为第 l 层的第 i 个输出特征图; w_i^l 为第 l 层中第 i 个权重矩阵; y^{l-1} 为 $l-1$ 层输出特征图; b 为卷积层偏置值,*为卷积运算; $f(\cdot)$ 为激活函数。

每1个卷积层都需要使用激活函数与后1个池化层相连,通过引入激活函数,神经网络能捕捉数据中的非线性关系。常见的有ReLU、tanh、Sigmoid激活函数。ReLU函数能够改善梯度消失问题,减少过拟合,常用于CNN的激活函数,其表达式如下:

$$\text{ReLU}(x) = \max(0, x) \quad (7)$$

与单传感器信号输入相比,多传感器信号的输入能丰富故障信号特征,提高故障诊断的准确率^[15-18]。本文采用双分支信号输入至CNN中进行特征提取。

1.3 BiLSTM网络

BiLSTM由2个LSTM单元构成,1个按时间顺序处理序列,另1个逆序处理,从而有效捕捉序列中的长期依赖性。利用双向信息流,模型不仅分析了数据的正向关联,还考虑了反向关联,使故障诊断模型对输入特征的捕捉能力得到增强,模型的稳定性和泛化性也得到提高^[19]。LSTM单元的模型结构如图2所示。其中, f_t 为在时间步 t 的遗忘门的输出, i_t 为在时间步 t 的输入门的输出, c_t 为在时间步 t 的候选状态单元的输出, H_t 为在时间步 t 的状态单元的输出,也就是隐藏状态, O_t 为在时间步 t 的输出门的输出, h_t 为在时间步 t 的输出,即最终的输

出, x_t 为在时间步 t 的输入样本, h_{t-1} 为在时间步 $t-1$ 的输出,也就是上一时间步的隐藏状态, σ 为Sigmoid激活函数。LSTM网络通过这些门的协同工作来决定哪些信息应该被保留、更新或遗忘,从而实现了对序列数据的有效处理^[20-21]。

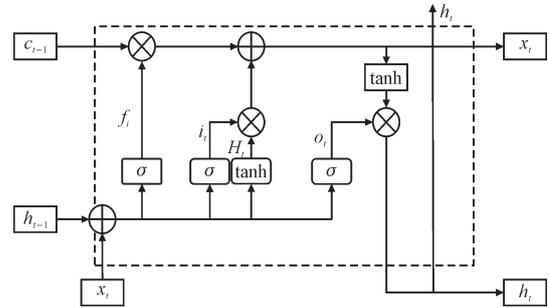


图2 LSTM模型结构

Fig.2 Structure of LSTM model

输入数据沿LSTM模型单向传播,传输状态由遗忘门 F_t 、输入门 I_t 和输出门 O_t 3个门结构控制。其主要公式如下:

$$\begin{cases} F_t = \sigma(x_t W_{xf} + h_{t-1} W_{hf} + b_f) \\ I_t = \sigma(x_t W_{xi} + h_{t-1} W_{hi} + b_i) \\ O_t = \sigma(x_t W_{xo} + h_{t-1} W_{ho} + b_o) \end{cases} \quad (8)$$

式中: $W_{xf}, W_{hf}, W_{xi}, W_{hi}, W_{xo}, W_{ho}$ 分别为3个门的权重, b_f, b_i, b_o 分别代表3个门的偏置量。

BiLSTM模型结构如图3所示。图中 $LSTM_f$ 和 $LSTM_b$ 分别为前向LSTM,反向LSTM, h_{t-1}, h_t, h_{t+1} 分别为 $t-1, t, t+1$ 时刻的输出信息, x_{t-1}, x_t, x_{t+1} 分别为 $t-1, t, t+1$ 时刻的输入信息。

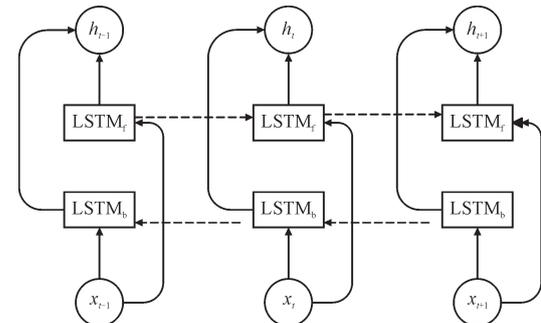


图3 BiLSTM结构

Fig.3 Structure of BiLSTM

1.4 PSA注意力机制

已有研究表明:将注意力机制模块嵌入到神经网络模型中可以大幅度提高模型的性能^[22-24]。常见的注意力机制模块有SENet, ECANet, BAM, CBAM等。SE(Squeeze-and-Excitation)和ECA(Efficient Channel Attention)仅关注了通道注意力机制,而没有

涉及到空间注意力。尽管 BAM(Bottleneck Attention Module) 和 CBAM (Convolutional Block Attention Module)在通道和空间注意力方面取得了进展,但它们仍然面临 2 个关键问题:首先,它们未能捕捉不同尺度的空间信息,限制了特征空间的丰富性;其次,它们在通道或空间注意力上主要集中于局部信息的捕获,而未能有效建立特征之间的长期依赖关系。

本文通过应用 PSA,不仅可以有效处理不同尺度输入特征的空间信息,还能在多尺度通道注意力之间构建持久的依赖关系。PSA 注意力机制模块的工作流程如图 4 所示。

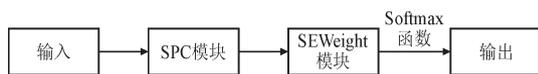


图4 PSA模块结构

Fig.4 Structure of PSA module

PSA 模块主要通过 4 个步骤实现:

1)通过 SPC 模块对通道进行细分,然后对每个细分后的通道特征图执行多尺度的空间特征提取。

2)利用 SEWeight 模块计算通道注意力系数,从而为不同尺度的特征图分配相应的通道注意力权重。

3)通过 Softmax 函数对这些多尺度通道注意力权重进行标准化处理,确保它们能够合理地反映特征的重要性,从而获得调整后的多尺度通道注意力权重。

4)将这些重新校准的注意力权重与相应的特征图进行逐元素乘法操作,生成一个经过多尺度特征信息加权的特征图。这一特征图在多尺度信息的表达能力上更为丰富。

1.5 特征连接

特征融合的主要目的是将来自多个不同源的特征合并为 1 个更好的特征表示,采用特征融合技术可提高分类准确率,提高模型的鲁棒性,同时还可以减少模型的过拟合风险^[25-28]。本文采用的特征融合方法为特征连接。特征连接是指将不同特征图按照特定维度(通常是通道维度)拼接在一起。例如,如果 2 个特征图的形状分别是 $(B, C1, H, W)$ 和 $(B, C2, H, W)$,其中 B 为批处理样本数, $C1$ 和 $C2$ 分别为通道数, H 和 W 为高度和宽度,那么将它们特征连接后,得到的特征图形状将是 $(B, C1+C2,$

$H, W)$ 。特征连接可以用于多尺度特征融合,以充分利用来自不同分支或不同层次的信息。通过这种方式,模型能够获得更为全面的特征表示。这种多尺度的特征融合策略,增强了模型对数据的理解和处理能力,使得模型在执行故障检测任务时能够提供更高的精确度和更强的稳定性。

2 故障诊断模型及步骤

2.1 故障诊断模型

本文所提出的基于 PSA 引导双分支神经网络特征融合的故障诊断模型结构如图 5 所示。电流信号和振动信号作为 2 个分支输入,分别通过卷积层提取输入信号的特征,为了加快训练速度并增强模型的泛化能力,每个卷积层之后都紧跟着批归一化层。接着,信号通过 ReLU 激活函数进行非线性转换,并与后续的最大池化层相连。本文使用的是最大池化层来提取局部区域内的最大值来减小特征图的尺寸,从而减少模型的参数和计算量。再经过 BiLSTM 层,使模型能够更好地理解复杂的序列关系。特征融合层将 2 个分支的信号进行特征融合后输入 PSA 注意力机制模块。PSA 注意力机制模块可以从融合信号中提取到更丰富的特征信息,之后送入自适应平均池化层和 2 个全连接层输出诊断结果。

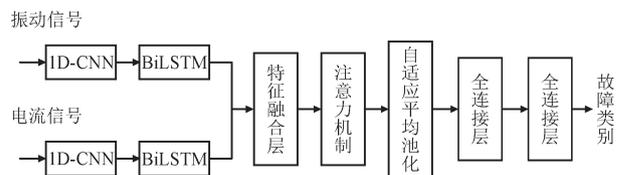


图5 故障诊断模型结构

Fig.5 Structure of fault diagnosis model

2.2 故障诊断步骤

首先将数据划分为训练集、验证集和测试集,数据随后被送入本研究提出的故障诊断模型。模型首先通过 3 层卷积操作、批处理归一化和最大池化处理,然后将结果输入到 BiLSTM 层。在特征融合层,不同来源的特征被合并,合并后的特征进一步送入 PSA 模块。最终,经过 2 层全连接层的处理,模型输出故障类别的概率。具体故障诊断流程如图 6 所示。模型采用 Adam 优化算法,依据计算出的误差梯度对模型参数进行更新,并自适应地调整各参数的学习率以提升模型表现。

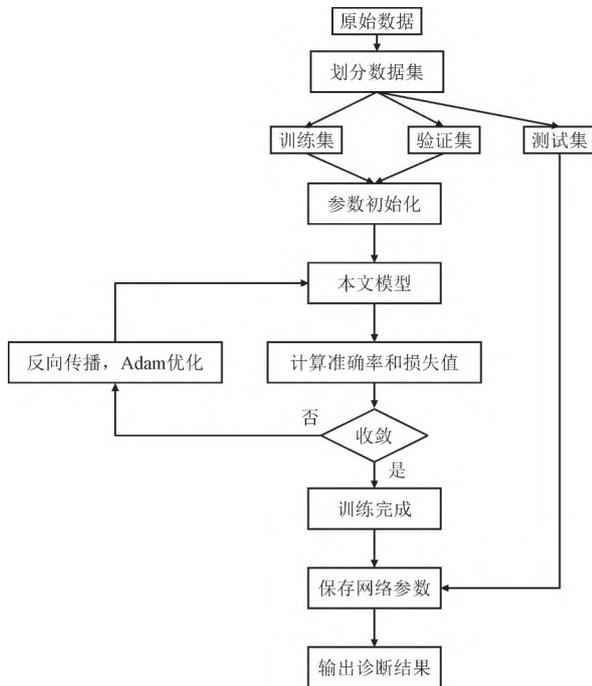


图6 故障诊断流程

Fig.6 Fault diagnosis process

3 仿真实验

3.1 实验数据来源

为了验证所提模型的有效性,选取某大学动态模拟实验室故障模拟同步电机作为实验对象。实验电机的参数如表 1 所示。

表 1 实验电机参数

Table 1 Experimental motor parameters

参数	数值
额定容量/kVA	30
额定电压/V	400
功率因数	0.8
定子内径/mm	605
定子铁心长度/mm	220

实验主要研究同步电机的定子匝间短路,由于实验验证的同步电机并网,所以现有实验数据是在恒定转速和恒定负载的条件下测得的。实验电机定子绕组引出线上接有特定百分比的抽头。在 2 个抽头间接入滑动变阻器,通过调整滑动变阻器的电阻来调整短路程度。使用传感器采集正常工况和不同程度匝间短路工况下的三相电流和定转子振动信号数据,构成 1 个多变量的数据集。采样频率设定为 100 kHz,采集时长为 2 s。实验平台现场如图 7 所示,同步电机不同故障程度下的相电流、定子振动、转子振动信号如图 8 所示。

定子匝间短路故障电流通过调节滑动变阻器

控制,定子匝间短路故障程度的表达式如式(9)。



图7 实验平台现场

Fig.7 Experimental platform site

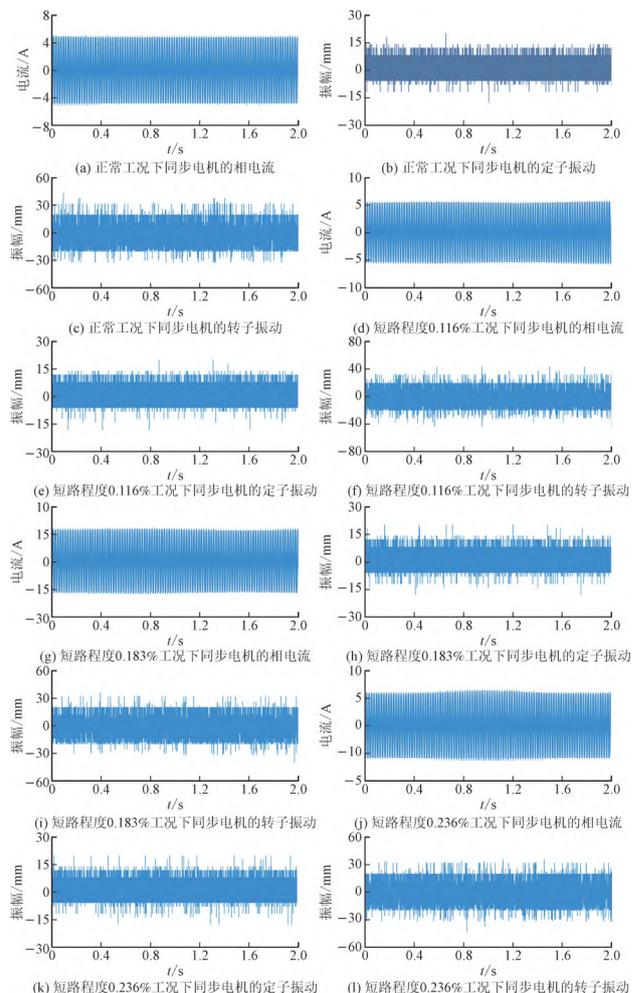


图8 同步电机不同故障程度下的相电流、定子振动、转子振动信号

Fig.8 Phase current, stator vibration, and rotor vibration signals of synchronous motor with different fault degrees

$$\lambda = \frac{I_{sip}}{I_r} \cdot \eta \quad (9)$$

式中: I_{sip} 为滑动变阻器电流; I_r 为故障相短路电流; η 为定子匝间短路抽头占比。

其中,模拟定子匝间短路实验中,定子匝间短

路的短路抽头 η 为 3%。

本文实验共采集 4 种不同工况下的运行状态数据,分别用标签 0—3 来表示。同步发电机标签对应故障种类如表 2 所示。

表 2 同步发电机标签对应故障种类

Table 2 Corresponding fault types of synchronous generator labels

标签	故障种类
0	正常
1	短路程度 0.116%
2	短路程度 0.183%
3	短路程度 0.236%

3.2 模型结构及参数

故障模型中 2 个 CNN-BiLSTM 分支的结构相同,其中 1 条支路的参数如表 3 所示。

表 3 CNN 及 BiLSTM 模型部分参数

Table 3 Partial model parameters for CNN and BiLSTM

层类型	卷积核个数	卷积核尺寸
卷积层	32	3
最大池化	32	2
卷积层	64	3
最大池化	64	2
卷积层	128	3
最大池化	128	2
BiLSTM	128	

将采集到的电流和振动信号输入到搭建好的模型中,进行训练和测试。模型训练的主要参数为:批处理样本数为 64 个,损失函数为交叉熵,训练轮数为 50 轮,优化器为 Adam,学习率设置为 0.000 1。根据模型计算的损失值,使用 Adam 进行梯度下降,不断地更新网络参数。

表 4 特征融合层及输出层模型参数

Table 4 Model parameters for feature fusion layer and output layer

层类型	通道数/个	层数
特征融合层	PSA 层	1
	自适应平均池化层	1
输出层	全连接层	1
	Dropout 层	1
	全连接层	1

3.3 实验结果分析

测试集的准确率变化曲线如图 9 所示。在前 10 轮迭代中测试集的准确率急剧上升,在第 10 轮迭代之后准确率有较小幅度的提升。模型训练结束之前,测试集的准确率收敛于 99.58%。结果表明所提方法使用的模型可以极大的提升运算效率,对于同步发电机不同故障程度的故障状态具有很好的诊断效果。

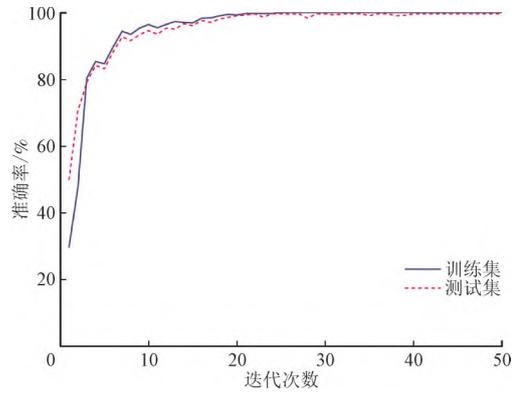


图 9 准确率变化曲线

Fig.9 Change curves for accuracy

本文还采用 t-分布随机邻域嵌入算法 (t-Distributed Stochastic Neighbor Embedding, t-SNE) 对高维数据进行了降维处理,并通过可视化手段,展示了所提出方法在区分不同故障程度特征方面的有效性。当处理高维数据时,很难直观地理解数据之间的关系。t-SNE 的目标是在一个更低维度的空间中对数据进行可视化,同时保留数据点之间的相似性关系。原始数据和经模型处理后的特征数据降维后的聚类结果图 10、图 11 所示,其中标签 0—3 采用不同颜色的标记,并且与表 2 的故障种类对应。

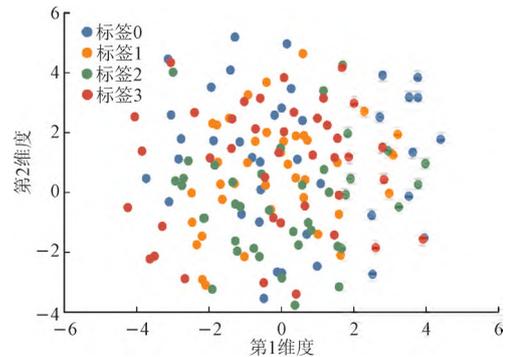


图 10 原始数据可视化图

Fig.10 Visualization of raw data

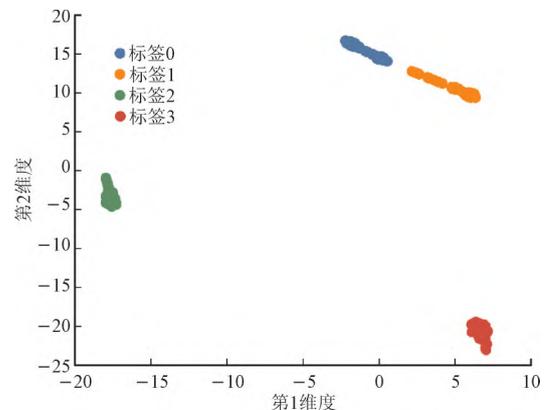


图 11 特征数据可视化图

Fig.11 Visualization of feature data

3.4 与其他方法比较分析

为了进一步验证本文所提方法和模型在同步发电机故障诊断中的准确率优势,设计了以下3组对比实验:实验1采用双分支信号输入但不加PSA注意力机制模块(CNN-BiLSTM)。实验2单电流信号输入本文模型(CNN-BiLSTM-Cur);实验3采用单振动信号输入本文模型(CNN-BiLSTM-Vib)。迭代轮数都设置为50轮。将3组实验多次训练后的准确率与本文所提方法进行比较。不同方法实验的迭代50轮的准确率如图12所示。

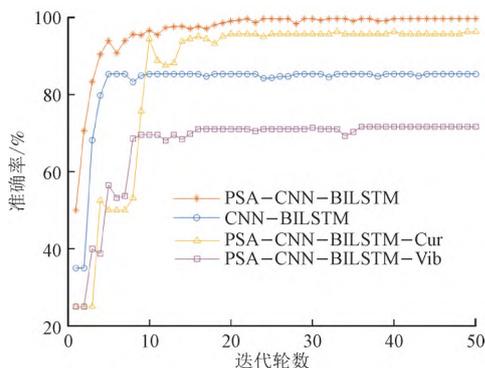


图12 4种方法测试集准确率对比

Fig.12 Comparison of testing set accuracy among four methods

为了确保实验结果的可靠性并减少偶然误差对最终结论的影响,对以上4种方法在相同的数据下各进行10次实验,取准确率平均值作为平均诊断准确率。实验结果如表5所示。

表5 不同方法的平均诊断准确率

Table 5 Average diagnostic accuracy of different methods

诊断方法	平均诊断准确率/%
PSA-CNN-BiLSTM	99.58
CNN-BiLSTM	85.25
PSA-CNN-BiLSTM-Cur	96.25
PSA-CNN-BiLSTM-Vib	71.65

本文提出的基于PSA的CNN-BiLSTM模型较传统的CNN-LSTM模型故障识别准确率有了较大提升,平均诊断准确率提高了14.33%。振动信号作为输入时,故障识别准确率较低,仅为71.65%,三相电流作为输入时,故障识别较为准确,能达到96.25%。当同时输入三相电流和振动信号时,模型的平均诊断准确率较只输入电流信号情况或工况提高3.33%。证明电流信号和振动信号特征融合进行故障识别的方法是可行的。

4 结语

在同步电机故障诊断识别中,针对单一信号提

取的特征不全而产生误差,造成故障识别准确率不高的问题,本文提出了基于PSA引导双分支特征融合的CNN-BiLSTM模型。引入的PSA注意力机制可以多尺度、多通道的训练模型;采用双分支信号特征融合,使不同分支的传感器信号数据进行互补,在拓展信息来源的同时,还可以提高融合特征的可信度。与常规的CNN-BiLSTM模型相比,其特征融合后通常只能将准确率提升至85%左右,本文提出的模型通过引入PSA,显著地提升了故障诊断的准确率;单信号输入模型其诊断效果受到采集数据信号的影响较大,本文所提模型可对融合信号不同通道的重要性进行加权,大大提高了故障诊断的准确率。

参考文献

- [1] 杨梅,贾广成,王永霞,等.同步发电机的结构特点及故障分析[J].计量与测试技术,2024,51(5):12-15,20.
YANG Mei, JIA Guangcheng, WANG Yongxia, et al. Structural characteristics and fault analysis of synchronous generator[J]. Metrology & Measurement Technique, 2024, 51(5): 12-15, 20.
- [2] 何玉灵,李勇,张文,等.永磁同步发电机匝间短路故障对绕组绝缘温升特性的影响[J].电机与控制学报,2024,28(4):18-30.
HE Yuling, LI Yong, ZHANG Wen, et al. Structural characteristics and fault analysis of synchronous generator[J]. Electric Machines and Control, 2024, 28(4): 18-30.
- [3] 方正云,刘红文,黄继盛.基于小波变换的局部放电信号尖峰去噪研究[J].电力电容器与无功补偿,2022,43(5):102-108,117.
FANG Zhengyun, LIU Hongwen, HUANG Jisheng. Study on peak denoising of partial discharge signals based on wavelet transform[J]. Power Capacitor & Reactive Power Compensation, 2022, 43(5): 102-108, 117.
- [4] 苏靖程,王志强,屈江江,等.基于BP神经网络和支持向量回归的燃煤电厂空气预热器压差预测[J].发电技术,2023,44(4):550-556.
SU Jingcheng, WANG Zhiqiang, QU Jiangjiang, et al. Pressure difference prediction of air preheater in coal-fired power plant based on bp neural network and support vector regression[J]. Power Generation Technology, 2023, 44(4): 550-556.
- [5] 高昆仑,杨帅,刘思言,等.基于一维卷积神经网络的电力系统暂态稳定评估[J].电力系统自动化,2019,43(12):18-26.
GAO Kunlun, YANG Shuai, LIU Siyan, et al. Transient stability assessment for power system based on one-dimensional convolutional neural network[J]. Automation of Electric Power Systems, 2019, 43(12): 18-26.
- [6] 李聪,丁强,刘亚祥,等.结合LSTM与1DCNN的冷水机组故障诊断方法研究[J].建筑科学,2024,40(6):146-154,208.
LI Cong, DING Qiang, LIU Yaxiang, et al. Study on fault diagnosis methods for chillers combining LSTM and 1DCNN[J]. Building Science, 2024, 40(6): 146-154, 208.
- [7] 李俊卿,张承志,韩小平,等.基于Hotelling T2-BiLSTM的同步调相机故障诊断方法[J].智慧电力,2024,52(7):96-102,127.
LI Junqing, ZHANG Chengzhi, HAN Xiaoping, et al. Fault diagnosis method of synchronous condenser based on Hotelling T2-BiLSTM[J]. Smart Power, 2024, 52(7): 96-102, 127.

- [8] 王云,徐彦伟,何可承,等.基于信息融合和SA-CNN的轴承故障诊断[J].机械与电子,2024,42(7):3-9.
WANG Yun, XU Yanwei, HE Kecheng, et al. Bearing fault diagnosis method based on information fusion and self-attention convolutional neural network[J]. Machinery & Electronics, 2024, 42(7):3-9.
- [9] 叶东.电机学[M].天津:天津科学技术出版社,1995.
- [10] 万书亭,李和明,许兆凤,等.定子绕组匝间短路对发电机定子径向振动特性的影响[J].中国电机工程学报,2004,24(4):157-161.
WAN Shuting, LI Heming, XU Zhaofeng, et al. Analysis of generator vibration characteristic on stator winding inter-turn short circuit fault[J]. Proceedings of the CSEE, 2004, 24(4): 157-161.
- [11] 黄朝凯,吴丹妍,郑惠哲,等.基于CNN的电力数据分析模型研究[J].自动化仪表,2023,44(10):65-69,74.
HUANG Chaokai, WU Danyan, ZHENG Huizhe, et al. Research on power data analysis model based on CNN[J]. Process Automation Instrumentation, 2023, 44(10): 65-69, 74.
- [12] 徐行,李军星,贾现召,等.基于1DCNN-BiLSTM的端到端滚动轴承故障诊断方法[J].机床与液压,2024,52(11):211-218.
XU Xing, LI Junxing, JIA Xianzhao, et al. End-to-end rolling bearing fault diagnosis method based on 1DCNN-BiLSTM[J]. Machine Tool & Hydraulics, 2024, 52(11): 211-218.
- [13] 刘英杰,董诤依,刘鹏鹏,等.基于1DCNN-GRU的启闭机液压系统故障诊断[J].现代制造技术与装备,2024,60(4):169-173.
LIU Yingjie, DONG Xuyi, LIU Pengpeng, et al. Fault diagnosis of hoist hydraulic system based on 1DCNN-GRU[J]. Modern Manufacturing Technology and Equipment, 2024, 60(4): 169-173.
- [14] 金维旭,南新元,李晓光,等.基于改进Mask R-CNN强风沙环境绝缘子识别[J].电瓷避雷器,2022,(6):2024-210.
JIN Weixu, NAN Xinyuan, LI Xiaoguang, et al. Insulator recognition for transmission lines in strong wind and sand environment based on improved Mask R-CNN[J]. Insulators and Surge Arresters, 2022, (6): 204-210.
- [15] 薛松,潘成辉,张子涵,等.多传感器信息融合的天线促动器故障诊断[J].电子机械工程,2024,40(3):9-16.
XUE Song, PAN Chenghui, ZHANG Zihan, et al. Fault diagnosis of antenna actuator based on multi-sensor information fusion[J]. Electro-Mechanical Engineering, 2024, 40(3): 9-16.
- [16] 包从望,江伟,张彩虹,等.多传感器信息融合的轴承故障迁移诊断方法[J].机电工程,2024,41(5):878-885.
BAO Congwang, JIANG Wei, ZHANG Caihong, et al. Transfer learning method for shearer fault diagnosis under variable working conditions[J]. Journal of Mechanical & Electrical Engineering, 2024, 41(5): 878-885.
- [17] 王成兵.基于多传感器信息融合和双流CNN的齿轮箱故障诊断[J].工程机械,2024,55(4):69-78,10-11.
WANG Chengbing. Fault diagnosis of gearbox based on multi-sensor information fusion and two-stream CNN[J]. Construction Machinery and Equipment, 2024, 55(4): 69-78, 10-11.
- [18] 陈雅鑫.基于数据融合技术的滚动轴承故障诊断方法研究[D].天津,天津职业技术师范大学,2024.
- [19] 曹景胜,于洋,王琦,等.基于优化VMD-CNN-BiLSTM的电机轴承智能故障诊断研究[J].现代电子技术,2024,47(12):115-121.
CAO Jingsheng, YU Yang, WANG Qi, et al. Research on intelligent diagnosis of motor bearing faults based on optimized VMD-CNN-BiLSTM[J]. Modern Electronics Technique, 2024, 47(12): 115-121.
- [20] 李俊卿,陈雅婷.LSTM-CNN网络在同步电机励磁绕组匝间短路故障预警中的应用[J].华北电力大学学报(自然科学版),2020,47(4):61-70.
LI Junqing, CHEN Yating. Application of LSTM-CNN network in fault warning of inter-turn short circuit in field windings of synchronous generator[J]. Journal of North China Electric Power University, 2020, 47(4): 61-70.
- [21] 李俊卿,陈雅婷.基于LSTM网络的同步电机励磁绕组匝间短路故障预警[J].电力科学与工程,2020,36(6):37-42.
LI Junqing, CHEN Yating. Field winding short circuit fault warning of synchronous motor excitation winding based on LSTM network[J]. Electric Power Science and Engineering, 2020, 36(6): 37-42.
- [22] 王延年,阮佩,廉继红,等.用于自动驾驶的双注意力机制语义分割方法[J].西安工程大学学报,2023,37(6):114-120.
WANG Yannian, RUAN Pei, LIAN Jihong, et al. A dual attention mechanism semantic segmentation method for autonomous driving[J]. Journal of Xi'an Polytechnic University, 2023, 37(6): 114-120.
- [23] 李云红,马登飞,于惠康,等.多尺度混合注意力网络的图像超分辨率重建[J].西安工程大学学报,2023,37(3):92-100.
LI Yunhong, MA Dengfei, YU Huikang, et al. Multi-scale hybrid attention network for image super-resolution reconstruction[J]. Journal of Xi'an Polytechnic University, 2023, 37(3): 92-100.
- [24] 李季,刘乐,牛雨潇,等.融入注意力的YOLOv3绝缘子串识别方法[J].高压电器,2022,58(11):67-74.
LI Ji, LIU Le, NIU Yuxiao, et al. YOLOv3 Identification method incorporating attention for insulator string[J]. High Voltage Apparatus, 2022, 58(11): 67-74.
- [25] 律方成,金虎,王子建,等.基于组合核多特征融合的GIS局部放电检测与识别[J].电工技术学报,2014,29(10):334-340.
LYU Fangcheng, JIN Hu, WANG Zijian, et al. Gis partial discharge detection and recognition based on the kernel combination and multiple feature fusion method[J]. Transactions of China Electrotechnical Society, 2014, 29(10): 334-340.
- [26] 来春庆,黄勇,朱喆,等.基于特征融合多尺度卷积网络的光伏组件红外图像故障诊断[J].机电工程技术,2023,52(9):145-151.
LAI Chunqing, HUANG Yong, ZHU Zhe, et al. Infrared image fault diagnosis of photovoltaic modules based on feature fusion multi-scale convolutional network[J]. Mechanical & Electrical Engineering Technology, 2023, 52(9): 145-151.
- [27] 向泽林,杨洋,李平,等.基于双通道时频卷积神经网络的故障电弧检测[J].四川大学学报(自然科学版),2024,61(4):198-208.
XIANG Zelin, YANG Yang, LI Ping, et al. Arc fault detection based on dual-channel time-frequency convolutional neural network[J]. Journal of Sichuan University (Natural Science Edition), 2024, 61(4): 198-208.
- [28] 王妮妮,马萍,张宏立,等.基于多尺度深度卷积网络特征融合的滚动轴承故障诊断[J].太阳能学报,2022,43(4):351-358.
WANG Nini, MA Ping, ZHANG Hongli, et al. Fault diagnosis of rolling bearing based on feature fusion of multi-scale deep convolutional network[J]. Acta Energetica Solaris Sinica, 2022, 43(4): 351-358.

(责任编辑 杨海波)

收稿日期:2024-08-14; 修改日期:2024-11-15

作者简介:李俊卿(1967),女,河北保定人,博士,教授,主要研究方向为电气设备故障诊断。