

基于遗传算法优化卷积神经网络的IGBT剩余寿命预测

龚丹丹¹, 李涵¹, 袁颖¹, 赵立有²

¹上海对外经贸大学统计与信息学院, 上海

²上海精密计量测试研究所元器件保证事业部, 上海

收稿日期: 2023年11月13日; 录用日期: 2023年12月20日; 发布日期: 2023年12月28日

摘要

绝缘栅双极性晶体管(Insulated gate bipolar transistor, IGBT)是一种常用于功率电子设备的半导体器件,在电力变换和驱动系统中有着广泛的应用,其稳定性和可靠性对电力系统和工业应用具有重要意义。传统的基于数据驱动的方法针对不同场景无法做到统一,且其预测过程不够直观。本文提出一种更具普适性且直接预测出剩余寿命的方法,首先对IGBT加速老化时的稳态数据和瞬态数据进行分析,提取出和老化相关的9个特征因素,建立卷积神经网络的IGBT剩余寿命预测模型,并用遗传算法进行优化,以提高预测模型的性能和收敛速度。结果表明,基于遗传算法改进的卷积神经网络预测模型准确率高,误差小,相比于SVR、MLP和CNN网络,更能准确地预测出IGBT的剩余寿命。

关键词

IGBT剩余寿命预测, 卷积神经网络, 遗传算法

Prediction Remaining Life of IGBT Using Convolutional Neural Network Optimized by Genetic Algorithm

Dandan Gong¹, Han Li¹, Ying Yuan¹, Liyou Zhao²

¹School of Statistics and Information, Shanghai University of International Business and Economics, Shanghai

²Components Assurance Department, Shanghai Precision Metrology and Test Research Institute, Shanghai

Received: Nov. 13th, 2023; accepted: Dec. 20th, 2023; published: Dec. 28th, 2023

Abstract

Insulated gate bipolar transistor (IGBT) is a semiconductor device commonly used in power elec-

tronic devices. It has a wide range of applications in power conversion and drive systems, and its stability and reliability are of great significance for power systems and industrial applications. Traditional data-driven methods cannot achieve uniformity for different scenarios, and their prediction process is not intuitive enough. This article proposes a more universal and direct method for predicting the remaining lifespan of IGBT. Firstly, the steady-state and transient data during accelerated aging of IGBT are analyzed, and 9 characteristic factors related to aging are extracted. A convolutional neural network model for predicting the remaining lifespan of IGBT is established, and optimized using genetic algorithm to improve the performance and convergence speed of the prediction model. The results show that the improved convolutional neural network prediction model based on genetic algorithm has high accuracy and small error, and can more accurately predict the remaining life of IGBT compared to SVR, MLP, and CNN networks.

Keywords

IGBT Remaining Life Prediction, Convolutional Neural Network, Genetic Algorithm

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

绝缘栅双极型晶体管具有高电压、高电流和高开关速度等优良特性，其涉及到各个领域，比如航空航天、军用领域、电子通讯、医疗器械、再生能源等。然而，由于 IGBT 器件在工作过程中会遭受高温、大电流和高压等恶劣环境，随着使用时间的增加，器件可能会发生各种故障和老化失效的问题[1]。IGBT 发生故障后，不仅会导致整个电气系统瘫痪，还有可能发生连锁反应损坏其他相关部件，因此预测 IGBT 的寿命对于电力系统和工业应用具有重要意义[2] [3]。

目前研究方法可以分为基于物理模型的有限元仿真方法、基于解析模型的实验统计方法和基于数据驱动的方法三大类。

基于物理模型的有限元仿真方法：该方法主要是基于 IGBT 器件的物理特性和工作原理来建立数学模型，通过模拟器件的参数和环境条件来预测寿命。这些方法通常需要深入了解 IGBT 的物理特性和材料特性以及外部的应力因素。例如：黄小华[4]等人通过有限元仿真方法，找到了温度、热膨胀系数等因素对应力应变的影响，杜雄[5]等人借助 IPOSIM 仿真软件用物理热模型计算模块温度，然后使用基于能量的物理模型预估剩余寿命。物理模型方法能够在已知 IGBT 参数和运行环境的情况下较准确地预测寿命，但通常各参数的确定较为困难，所以在实际应用中非常受限。

基于解析模型的实验统计方法：该方法通过拟合模块的剩余寿命与模块电气参数的关系表达式，来计算剩余寿命。实验发现 IGBT 老化的循环总次数与温度的关系符合 Coffin-Manson 理论，毛娅婕[6]等人通过做大量的老化试验，求解了 Coffin-Manson 理论的待估参数，从而确定了结温与寿命的解析公式。Bayerer [7]等人提出了 Bayerer 模型，除了结温，还增加了负载电流、阻断电压、升温时间、键合线直径等物理量，该模型考虑的因素更为全面，预测精度也更高。但是这种方法想要准确估计各参数的值，需要做大量的实验，并不适用与实际工况中需要快速结果的情况。

基于数据驱动的方法：该方法主要依赖于采集的 IGBT 工作数据，如电流、电压、温度、振动等，以及器件寿命数据，通过数据分析和机器学习技术来预测寿命[8]。国内外的研究包括使用监督学习算法

如回归分析、支持向量机、神经网络等,以及无监督学习算法如聚类分析等来建立 IGBT 寿命预测模型[9]。起初, Alghassi A [10]等人选择集电极 - 发射极电压作为老化参量,使用高斯回归和贝叶斯相结合的方法预测了 IGBT 模块的剩余寿命。Ahsan M [11]等人选择集电极 - 发射极电压作为老化参量,通过比较神经网络和模糊推理两种方法,证明了神经网络方法在 IGBT 寿命预测中的优势。之后为提高预测精度,研究者们不断地对机器学习方法进行改进,比如 Liu Z [12]等人发现集电极 - 发射极的噪声较大,提出了一种改进的极限学习预测剩余寿命,并与同类算法进行比较发现该算法效果更好。

基于数据驱动的方法的研究思路大致是:确定老化参量,预测老化参量的未来趋势,确定失效标准进而推测老化参量。但当 IGBT 的应用场景不同,反映其老化的物理参量及其失效标准也会发生变化,很难将其统一。随着深度学习的不断发展,本文将采用卷积神经网络直接预测出其剩余寿命,预测更为直观,且预测精度更好。

2. 基于遗传算法改进的卷积神经网络

2.1. 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是深度学习中的经典模型。与传统神经网络相比, CNN 通过卷积层中的卷积核提取输入数据的特征,通过池化层对有效特征进行提取,并通过局部连接对输入数据的相关性进行分析,权值共享和子采样,降低了相同网络规模下待训练的参数量与计算量。图 1 为典型的卷积神经网络结构图。可以看到,基本的 CNN 包括输入层、隐藏层、输出层,其中隐藏层包括三个环节:卷积层、池化层和全连接层[13]。




Figure 1. CNN structure
图 1. 卷积神经网络模型示意图

卷积层由一组卷积核组成,其作用是对输入矩阵进行递归操作,以提取相应的特征。卷积层从上一层神经网络取一小部分,选择一个卷积核放进被卷积层中,将卷积核乘以对应的被卷积层中的神经元的值,即可得到卷积结果。接着,再按固定的方向进行遍历并进行卷积计算,最终得到卷积结果。在训练过程中,卷积层需要设置移动步长(s),表示每次卷积核所移动的长度,则输出结果的大小可以表示为:

$$output_size = floor\left(\frac{i-f}{s} + 1\right) \tag{1}$$

式中, floor 表示取整函数, i 表示输入边长, f 表示卷积核边长。

池化层通常在卷积层之后,通过对输入数据进行局部运算来降低卷积层输出的特征维数,降低后续网络训练复杂度。池化层有两种方式:平均池化和最大池化,公式如下所示。

$$y_{pool_avg} = avg(x[i, j]), i \in [1, k], j \in [1, k] \tag{2}$$

$$y_{pool_max} = max(x[i, j]), i \in [1, k], j \in [1, k] \tag{3}$$

经过卷积和池化运算,最后一个池化层的输出转化为了一个一维特征向量,作为输入送入全连接层,全连接层完成特征到输出层的映射,连接到网络的输出层,完成分类或预测。

在训练卷积神经网络时,需要更新的参数包括:卷积核、全连接层的权重以及激活函数的参数。网

络训练结果受权重初始值影响较大,且初始参数为随机产生,可能使损失函数过早收敛,得到局部最优解,影响预测精度[14][15]。

2.2. 遗传算法

遗传算法是一种随机全局搜索优化方法,它从任意初始种群出发,通过随机选择、交叉和变异操作,产生一群更适合环境的个体,使群体进化到搜索空间中越来越好的区域,最后收敛到一群最适应环境的个体,从而求得问题的优质解[16][17][18]。遗传算法具有良好的鲁棒性和全局搜索能力,算法的主要流程如图2所示。

(1) 创建初始种群:初始种群是随机选择的一组有效候选解(个体)。并确定种群的大小以及取值范围。

(2) 计算适应度:适应度函数的值是针对每个个体计算的。对于初始种群,此操作将执行一次,然后在应用选择、交叉和突变的遗传算子后,再对每个新一代进行。由于适应度计算之后的选择阶段通常认为适应度得分较高的个体是更好的解决方案,因此遗传算法专注于寻找适应度得分的最大值。

(3) 选择、交叉和变异:将选择,交叉和突变的遗传算子应用到种群中,就产生了新一代,该新一代基于当前代中较好的个体。选择操作负责在当前种群中选择有优势的个体;交叉操作从选定的个体创建后代;变异操作可以将每个新创建个体的一个或多个染色体值随机进行变化。

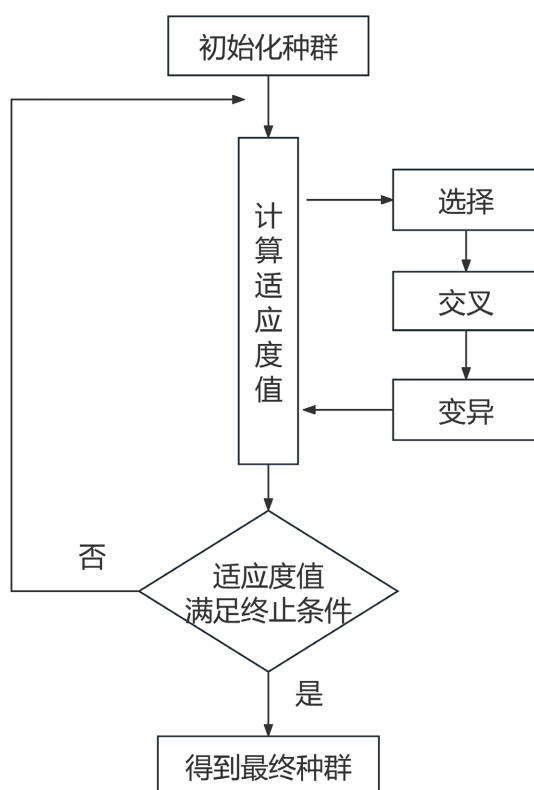


Figure 2. Genetic algorithm structure

图2. 遗传算法的流程图

2.3. 基于遗传算法改进的卷积神经网络

传统的卷积神经网络的学习性能受超参数的选择和初始化参数的设置影响较大,为解决这一问题,本文提出了结合遗传算法优化的卷积神经网络模型,其基本框架如下图3所示。

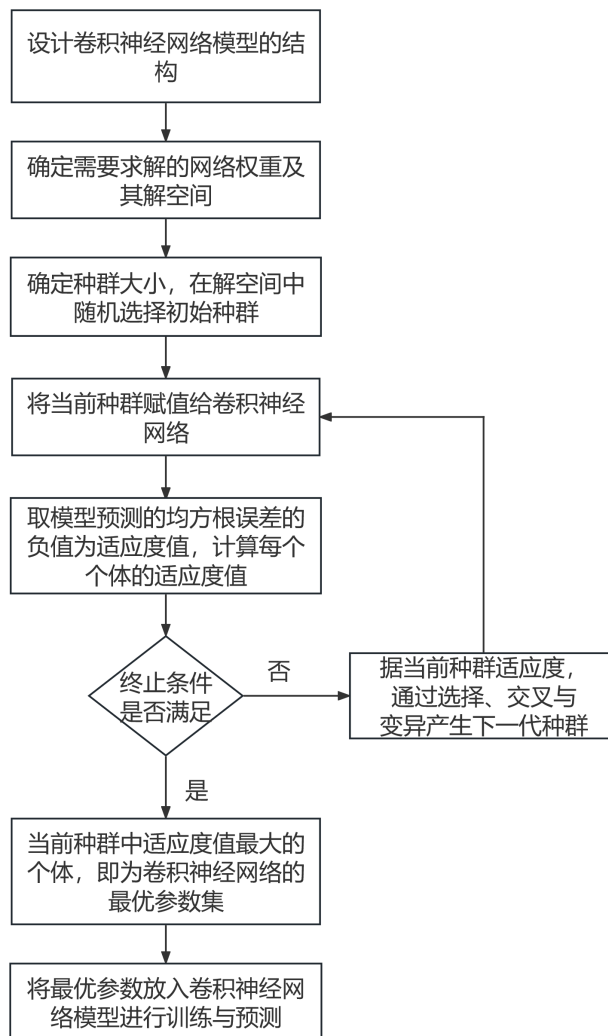


Figure 3. GA-CNN structure
图 3. GA-CNN 流程图

基本思路是将卷积层和全连接层的各参数作为遗传算法的染色体，经选择、交叉、变异操作，得到参数的最优解，并用于卷积神经网络预测模型，具体步骤如下。

- (1) 确定好需要优化的超参数和初始化参数，并确定解空间以及种群大小。
- (2) 定义一个适应度函数，用来衡量个体的性能，本文需要衡量 CNN 模型的预测性能。
- (3) 在解空间中随机选择初始种群，并对种群进行二进制编码。
- (4) 将当前种群的参数赋值给卷积神经网络，计算适应度，执行遗传算法的迭代过程，即选择、交叉和编译操作，并选择优秀的个体用于下一代。
- (5) 根据适应度函数值判断是否停止迭代，如果满足条件则进入下一步，否则重复第(4)步。
- (6) 在遗传算法的最后一代，根据适应度函数值选择最佳的个体，作为卷积神经网络的最优参数，并用该网络进行预测。

卷积神经网络训练结果受权重初始值影响较大，容易陷入局部最优，影响预测效果，而遗传算法有很好的全局搜索能力，不容易陷入局部最优[19]。经遗传算法输出的最优参数集，更适合用于模型训练，基本上避免了陷入局部最优的问题，预测精度也更好。

3. 实验结果分析

3.1. 数据准备

本文的数据集采用了 NASA 公布的 IGBT 老化数据集，NASA 研究人员在栅极施加方波电压进行加速老化实验，同时测量电气参数，经过 418 次开通 - 关断之后，IGBT 模块出现了闩锁效应，认为 IGBT 彻底失效。测量的电气参数有栅极电压、集电极 - 发射极电压、集电极 - 发射极电流，由于电参数在一个周期内变化幅度较大，原始数据不适合放入模型，所以先对电参数进行特征提取，本文提取的特征如下表 1 所示。

Table 1. Extracted features

表 1. 提取特征表

特征名称	计算公式
Mean	$\mu = \sum_{i=1}^N s_i / N$
Max	$Max = \max(s_i)$
Min	$Min = \min(s_i)$
Peak Value	$PV = \max(s_i) - \min(s_i)$
Variance	$\sigma^2 = \sum_{i=1}^N (s_i - \mu)^2 / N$
RMS	$RMS = \sqrt{\sum_{i=1}^N s_i^2 / N}$
Kurt	$Kurt = \sum_{i=1}^N ((s_i - \mu) / \sigma)^4 / N - 3$
Skew	$Skew = \sum_{i=1}^N ((s_i - \mu) / \sigma^3) / N$
MAV	$MAV = \sum_{i=1}^N s_i / N$

为了剔除冗余特征，减少计算量，本文根据如下规则进行了特征选择。

(1) 特征与目标变量的相关性：剔除与剩余寿命的相关系数的绝对值小于 0.3 的特征。

(2) 特征之间的相关性：计算特征之间的相关性，选出相关性高于 0.7 的特征，从中剔除与剩余寿命相关性第的特征[20]。

最终进入模型的特征有：集电极 - 发射极电压的最大值、均值、绝对值均值，集电极 - 发射极电流的均方根、绝对值均值、均值、峰态、方差、偏态，下文用 x_1, \dots, x_9 表示。

由于经典的卷积神经网络是用于图像识别的二维卷积神经网络，再考虑到我们的数据是时间序列数据，而卷积神经网络不能之间学习特征之间的时序关系，所以本文的输入数据，除了本周期的电参量特征，再追加当下前 5 个周期的电参量特征，共同作为输入数据，现在输入数据转变成 6×9 的二维矩阵。最终卷积神经网络的输入表达式如式(4)所示：

$$Input = \begin{bmatrix} x_1^{t-5} & x_2^{t-5} & x_3^{t-5} & x_4^{t-5} & x_5^{t-5} & x_6^{t-5} & x_7^{t-5} & x_8^{t-5} & x_9^{t-5} \\ x_1^{t-4} & x_2^{t-4} & x_3^{t-4} & x_4^{t-4} & x_5^{t-4} & x_6^{t-4} & x_7^{t-4} & x_8^{t-4} & x_9^{t-4} \\ x_1^{t-3} & x_2^{t-3} & x_3^{t-3} & x_4^{t-3} & x_5^{t-3} & x_6^{t-3} & x_7^{t-3} & x_8^{t-3} & x_9^{t-3} \\ x_1^{t-2} & x_2^{t-2} & x_3^{t-2} & x_4^{t-2} & x_5^{t-2} & x_6^{t-2} & x_7^{t-2} & x_8^{t-2} & x_9^{t-2} \\ x_1^{t-1} & x_2^{t-1} & x_3^{t-1} & x_4^{t-1} & x_5^{t-1} & x_6^{t-1} & x_7^{t-1} & x_8^{t-1} & x_9^{t-1} \\ x_1^t & x_2^t & x_3^t & x_4^t & x_5^t & x_6^t & x_7^t & x_8^t & x_9^t \end{bmatrix} \quad (4)$$

3.2. 模型设计

相比图像处理，本数据集输入维度较小，是一个 6×9 的二维矩阵，因此本文选择的卷积核尺寸和数

量也较小,卷积层 1 使用 4 个大小为 2×2 的卷积核来提取输入矩阵,并将矩阵的边缘部分用 0 填充,由于输入矩阵的维度较小,在卷积层 1 后暂不添加池化层。将卷积层 1 的运算结果输入到下一层,卷积层 2 又分别使用 8 个大小为 2×2 的卷积核继续提取特征,随后进入池化层,对数据进行平均池化,采用 3×3 的卷积核,步长为 3,最后得到 8 张 3×3 的特征,将其展平,形成一个具有 72 个节点特征向量,全连接到一个节点中,该节点的输出即为当前时刻下 IGBT 的剩余寿命。卷积神经网络结构的参数如下表 2 所示。

Table 2. Structural parameters of convolutional neural networks
表 2. 卷积神经网络结构参数

层数	名称	卷积核大小	卷积核数	步长
1	卷积层 1	2×2	4	1
2	卷积层 2	2×2	8	1
3	池化层 1	3×3	-	3

确定好卷积神经网络模型的结构,下一步用遗传算法求解卷积神经网络的各参数。根据结构可知,需要确定卷积层 1、卷积层 2 和全连接层的卷积核初始化参数,以及激活函数、优化器、批量大小等超参数,这些参数共同组成了优化算法的种群。分别给出每个参数的可行域或映射关系,确定最终的解空间,并确定本文的种群大小为 40。本文选择卷积神经网络预测的均方误差作为优化算法的适应度,具体表达式如式(5)。确定好这些信息,即可按照 2.3 的结构进行模型训练,得出最优参数解,最终得到最优的卷积神经网络寿命预测模型。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{5}$$

3.3. 模型评估

本文采用决定系数(r-square, R)、均方根误差(root mean squared error, RMSE)和绝对误差(mean absolute error, MAE)作为预测模型的评估标准,其具体公式如式(5)(6)(7):

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y} - y_i)^2} \tag{6}$$

$$MAE = \frac{1}{n} \sum_i |(y_i - \hat{y}_i)| \tag{7}$$

式中 y_i 表示 IGBT 的真实剩余寿命, \hat{y}_i 表示模型预测的 IGBT 的剩余寿命, \bar{y} 表示 IGBT 实际剩余寿命的平均值。注意这里是寿命指的是剩余的开关周期数,并非剩余时间。

本文种群大小为 40,遗传算法的终止进化代数为 200,交叉率取 0.8,变异率取 0.005,以预测剩余寿命和实际剩余寿命的均方根误差作为适应度进行模型训练,并用测试集进行测试,验证模型效果,其预测效果如图 4 所示。

由图 4 可知,剩余寿命预测曲线与真实的剩余寿命曲线拟合度较高,模型的拟合优度 R^2 高达 98.43%,均方误差为 16.47。为了验证基于遗传算法优化的卷积神经网络的精确性和准确性,采用 SVR 模型、MLP 模型、CNN 模型进行试验对比,图 5 为各模型寿命预测效果的对比图,发现 GA-CNN 的剩余寿命预测曲线和真实剩余寿命曲线拟合地最好。

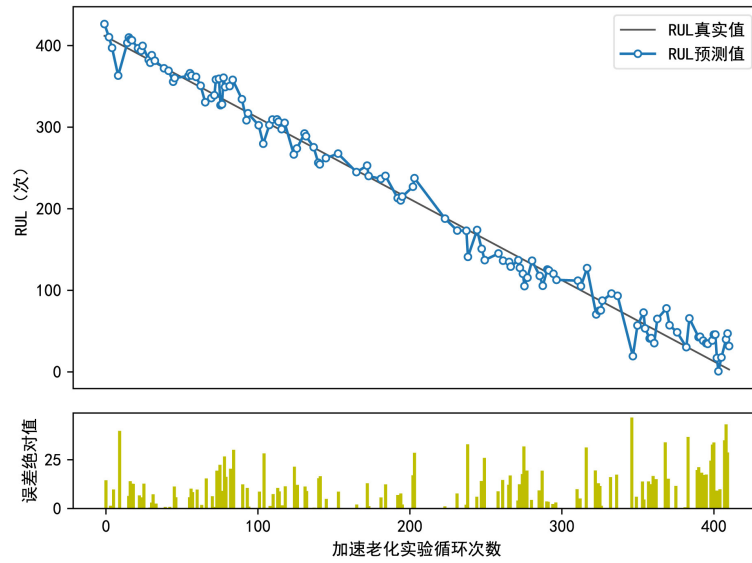


Figure 4. RUL prediction results

图 4. 寿命预测结果




Figure 5. Comparison of RUL prediction results

图 5. 寿命预测结果对比

之后，用决定系数、均方根误差和绝对误差作为预测模型的评估标准，其结果如下表 3 所示。相较于其他模型，GA-CNN 的预测效果在 R^2 、MSE、MAE 上都有显著提升。

Table 3. The errors of RUL prediction

表 3. 寿命预测误差对比

模型	R^2	RMSE	MAE
SVR	82.16%	55.64	41.62
MLP	92.92%	35.06	28.01
CNN	96.68%	23.22	17.87
GA-CNN	98.43%	16.47	13.04

4. 结论

传统的 IGBT 剩余寿命预测方法, 通过输入前一段时期的电参数状态, 预测未来的电参数状态, 确定各参数的失效阈值, 超过阈值判断为失效, 这种方法对剩余寿命的预测既不稳定也不直接。本文选取合适的电参数特征作为输入, 剩余寿命作为输出, 可以直接预测任意状态下的剩余寿命。本文提出了基于遗传算法的卷积神经网络预测方法, 其决定系数能够稳定高达 98.43%, 均方根误差稳定在 16, 相比于 SVR、MLP 和 CNN 方法, 具有更高的精度和稳定性。

参考文献

- [1] 陈曦. 变频器中 IGBT 的驱动保护及故障识别研究[D]: [硕士学位论文]. 济南: 山东交通学院, 2021.
<https://doi.org/10.27864/d.cnki.gsitd.2020.000037>
- [2] 曾杰, 檀浩浩, 杨方, 周望君, 李亮星, 常桂钦, 罗海辉. IGBT 模块焊层的被动热循环可靠性分析[J]. 焊接学报, 2023, 44(7): 123-128+136.
- [3] 任政焱. IGBT 模块疲劳失效分析与结温预测研究[D]: [硕士学位论文]. 大连: 大连理工大学, 2023.
<https://doi.org/10.26991/d.cnki.gdlu.2022.000220>
- [4] 黄小华, 郭红利. 基于有限元仿真的 IGBT 模块的应力应变分析[J]. 精密制造与自动化, 2017(3): 22-25+40.
- [5] 沈刚, 周维维, 杜雄, 等. 基于小波奇异熵理论的 IGBT 模块键合线脱落故障特征分析[J]. 电工技术学报, 2013, 28(6): 165-171.
- [6] 毛娅婕, 周维维, 杜雄, 等. IGBT 加速老化实验研究[J]. 电源技术, 2014, 38(12): 2383-2385+2420.
- [7] Bayerer, R., Herrmann, T., Licht, T., *et al.* (2008) Model for Power Cycling Lifetime of IGBT Modules—Various Factors Influencing Lifetime. *Proceedings of the 5th International Conference on Integrated Power Systems*, Nuremberg, 11-13 March 2008, 1-6.
- [8] 王加昌, 郑代威, 唐雷, 等. 基于机器学习的剩余使用寿命预测实证研究[J]. 计算机科学, 2022, 49(S2): 937-945.
- [9] 刘嘉诚. 基于机器学习算法的 IGBT 寿命预测研究[D]: [硕士学位论文]. 合肥: 合肥工业大学, 2021.
<https://doi.org/10.27101/d.cnki.ghfu.2020.001704>
- [10] Alghassi, A., Perinpanayagam, S. and Jennions, I.K. (2013) A Simple State-Based Prognostic Model for Predicting Remaining Useful Life of IGBT Power Module. *Proceedings of the 2013 15th European Conference on Power Electronics and Applications*, Lille, 2-6 September 2013, 1-7.
- [11] Ahsan, M., Stoyanov, S. and Bailey, C. (2016) Data Driven Prognostics for Predicting Remaining Useful Life of IGBT. *The Proceedings of the International Spring Seminar on Electronics Technology*, Pilsen, 18-22 May 2016, 273-278.
- [12] Liu, Z., Mei, W., Zeng, X., *et al.* (2017) Remaining Useful Life Estimation of Insulated Gate Bipolar Transistors (IGBTs) Based on a Novel Volterra K-Nearest Neighbor Optimally Pruned Extreme Learning Machine (VKOPP) Model Using Degradation Data. *Sensors (Switzerland)*, **17**, Article No. 2524.
- [13] 鲁远耀. 深度学习架构与实践[M]. 北京: 机械工业出版社, 2021: 258.
- [14] 杨玉青. 基于遗传算法的神经网络架构优化方法研究[D]: [硕士学位论文]. 连云港: 江苏海洋大学, 2023.
<https://doi.org/10.44354/d.cnki.gjsuy.2022.000159>
- [15] 王丽敏, 乔玲玲, 魏霖静. 结合遗传算法的优化卷积神经网络学习方法[J]. 计算机工程与设计, 2017, 38(7): 1945-1950. <https://doi.org/10.16208/j.issn1000-7024.2017.07.044>
- [16] 赵羽, 蔡磊, 管延文, 等. 基于遗传算法的燃气管道阻力系数辨识研究[J]. 煤气与热力, 2022, 42(5): 1-6+10.
<https://doi.org/10.13608/j.cnki.1000-4416.2022.05.009>
- [17] 周昌微, 谢贤平, 都喜东. 基于 GA-BP 神经网络的矿井粉尘浓度预测[J]. 有色金属(矿山部分), 2023, 75(6): 88-93.
- [18] 宋明达. 基于改进遗传算法优化 Elman 神经网络的短期负荷预测[D]: [硕士学位论文]. 衡阳: 南华大学, 2021.
<https://doi.org/10.27234/d.cnki.gnhuu.2020.000379>
- [19] 谭锦新, 秦斐燕, 任斌. 基于遗传算法改进的卷积神经网络短时交通流预测[J]. 东莞理工学院学报, 2021, 28(5): 31-37. <https://doi.org/10.16002/j.cnki.10090312.2021.05.004>
- [20] 葛建文. 电机驱动器 IGBT 模块老化试验和寿命预测[D]: [硕士学位论文]. 上海: 上海交通大学, 2021.
<https://doi.org/10.27307/d.cnki.gsjtu.2021.000644>