

# 基于神经网络的绝缘栅双极型晶体管 开关损耗预测

王长华 李祥雄 梁顺发 陈荣东  
(顺特电气设备有限公司, 广东 佛山 528300)

**摘要** 针对级联储能应用领域大量绝缘栅双极型晶体管 (IGBT) 的开关损耗难以准确在线测量的问题, 引入误差反向传播神经网络, 建立 IGBT 开关损耗预测模型。首先采用级联 H 桥功率模块搭建开关损耗动态测试系统, 通过调整直流母线电压、交流电流及冷却液温度, 获得大量测试数据; 然后将影响 IGBT 开关损耗的 3 个主要因素——集射极电压、集电极电流、结温作为预测模型的输入, 采用粒子群优化算法优化开关损耗预测模型的初始权值和阈值, 以提升预测开通损耗、关断损耗及二极管反向关断损耗的准确度并加速学习规律的收敛; 最后与随机给定初始权值及阈值的开关损耗预测模型进行对比分析。结果表明, 引入粒子群优化算法所建立的开关损耗预测模型的预测准确度更高, 针对 50 组随机验证数据的最大百分误差为 3.3%。

**关键词:** 绝缘栅双极型晶体管 (IGBT); 开关损耗预测; 神经网络; 粒子群优化算法

## Insulated gate bipolar transistor switching loss prediction based on neural network

WANG Changhua LI Xiangxiong LIANG Shunfa CHEN Rongdong  
(SUNTEN Electrical Equipment Co., Ltd, Foshan, Guangdong 528300)

**Abstract** Aiming at the disadvantages that numerous insulated gate bipolar transistor (IGBT) switching loss are difficult to accurately measure online in the cascaded energy storage application area, switching loss prediction model is established based on the error back propagation neural network. Firstly, dynamic test system of switching loss is built with cascaded H bridge power module, the massive switching loss data is obtained with changing the direct current bus voltage, alternating current and coolant temperature of power module. 3 main factors including collector-emitter voltage, collector current and device junction temperature are taken as the input of IGBT switching loss prediction model. The particle swarm optimization is used to optimize the initial weight and threshold of prediction model, improving prediction accuracy and accelerating the convergence of learning laws. The optimized performance of this model is compared and analyzed with the prediction model that the initial weight and threshold are given randomly. The results show that the prediction accuracy of the model proposed in this paper is higher. The maximum percentage error for 50 sets of random validation data is 3.3%.

**Keywords:** insulated gate bipolar transistor (IGBT); switching loss prediction; neural network; particle swarm optimization

## 0 引言

级联 H 桥多电平储能<sup>[1]</sup>因具有多种优势而成为当前研究及应用的热点, 但是系统所含绝缘栅双极型晶体管 (insulated gate bipolar transistor, IGBT) 数

量成百上千, 其开关瞬态过程与主回路元件紧密耦合<sup>[2]</sup>, 造成开关瞬态电磁现象复杂<sup>[3]</sup>。因此, 对多电平 IGBT 的故障模拟、故障诊断研究应运而生<sup>[4-6]</sup>。级联 H 桥 IGBT 的开关过程持续时间极短, 开关损耗产生大量热能<sup>[7-8]</sup>, 直接影响散热、硬件电路、保

护系统的设计,以及液冷机组和空调的选型。本文针对 IGBT 的开关损耗进行研究,以期为准设计系统的散热器、硬件电路、保护系统等提供依据。

当前,IGBT 开关损耗计算主要基于数学和物理的方法。其中,数学方法需要借助实验数据及 IGBT 数据手册<sup>[7]</sup>,物理方法需要建立精确的 IGBT 等效模型。两种方法均需要专业的知识和复杂的测试工作。例如,文献<sup>[9]</sup>所述的基于物理模型法和文献<sup>[10]</sup>所述的基于数学算法,普通工程师可能因专业知识不足而难以进行实际应用。

随着人工智能在新能源领域的广泛应用,人工智能神经网络算法在电源的可靠性预测<sup>[11]</sup>、电力负荷预测<sup>[12]</sup>、IGBT 故障诊断<sup>[5-6]</sup>、IGBT 温度监测<sup>[8]</sup>、IGBT 寿命预测及老化失效预测<sup>[13-16]</sup>方面得到推广应用。研究表明,采用 BP 神经网络<sup>[17-18]</sup>、记忆循环神经网络<sup>[8]</sup>、贝叶斯-双向长短期记忆神经网络<sup>[16]</sup>等可实现对 IGBT 开关损耗、结温、剩余寿命的准确预测及监测。

由于无需建立 IGBT 模型,也无需了解其内部结构,即可利用 BP 神经网络实现对 IGBT 开关损耗的预测<sup>[17-18]</sup>,故本文采用 BP 神经网络来建立级联 H 桥 IGBT 的开关损耗预测模型。

文献<sup>[7, 17-18]</sup>采用 BP 神经网络来预测 IGBT 开关损耗,均基于实验室离线双脉冲法获取测试数据,而 IGBT 开关损耗受主回路、工作环境、实际工况等影响<sup>[2-3]</sup>,其实际值与双脉冲测试数据相差大,故实际预测的可靠性无法保证。另外,在级联 H 桥多电平应用领域,大容量 IGBT 主回路存在杂散电感,IGBT 反向并联的二极管在关断过程中会产生电压过冲,而且关断尖峰电流大,故二极管反向关断损耗不可忽略<sup>[19]</sup>。目前,少有文献对 IGBT 二极管的反向关断损耗进行神经网络预测。

因此,本文采用实际产品的级联 H 桥功率模块,搭建准在线动态测试系统,以尽量减少关联电路及外部环境的影响;模拟级联 H 桥全部工况,以获取 IGBT 开关损耗(包括开通损耗、关断损耗、二极管反向关断损耗)测试数据,减少测试数据与实际损耗的误差;引入 BP 神经网络,建立级联 H 桥 IGBT 开关损耗的预测模型。

为提高预测模型的准确度、加速学习规律的收敛,采用粒子群优化算法优化 IGBT 开关损耗预测模型的初始权值和阈值,并与随机给定初始权值和阈值的 IGBT 开关损耗预测模型进行性能对比。

## 1 IGBT 开关损耗测试

### 1.1 IGBT 开关损耗定义

级联 H 桥 IGBT 开关损耗是 IGBT 在开关瞬态过程中的高电压及大电流产生的能量损耗,可分为开通损耗、关断损耗及二极管反向关断损耗。图 1 所示为 IGBT 开关损耗示意图,其中  $V_{ce}$  为 IGBT 集射极电压,  $V_{rec}$  为二极管反向关断电压,  $V_{dc}$  为二极管承受的反向电压,  $i(t)$  为 IGBT 开关瞬间电流及二极管反向关断电流,  $i_{rr}$  为二极管反向关断尖峰电流,  $t_{on}$  为开通时间,  $t_{con}$  为导通时间,  $t_{off}$  为关断时间,  $t_{rr}$  为反向关断时间。




图 1 IGBT 开关损耗示意图

根据图 1 的描述,IGBT 开关损耗为

$$E_{on} = \int_{t_{on}} V_{ce}(t)i(t)K(T_j)dt \quad (1)$$

$$E_{off} = \int_{t_{off}} V_{ce}(t)i(t)K(T_j)dt \quad (2)$$

$$E_{rec} = \int_{t_{rr}} V_{rec}(t)i(t)K(T_j)dt \quad (3)$$

式中:  $E_{on}$  为开通损耗;  $E_{off}$  为关断损耗;  $E_{rec}$  为二极管反向关断损耗;  $K(T_j)$  为 IGBT 的结温系数;  $T_j$  为 IGBT 结温。

### 1.2 IGBT 开关损耗的影响因素

影响 IGBT 开关损耗的因素有开关频率  $f_s$ 、门极驱动电压  $U_{ge}$ 、集射极电压  $V_{ce}$ 、集电极电流  $i_c$ 、门极驱动电阻  $R_g$ 、主回路寄生电感  $L_s$  及器件结温  $T_j$ <sup>[17-18]</sup>。对于级联 H 桥 IGBT,其驱动电压、驱动电阻、开关频率及主回路的寄生参数是确定的,几乎不受外部环境及工况的影响。因此,只需考虑其直流工作电压、交流电流及器件结温的影响,故选取上述 3 个参数作为 IGBT 开关损耗预测模型的输入变量。

### 1.3 IGBT 开关损耗动态测试系统

图 2 为 IGBT 开关损耗动态测试系统框图,级联 H 桥功率模块由 IGBT、驱动板、电容器、滤波

电抗器、熔断器、直流接触器、光纤接口、液冷散热等组成；负载为 2.6mH/420A 交流电抗器；控制器由电源、数字信号处理器（digital signal processor, DSP）、现场可编程门阵列（field programmable gate array, FPGA）、采样电路、外设驱动电路及光纤接口等组成；直流源输出范围为 DC 50V~DC 1 500V；温控系统由冷却机组提供，IGBT 内置热敏电阻，可实时在线监测 IGBT 结温；测试系统由高端示波器、高精度、高性能的电压电流探头组成。




图 2 IGBT 开关损耗动态测试系统框图

## 2 IGBT 开关损耗预测模型

### 2.1 IGBT 开关损耗预测模型原理

IGBT 的集射极电压、集电极电流、结温之间具有复杂的非线性关系，BP 神经网络可考虑多种因素，并能通过学习训练逼近任意非线性映射<sup>[17-18]</sup>，故采用 BP 神经网络来预测级联 H 桥 IGBT 的开关损耗。

先将 IGBT 看作黑盒系统，建立一个多输入-多输出的 BP 神经网络预测模型；再对级联 H 桥 IGBT 典型工况进行测试，获取大量 IGBT 开关损耗数据；最后，将 IGBT 开关损耗数据输入预测模型，学习并存储输入输出模型的映射关系，通过误差的反向传播不断调整预测模型的权值和阈值，使预测模型误差最小<sup>[17-18]</sup>。级联 H 桥 IGBT 开关损耗预测模型原理如图 3 所示。

### 2.2 IGBT 开关损耗预测模型结构设计

IGBT 开关损耗预测模型设计的关键是控制网络复杂度，确定合理的预测模型结构<sup>[17-18]</sup>，具体包括确定 IGBT 开关损耗预测模型的层数、隐含层节点数、每层节点的激活函数，确定 IGBT 开关损耗预测模型的初始权值及阈值等。

#### 1) 网络层数选取

通常 1 个隐含层的 BP 神经网络就能以任意精度逼近任意连续函数<sup>[17-18]</sup>，因此本文预测模型的结构为 3 层（输入层、输出层、隐含层）神经网络结构。

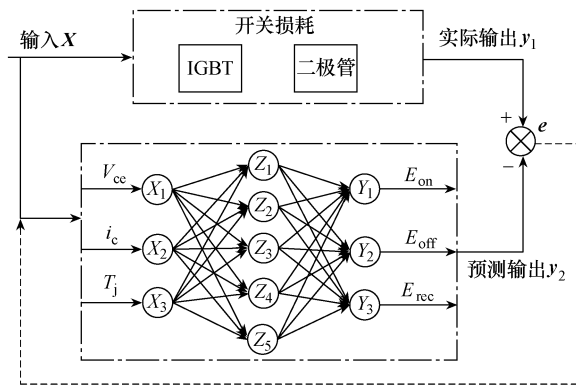


图 3 级联 H 桥 IGBT 开关损耗预测模型原理

#### 2) 隐含层节点数计算

在 3 层 IGBT 开关损耗预测模型中，隐含层节点数  $q$  与输入节点数  $n$ 、输出节点数  $m$  的关系<sup>[15]</sup>为

$$q = 1 + \sqrt{n(m+2)} \quad (4)$$

由于  $n=m=3$ ，经式 (4) 计算得  $q=5$ 。

#### 3) 初始权值和阈值优化

初始权值和阈值对 IGBT 开关损耗预测模型的性能影响较大<sup>[17-18]</sup>。常规神经网络预测模型的初始权值和阈值通常采用 [0, 1] 区间内的随机数，对初始权值和阈值要求高，容易陷入局部最优解。

粒子群算法可快速确定个体极值和全局极值，故采用粒子群算法搜索最佳初始权值和阈值<sup>[15]</sup>，以加速模型收敛，减少迭代次数，提升预测准确度。粒子群按式 (5) 和式 (6) 不断更新速度和位置。

$$v_{i,j}^{k+1} = \omega v_{i,j}^k + c_1 r_1 (m_{i,j}^k - x_{i,j}^k) + c_2 r_2 (n_j^k - x_{i,j}^k) \quad (5)$$

$$x_i^{k+1} = (x_{i,1}^k + v_{i,1}^{k+1}, x_{i,2}^k + v_{i,2}^{k+1}, \dots, x_{i,D}^k + v_{i,D}^{k+1}) \quad (6)$$

式中： $v_{i,j}^k$  为第  $k$  次迭代中第  $i$  个粒子第  $j$  维的速度； $x_{i,j}^k$  为第  $k$  次迭代中第  $i$  个粒子第  $j$  维的位置； $\omega$  为粒子惯性系数； $c_1$ 、 $c_2$  为粒子非负加速度系数； $r_1$ 、 $r_2$  均为 [0, 1] 区间内的随机数； $m_{i,j}^k$  为第  $k$  次迭代中第  $i$  个粒子第  $j$  维的历史最优位置； $n_j^k$  为第  $k$  次迭代中整个粒子群的历史最优位置； $x_i^{k+1}$  为第  $k+1$  次迭代中第  $i$  个粒子位置； $D$  为粒子的维度。

由粒子译码得到初始权值和阈值，利用训练样本训练 IGBT 开关损耗预测模型，再用测试样本对训练后的预测模型进行测试。通过与随机给定初始权值和阈值的预测模型进行对比，来评价引入粒子群优化的预测模型的性能。

#### 4) 激活函数选取

激活函数负责将神经元的输入映射到输出端。常用的激活函数有线性函数、阶跃函数、双曲正切 S 型函数等。IGBT 开关损耗预测模型属于函数逼近型，其隐含层神经元的激活函数选择双曲正切 S 型函数  $\text{tansig}$ ，该函数的反对称性使模型的学习速度更快<sup>[17-18]</sup>。对只含 1 个隐含层且采用  $\text{tansig}$  作为激活函数的 IGBT 开关损耗预测模型来说，输出层采用线性函数  $\text{purelin}$  作为激活函数，可实现对多输入函数任意精度的逼近<sup>[20]</sup>。输出层和隐含层的神经元激活函数如图 4 所示，对应的激活函数表达式分别为

$$\text{purelin}(x) = x \quad (7)$$

$$\text{tansig}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$




图 4 神经元激活函数

IGBT 开关损耗预测模型结构如图 5 所示。其中， $\mathbf{b}^1$  为连接输入层与隐含层的阈值矩阵， $\mathbf{b}^2$  为连接隐含层与输出层的阈值矩阵， $\mathbf{V}$  为连接输入层与隐含层的权值矩阵， $\mathbf{W}$  为连接隐含层与输出层的权值矩阵<sup>[17-18]</sup>。

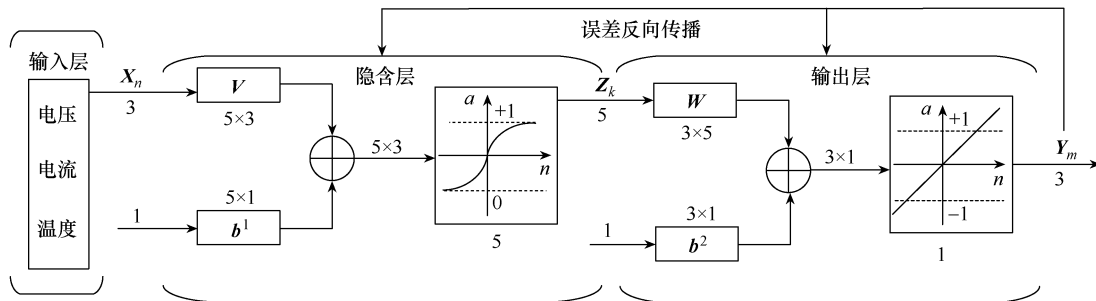


图 5 IGBT 开关损耗预测模型结构

在每次迭代完成后，IGBT 开关损耗预测模型根据粒子群算法优化结果更新神经网络的最优权值和阈值，直至训练结束。IGBT 开关损耗预测模型参数见表 1。

表 1 IGBT 开关损耗预测模型参数

参数	数值 (类型)
输入参数	$V_{ce}, i_c, T_j$
输出参数	$E_{on}, E_{off}, E_{rec}$
隐含层激活函数	$\text{tansig}$
输出层激活函数	$\text{purelin}$
阈值初始取值范围	(0, 1)
权值初始取值范围	(0, 1)
最大训练次数	1 000

### 3 实验

#### 3.1 测试数据获取

IGBT 开关损耗动态测试系统参数见表 2。通过调整直流电压、控制交流电流、调节冷却液温度，

表 2 IGBT 开关损耗动态测试系统参数

参数	数值
IGBT 规格	1 700V/450A (并联)
IGBT 开通电阻/ $\Omega$	3.8
IGBT 关断电阻/ $\Omega$	5.0
IGBT 驱动电压/V	+15/-10
IGBT 模块寄生电感/nH	20
叠层母排寄生电感/nH	72
直流母线电容	730 $\mu$ F $\times$ 16/1 400V

即可获取测试数据。

用示波器记录级联 H 桥 IGBT 开关瞬态电压、电流波形。直流母线电压为 718.7V，交流侧电流为 495.1A，IGBT 结温为 45 $^{\circ}$ C 条件下的 IGBT 开关损耗测试波形如图 6 所示，其中 Ch1 为 H 桥交流电压，Ch2 为 H 桥直流电压，Ch3 为 H 桥交流电流，Ch4 为 H 桥直流电流。根据 1.1 节对 IGBT 开通损耗、关断损耗及二极管反向关断损耗的定义，即可计算出相应的损耗测试值。




图 6 IGBT 开关损耗测试波形

由于 IGBT 开关损耗测试数值变动范围大, 为提高 IGBT 开关损耗预测模型的性能, 对测试数据进行归一化处理, 即

$$V_g = \frac{V_y}{V_{y\max}} \quad (9)$$

式中:  $V_g$  为归一化后的数据;  $V_y$  为原始数据;  $V_{y\max}$  为原始数据的最大值。

### 3.2 测试点数据选择

所选择样本测试点须覆盖级联 H 桥 IGBT 功率模块的全部工况<sup>[15]</sup>。样本数据测试点见表 3, 在不同电压、电流及结温测试条件下, 共计 1 768 个测试点。

表 3 样本数据测试点

测试条件	测试点	样本数
电压/V	600, 650, 700, ..., 1 100, 1 150, 1 200	13
电流/A	100, 150, 200, ..., 800, 850, 1 200	17
结温/°C	25, 35, 45, 55, 65, 75, 85, 95	8


### 3.3 测试数据处理及预测模型训练

首先清洗 1 768 个测试点中的 25 个异常点, 然后随机抽取 50 个测试点, 用于 IGBT 开关损耗预测模型性能对比, 最后将剩余 1 693 个测试点分别输入基于粒子群优化的预测模型及基于常规算法 (随机给定初始权值和阈值) 建立的预测模型进行训练, 并保存两个训练模型。


### 3.4 IGBT 开关损耗预测模型性能对比

图 7 所示为基于粒子群算法优化的 BP 神经网络训练过程及基于随机给定初始权值和阈值的 BP 神经网络训练过程对比。

由图 7 (a) 可知, 基于粒子群算法优化的神经网络在第 53 次训练时的方均误差达到最小, 为 0.000 134 16。由图 7 (b) 可知, 基于随机给定初始权值和阈值的神经网络在第 92 次训练时的方均误差达到最小, 为 0.000 150 03。



(a) 基于粒子群算法优化的神经网络训练过程




(b) 基于随机给定初始权值和阈值的神经网络训练过程

### 图 7 BP 神经网络训练过程对比


显然, 采用粒子群算法优化后的预测模型迭代次数更少。这是因为, 粒子群算法利用粒子群中个体和群体的最优信息来更新粒子速度和位置, 从而加速了迭代过程, 减少了迭代次数; 而常规神经网络中随机给定的初始权值和阈值较小时, 会导致神经网络训练过程的迭代次数较多、收敛速度慢<sup>[17-18]</sup>。

为了定性对比两种预测模型的准确度, 随机抽取 50 个测试点, 得到 IGBT 开关损耗预测结果对比如图 8 所示。显然, 图 8 (a) 比图 8 (b) 的曲线拟合度更好, 即基于粒子群算法优化的预测模型准确度更高。

为了定量对比两种预测模型的准确度, 随机抽取 50 个测试点, 得到两种预测模型的百分误差对比如图 9 所示。图 9 (a) 中, 第 19 个测试样本的二极管反向关断损耗预测值的百分误差最大, 约为 3.3%; 第 47 个测试样本的 IGBT 开通损耗预测值的百分误差最大, 约为 1.6%; 第 30 个测试样本的 IGBT 关断损耗预测值的百分误差最大, 约为 2.0%。图 9



(a) 基于粒子群算法优化的模型预测值与实测值




(b) 基于随机给定初始权值和阈值的模型预测值与实测值


图8 IGBT 开关损耗预测结果对比

(b)中,第14个测试样本的二极管反向关断损耗预测值的百分误差最大,约为8.6%;第40个测试样本的IGBT关断损耗预测值的百分误差最大,约为8.6%;第42个测试样本的IGBT开通损耗预测值的百分误差最大,约为9.2%。图9(a)的百分误差整体比图9(b)更小,因此基于粒子群算法优化初始权值及阈值的预测模型准确度更高。

两个预测模型针对第42个测试样本的预测数据



(a) 基于粒子群算法优化的预测模型百分误差



(b) 基于随机给定初始权值和阈值的预测模型百分误差

图9 两种预测模型百分误差对比

据见表4。由表4可知,引入粒子群算法后的IGBT开关损耗预测模型的百分误差降低了5.4~7.7个百分点。

表4 两个预测模型针对第42个测试样本的预测数据

参数	开通损耗	关断损耗	反向恢复损耗
开关损耗实际值/mJ	121.3	119.9	70.4
粒子群优化预测值/mJ	123.1	117.6	69.6
粒子群优化预测值百分误差/%	1.5	1.9	1.1
随机预测值/mJ	132.5	111.2	65.3
随机预测值百分误差/%	9.2	7.3	7.2

基于粒子群算法优化的预测模型,通过全局搜索和局部搜索相结合的方式,避免神经网络陷入局部最优,从而使预测模型预测值的误差较小;而基于随机给定初始权值及阈值的预测模型,由于初始权值和阈值随机给定,每次训练结果不同,导致预测值误差较大。

综上所述,引入粒子群算法优化的IGBT开关损耗预测模型具有更高的预测准确度,能够应用于级联H桥IGBT开关损耗的预测。

## 4 结论

本文选取实际级联H桥IGBT功率模块搭建准在线动态测试系统,利用大量实验数据,结合粒子群算法优秀的全局优化能力,提高了IGBT开关损耗预测模型的预测准确度。与常规IGBT开关损耗计算相比,采用人工神经网络可将IGBT开关损耗与环境关联因素统一考虑,从而获得更高的IGBT开关损耗预测准确度(最大预测百分误差为3.3%),有利于工程师准确完成散热器、保护系统、硬件电

路设计及对产品性能的评估。

### 参考文献

- [1] 蔡旭, 李睿, 李征. 储能功率变换与并网技术[M]. 北京: 科学出版社, 2019.
- [2] 张午宇, 齐磊, 张翔宇, 等. 计及金属化薄膜电容器与 IGBT 模块退化过程相关性的柔直换流阀组件可靠性评估方法[J]. 电工技术学报, 2024, 39(14): 4508-4518.
- [3] 李雨泽, 张秀敏, 袁文迁, 等. 基于电参数的 IGBT 开关瞬态过程耦合关系分析[J]. 高电压技术, 2024, 50(3): 1252-1263.
- [4] 邹毅军, 魏明洋. 模块化多电平换流器子模块故障模拟方法[J]. 电气技术, 2022, 23(4): 96-101.
- [5] AN Yang, SUN Xiangdong, REN Biying, et al. A data-driven method for IGBT open-circuit fault diagnosis for the modular multilevel converter based on a modified Elman neural network[J]. Energy Reports, 2022, 8: 80-88.
- [6] SIVAPRIYA A, KALAIARASI N. A novel enhanced deep learning-based fault diagnosis approach for cascaded multilevel inverter[J]. e-Prime-Advances in Electrical Engineering, Electronics and Energy, 2023, 5: 100253.
- [7] 李志刚, 梅霜. 基于神经网络的功率模块开关损耗预测[J]. 现代电子技术, 2016, 39(20): 101-103.
- [8] LIU Yunhe, GUO Tengfei, LI Jinda, et al. A study on temperature monitoring method for inverter IGBT based on memory recurrent neural network[J]. High-speed Railway, 2024, 2(1): 64-70.
- [9] 普靖, 罗毅飞, 肖飞, 等. 针对高压 IGBT 的改进瞬态模型[J]. 高电压技术, 2018, 44(2): 448-455.
- [10] 杨立敏, 王晖, 韩志勇, 等. 全桥型模块化多电平换流器损耗简化计算模型研究[J]. 电工电能新技术, 2019, 38(8): 53-62.
- [11] 黄李奔. 基于 BP 神经网络模型的智慧杆电源热稳定性评估方法[J]. 电气技术, 2023, 24(6): 47-56.
- [12] 徐扬, 张紫涛. 基于遗传模拟退火算法改进 BP 神经网络的中长期电力负荷预测[J]. 电气技术, 2021, 22(9): 70-76.
- [13] 任宏宇, 余瑶怡, 杜雄, 等. 基于优化长短期记忆神经网络的 IGBT 寿命预测模型[J]. 电工技术学报, 2024, 39(4): 1074-1086.
- [14] 唐圣学, 张继欣, 姚芳, 等. IGBT 模块寿命预测方法研究综述[J]. 电源学报, 2023, 21(1): 177-194.
- [15] 刘嘉诚. 基于机器学习算法的 IGBT 寿命预测研究[D]. 合肥: 合肥工业大学, 2020.
- [16] 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.
- [17] 陈娜, 李鹏, 江剑, 等. 中高压 IGBT 开关特性的遗传神经网络预测[J]. 电工技术学报, 2013, 28(2): 239-247, 254.
- [18] 唐波, 刘任, 江浩田, 等. 基于 BP 神经网络的 IGBT 模块开关损耗求解[J]. 高压电器, 2019, 55(7): 27-32.
- [19] 田安民, 孙光淼, 卢文冰, 等. 大容量变流器中 IGBT 关断过电压抑制技术研究[J]. 电力电子技术, 2023, 57(10): 13-16.
- 
- 收稿日期: 2024-09-19  
修回日期: 2024-10-16  
作者简介  
王长华(1983—), 男, 湖南省邵阳市人, 硕士, 工程师, 主要从事电力电子技术与电池储能研发工作。
- 
- (上接第 41 页)
- [14] 刘动, 孟晨旭, 潘正阳, 等. 居民小区经营性电动汽车充电站投资建设研究[J]. 电气技术, 2022, 23(6): 104-108.
- [15] 孙宇乐. 计及需求敏感性的电动私家车充电站规划[J]. 电气技术, 2022, 23(6): 99-103, 108.
- [16] 房宇轩, 胡俊杰, 马文帅. 计及用户意愿的电动汽车聚合商主从博弈优化调度策略[J]. 电工技术学报, 2024, 39(16): 5091-5103.
- [17] 葛少云, 朱林伟, 刘洪, 等. 基于动态交通仿真的高速公路电动汽车充电站规划[J]. 电工技术学报, 2018, 33(13): 2991-3001.
- 
- 收稿日期: 2024-11-29  
修回日期: 2024-12-17  
作者简介  
王博(1995—), 男, 河南郑州人, 硕士, 主要从事电力监控系统开发、电力人工智能等方面的研究工作。