

DOI:10.13296/j.1001-1609.hva.2026.10.026

基于深度学习的压接式IGBT运行特性预测方法

肖 凯¹, 王 振¹, 邹延生¹, 严喜林¹, 许琳浩¹, 黄晨浩²

(1. 中国南方电网有限责任公司超高压输电公司电力科研院, 广州 510663; 2. 湖南大学电气与信息工程学院, 长沙 410082)

摘要: 压接式IGBT是柔直输电系统的关键环境,其寿命评估是提高系统可靠性的重要环节,其中掌握IGBT模块多场特征是关键。尽管现有多场仿真技术能够实现压接式IGBT模块的完备分析,但是存在计算效率低的问题。因此,文中提出了融合深度学习和多场模型的压接式IGBT模块多场运行特征分析方法,以实现压接IGBT模块运行信息的快速获取,支撑其数字孪生模型的构建。首先,构建了压接式IGBT模块电—热—力多场耦合模型,分析了不同工况下IGBT模型重要寿命评估特征变化规律;其次,提出了BPBR神经网络与网格搜索法相结合的深度学习方法,以实现压接式IGBT模块多场耦合信息的快速预测;最后,测试了所提出方法的高效性,结果表明:所提出模型能够有效分析压接式IGBT模块多场信息,与有限元计算结果吻合度好,偏差率小于1%,且计算时间不到仿真的万分之一。研究成果能够支撑压接式IGBT模块多场信息的快速获取,进而支撑压接式IGBT模块数字孪生体的构建和状态实时监测。

关键词: 压接式IGBT; 有限元法; BP神经网络; 深度学习; 数据预测

Operation Characteristics Prediction Method of Press-pack IGBT Based on Deep Learning

XIAO Kai¹, WANG Zhen¹, ZOU Yansheng¹, YAN Xilin¹, XU Linhao¹, HUANG Chenhao²

(1. Electric Power Research Institute, CSG EHV Power Transmission Company, Guangzhou 510663, China; 2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: Press-pack IGBT is the key environment of VSC-HVDC transmission system, and its life assessment is a crucial part of improving system reliability, in which mastering the multi-field characteristics of IGBT module is of critical importance. Although the existing multi-field simulation technology can achieve thorough analysis of IGBT module, its computational efficiency remains limited. Therefore, in this paper an analysis method of multi-field operation characteristics of IGBT module with deep learning and multi-field model is proposed in order to realize the rapid acquisition of operation information of IGBT module and support the construction of its digital twin model. First, the electric-thermal-mechanical multi-field coupling model of press-pack IGBT module is constructed, and the variation of important life assessment characteristics of IGBT model under different working conditions is analyzed. Then, a deep learning method combining BPBR neural network and grid search method is proposed to realize the rapid prediction of multi-field coupling information of IGBT module. Finally, the high efficiency of the proposed method is tested. The result shows that the proposed model can effectively analyze the multi-field information of the IGBT module, which is in good agreement with the finite element calculation results, with deviation rate less than 1% and calculation time less than one ten-thousandth of that of the simulation. The research results can support the rapid acquisition of multi-field information of IGBT module, and then support the construction and real-time monitoring of digital twins of IGBT module.

Key words: press-pack IGBT; finite element method; BP neural network; deep learning; data prediction

收稿日期:2026-05-22; 修回日期:2026-07-10

基金项目:中国南方电网有限责任公司科技项目(CGYKJXM20220108)。

Project Supported by Science and Technology Project of China Southern Power Grid(CGYKJXM20220108).

0 引言

柔性直流输电技术可以增强电力系统的可靠性、提高能源利用效率,在电力系统中具有广泛的应用前景^[1-2]。绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)具备导通损耗低、耐压强度高、开关速度快等优点,是柔直系统实现交直流转换最重要的器件之一,占有功率半导体器件使用比例的42%^[3-4]。其主要分为:焊接式IGBT、压接式IGBT两种,压接式内部采用压力接触互联,具有大功率密度、便于串联、双面散热和失效短路的优点,近年越来越受应用市场青睐,已逐渐代替焊接式IGBT器件^[5-7]。但现今半导体器件的失效率高达31%,是柔直系统可靠运行的一大威胁,进一步推进压接式IGBT失效机理解构与寿命可靠预测对电力系统安全运行至关重要^[8]。

压接式IGBT寿命评估常采用功率循环试验与有限元建模仿真。功率循环试验能够模拟压接式IGBT正常运行工况,在不改变器件失效分布的情况下预测器件在特定条件下的工作可靠性水平,可以评估器件是否满足设计要求,是最常用也是最接近真实工况的试验^[9]。但搭建试验平台进行实测试验存在操作复杂、成本巨大、周期较长等问题,依靠有限元仿真模型模拟功率循环试验是更常见的方式。华北电力大学对各部件金属疲劳过程进行仿真模拟已预测了压接型IGBT器件单芯片子模块的可靠性寿命,利用二维与三维结合的方式解析了微动磨损的影响,采用改进的多元线性回归方法提出了多变量解析寿命模型,进而提出了一种压接式IGBT器件的新型封装结构^[10-14];重庆大学结合非线性损伤机理与小载荷作用机制提出了分段式疲劳累积损伤模型,分析了双馈风机机侧变流器中IGBT模块的多时间尺度热失效率以及老化进程对不同时间尺度热载荷失效率的影响规律^[15-17]。

随着深度学习等人工智能技术日渐成熟,数值模拟方法与机器学习相融合已经成为一种可能,以神经网络替代有限元模拟从而快速得到模型预测数据是现今提高分析效率、实现参数优化的一种方向。在国内,张筱迪等人建立神经网络预测模型替代有限元,实现对焊点应力应变演化结果的预测^[18];天津工业大学将人工智能深度学习算法应用于永磁同步电机齿槽转矩的预测中,得到了较为准确的预测结果^[19-25];西南科技大学采用深度神经网络算法拟合电机结构参数与输出推力的非线性关系,实

现了电机参数的快速优化^[26]。在国外,HongLei Jing提出一种基于深度神经网络的冷水机组节能控制方法,结果表明该方法具有更为理想的节能控制性能^[27];Ma'd E提出了一种基于自适应经验小波变换(EWT)和长短时记忆神经网络(LSTM)的新型广义锂离子电池容量估算方法,能准确估计锂离子电池容量^[28];Meiling Z以一种点对点的卷积神经网络(CNN)模型来重建了腔体内电磁参数的数值和分布,并预测了界面的形状和位置^[29]。而压接式IGBT模块有限元仿真过程中,存在多物理场时间尺度匹配问题与多场间的数据传递问题,即使经过了简化,精确瞬态仿真长时间的电热力特性也依然需要消耗大量的算力与时间^[30-31]。引入深度学习到压接式IGBT有限元仿真和寿命评估中能够大大提升压接式IGBT模块模型计算能力,实现内部三维多场耦合信息的快速感知,对柔直系统可靠性和稳定运行具有重要意义。

基于现有研究基础,文中提出了一种压接式IGBT运行特性预测方法。首先,搭建了压接式IGBT多场耦合模型,分析了不同工况下关键寿命信息的变化规律,然后,引入深度学习思想构建了IGBT模块多场信息预测模型,实现了多场复杂工况下特性的快速获取。最后,对比分析了不同方法的计算性能,结果表明所提出方法具有良好的计算效果,回归 R 值超过了99.9%,计算时间不到多场仿真的万分之一,证明了文中所提出的深度学习方法的可靠性与有效性。

1 柔直用压接式IGBT结构分析

以南网柔直换流站中常用的StakPak型压接式IGBT为研究对象,其为弹簧压接封装形式,最大的优势在于器件内部各芯片间压力的均衡可以得到有效的保证,多余的压力可以被框架给有效吸收,从而减少了因机械压力而造成的失效,但也正是由于弹簧的存在,这种封装形式实际上不能达到双面散热的效果,同时还需要一个铜片作为导电通道,增加了寄生参数的影响。

器件内部采用子模组的形式,每个子模组内部包括8个IGBT芯片和4个FRD芯片。一个子模组形成一个独立的电气单元,电压等级为4 500 V/500 A,然后再由这些子模组形成整个压接式IGBT器件。芯片分布与单芯片模组结构见图1。




图1 StakPak芯片分布与单芯片模组结构

Fig. 1 Chip layout and single-chip submodule structure on StakPak

图1中,一个子模组的集电极的焊接面上,总共焊接有8个IGBT芯片(标记为 T_1 - T_8),4个FWD芯片(标记为 D_1 - D_4),以及2个栅极片(标记为 G_1 - G_2),IGBT芯片和FWD芯片面积一致,长宽尺寸均为 $14\text{ mm} \times 14\text{ mm}$ 。由于IGBT模块基于6个完全相同的500 A子模块并联而成,各子模组之间的物理量又互不干扰,文中分析主要考虑器件内部各芯片表面的情况,其他的组件如:塑料框架、驱动连接板等对器件内部芯片表面压力分布基本没有影响,建模时可以进行省略简化,为了得到初步的研究结果,首先对单芯片子模组进行研究。相应的材料设置见表1。

表1 多物理场模型材料设置

Table 1 Material settings for multi-physical field modeling

组件	材料	组件	材料
集电极	Mo	铜柱	Cu
焊料层	SnAgCu	芯柱	合金
IGBT芯片	Si(表面Al金属化)	碟簧	合金
小铜片	Mo	导流片	Cu
铝片	Al	发射极	Cu

2 压接式IGBT电—热—力多物理场耦合仿真

2.1 压接式IGBT多物理场数学模型

在栅极控制电信号的操纵下,压接式IGBT集—射极间在通态与断态间转换。导通时电流电压将在芯片上产生热损耗,导致温度升高与材料膨胀。所以压接式IGBT模块涉及复杂的电—热—力耦合过程,构建其多场耦合模型是压接式IGBT模块设计和寿命评估的前提。

2.1.1 电场模型

基于PWM控制策略,IGBT模块集电极和发射

级在开通与关断间反复切换,其内部电场场可以采用下式计算

$$\begin{cases} \nabla J = Q_i \\ J = \sigma E + J_e \\ E = -\nabla U \end{cases} \quad (1)$$

式(1)中: ∇ 为梯度算子; J 为电流密度, A/m^2 ; Q_i 为自由电荷密度, C/m^2 ; σ 为电导率, S/m ; J_e 为自有电流密度, A/m^2 ; E 为电场强度, V/m ; U 为电位, V 。

2.1.2 温度场模型

压接式IGBT导通时主要在硅芯片上产生损耗,这些损耗将转变为热能,以热传导的形式在固体材料内部由高温处向低温处传导,而温度升高会引起热膨胀,必须考虑内部温度的影响,温度场情况可以采用公式计算得到

$$\begin{cases} \rho C_p \frac{\partial T}{\partial t} + \nabla \cdot q = Q \\ q = -k \nabla T \end{cases} \quad (2)$$

式(2)中: ρ 为密度, kg/m^3 ; C_p 为恒压热容, $\text{J/(kg} \cdot \text{K)}$; T 为温度, K ; t 为时间, s ; q 为热流密度, W/m^2 ; Q 为热源,此处即功率损耗, J ; k 为导热系数, $\text{W/(m} \cdot \text{K)}$ 。

2.1.3 应力场模型

压接式IGBT受夹具压力以保持组件间的有效连接,运行过程中各组件随温度变化重复热膨胀与收缩的过程,期间存在相互间应力变化与内部膨胀应力变化的复杂过程,应力变化过程可计算得

$$\begin{cases} 0 = \nabla \cdot (FS)^T + Fv \\ F = I + \nabla U \end{cases} \quad (3)$$

式(3)中: F 为形变梯度张量; S 为柯西应力张量, Pa ; T 为温度, K ; v 为物体的速度, m/s ; I 为单位张量,表现为一个单位矩阵; U 为位移, m 。

2.2 边界条件

为了减小模型的计算时间和计算量,在保证计算精度的前提下,对器件模型进行了如下简化:①忽略对器件内部芯片表面压力分布基本没有影响的其他的组件如:塑料框架、驱动连接板等。②忽略模块内部倒角、圆角等细微结构。③忽略芯片有源区外其他结构和接触面的功率损耗。结合实物数据搭建单芯片子模组仿真模型见图2。

其多物理场模型各材料参数设置见表2,仿真计算模型边界条件设置见表3。




图2 单芯片子模组模型

Fig. 2 Single chip submodule model

表2 各材料的热力学参数

Table 2 Thermodynamic parameters of each material

组件	热导率/ [W·(mK) ⁻¹]	密度/(Kg·m ⁻³)	比热容/[J·/(kg·°C) ⁻¹]
Mo	138	10 200	250
Si	130	2 330	700
Al	238	2 700	900
Cu	400	8 960	385

表3 压接式IGBT多物理场模型边界条件

Table 3 Boundary conditions of multi-physical field model of press-pack IGBT

类型	边界条件
S ₁	终端电流;热通量传热系数;边界载荷总力
S ₂	接地;热通量传热系数;固定约束
S ₃	热源热耗率
γ	热接触;接触
Cu、Al	弹塑性材料
其他	环境温度;线弹性材料

2.3 不同工况结果分析

功率损耗为芯片流经电流时所产生的热量值,边界载荷代表夹具所加压力大小,传热系数与环境温度代表着散热器的散热情况,这4种运行工况对寿命有较大影响且能方便进行调整;芯片是压接式IGBT的薄弱环节,其温度与应力最大值常被用于寿命计算中。因此仿真重点聚焦于4种工况与芯片结温、应力的关系情况上。进行有限元仿真计算,得到压接式IGBT温度与应力分布见图3。

由仿真可知,器件温度最高处为产生功率损耗的芯片有源区,弹簧影响了发射极侧导热能力,器件散热主要通过集电极侧;应力在器件中不规则分布,主要关心芯片表面情况,表面应力最大值在芯片与铜片相交的边缘处。采用参数化扫描考察不同边界载荷下结温与应力的变化情况见图4。






图3 压接式IGBT温度与应力分布

Fig. 3 Temperature and stress distribution on press-pack IGBT



(a) 结温关系



(b) 应力关系

图4 边界载荷与结温、应力关系曲线

Fig. 4 Relationship curve between boundary load and junction temperature and stress

边界载荷代表夹具在器件两端所加压力大小,压力越大芯片应力自然越大,但随着压力增大组件

间的接触更为紧凑,内部导热能力提升,最终表现为结温降低。进一步的分析不同散热情况对结温的影响,见图5。




图5 散热情况与结温的关系

Fig. 5 Relationship between heat dissipation and junction temperature

图5中可见,环境温度与结温间为正相关,环境温度越高意味着内外相对温差越小,散热效率低从而导致结温温度升高;传热系数代表器件与外界间的换热能力,数值越高散热能力越强,散热系数增大过程中结温变化率逐渐减小是环境温度限制了散热效果。仿真结果与预期相同,具备较高可信度,为下文研究提供数据支撑。

使用有限元模型实现一种工况下的计算需花费时间358 s,接近6 min,期间i7-10700CPU占用始终在80%左右,最大使用物理内存8.82 G,虚拟内存10.69 G,消耗了大量算力。这仅为简化后单芯片子模组在单种工况下的稳态仿真,如果对整个压接式IGBT器件进行瞬态仿真消耗的资源将呈指数级增长。为了实现数据的快速获取,提出了以深度学习模型代替有限元仿真的方法。

3 融合深度学习的多场特性快速分析方法

深度学习中的“深度”指的是神经网络的层数,即网络中堆叠的神经网络层的数量。核心思想是通过建立多层神经网络(也称为深度神经网络)来模拟人脑神经元的结构,从而提升对数据的抽象和表示能力。每一层网络对输入数据进行一系列非线性转换和特征提取,逐渐形成对输入数据更加抽象和高级的表示。

传统的机器学习算法通常只使用一到两层的线性模型或非线性模型,而深度学习算法可以具有数十上百甚至更多层。通过增加隐藏层层数,深度学习可以更好地学习到数据中的复杂模式和特征

表示,从而提高模型的表达能力,在处理图像、语音等大规模、复杂数据方面具有显著优势。文中利用BPBR神经网络训练深度学习数据预测模型。

3.1 反向传播

反向传播(back-propagation, BP)是深度学习的关键技术之一,也是最常见和广泛应用的神经网络训练算法之一,其通过最小化网络输出与目标输出之间的误差来调整网络的权重和偏置,从而使网络的预测结果接近目标值。这个过程包括两个阶段:前向传播和反向传播。

在前向传播阶段,输入数据通过网络的每一层,从输入层逐渐传递到输出层。每个神经元将其输入进行加权求和,并通过激活函数进行非线性转换,将输出传递给下一层的神经元。在反向传播阶段,通过比较网络预测输出和目标输出的误差,计算不同层之间的误差梯度。然后,该误差梯度逆向传播回网络,根据链式法则计算每个权重和偏置的梯度。

通过迭代的方式,持续进行前向传播和反向传播,根据梯度下降算法更新网络参数,直到达到预定的训练条件或误差收敛。BP法的优点包括能够处理非线性问题、适用于大规模网络和灵活的模型表示能力。

3.2 贝叶斯正则化BP神经网络

传统的BP神经网络存在训练速度慢、局部最优与容易出现过拟合等问题^[32-33]。文中提出采用贝叶斯正则化法(Bayesian regularization, BR)改进训练性能函数,以规范网络规模,提高网络泛化能力。

贝叶斯正则化法是一种正则化方法,用于在学习算法中控制模型的复杂度。正则化理论可以很好的提高网络的泛化能力,贝叶斯正则化算法是通过修正神经网络的性能函数来提高优化能力的。常规的BP神经网络训练性能函数采用网络响应的均方误差 e_{MSE} (mean squared error)

$$e_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2 \quad (4)$$

式(4)中: N 为样本总数; f_i 为预测值; y_i 为实际值。贝叶斯正则化的思路是在误差函数的基础上加上正则化项 E_{ω} ,即网络权值的均方误差。此时正则化下BP神经网络的训练性能函数 F_0 改写为:

$$F_0 = \alpha E_{\omega} + \beta e_{\text{MSE}} \quad (5)$$

$$E_{\omega} = \frac{1}{m} \sum_{j=1}^m \omega_j^2 \quad (6)$$

式(4)、(5)中: α 、 β 为正则化系数; m 为网络的权

值总数; ω_j 为网络权值。

若 $\alpha \gg \beta$, 则网络训练倾向于泛化能力, 往往会导致网络欠拟合; 若 $\alpha \ll \beta$, 则网络训练倾向于减小网络误差, 往往会导致网络过拟合。贝叶斯理论框架下可以推导出

$$\begin{cases} \alpha = \frac{\gamma}{2E_{\omega}} \\ \beta = \frac{N - \gamma}{2e_{\text{MSE}}} \end{cases} \quad (7)$$

式(7)中: γ 为有效参数的数量, $\gamma = m - 2\alpha \cdot \text{tr}(\mathbf{H})^1$; $\mathbf{H}$ 为 F_0 的 Hessian 矩阵, $\mathbf{H} = \alpha \nabla^2 E_{\omega} + \beta \nabla^2 e_{\text{MSE}}$ 。

贝叶斯正则化算法将 BP 神经网络中各网络权值看作随机变量, 以最大后验概率为目标, 能够自适应地修正 α 、 β 的参数大小, 在保证网络均方误差最小的前提下, 能够有效地控制网络的复杂程度。

改进后网络具体计算步骤更新如下:

- 1) 初始化 α 、 β 和各神经元之间的连接权值。
- 2) 利用 BP 训练算法, 最小化目标函数 F_0 。
- 3) 求 Hessian 矩阵, 计算有效参数个数 γ 。
- 4) 由式(7)计算超参数 α 、 β 的新值。
- 5) 重复步骤 2)-4) 直到达到设定精度或预定训练次数^[24-25]。

基于有限元仿真所得数据, 通过 BRBP 神经网络训练深度学习的数据预测模型, 模型结构设置 4 输入、双输出, 隐藏层层数与节点数通过网格搜索法确定。输入变量分别为功率损耗、边界载荷、传热系数与环境温度, 输出变量分别为预测目标结温与应力, 模型结构见图 6。




图6 数据预测模型结构

Fig. 6 Data prediction model structure

4 深度学习数据预测模型实验分析

4.1 建立样本空间

基于前文分析, 文中选择功率损耗、边界载荷、

传热系数与环境温度 4 个条件参数作为输入变量 $\{x_1, x_2, x_3, x_4\}$, 每个输入变量各取 5 个值; 以结温与应力作为输出变量 $\{y_1, y_2\}$, 经有限元多物理场模型计算得到 4 种工况与结温、应力的数据共 625 组。在训练压接式 IGBT 深度学习数据预测模型时, 将样本数据划分为训练集和测试集。取 85% 作为训练集, 剩下 15% 作为测试集, 用于测试评估数据预测模型的预测准确性以及模型泛化能力。

4.2 搭建数据预测模型

神经网络的隐藏层层数和隐藏层节点数是决定网络复杂度和性能的两个重要参数。增加层数一般会带来更高的网络复杂度和表达能力, 但同时也会增加训练复杂度和可能的梯度消失问题; 增加节点数可以增加网络的非线性表达能力, 但也会带来更多的参数和更高的计算资源需求。

为了得到最佳隐藏层层数与隐藏层节点数, 采用网格搜索法进行参数调优。网格搜索法为在所有候选的参数选择中, 通过循环遍历计算出每一种情况的预测结果, 从中找到最优的参数组合。选择绝对值误差 e_{MAE} (mean absolute error) 与均方误差共同作为损失函数确定最优隐藏层层数与最优隐藏层节点数。 e_{MAE} 公式为

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |f_i - y_i| \quad (8)$$

为了能够客观显示对应网络结构下的预测能力, 每次训练让软件随机划分数据集; 同时为了保证随机取得的数据能够稳定展示网络预测效果, 在同一网络结构下进行 5 次训练得到五组预测数据, 去掉预测误差最大与最小的两组数据, 对剩下的 3 组数据取平均值得到相应网络结构的 e_{MSE} 、 e_{MAE} 。循环遍历采用逐层增加、每层单元数以 2 的倍数递增的方法。即先逐渐增加节点数, 找到预测效果最佳情况以确定该层最优节点数, 再增加层数重复该操作, 直到加入新隐藏层无法使预测误差下降为止, 得到最佳隐藏层层数与相应各隐藏层节点数。

BR 法不同网络结构时的预测性能见表 4。分析数据可以发现, 随着节点数与隐藏层层数的增加, 训练 e_{MSE} 与 e_{MAE} 始终呈现下降趋势, 且在数值小于 1 时, e_{MSE} 是小于 e_{MAE} 的, 这与小于 1 的数平方变小对应; 然而测试数据中 e_{MSE} 大于 e_{MAE} , 这意味着误差呈现集中的趋势——大多数预测数据具有较高的预测精度, 而个别预测数据存在较大误差, 并由平方放大以致于 e_{MSE} 偏大。

当第一层隐藏层节点数为 32 时, 虽然训练误差比 64 节点时大, 但其测试误差却更小, 体现出了更

表 4 不同网络结构时的预测性能
Table 4 Predictive performance under different network structures

隐藏层 层数	隐藏层 节点数	训练数据		测试数据	
		e_{MSE}	e_{MAE}	e_{MSE}	e_{MAE}
1	8	19.712 5	2.995 4	24.506 8	3.357 4
	16	2.833 3	0.800 8	3.613 8	1.173 1
	32	0.380 0	0.391 2	1.080 0	0.593 0
	64	0.156 4	0.240 9	4.414 7	0.643 0
2	2	0.541 3	0.474 4	1.511 3	0.749 2
	4	0.172 3	0.266 2	0.890 0	0.588 4
	8	0.031 6	0.125 6	1.625 0	0.618 7
3	2	0.202 6	0.264 8	0.938 2	0.616 8
	4	0.148 4	0.255 8	0.790 5	0.549 6
	8	0.589 5	0.243 5	0.756 9	0.517 9
	16	0.114 9	0.228 1	1.100 3	0.510 3
4	2	0.173 9	0.262 6	0.730 2	0.514 3
	4	0.119 1	0.224 5	0.816 1	0.541 0
5	2	0.131 7	0.237 2	1.064 8	0.553 4

高的泛化性,故第1层取32个节点;同理,第2层隐藏层的节点数为4,第3层隐藏层的节点数为8,以及第4层隐藏层的节点数为2时的预测性能最好,选择他们作为相应隐藏层节点数。而添加第5层隐藏层后训练误差明显增大,遍历结束,模型确定为4隐藏层结构。综上所述,BRBP法构建的神经网络数据预测模型为4输入、双输出、4隐藏层的网络结构,隐藏层节点数分别为32、8、2、2,此时模型具有最佳的预测性能。

BR法的训练速度偏慢,但也因此具备了较高的泛化能力,在仅仅具有一层隐藏层的情况下其测试 e_{MAE} 就达到了0.593 0。虽然其隐藏层层数从一层增加到最优的4层情况下测试 e_{MAE} 没有得到明显下降,从0.593 0到0.514 3仅仅降低了0.0787、13.3%,但测试 e_{MSE} 还是取得了一定的优化,其值从1.080 0降至0.730 2,降低了0.349 8、32.4%,这意味着神经网络结构优化主要在一定程度上缓解了误差集中问题,提高了数据预测的稳定性。

4.3 实验结果分析

为了更直观地观察数据预测模型的预测性能,对最优状态模型进行性能实验,将实验数据结果可视化,见图7、8。

将真实值与预测值绘出,二者几乎完全重合,仅极少数能直接观察到偏差;从图7(b)可以看出,与前文分析一致,大多数预测数据具有较高的预测精度,有一半左右的预测数据误差值小于0.05,精度达




图7 模型实验误差分析图

Fig. 7 Error analysis diagram of model experiment




图8 测试集回归

Fig. 8 Test regression

到了1‰;而个别预测数据存在较大误差,超过了3.6,相当于72个0.05之和,表现出误差集中现象,但该项偏差率也依然不到1/10,且为极个别现象,不会对数据预测模型的预测稳定性造成严重影响。

回归 R 值指的是模型可以解释的信息所占的百分比,代表着输出与响应之间的相关性,其值越大意味着预测值和实际值之间的相关性越强,模型

的可解释性越好。图8中可见,测试集回归 R 值高达0.999 95,测试集预测数据基本位于拟合函数线上,证明文中提出的神经网络数据预测模型表现出优秀的预测性能,能够极为准确地表达出压接式IGBT的4种工况与结温、应力之间的非线性关系,从而在跳过复杂的电—热—力有限元仿真计算的情况下得到预测数据。

取一种工况对比仿真与预测性能,见表5。结温与应力分别通过仿真与神经网络计算得到;内存与CPU占用情况通过任务管理器的性能面板查看;仿真软件能够自动记录时间花费,神经网络计算时间通过tic、toc命令查看。

表5 仿真性能与预测性能对比

Table 5 Comparison between simulation performance and prediction performance

模型	结温/℃	应力/ (N·mm ⁻²)	内存/G	CPU/%	时间/s
有限元模型	117.56	258.38	8.459	80	347.000 0
数据预测模型	117.73	258.60	2.131	10	0.026 5

与前文一致,深度学习数据预测结果与有限元计算结果偏差值不到0.3,偏差率不到1%,有极高的精确度;与此同时,内存占用降至1/4,CPU占用降至1/8,计算所花费的时间更是从接近6 min降至不足0.1 s,不及原本万分之一。可见,构建深度学习模型实现压接式IGBT数据预测能够极大减少计算资源消耗,为现场复杂工况环境提供快捷、有效指导,保证柔直输电系统稳定运行。

为了能更直观地表征预测数据的偏移情况,引入平均绝对百分误差 e_{MAPE} (mean absolute percentage error)作为指标,该误差值的计算考虑到了数据本身的大小,其公式为

$$e_{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|f_i - y_i|}{y_i} \times 100\% \quad (9)$$

结合 e_{MSE} 、 e_{MAE} 、 e_{MAPE} 3项指标,考察BR法、(levenberg - marquardt)LM法与量化共轭梯度法(scaled conjugate gradient, SCG)改进BP模型对测试集的预测精度,见表6。

表6 不同算法评价指标对比

Table 6 Comparison of evaluation indexes of different algorithms

评价指标	BR法	LM法	SCG法
e_{MSE}	0.730 2	1.664 7	93.447 8
e_{MAE}	0.514 3	0.984 2	8.543 4
$e_{MAPE}/\%$	0.394 4	0.590 4	6.820 7

BR法拥有最高的预测性能,而以BR法与LM法搭建的数据预测模型的平均绝对百分误差皆低于1%,这说明在选择了合适的算法与网络结构的情况下,文中所提出的基于神经网络代替有限元计算的方法具备充分的可靠性与可实施性。

将LM法与BR法构建的预测模型进行性能对比,见图9。




图9 LM法与BR法性能对比

Fig. 9 Performance comparison between LM and BR method

两种算法所得训练 e_{MAE} 均小于测试 e_{MAE} ,在隐藏层层数逐渐增加的过程中,LM法的测试 e_{MSE} 无论是数值上还是比例上都得到了更明显的减小;而BR法则表现出更高的预测精度,其误差值始终保持在LM法的一半左右,更长的模型搭建时间使其得到了更精准的预测效果。

5 结论

文中分析了柔直用压接式IGBT的基本构造,在此基础上搭建了多场耦合有限元仿真模型,分析了不同工况下结温与应力的变化趋势。其次,将BPBR神经网络应用于压接式IGBT的运行数据预测中,通过有限元仿真取得所需训练数据,结合网格搜索法完成了深度学习的数据预测模型构建,并结合多种算法完成了性能验证。

1)提取弹簧压接式IGBT关键单芯片子模组结构搭建仿真模型,所得电—热—力多场耦合模型符合理论实际,能够有效模拟IGBT的运行情况。

2)基于BPBR神经网络搭建的深度学习数据预测模型回归 R 值超过99%,平均百分误差不到0.4%,具有极高的预测精度,且算力消耗大幅降低,内存占用由8 G降至2 G,CPU占用从80%降至10%,计算时间更是不到仿真的万分之一,能够为压接式IGBT寿命预测快速提供数据支持。

3)对比多种算法网络性能,发现LM法也具备

较强的预测性能,平均百分误差不到0.6%,表明在选择了合适算法网络的情况下,文中所提出的以深度学习数据预测模型代替有限元计算的方法具备充分的可靠性与可实施性,其中BRBP神经网络的预测性能最强。

参考文献:

- [1] 郑全旭,孙小平,姜彦涛,等. ± 500 kV海上柔直换流阀轻型化设计及仿真分析[J]. 高压电器, 2023, 59(6): 188-201.
Zheng Quanxu, Sun Xiaoping, Lou Yantao, et al. Lightweight design and simulation analysis of ± 500 kV offshore VSC converter valve [J]. High Voltage Apparatus, 2023, 59(6): 188-201.
- [2] 贾科,刘可歆,毕天姝,等.基于波形匹配的柔性直流输电线路单端量保护研究[J]. 电力系统保护与控制, 2025, 53(3): 13-26.
Jia Ke, Liu Kexin, Bi Tianshu, et al. Research on single-ended protection of a flexible HVDC transmission line based on waveform matching[J]. Power System Protection and Control, 2025, 53(3): 13-26.
- [3] 孙凯,卢世蕾,易哲媛,等.面向电力电子变压器应用的大容量高频变压器技术综述[J]. 中国电机工程学报, 2021, 41(24): 8531-8545.
Sun Kai, Lu Shilei, Yi Zheyuan, et al. A review of high-power high-frequency transformer technology for power electronic transformer applications[J]. Proceedings of the CSEE, 2021, 41(24): 8531-8545.
- [4] Han Lubin, Liang Lin, Wang Yijian, et al. Performance limits of high voltage press-pack SiC IGBT and SiC MOSFET devices[J]. Power Electronic Devices and Components, 2022(3): 100019.
- [5] Oh H, Han B, Mccluskey P, et al. Physics-of-failure, condition monitoring, and prognostics of insulated gate bipolar transistor modules: a review[J]. IEEE Transactions on Power Electronics, 2015, 30(5): 2413-2426.
- [6] Huang Zhiliang, Yang Tianguai, Li Chuanbo, et al. Optimization of the pressure distribution in press-pack insulated gate bipolar transistors[J]. Structural and Multidisciplinary Optimization, 2021, 63(2): 855-865.
- [7] 杨兵,王胜利,王文杰,等.混合式直流断路器IGBT关断能力提升技术研究[J]. 高压电器, 2020, 56(5): 24-32.
Yang Bing, Wang Shengli, Wang Wenjie, et al. Research on IGBT turning off capacity enhancement technology of hybrid DC circuit breaker[J]. High Voltage Apparatus, 2020, 56(5): 24-32.
- [8] Liu Renkuan, Li Hui, Yao Ran, et al. Research on long-term reliability of silver sintered press-pack IGBT modules[J]. Power Electronic Devices and Components, 2022(3): 100012.
- [9] Lutz J, Schlangenotto H, Scheyermann U, et al. Semiconductor power devices: physics, characteristics, reliability[M]. Berlin Heidelberg: Springer-Verlag, 2011.
- [10] 任斌,黄永章.压接型IGBT器件单芯片子模组可靠性寿命仿真研究[J]. 华北电力大学学报(自然科学版), 2020, 47(3): 49-57.
Ren Bin, Huang Yongzhang. Simulation on reliability lifetime of single IGBT chip module of press-pack IGBTs [J]. Journal of North China Electric Power University(Natural Science Edition), 2020, 47(3): 49-57.
- [11] 张经纬.基于有限元法的压接型IGBT器件单芯片子模组疲劳寿命预测[D]. 北京:华北电力大学, 2018.
Zhang Jingwei. Fatigue life prediction of single-chip submodule of press-pack IGBTs based on finite element method[D]. Beijing: North China Electric Power University, 2018.
- [12] 郭佳奇,张一鸣,邓二平,等.考虑接触界面全接触的压接型IGBT器件功率循环寿命预测[J]. 华北电力大学学报(自然科学版), 2023, 50(2): 63-72.
Guo Jiaqi, Zhang Yiming, Deng Erping, et al. Prediction of power cycle life of press-pack IGBTs considering full contact of contact interface[J]. Journal of North China Electric Power University (Natural Science Edition), 2023, 50(2): 63-72.
- [13] 任斌.压接型IGBT器件可靠性寿命模型与相关仿真研究[D]. 北京:华北电力大学, 2020.
Ren Bin. Simulation on reliability lifetime of single IGBT chip module of press-pack IGBTs[D]. Beijing: North China Electric Power University, 2020.
- [14] 韩文超,路茂增,马新喜,等.高压大容量混合型MMC半桥子模块下部IGBT损耗优化方法[J]. 电力工程技术, 2024, 43(2): 189-198.
Han Wenchao, Lu Maozeng, Ma Xinxi, et al. Loss optimization method for bottom IGBT in half bridge sub-module of high voltage and large capacity hybrid MMC[J]. Electric Power Engineering Technology, 2024, 43(2): 189-198.
- [15] 邓吉利.柔性直流换流阀压接式IGBT器件可靠性建模与评估[D]. 重庆:重庆大学, 2018.
Deng Jili. Reliability modeling and evaluation of press-pack IGBT devices for VSC-HVDC converter valves[D]. Chongqing: Chongqing University, 2018.
- [16] 邓真宇,陈民铀,赖伟,等.多芯片并联压接式IGBT中温度不均对电流分布的影响[J]. 中国电力, 2020, 53(12): 10-17.
Deng Zhenyu, Chen Minyou, Lai Wei, et al. Influence of uneven temperature on current distribution in paralleled multi-chips press pack IGBT[J]. Electric Power, 2020, 53(12): 10-17.
- [17] 李洁,党晓圆,邓真宇,等.多芯片并联压接式IGBT器件多物理场耦合建模分析[J]. 电力电子技术, 2021, 55(12): 9-12.
Li Jie, Dang Xiaoyuan, Deng Zhenyu, et al. Multi-physical field coupling modeling analysis of multi-chip parallel press pack IGBT devices[J]. Power Electronics, 2021, 55(12): 9-12.
- [18] 张筱迪,毛明晖,卢昶衡,等.基于有限元分析和机器学习的跌落所致封装结构力学行为预测[J]. 电子与封装, 2021, 21(2): 73-80.
Zhang Xiaodi, Mao Minghui, Lu Changheng, et al. Prediction of mechanical behavior of package structure subjected to drop impact based on finite element analysis and machine learning[J]. Electronics and Packaging, 2021, 21(2): 73-80.
- [19] 金亮,王飞,杨庆新,等.永磁同步电机性能分析的典型深度学习模型与训练方法[J]. 电工技术学报, 2018, 33(s1): 41-48.
Jin Liang, Wang Fei, Yang Qingxin, et al. Typical deep learning model and training method for performance analysis of permanent magnet synchronous motor[J]. Transactions of China Electrotechnical Society, 2018, 33(s1): 41-48.
- [20] 王要强,陈晨,张世达,等.基于新型趋近律的表贴式永磁同步

- 电机抗滑模控制策略[J]. 电力系统保护与控制, 2026, 54(2): 151-161.
- Wang Yaoqiang, Chen Chen, Zhang Shida, et al. Anti-disturbance sliding mode control strategy for surface-mounted permanent magnet synchronous motors based on a novel reaching law[J]. Power System Protection and Control, 2026, 54(2): 151-161.
- [21] 魏尧, 付俊荣, 王高林, 等. 基于陷波抗滞滞的永磁同步电机无模型预测电流滑模控制[J]. 电工技术学报, 2026, 41(2): 475-486.
- Wei Yao, Fu Junrong, Wang Gaolin, et al. Notch anti-stagnation based model-free predictive current sliding mode control of permanent magnet synchronous motor drives[J]. Transactions of China Electrotechnical Society, 2026, 41(2): 475-486.
- [22] 李耀华, 种国臣, 王钦政, 等. 永磁同步电机模型预测电流控制简化研究[J]. 电力电子技术, 2026, 60(2): 137-143.
- Li Yaohua, Chong Guochen, Wang Qinzheng, et al. Research on simplified model predictive current control for permanent magnet synchronous motor[J]. Power Electronics, 2026, 60(2): 137-143.
- [23] 宋诗雨, 吴永斌, 尹海韬, 等. 基于混合式BPNN/PSO-MRAS的永磁同步电机参数在线辨识[J]. 智慧电力, 2026, 54(4): 111-118.
- Song Shiyu, Wu Yongbin, Yin Haitao, et al. Online parameter identification of permanent magnet synchronous motor based on hybrid BPNN/PSO-MRAS[J]. Smart Power, 2026, 54(4): 111-118.
- [24] 王鸣宇, 汤毅, 许彦祺, 等. 表贴式永磁同步电机空载电磁性能解析分析[J]. 大电机技术, 2026(1): 40-48.
- Wang Mingyu, Tang Yi, Xu Yanqi, et al. Analytical analysis of no-load electromagnetic performance of surface mounted permanent magnet synchronous motor[J]. Large Electric Machine and Hydraulic Turbine, 2026(1): 40-48.
- [25] 刘向贞. 永磁同步电机性能分析的深度学习算法与应用[D]. 天津: 天津工业大学, 2020.
- Liu Xiangzhen. Deep learning algorithm for performance analysis of permanent magnet synchronous motor and its application[D]. Tianjin: Tiangong University, 2020.
- [26] 阎世梁, 王银玲, 路丹丹, 等. 基于深度神经网络的永磁直线电机仿真与优化[J]. 系统仿真学报, 2024, 36(3): 713-725.
- Yan Shiliang, Wang Yinling, Lu Dandan, et al. Simulation and optimization of permanent magnet linear machine based on deep neural network[J]. Journal of System Simulation, 2024, 36(3): 713-725.
- [27] Jing Honglei. Deep neural network based chiller energy saving control method[J]. Computer Informatization and Mechanical System, 2023, 6(5): 73-78.
- [28] El-dalameh M, Al-greer M, El-dalameh M, et al. Capacity estimation of lithium-ion batteries based on adaptive empirical wavelet transform and long short-term memory neural network[J]. Journal of Energy Storage, 2023 (70): 108046.
- [29] Zhao Meiling, Zhang Yunwei, Yuan Zhanbin, et al. A point-to-point convolutional neural network for reconstructing electromagnetic parameters of multiple cavities scattering with inhomogeneous anisotropic media[J]. Engineering Analysis With Boundary Elements, 2023(155): 281-296.
- [30] 耿学锋, 何赞泽, 李孟川, 等. IGBT多物理场建模技术与应用研究概述[J]. 中国电机工程学报, 2022, 42(1): 271-290.
- Geng Xuefeng, He Yunze, Li Mengchuan, et al. An overview of IGBT multiphysics modeling technology and application[J]. Proceedings of the CSEE, 2022, 42(1): 271-290.
- [31] 范继锋, 王永强, 张天龙, 等. 基于时频分析矩阵与BP神经网络的输电线路保护方法[J]. 电力科学与技术学报, 2026, 41(1): 46-52.
- Fan Jifeng, Wang Yongqiang, Zhang Tianlong, et al. Transmission line protection method based on time-frequency analysis matrix and BP neural network[J]. Journal of Electric Power Science and Technology, 2026, 41(1): 46-52.
- [32] 夏世远, 苏建徽, 杜燕, 等. 基于贝叶斯正则化BP神经网络的PEMFC电堆建模[J]. 合肥工业大学学报(自然科学版), 2021, 44(7): 895-899.
- Xia Shiyuan, Su Jianhui, Du Yan, et al. Modeling of PEMFC stack based on Bayesian regularized BP neural network[J]. Journal of Hefei University of Technology(Natural Science), 2021, 44(7): 895-899.
- [33] Ghahramani Z. Probabilistic machine learning and artificial intelligence[J]. Nature, 2015, 521(7553): 452-459.
- 肖凯(1991—), 男, 工程师, 从事高压直流输电换流阀及阀冷工作(通信作者)(E-mail: xiaokaiehv@163.com)。