

基于 CNN-Attention-LSTM 的 IGBT 键合线失效状态评估

胡翔政¹, 甘培¹, 李科², 吴文奇², 郭汉挺², 黄先进¹

(1. 北京交通大学 电气工程学院, 北京 100044;

2. 大秦铁路股份有限公司湖东电力机务段, 山西 大同 037300)

摘要: 绝缘栅双极型晶体管(IGBT)作为电力电子系统的核心器件,因其高效率和高开关频率等特性广泛应用于工业控制、交通运输和新能源发电等领域。然而,其内部键合线在长期运行中,易受热应力与电流冲击的影响发生老化与断裂,这也成为IGBT模块失效的主要原因之一。为精准评估键合线的健康状态,提出一种结合卷积神经网络(CNN)、注意力机制与长短期记忆网络(LSTM)的混合模型。通过剪断键合线实验采集短路电流数据,并基于短路电流偏差量将健康状态划分为健康、受损和故障3类,而CNN用于提取短路电流的局部特征,注意力机制聚焦关键时间步的异常变化,LSTM捕捉短路电流的时序依赖关系,从而实现对键合线失效状态的精准分类。结果表明,该模型在验证集上的分类准确率较高,能够有效区分键合线的不同健康状态。研究成果为IGBT模块的健康监测与失效诊断提供了科学依据,具有重要的工程应用价值。

关键词: IGBT器件;键合线;卷积神经网络;长短期记忆网络;健康状态评估

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed26454

Failure State Evaluation of IGBT Bonding Wire Based on CNN-Attention-LSTM

HU Xiangzheng¹, GAN Pei¹, LI Ke², WU Wenqi², GUO Hanting², HUANG Xianjin¹

(1. School of Electric Engineering, Beijing Jiaotong University, Beijing 100044, China;

2. Hudong Electric Power Depot of Daqin Railway Co., Ltd., Datong 037300, Shanxi, China)

Abstract: The insulated gate bipolar transistor (IGBT), as the core device of power electronics system, is widely used in industrial control, transportation and new energy power generation due to its high efficiency and high switching frequency. However, the internal bonding wire is vulnerable to thermal stress and current shock during long-term operation, which has become one of the main reasons for IGBT module failure. A hybrid model combining convolutional neural network (CNN), attention mechanisms, and long short-term memory (LSTM) was proposed to accurately evaluate the health of bonding wire. Short-circuit current data were collected by cutting the bonding wire experiment, and the health state was divided into three categories: healthy, damaged and faulty based on the short-circuit current deviation. CNN was used to extract the local characteristics of the short-circuit current, and the attention mechanism focused on the abnormal change of the key time step. LSTM captured the time-sequence dependence of the short-circuit current, so as to realize the accurate classification of the failure state of the bonding wire. The results show that the model has high classification accuracy on verification set and can distinguish the different health states of bonding wire effectively. The research results provide scientific basis for health monitoring and failure diagnosis of IGBT module, and have important engineering application value.

Key words: insulated gate bipolar transistor (IGBT) device; bonding wire; convolutional neural network (CNN); long short-term memory (LSTM) network; health status assessment

随着电力电子设备在工业自动化、轨道交通和清洁能源等领域的广泛应用,IGBT以其高效率和高开关频率的特性在上述领域中发挥了重要作用。然而,在长期运行过程中,IGBT模块内部

基金项目: 中国铁路太原局集团有限公司科技研究开发计划课题(湖机技术合2023464号)

作者简介: 胡翔政(2002—),男,硕士,Email:24126233@bjtu.edu.cn

的键合线由于承受反复的热应力和电流冲击,容易出现老化和断裂问题。这种退化过程直接削弱了键合线的导电能力,严重时可能导致模块失效,成为IGBT模块性能下降的主要原因之一^[1]。因此,对键合线健康状态的准确评估不仅关系到IGBT模块的可靠性提升,也直接影响到整个系统的安全性与稳定性,是当前研究中的重要挑战之一。

现有研究中,短路电流被广泛认为是表征键合线失效的关键电学特征,其偏差量能够直接反映键合线断裂的累积效应。在键合线退化过程中,短路电流随着键合线的逐步断裂呈现出显著的非线性变化,尤其在阶段,偏差量的变化趋势表现出较强的阶段性特征。这为基于短路电流数据的状态分类提供了重要依据。然而,短路电流的非线性特征与时间依赖性也使得传统的统计方法和浅层机器学习方法难以捕捉其深层规律,导致状态评估的准确性难以满足实际需求。一般来讲,IGBT模块的失效预测方法主要分为解析模型、物理模型和数据驱动模型3类。解析模型通过数学模型模拟IGBT的运行行为,以实现故障预测;物理模型则采用有限元仿真技术,分析模块内部结构的动态变化过程;数据驱动模型更注重基于历史失效数据的分析,通过提取模块的关键参数(如集电极电压、电流和结温等),对失效状态进行分类与预测^[2]。这些方法从不同层面对IGBT的老化失效提供了深入研究视角。

在IGBT键合线失效评估的相关研究中,不同学者提出了多种方法以提升评估精度和可靠性。文献[3]结合热网络模型与仿真技术对键合线老化过程进行分析,大幅提升了结温计算的精度,同时对硬件计算能力提出了更高要求;文献[4]提出基于长短期记忆网络(long short-term memory, LSTM)的参数辨识方法,在处理时序特征方面表现出显著优势,但对输入数据的质量依赖性较强;文献[5]利用有限元仿真研究键合线脱落对健康状态的影响,构建了模块失效进程与结温变化的关联模型,其实现过程相对复杂。文献[6]通过结合贝叶斯优化与双向LSTM(Bo-BiLSTM)网络提升了失效预测的分类精度,但对数据的多样性提出了更高要求;文献[7]采用聚类与分类算法结合的方式,利用K-Means和支持向量机(support vector machines, SVM)完成健康状态区间的划分,方法灵活但模型复杂度较高,需要针对具体工况进一步优化。上述研究为IGBT健康

状态评估提供了重要理论支撑,但在处理复杂时序数据、提取非线性特征及分类精度优化方面仍有进一步提升空间。

研究结合深度学习方法,提出了一种基于卷积神经网络、注意力机制与长短期记忆网络的混合模型,用于对IGBT键合线退化过程的健康状态评估。模型充分利用卷积神经网络(convolutional neural network, CNN)的局部特征提取能力、注意力机制对关键时间步的聚焦能力以及LSTM的时序依赖建模能力,最终实现健康、受损、故障3类状态的精准分类。通过剪断键合线实验采集短路电流数据,计算偏差量,并设定分类阈值,为模型训练与评估提供高质量的数据支撑。研究结果证明了该方法的有效性,为IGBT模块的健康监测和失效预测提供了新思路。

1 IGBT退化过程特性分析

1.1 IGBT模块结构

IGBT模块由多个功能层级组成,每一部分在电流传输、热管理和机械支撑方面均发挥着重要作用。模块内部包含键合线、芯片、芯片焊料层、陶瓷绝缘基板以及散热器等核心组件,如图1所示。键合线用于连接芯片的顶部电极与外部电路,承担大电流的导通与传输功能。芯片通过焊料层固定在DBC基板上,焊料层不仅提供了可靠的机械连接,还通过良好的导热性能将芯片工作中产生的热量高效传递至DBC。DBC基板由陶瓷绝缘层与上下铜箔组成,其优异的导热性和电绝缘性为芯片和键合线提供稳定的支撑与电气连接。最底层的散热器则将热量进一步导出模块,确保运行过程中模块的热量能够迅速散失^[8]。




图1 IGBT模块结构图

Fig.1 IGBT module structure diagram

IGBT模块的多层结构设计在电气性能、机械稳定性和散热能力之间达成了良好的平衡,从而满足高功率密度和高可靠性应用的需求。

1.2 键合线退化特性分析

在IGBT模块中,键合线作为连接芯片与外部电路的关键部件,其失效将显著影响模块的电

气性能和运行稳定性。键合线断裂会导致短路电流发生明显的变化,而这种变化又与IGBT模块的导通特性密切相关。在模块导通时,IGBT的等效结构可以看作一个P-i-N二极管与一个线性运行区的MOSFET组成的复合结构,如图2所示。其中,P-i-N二极管负责承载模块的大部分电流,而MOSFET则通过调节栅极电压实现对导通状态的控制。




图2 IGBT结构上的等效电路

Fig.2 Equivalent circuit on IGBT structure

随着键合线断裂,模块的等效电路特性发生改变,导通压降会因键合线老化脱落引发的热积累而显著增加,从而对模块的稳定运行构成威胁。在集电极电流密度较小时,饱和压降主要由P-i-N二极管引起;而随着集电极电流密度增加,饱和压降逐渐由MOSFET的导通压降主导。当键合线失效程度加剧时,模块的导热性能进一步恶化,导致内部温度显著升高,进而加剧了饱和压降的上升趋势。这种恶性循环对模块的长期可靠性提出了更高的要求。

本研究采用的IGBT模块如图3所示,其展示了IGBT模块的实际结构以及键合线与芯片的详细连接方式,直观体现了键合线在IGBT模块电气传输与结构支撑中的关键作用。

除了导通压降,短路电流的变化特性在键合线断裂的不同阶段表现出明显的趋势,这为评估键合线的退化状态提供了重要的参考依据,本研究即着重关注短路电流与键合线退化的关系。结合文献[9]中处于短路工况时IGBT的短路电流公式,可推导出芯片并联数为 a ,每个芯片上的键合线数量为 b 的模块,其短路电流表达式如下式




图3 键合线在IGBT模块上的实物示意图

Fig.3 Physical diagram of bonding wire on IGBT module

所示:

$$I_{SC} = a \frac{\mu_{ni} C_{ox} Z}{2L_{ch}(1 - \alpha_{PNP})} (V_{GE} - \frac{RI_{SC}}{ab} - V_{TH})^2 \quad (1)$$

式中: R 为单根键合线的电阻; μ_{ni} 为电子迁移率; C_{ox} 为氧化层电容; Z 为沟道宽度; L_{ch} 为沟道长度; α_{PNP} 为PNP晶体管的共基极放大倍数; V_{GE} , V_{TH} 分别为模块栅射极电压和栅极阈值电压。

由式(1)可知,IGBT模块的短路电流受其材料、结构特性以及键合线的共同影响。随着IGBT的老化失效,键合线数量或并联芯片数量减少,即 a 或 b 减小,会导致短路电流 I_{SC} 随之降低。

在健康阶段,所有键合线均处于完整状态,短路电流基本保持正常水平,此时偏差量极小,IGBT模块能够稳定运行;进入受损阶段时,部分键合线逐渐断裂,短路电流开始出现下降趋势,偏差量随之增大,但整体变化幅度仍较为平稳;当进入故障阶段时,键合线断裂达到一定临界数量,短路电流急剧下降,偏差量迅速增大,模块的电气性能与可靠性受到严重影响。上述阶段的变化特性表明,键合线断裂数量与短路电流偏差量之间存在明确的关联性,研究这一变化规律对模块健康状态的分类与评估具有重要意义。

2 IGBT短路电流实验与数据分析

2.1 短路电流实验设计

为深入探究IGBT模块键合线退化过程中健康状态的变化规律,本研究设计并开展了基于逐步剪断键合线的短路电流实验。图4展示了短路测试实验的原理图,在实际电路中对应直流电源、示波器、IGBT驱动电路、信号发生器以及测试模块。该实验通过对英飞凌公司的FF450R17ME4模块键合线进行剪断操作,模拟其逐步老化或失效的过程,研究其对短路电流的影响程度。为了尽量

减少外部因素的干扰,实验在特定环境温度下进行,并通过高精度传感器实时监测电流,确保采集数据的准确性和稳定性。

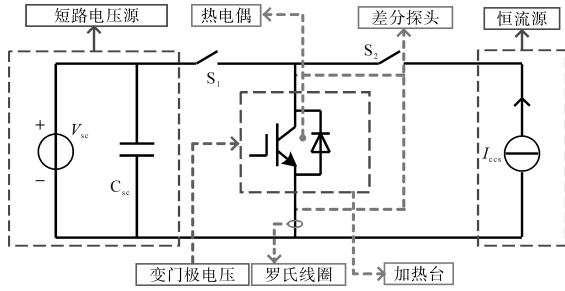


图4 短路测试实验原理图

Fig.4 Schematic diagram of short-circuit test experiment

实验中,首先对IGBT模块进行初始化,确保键合线处于健康状态,并记录短路电流的初始值作为基准数据。随后,逐次剪断键合线,每次剪断一根键合线即记录相应的短路电流变化值,直至键合线断裂数量达到8根。通过对剪断前后短路电流的对比分析,能够直观反映键合线状态与短路电流之间的关系。同时,为了保证实验数据的完整性和可靠性,在每次剪断操作后,均通过多次重复采样和波形监测以排除偶然误差。此外,为防止环境因素对结果的干扰,采样点选择在电流波形稳定时进行记录,最大程度还原键合线失效对短路电流的真实影响。由于实验次数较多,此处只展示实验采集的数据波形示意图,如图5所示,其展示了在不同键合线状态下短路电流的动态变化特性,不同测试条件下其曲线也会有对应的差异,相应数据以数据表的形式暂存。




图5 实验波形示意图

Fig.5 Schematic diagram of experimental waveform

通过对波形细节的分析,可以提取反映键合线健康状态的关键参数。例如,自激短路的回路特性、短路电流下降的幅度等,其均能够提供关于键合线退化的重要信息,也为后续的数据采集与处理过程提供了一定的理论支撑。

2.2 数据采集与偏差计算

实验数据采集过程中,基于波形图对应的数据表,分别提取了剪断0根到8根键合线时的短路电流值,形成了一个多维数据集。数据集包含两部分:一是健康状态下的基准电流值(剪断0根键合线);二是逐次剪断键合线后的短路电流值。

基于采集到的原始电流数据,计算短路电流的偏差量,具体公式如下:

$$\text{偏差量} = \frac{|I_{\text{断裂}} - I_{\text{健康}}|}{I_{\text{健康}}} \times 100\% \quad (2)$$

式中: $I_{\text{健康}}$ 为健康状态下的短路电流值; $I_{\text{断裂}}$ 为剪断键合线后的短路电流值。

通过计算各阶段的偏差量,可观察到短路电流在不同根数键合线断裂时,偏差量和变化幅度。

此外,为提高数据的适配性和准确性,对采集到的数据进行了归一化处理,公式如下:

$$I_{\text{归一化}} = (I - I_{\text{最小值}}) / (I_{\text{最大值}} - I_{\text{最小值}}) \quad (3)$$

式中: I 为原始短路电流值; $I_{\text{最大值}}$, $I_{\text{最小值}}$ 分别为整个数据集中短路电流的最大值和最小值。

归一化后的数据范围为[0, 1],能够有效避免数值差异过大对后续模型训练造成的不稳定性。

2.3 阈值划分与结果分析

在IGBT模块的键合线退化状态评估中,短路电流被选为主要的状态特征量,主要基于其物理关联性和数据表现的优越性。键合线作为电流传输的核心路径,当发生老化或断裂时,电流通受到阻碍,短路电流随之减小,这一变化直接反映了键合线的健康状态,且随着断裂数量的增加,短路电流的下降趋势愈加显著,具有明显的阶段性特征。此外,短路电流易于测量,测试条件易控且数据稳定,能够确保高精度的数据采集。在对比其他指标时, V_{CE} 和结温虽与IGBT模块的状态存在一定关联,但 V_{CE} 主要受温度变化影响,变化较为平缓,难以准确反映键合线逐步退化的过程;结温则受外部因素影响较大,存在一定的滞后性,难以直接与键合线的失效过程建立高关联性。相比之下,短路电流对键合线退化状态的响应更加灵敏,能够清晰地区分健康、受损与故障3类状态,且具有显著的非线性变化特征。

基于剪断键合线实验获得的原始短路电流数据综合分析,为了准确地反映不同剪断键合线数对短路电流的总体影响,选取对应短路电流数

据的平均值,将短路电流偏差量按剪断键合线数量进行排序,观察偏差量的变化趋势,可得其在不同状态下的短路电流值及偏差量对应关系,如图6所示。




图6 动态偏差变化图

Fig.6 Dynamic deviation variation chart

结果显示,偏差量在0~4根键合线断裂时分布较为集中,最大值约为4%左右;第5~7根键合线断裂时,偏差量逐渐增加,约为4%~8%;而在第8根键合线断裂时,偏差量显著增加且达到10%以上,可认为进入故障区间。综合考虑测量偏差及裕度问题,通过对短路电流偏差量的分布特性进行统计分析,此处选取4.5%和8.5%作为健康、受损和故障状态的分类阈值,将短路电流偏差量划分为健康、受损和故障3个类别。

3 混合神经网络模型构建与参数设置

3.1 数据预处理

由于实验条件限制,原始数据的样本量相对较少,而深度学习模型通常需要大量样本来实现较好的泛化性能。为了解决数据量不足的问题,研究采用了数据增强技术扩充数据集。例如,在短路电流数据上叠加高斯噪声,模拟键合线在不同老化状态下的电流波动;此外,还通过引入随机扰动(如随机微调采样点、调整幅度等)生成多样化的样本。经过这些操作,数据集的样本量得到了显著提升,同时保留了数据的基本特性,有效提高了模型的泛化能力。

在标签的生成与划分中,基于短路电流偏差量的阈值设定,将健康状态、受损状态和故障状态分别对应的偏差区间划分为 $[0, 4.5\%]$, $[4.5\%, 8.5\%]$ 以及 $[8.5\%, +\infty]$ 。经过处理后,完整数据集中85%划分为训练集,15%划分为验证集,并确保每个类别在两个子集中保持分布的一致性。

3.2 卷积神经网络与注意力机制

卷积神经网络是一种广泛应用于图像、信号和时序数据处理的深度学习算法,其核心由卷积

层、池化层和全连接层构成,用于提取数据的层次化特征。输入数据通过卷积层的卷积核与特定窗口滑动计算,提取局部特征;通过池化层降低特征图的维度,提高模型的计算效率,同时保留关键信息。这些提取的特征最终传递到全连接层,用于完成具体的分类或回归任务,图7展示了典型卷积神经网络的结构及其工作原理。




图7 卷积神经网络结构图

Fig.7 Convolutional neural network structure

此外,为提升模型对关键特征的捕捉能力,引入了注意力机制作为特征加权模块。在CNN提取的局部特征基础上,通过计算每个时间步的重要性权重,自动聚焦对分类结果影响较大的时间步数据。具体到实现过程上,注意力机制通过权重矩阵与输入特征的逐点相乘操作,突出高权重时间步的数据贡献,并生成全局加权后的特征表征,为后续的LSTM网络的时序依赖建模提供更具区分度的输入。

3.3 长短期记忆网络

长短期记忆网络是一种能够处理长时间序列依赖的循环神经网络(RNN),其设计目的在于解决传统RNN在长序列训练中容易出现的梯度消失与梯度爆炸问题。LSTM通过引入遗忘门、输入门和输出门等门控机制,动态调节信息的记忆与遗忘,使得网络能够有效捕捉长时间跨度的依赖关系。图8展示了LSTM单元的内部结构及信息流动过程。




图8 长短期记忆网络结构图

Fig.8 Structure of long short-term memory network

通过上述机制,LSTM能够捕捉到输入数据的时间序列依赖特性,并在长时间跨度的序列建模中发挥更好的作用。

3.4 模型参数设计与优化

在IGBT模块键合线失效评估中,短路电流的动态变化与键合线断裂数量密切相关。为了保证计算效率与准确率的平衡,CNN及LSTM层数均设置为1,单元数均设置为32,卷积核设置为3,选择ReLU激活函数,这一设置能够保证模型对时间序列特征的有效建模,同时避免参数过多导致训练时间延长和过拟合风险。基于其具备自适应学习率调整的特性,优化器选择Adam(自适应矩估计),其能够在训练过程中根据梯度的稀疏性与分布特征动态调整学习率,适用于非线性数据建模的任务。学习率设置为0.0005,经过多次实验验证,该学习率能够有效平衡模型的收敛速度与训练稳定性,避免学习率过高导致模型振荡或过低导致收敛缓慢。Dropout率设置为0.3,主要用于防止模型过拟合,在模型训练时随机屏蔽部分神经元,以提高模型的泛化能力。此外,批量大小设置为256,能够在单次训练中保证足够的样本量,平滑梯度更新,进一步提高模型的训练效率。

混合模型的整体评估流程如图9所示,此处将CNN与LSTM进行结合,通过注意力机制突出关键时间步,有效实现了特征提取与时序建模的结合。CNN提取短路电流数据的局部特征,而LSTM则将这些特征建模为连续的时间序列,捕捉键合线失效随时间累积的动态变化。注意力机制进一步增强了对关键时间步的关注,有助于识别关键特征信息,提升分类效果。

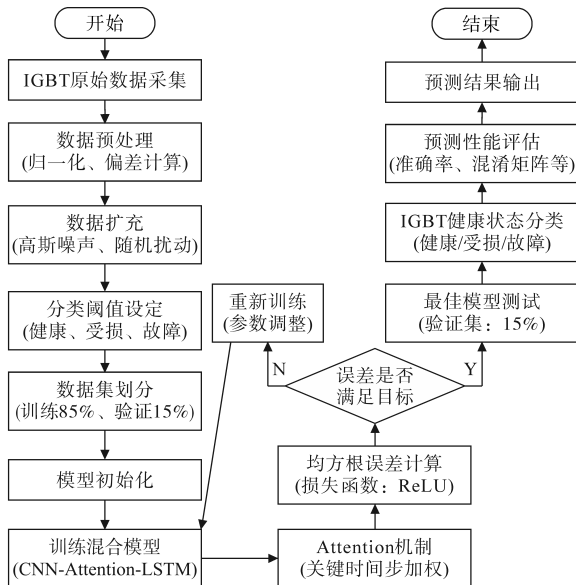


图9 整体评估流程图

Fig.9 Overall evaluation flow chart

4 模型结果与性能评估

4.1 模型分类结果

实验环境采用Anaconda3和Python3.12,编译环境使用Jupyter Notebook,实验框架采用PyTorch。通过在验证集上验证训练好的混合模型,得到健康、受损和故障3类状态的分类结果。模型在验证集上的整体准确率达到较高水平,表明该方法能够有效区分不同退化状态。在实际分类中,健康状态的识别准确率最高,受损状态的识别效果次之,而故障状态的分类表现稍有波动。这一结果与数据分布特点密切相关,受损状态与故障状态的特征相对接近,导致部分样本在分类过程中出现混淆。

此处绘制了如图10所示的混淆矩阵,可以直观地展示模型的分类效果,混淆矩阵是一个方阵,行表示真实标签,列表示预测标签,其直观展示了模型在不同类别上的预测表现。从混淆矩阵可以看出,健康类别的预测误差较小,而受损与故障类别之间存在少量误分类,主要由于两类样本在偏差量上的分布存在一定重叠。




图10 基于CNN-Attention-LSTM的混淆矩阵

Fig.10 Confusion matrix based on CNN-Attention-LSTM

为了进一步验证上述基于CNN-Attention-LSTM的混淆矩阵的优越性,研究将其与分别使用卷积神经网络和长短期记忆网络的模型进行对比。使用上述两种常见的神经网络架构输出的混淆矩阵如图11、图12所示。

从图11和图12所示的混淆矩阵可以看出,仅使用CNN和LSTM在故障诊断任务中的表现较为相似,但在某些类别的分类上存在差异。CNN模型虽然在健康和故障状态下表现出较好的预测准确性,但对于受损类别的误分类率较高,特别是将受损类别误判为故障的情况较为明显。




图 11 基于 CNN 的混淆矩阵

Fig.11 Confusion matrix based on CNN




图 12 基于 LSTM 的混淆矩阵

Fig.12 Confusion matrix based on LSTM

LSTM 模型在处理时序数据时能较好地捕捉短路电流的动态变化,虽然其在故障状态的识别上有所改善,但仍存在一定的误分类,尤其是受损和故障类别的区分。相较之下,混合 CNN-Attention-LSTM 的模型在这些类别的区分上表现出更高的准确率,进一步验证了其在此任务中的优越性。

4.2 模型性能评估

为了全面评价模型的性能,选取整体分类准确率以及各类别的精确率、召回率和 F1 分数作为主要指标,结果如表 1 所示。

表 1 模型性能评估指标

Tab.1 Performance evaluation indexes of the model

指标	精确率/%	召回率/%	F1 分数/%	支持样本数
健康	99.62	99.62	99.62	262
受损	98.23	97.88	98.05	283
故障	97.74	98.18	97.96	220

其中,精确率用于衡量在所有预测为某类别的样本中,实际属于该类别的比例;召回率则表示实际属于某类别的样本中,模型正确预测的比例;F1 分数结合了精确率和召回率的调和平均,

用于综合评估模型的整体性能;支持样本数则用于表明每个类别的实际样本数量,以反映类别间样本不均衡对模型性能的影响。此外,由于本研究属于分类任务,且类别之间样本分布不均,单独评估某个类别的 F1 分数可能会导致结果的偏差,无法真实反映模型的全面能力。因此,此处额外选择加权平均的 F1 分数作为评估标准,图 13 展示了训练过程中 F1 分数的变化。




图 13 F1 分数曲线

Fig.13 F1 score curve

从各类别指标来看,健康状态的精确率和召回率均接近 100%,表明模型在预测健康状态样本时具有极高的可靠性。而受损和故障状态的精确率和召回率略有下降,可能与数据标签划分过程中类别间的样本数量分布不均有关。而根据 F1 分数曲线,模型在训练过程中表现稳定,F1 分数始终维持在较高水平,表明其在多个类别上的分类能力较为均衡。尽管存在一定波动,但总体趋势表明模型在多轮训练后保持了较好的鲁棒性和稳定性。

在模型的训练过程中,下方输出的图 14 展示了训练损失和训练准确率的变化。可以看到,随着训练的推进,训练损失逐步降低,准确率不断提高,表明模型在训练集上的学习效果良好。




图 14 训练集损失与准确率曲线

Fig.14 Training set loss and accuracy curves

图 15 则展示了验证损失和验证准确率的曲线,验证集上的损失逐渐下降,准确率逐步上升,说明模型在未见数据上的泛化能力较强。

同时,图 14 和图 15 通过模型对数据集损失




图 15 验证集损失与准确率曲线

Fig.15 Verification set loss and accuracy curves

与准确率曲线的展示,也表明模型参数的优化设置是合理的,通过引入 Dropout 层有效防止了过拟合风险,提高了模型的泛化能力,模型的性能在不同状态分类任务中表现出较高的稳定性。

4.3 模型改进与优化讨论

虽然模型在短路电流数据上的分类表现较好,但受数据特征与样本分布的影响,仍存在进一步优化空间。首先,针对受损与故障状态的分类混淆问题,可以引入更复杂的注意力机制,如自注意力机制(self-attention),以更精确地聚焦于关键时间步,减少类别间的误分类率。此外,可以增加 LSTM 层的深度,增强时序建模能力,以更好地捕捉短路电流偏差的动态变化特征,也可以结合其他传感器数据(如温度和电压特性),通过多模态数据融合方法进一步提高分类性能。

在模型参数优化方面,可尝试使用网格搜索或贝叶斯优化等方法,对卷积核大小、LSTM 单元数、学习率和 Dropout 率进行自动调参,以进一步提升模型性能。

5 结论

研究提出了一种基于 CNN-Attention-LSTM 的混合模型,实现了对 IGBT 模块键合线健康状态的评估。

1)通过剪断键合线实验,采集短路电流数据并计算偏差量,科学划分健康、受损与故障 3 类状态,为模型训练提供高质量标签。

2)混合模型结构设计合理,充分利用了 CNN 的局部特征提取能力、注意力机制的关键时间步聚焦能力以及 LSTM 的时序建模能力,在验证集上的分类准确率达到较高水平。

3)研究结果为 IGBT 模块的健康状态监测与故障预测提供了理论依据与技术支持,具有广泛的工程应用前景,尤其在电力电子设备的状态监

测和维护管理领域具有重要的推广价值。

参考文献

- [1] YANG S, BRYANT A, MAWBY P, et al. An industry-based survey of reliability in power electronic converters[J]. IEEE Trans. on Ind. Appl., 2011, 47(3): 1441-1451.
- [2] 陈雨晨,陈凯楠,郑树轩,等.无线电能传输磁耦合机构磁心解析模型与设计方法[J].电气技术,2022,23(6):83-92.
CHEN Yuchen, CHEN Kainan, ZHENG Shuxuan, et al. Analytical model and design method of magnetic core for wireless power transfer magnetic coupler[J]. Electrical Technology, 2022, 23(6): 83-92.
- [3] 何梦宇,许智亮,谢望玉,等.计及 IGBT 模块键合线与芯片焊料层老化的热网络法结温计算[J].铁道机车车辆,2024, 44(4):28-35.
HE Mengyu, XU Zhiliang, XIE Wangyu, et al. Junction temperature calculation by thermal network method considering IGBT module bonding wire and chip solder layer aging[J]. Railway Rolling Stock, 2024, 44(4): 28-35.
- [4] 金声超,罗玮,暨力,等.基于长短期记忆神经网络参数辨识的 IGBT 模块老化判据[J].电气应用,2024,43(11):96-103.
JIN Shengchao, LUO Wei, JI Li, et al. IGBT module aging criterion based on long short term memory neural network parameter identification[J]. Journal of Electrical Applications, 2024, 43(11): 96-103.
- [5] 史明明,葛雪峰,任政焱,等.基于 ANSYS 的 IGBT 模块健康状态研究[J].电力电子技术,2021,55(12):65-68.
SHI Mingming, GE Xuefeng, REN Zhengyi, et al. Research on health status of IGBT module based on ANSYS[J]. Power Electronics Technology, 2021, 55(12): 65-68.
- [6] 万庆祝,于佳松,佟庆彬,等.基于 Bo-BiLSTM 网络的 IGBT 老化失效预测方法[J].电气技术,2024,25(3):1-10.
WAN Qingzhu, YU Jiasong, TONG Qingbin, et al. IGBT aging failure prediction method based on Bo-BiLSTM network[J]. Electrical Technology, 2024, 25(3): 1-10.
- [7] 王志远,孙鹏菊,王海波,等.基于聚类分类算法的 IGBT 健康状态分类研究[J].电工电能新技术,2021,40(11):1-8.
WANG Zhiyuan, SUN Pengju, WANG Hai-bo, et al. Research on IGBT state classification based on cluster and classification algorithm[J]. New Technology of Electroengineering and Electric Energy, 2021, 40(11): 1-8.
- [8] 王学梅,张波,吴海平.基于失效物理的功率器件疲劳失效机理[J].电工技术学报,2019,34(4):717-727.
WANG X M, ZHANG B, WU H P. A review of fatigue mechanism of power devices based on physics-of-failure[J]. Transactions of China Electrotechnical Society, 2019, 34(4): 717-727.
- [9] PENGJU S, CAN G, XIONG D, et al. Condition monitoring IGBT module bond wires fatigue using short-circuit current identification[J]. IEEE Transactions on Power Electronics, 2017, 32(5): 3777-3786.

收稿日期:2025-02-12

修改稿日期:2025-05-12