

DOI:10.19651/j.cnki.emt.2314062

# 基于改进 DBO 优化 BiLSTM 的 IGBT 老化预测模型<sup>\*</sup>

韩素敏<sup>1,2</sup> 赵国帅<sup>1,2</sup> 尚志豪<sup>1,2</sup> 余悦伟<sup>1,2</sup> 郭宇<sup>1</sup>

(1. 河南理工大学电气工程与自动化学院 焦作 454003; 2. 河南省煤矿装备智能检测与控制重点实验室 焦作 454003)

**摘要:**为了表征逆变器故障中 IGBT 模块的老化趋势,提高老化过程的预测精度,本文提出一种基于改进蜣螂搜索算法(IDBO)优化双向长短期神经网络(BiLSTM)超参数的 IGBT 老化预测模型。首先提取老化过程中  $V_{ce(on)}$  的时频域特征,利用核主成分分析进行降维构建归一化综合指标。其次,针对蜣螂搜索算法(DBO)的不足,通过引入改进 Circle 混沌映射、Levy 飞行和自适应权重因子提升了 DBO 寻优能力和收敛性能,利用 IDBO 对 BiLSTM 预测模型超参数实现全局寻优。最后,通过实际 IGBT 退化数据验证了基于 IDBO 优化 BiLSTM 老化预测模型的有效性和优越性。结果表明,所构建的 IDBO-BiLSTM 模型与 BiLSTM 模型相比 RMSE 平均下降 36.42%、MAE 平均下降 31.77%、MAPE 平均下降 41.03%。

**关键词:** 蜣螂搜索算法;BiLSTM 神经网络;Levy 飞行策略;IGBT;老化预测

**中图分类号:** TN322.8; TN306    **文献标识码:** A    **国家标准学科分类代码:** 470.4031

## IGBT aging prediction model based on improved DBO optimization BiLSTM

Han Sumin<sup>1,2</sup> Zhao Guoshuai<sup>1,2</sup> Shang Zhihao<sup>1,2</sup> Yu Yuewei<sup>1,2</sup> Guo Yu<sup>1</sup>

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China;

2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Jiaozuo 454003, China)

**Abstract:** In order to characterize the aging trend of IGBT modules in inverter faults and improve the prediction accuracy of the aging process, this paper proposes an IGBT aging prediction model based on improved dung beetle optimizer (IDBO) optimizing the hyper-parameters of bidirectional long-short-term neural network (BiLSTM). Firstly, the time-frequency domain features of  $V_{ce(on)}$  in the aging process are extracted, and the normalized composite index is constructed by dimensionality reduction using kernel principal component analysis. Secondly, to address the shortcomings of the dung beetle optimizer (DBO), the optimization ability and convergence performance of the DBO are improved by introducing the improved Circle chaotic mapping, Levy flight, and adaptive weighting factors, and the global optimization is achieved by using the IDBO for the hyperparameters of the BiLSTM prediction model. Finally, the effectiveness and superiority of the BiLSTM aging prediction model optimized based on IDBO are verified by actual IGBT degradation data. The results show that the constructed IDBO-BiLSTM model reduces RMSE by 36.42%, MAE by 31.77%, and MAPE by 41.03% on average compared with the BiLSTM model.

**Keywords:** dung beetle optimizer; BiLSTM neural network; Levy flight strategy; IGBT; aging prediction

## 0 引言

绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)作为电力电子中的核心开关器件,被广泛应用于轨道交通、新能源发电等领域<sup>[1-3]</sup>。IGBT 在开关器件中的使用率高达 42%<sup>[1]</sup>,对维持电力系统的正常运行至关重要。但是工作环境的高温、高压引起的热疲劳效应会导致 IGBT 出现退化或物理失效现象,进而会导致电气设备的

损坏。对其开展退化预测研究可以为更换器件提供先验依据,防止大规模故障的发生,提升系统整体的可靠性和高效性<sup>[4]</sup>。

目前 IGBT 的退化预测研究主要包含基于物理模型、基于解析模型和基于数据驱动 3 类。基于物理模型的寿命预测需要通过分析 IGBT 内部失效情况,根据实际运行参数建立物理模型,并结合有限元分析进行预测<sup>[5-7]</sup>。但在实际应用中由于 IGBT 内部结构的复杂性和实际工况的不确

收稿日期:2023-07-09

\* 基金项目:河南省科技攻关项目(202102210094)、国家重点研发计划专项(2016YFC0600906)、河南理工大学博士基金(B2021-23)项目资助

定性使得相关几何参数获取十分困难。基于解析模型通过拟合老化数据,建立功率循环和电气参数的数学关系,进而构建老化预测模型<sup>[8]</sup>,但建立数学关系对数据精度要求较高且难度较大。

基于数据驱动模型不需要深度了解器件的物理特性和内部结构,仅通过从数据中提取器件的退化特征,并结合模型便能获得器件的老化趋势和剩余寿命。文献[9]针对退化过程中集电极-发射极饱和压降( $V_{ce, on}$ )信号不同阶段的不同退化趋势,提出了灰色预测和粒子滤波相结合的分段预测模型,取得了较好的预测效果。文献[10]基于 NASA 加速老化数据集中的尖峰关断电压( $V_{ce, peak}$ ),提出了一种基于逐次变分模态分解和贝叶斯优化长短期神经网络(long short-term memory, LSTM)的寿命预测模型。文献[11]通过计算  $V_{ce, on}$  和  $I_{ce}$  的马氏距离来判断 IGBT 模块是否进入退化阶段,当检测到异常行为时触发粒子滤波器算法预测剩余的使用寿命,设定的失效阈值为  $V_{ce, on}$  增加 20%。

虽然基于数据驱动的方法仅需要通过大量的实验数据提取退化特征就能够得到退化趋势或剩余寿命,但是如何选取合适的模型才能提升预测精度成为一个关键性难题。LSTM 的网络结构可以解决时间性长期依存问题,已经广泛应用于寿命预测领域<sup>[12-13]</sup>。但是神经网络的参数选取却大都依赖经验。文献[14]使用蜣螂搜索算法(dung beetle optimizer, DBO)对反向传播神经网络(back propagation, BP)进行优化,优化后的预测精度明显优于单一的 BP 神经网络。但相关文献表明 DBO 搜索算法在准确性和稳定性方面还存在较大的提升空间<sup>[15]</sup>。文献[16]使用改进的蜣螂搜索算法对 BP 神经网络参数进行寻优来预测热处理后木材的力学特性,结果表明改进蜣螂搜索算法有助于提高模型的预测精度。

基于以上问题,本文提出了一种改进蜣螂搜索算法(improved dung beetle optimizer, IDBO)优化双向长短期神经网络(bi-directional long short-term memory, BiLSTM)的 IGBT 老化预测模型。利用改进 Circle 映射、Levy 飞行策略和自适应权重因子对蜣螂搜索算法进行改进,然后使用改进蜣螂搜索算法对 BiLSTM 网络的超参数进行优化,得到 IDBO-BiLSTM 老化预测模型。将 NASA 实验室的加速老化数据集带入 IDBO-BiLSTM 模型进行实验验证,实验结果表明该模型相较其他模型具有较高的预测精度。

## 1 IGBT 老化指标的选取和处理

IGBT 在退化过程中,其特征参数随着其运行状态的改变而改变。选取合适退化特征参数会提高模型的预测精度。能表征 IGBT 退化的特征参数有很多,包括对闩锁效应和键合线脱落敏感的集电极-发射极电压( $V_{ce}$ )信号、能表征栅极氧化层退化的栅极漏电流( $I_g$ )、以及表征焊料层失效的集电极电流( $I_c$ )信号、门极-发射极电压( $V_{ge}$ )、导通/关断时间( $T_{on}/T_{off}$ )等。相关文献表明从线性、灵敏度、准

确度、通用性、能力和在线测量 6 个方面综合考虑  $V_{ce, on}$  信号相对于其他老化参数具有较强的性能<sup>[17]</sup>。由于加速老化实验数据获取较为困难,选取美国国家航空航天局(NASA)提供的加速老化数据集,原始数据如图 1 所示。

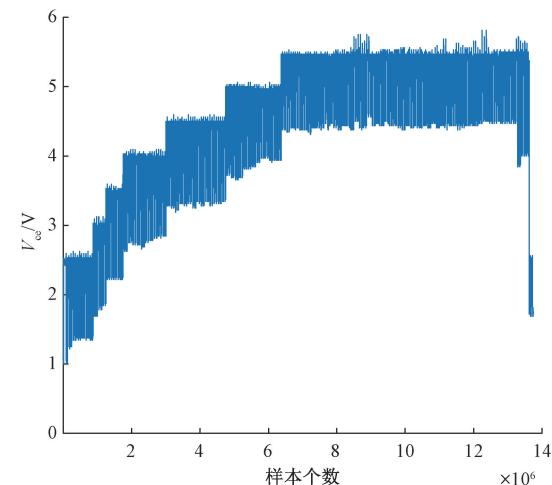


图 1 IGBT  $V_{ce}$  退化数据

提取每个采样周期内  $V_{ce, on}$  信号的时域、频域特征。表 1 为具体指标,其中  $TF_1 \sim TF_7$  为时域特征,  $FS_1$  和  $FS_2$  为频域特征,其具体计算公式参见文献[18]。

表 1 能表征退化趋势的时域、频域指标

序号	特征参数	序号	特征参数
$TF_1$	最大值	$TF_6$	方根幅值
$TF_2$	最小值	$TF_7$	能量
$TF_3$	平均值	$FS_1$	谱的均值
$TF_4$	整流平均值	$FS_2$	谱的均方根
$TF_5$	均方根		

大量的时域频域退化特征会造成数据冗余,影响老化预测模型效率和精度。核主成分分析(kernel principal component analysis, KPCA)是一种数据降维方法,其核心是在主成分分析(PCA)中引入核函数,提取特征空间中的线性和非线性关系,利用其将时域和频域特征融合为综合指标,可以降低特征之间的冗余相关性。所选取的多项式核函数如式(1)所示。

$$K = (\mathbf{Z}\mathbf{Z}^T + 1) \cdot para \quad (1)$$

式中: $\mathbf{Z}$  为  $n \times m$  的特征矩阵,  $para = 0.001$  为核函数参数,其中  $n = 1000$  表示所划分的生命周期,  $m = 9$  表示为特征维度。PCA 的计算过程参见文献[19]。

对降维后的综合指标进行归一化处理得到归一化综合指标  $G$ ,如式(2)所示。

$$G = \frac{g - g_{\min}}{g_{\max} - g_{\min}} \quad (2)$$

式中:  $g_{\max}, g_{\min}$  为 KPCA 降维后综合指标的最大最小值。

## 2 基于 IDBO 优化 BiLSTM 的 IGBT 老化预测模型

### 2.1 基于 BiLSTM 的 IGBT 老化预测模型

LSTM 是对循环神经网络 (recurrent neural network, RNN) 的优化, 继承了 RNN 的可记忆性功能, 同时引入了遗忘门、输入门和输出门改善了信号序列的传输路径, 有效缓解了标准 RNN 的长期依存问题, 避免了梯度消失和梯度爆炸<sup>[20]</sup>。其单元结构如图 2 所示。

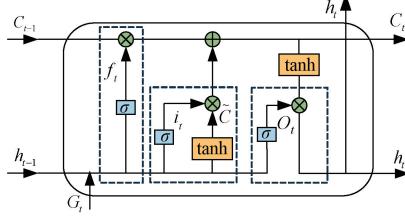


图 2 IGBT 老化预测模型 LSTM 单元结构

图 2 中  $C_{t-1}$  和  $h_{t-1}$  分别表示上一时刻的记忆状态和隐藏状态, 初始时刻为 0。 $G = [G_1, G_2, G_3, \dots, G_\epsilon]$  表示由归一化综合指标  $G$  构建的时间序列,  $G_t$  为当前时刻的输入。LSTM 首先利用上一时刻的输出状态  $h_{t-1}$  和当前时刻的输入  $G_t$  计算输入门  $i_t$ 、遗忘门  $f_t$ 、输出门  $O_t$ , 然后  $f_t$  和  $i_t$  共同作用于上一时刻记忆单元  $C_{t-1}$ , 并更新当前时刻记忆状态  $C_t$ , 最后输出门  $O_t$  将当前时刻记忆状态传递至隐藏状态  $h_t$ 。BiLSTM 是由两个方向相反的 LSTM 网络构成, 连接了一前一后两个反向的 LSTM 网络, 不仅包含对过去时刻的信息还加入了未来时刻的信息, 使得模型的序列信息提取能力有了进一步提升。计算过程如式(3)所示。

$$\begin{cases} i_t = \sigma(\mathbf{w}_i v_t + \mathbf{b}_i) \\ f_t = \sigma(\mathbf{w}_f v_t + \mathbf{b}_f) \\ o_t = \sigma(\mathbf{w}_o v_t + \mathbf{b}_o) \\ \tilde{c} = \tanh(\mathbf{w}_c v_t + \mathbf{b}_c) \\ c_t = f_t \odot c_{t-1} + \tilde{c} \odot i_t \\ h_t = o_t \odot \tanh(c_t) \end{cases} \quad \begin{cases} \tilde{\mathbf{h}}_t = \text{LSTM}(G_t, \tilde{\mathbf{h}}_{t-1}) \\ \tilde{\mathbf{h}}_t = \text{LSTM}(G_t, \tilde{\mathbf{h}}_{t-1}) \\ \mathbf{y}_t = \tilde{\mathbf{w}}\tilde{\mathbf{h}}_t + \tilde{\mathbf{w}} + \mathbf{b}_y \end{cases} \quad (3)$$

式中: 权重向量  $\mathbf{w} = [\mathbf{w}_i \quad \mathbf{w}_f \quad \mathbf{w}_o \quad \mathbf{w}_c \quad \tilde{\mathbf{w}} \quad \tilde{\mathbf{w}}]$  和偏置向量  $\mathbf{b} = [\mathbf{b}_i \quad \mathbf{b}_f \quad \mathbf{b}_o \quad \mathbf{b}_c \quad \mathbf{b}_y]$  为待训练网络参数,  $v_t = [h_{t-1}, G_t]$ ,  $\sigma$  表示 Sigmoid 函数。

### 2.2 IGBT 老化预测模型超参数优化

在使用 BiLSTM 进行 IGBT 老化预测时, 其隐含层神经元个数  $M$ 、初始学习率  $\eta$  和正则化系数  $\tau$  等网络超参数的选取对预测精度有很大影响。不同的超参数组合直接影响模型的预测性能, 而传统的经验法和试凑法既浪费时间又不能保证准确性。因此构建老化预测模型超参数空间并用 IDBO 对 BiLSTM 老化预测模型的超参数进行寻优, IDBO 优化 IGBT 老化预测模型超参数原理如图 3 所示, 所构建的超参数空间如式(4)所示。

$$x^* = \arg \min f(x), x \in \mathbf{X} \quad (4)$$

式中:  $f(x)$  为损失函数;  $x$  表示一组超参数组合;  $\mathbf{X}$  表示超参数组合空间; 选取训练过程的均方根误差作为 IGBT 老化预测模型的损失函数  $f(x)$ 。表达式如式(5)所示。

$$f_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{t, \text{pre}} - x_{t, \text{tru}})^2} \quad (5)$$

式中:  $x_{t, \text{pre}}$  表示训练集的预测值,  $x_{t, \text{tru}}$  表示训练集的期望值。

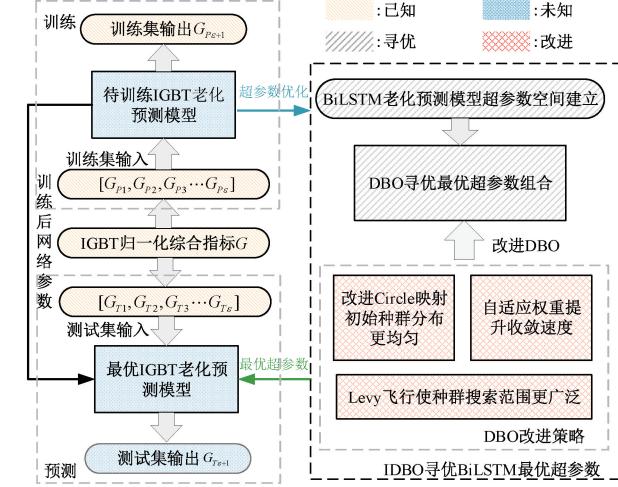


图 3 IDBO 优化 IGBT 老化预测模型原理

### 2.3 DBO 优化 IGBT 老化预测模型超参数

蜣螂搜索算法 DBO(dung beetle optimizer)是 2022 年由东华大学 Xue 等<sup>[21]</sup>提出的一种群体智能搜索算法。该算法通过对蜣螂滚球、繁殖、觅食和偷盗行为进行数学建模来进行求解, DBO 算法在收敛率、求解精度、稳定性方面具有强大的竞争力, 使用 DBO 对 IGBT 老化预测模型超参数进行迭代优化过程如下:

滚球是对 IGBT 老化预测模型超参数空间进行初步探索, 其探索寻优过程如式(6)所示。

$$\begin{cases} \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \vartheta \cdot 0.1 \cdot \mathbf{x}_i(t-1) + 0.3 \cdot \Delta \mathbf{x} \\ \Delta \mathbf{x} = |\mathbf{x}_i(t) - \mathbf{X}_{\text{worst}}| \\ \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \tan \theta |\mathbf{x}_i(t) - \mathbf{x}_i(t-1)| \end{cases} \quad (6)$$

式中:  $t$  表示当前迭代次数,  $\mathbf{x}_i(t)$  表示第  $t$  次迭代时第  $i$  只蜣螂的位置,  $\vartheta$  为自然系数, 当蜣螂偏离方向时取-1, 无偏离时间取 1,  $\mathbf{X}_{\text{worst}}$  表示全局的最差位置。需要注意的是当  $\theta = 0, \theta = \pi/2, \theta = \pi$  时, 位置不更新。

在对超参数空间进行初步探索后, 采用繁殖策略增加搜索种群数量, 繁殖蜣螂每个周期产生一个育雏球, 育雏球的位置随产卵区域动态改变, 其表达式如式(7)所示。

$$\begin{cases} \mathbf{Lb}^* = \max(\mathbf{X}^* \cdot (1-R), \mathbf{Lb}) \\ \mathbf{Ub}^* = \max(\mathbf{X}^* \cdot (1+R), \mathbf{Ub}) \\ \mathbf{B}_i(t+1) = \mathbf{X}^* + \alpha_1 \cdot (\mathbf{B}_i(t) - \mathbf{Lb}^*) + \\ \quad \alpha_2 \cdot (\mathbf{B}_i(t) - \mathbf{Ub}^*) \end{cases} \quad (7)$$

式中:  $\mathbf{X}^*$  表示当前局部最优超参数组合,  $\mathbf{Lb}^*, \mathbf{Ub}^*$  表示产卵区域的上界和下界,  $R = 1 - t/T_{\max}$ ,  $T_{\max}$  为最大迭代次数,  $\mathbf{Lb}, \mathbf{Ub}$  表示超参数空间的上界和下界,  $\mathbf{B}_i(t)$  表示第  $t$  次迭代时第  $i$  个产卵位置,  $\boldsymbol{\alpha}_1$  和  $\boldsymbol{\alpha}_2$  表示两个独立的随机向量, 大小为  $1 \times D$ ,  $D = 3$  为待优化超参数的个数。

小蜣螂成熟后, 开始进行觅食, 觅食是对超参数空间的全局探索, 其探索过程如式(8)所示。

$$\begin{cases} \mathbf{Lb}^b = \max(\mathbf{X}^b \cdot (1-R), \mathbf{Lb}) \\ \mathbf{Ub}^b = \max(\mathbf{X}^b \cdot (1+R), \mathbf{Ub}) \\ \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \lambda_1 \cdot (\mathbf{x}_i(t) - \mathbf{Lb}^b) + \\ \lambda_2 \cdot (\mathbf{x}_i(t) - \mathbf{Ub}^b) \end{cases} \quad (8)$$

式中:  $\mathbf{X}^b$  为食物的来源既蜣螂搜索的超参数空间最优组合,  $\mathbf{Lb}^b, \mathbf{Ub}^b$  表示觅食区域的上下界,  $\lambda_1$  为正态分布随机数,  $\lambda_2 \in (0, 1)$  为随机向量。

一些小蜣螂作为小偷从其他蜣螂处偷取超参数组合, 其位置更新方式如式(9)所示。

$$\mathbf{x}_i(t+1) = \mathbf{X}^b + S \cdot \boldsymbol{\xi} \cdot (|\mathbf{x}_i(t) - \mathbf{X}^*| + |\mathbf{x}_i(t) - \mathbf{X}^b|) \quad (9)$$

式中:  $\boldsymbol{\xi}$  为服从正态分布的随机向量,  $S$  通常取 0.5。算法设置的蜣螂种群比例为 6:6:7:11。

## 2.4 DBO 改进策略

利用传统 DBO 对 BiLSTM 老化预测模型进行超参数寻优时发现算法在迭代收敛过程中容易陷入局部最优且收敛速度慢等现象。为了提高老化预测精度, 对传统 DBO 算法进行如下优化: 通过改进 Circle 映射对蜣螂种群进行初始化增加初始种群分布的均匀性; 通过自适应权重因子改进最优个体对种群分布的影响, 提高收敛速度; 同时在繁殖阶段引入 Levy 飞行策略平衡全局寻优能力。

### 1) 改进 Circle 映射初始化

原始的 DBO 算法采用随机初始化, 在老化预测模型超参数空间的分布较为随机, 不利于种群对超参数空间的探索。初始种群分布越均匀, 其寻找到最优值的概率越大。Circle 作为混沌映射的典型代表, 其值较为稳定且混沌值的覆盖率高。但 Circle 映射的混沌值集中分布在 [0.2, 0.6] 区间内, 所以将 Circle 映射公式进行改进, 使其混沌值分布更加均匀, 改进前和改进后的公式如式(10)、(11)所示。

$$\mathbf{X}_{t+1} = \text{bmod}(\mathbf{X}_t + 0.2 - (\frac{0.5}{2\pi} \sin(2\pi \cdot \mathbf{X}_t), 1)) \quad (10)$$

$$\mathbf{X}_{t+1} = \text{bmod}(4.3\mathbf{X}_t + 0.31 - (\frac{0.5}{4.3\pi} \sin(4.3\pi \cdot \mathbf{X}_t), 1)) \quad (11)$$

### 2) Levy 飞行策略

Levy 飞行是一种模拟自然界随机现象行为的行走方式, 可以产生随机步长, 为解增加扰动量。在蜣螂觅食阶段引入 Levy 飞行策略, 有助于提升蜣螂的全局搜索能力, 跳出局部最优。其步长计算公式如式(12)所示。

$$levy = \mu / |v|^{\frac{1}{\beta}} \quad (12)$$

$\mu$  和  $v$  服从正态分布  $\mu \sim N(0, \sigma_\mu^2), v \sim N(0, \sigma_v^2)$ 。

$$\sigma_u = \left\{ \frac{\Gamma(1+\beta) \cdot \sin(\frac{\pi\beta}{2})}{\Gamma\left[\frac{(1+\beta)}{2}\right] \beta \cdot 2^{\frac{\beta-1}{2}}} \right\}^{\frac{1}{\beta}}, \sigma_v = 1 \quad (13)$$

$\Gamma(\beta)$  是 Gamma 函数, 更新后的觅食公式如式(14)所示:

$$\mathbf{x}_i(t+1) = \delta \cdot r \cdot levy \cdot \mathbf{x}_i(t) + \lambda_1 \cdot (\mathbf{x}_i(t) - \mathbf{Lb}^b) + \lambda_2 \cdot (\mathbf{x}_i(t) - \mathbf{Ub}^b) \quad (14)$$

式中:  $r$  为随机数,  $\delta$  为飞行步长。

为了更直观的展示 Levy 飞行的全局探索能力, 将 Levy 飞行和随机游走策略进行仿真验证。设置仿真步长 1 500 步, 仿真结果如图 4 所示。

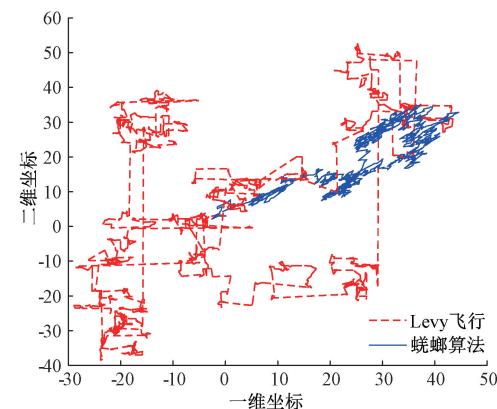


图 4 Levy 飞行与普通蜣螂搜索策略对比

从图 4 中可以看出, 在同样的搜索范围内 Levy 飞行的搜索范围更广泛, 且小步长能对局部搜索区域充分探索, 大步长有利于搜索种群跳出局部最优。

### 3) 自适应权重因子

偷窃者从迭代开始就向全局最优解进行靠近容易过早缩小搜索范围, 陷入局部最优, 并且影响算法收敛速度。因此引入自适应权重因子  $\psi$  对偷窃者进行位置更新, 迭代前期权值小但变化速度较快, 有利于全局搜索能力提升, 在迭代后期权值较大但变化缓慢, 保证了算法的收敛性和收敛速度。权重因子和改进后的位置更新如式(15)、(16)所示,  $t$  为当前迭代次数,  $Maxiteration$  为最大迭代次数。

$$\psi = 0.2 \cdot ((\pi/2) \cdot (1 - (t/Maxiteration))) \quad (15)$$

$$\mathbf{x}_i(t+1) = \psi \cdot \mathbf{X}^b + S \cdot \boldsymbol{\xi} \cdot (|\mathbf{x}_i(t) - \mathbf{X}^*| + |\mathbf{x}_i(t) - \mathbf{X}^b|) \quad (16)$$

## 2.5 IDBO-BiLSTM 预测流程及评价指标

### 1) IGBT 数据处理

首先计算  $V_{\text{ee, on}}$  信号的时频域特征, 构建特征矩阵, 然后使用 KPCA 降维并进行归一化。最后将归一化综合指标  $G$  使用滑动窗口构建时间序列, 并划分训练集和测试集。

### 2) IDBO 寻优 IGBT 老化预测模型超参数

(1) 设置蜣螂种群的数量为 30, 其中神经元个数搜索范围 $[30, 300]$ , 正则化参数搜索范围 $[1 \times 10^{-10}, 1 \times 10^{-2}]$ , 学习率搜索范围 $[0.001, 0.5]$ , 使用改进 Circle 映射初始化种群在超参数空间的位置。

(2) 初始化后蜣螂种群的每个个体代表一组解, 将每一组解带入寻优模型进行训练并计算损失函数 $f(\mathbf{x})$ , 将损失函数值最小的个体作为全局最优个体。

(3) 利用 IDBO 模型更新滚球、繁殖、觅食、偷窃种群在超参数空间的位置。

(4) 对位置更新后的个体重新计算其适应度, 并对全局最优个体适应度进行贪婪选择。

(5) 判断是否达到最大迭代次数, 未达到则返回(3), 达到则输出 IGBT 老化预测模型最优超参数组合, 寻优结束。

### 3) 最优 BiLSTM 模型老化预测

根据最优超参数组合训练 IGBT 老化预测模型, 训练完成后输入测试集进行预测, 得到预测值, 如图 5 所示。

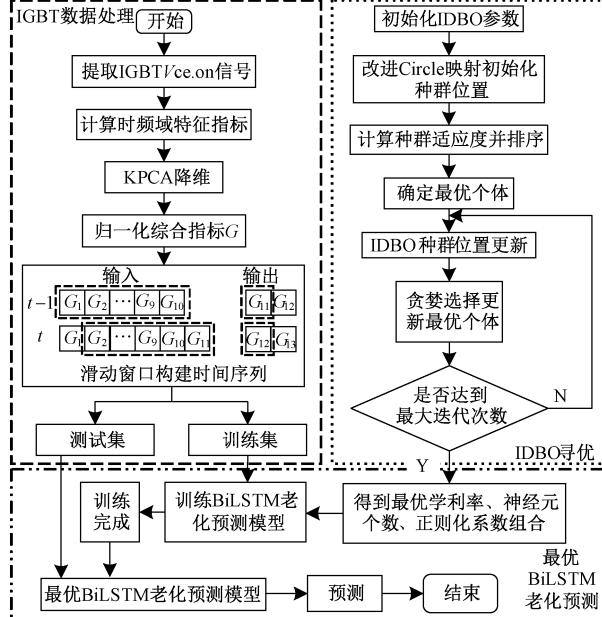


图 5 基于 IDBO-BiLSTM 老化预测流程

### 4) 老化预测模型评价指标

为了评估 IDBO-BiLSTM 模型的预测精准性, 选用均方根误差(root mean square error, RMSE), 平均绝对误差(mean absolute error, MAE) 以及平均绝对百分比误差(mean absolute percentage error, MAPE) 作为模型的评价指标<sup>[12]</sup>, 3 个评价指标越小, 则代表预测值越接近真实值, 结果越精确。

## 3 实验验证

### 3.1 IGBT 综合指标提取

选用美国 NASA 研究中心共享的 IGBT 老化数据进行实验验证, 该老化实验所设置的 IGBT 栅极信号幅值为

10 V, 采样频率 10 kHz, PWM 信号占空比 40%。选用其中的 4 个 IGBT 进行老化预测。IGBT1 的  $V_{ce.on}$  信号如图 6 所示。

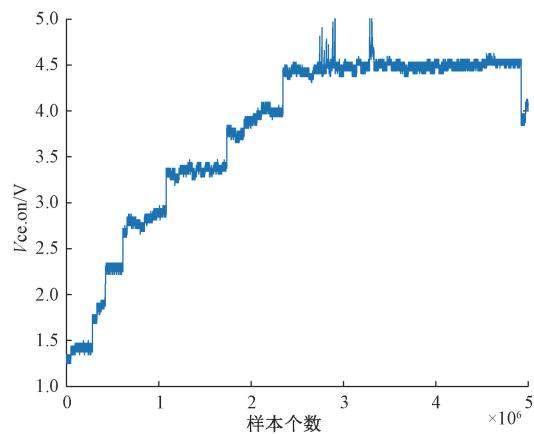


图 6 IGBT1 集射极饱和压降

由图 6 可知  $V_{ce.on}$  信号在整个退化过程中呈现波动上升的趋势, 能够表征 IGBT 的退化趋势。提取 IGBT1  $V_{ce.on}$  信号的时域、频域指标, 构建 9 维特征矩阵, 然后使用 KPCA 对特征矩阵进行非线性降维, 得到能够表征 IGBT 退化趋势的综合指标。降维后各主元的贡献率如表 2 所示。

表 2 降维后各主元贡献率

编号	第一主元	第二主元	第三主元
IGBT1	90.92	8.05	0.7
IGBT2	92.99	5.89	0.76
IGBT3	97.14	1.98	0.43
IGBT4	92.81	6.22	0.66

由文献[22]知当主成分累积贡献率达到 80% 时, 则该主成分能够充分表达所需要的信息。因此表 2 中的第一主元可以作为综合退化指标, 为了避免数据范围过大, 对 4 个 IGBT 的综合退化指标进行归一化, 4 个 IGBT 的归一化综合指标  $G$  如图 7 所示。

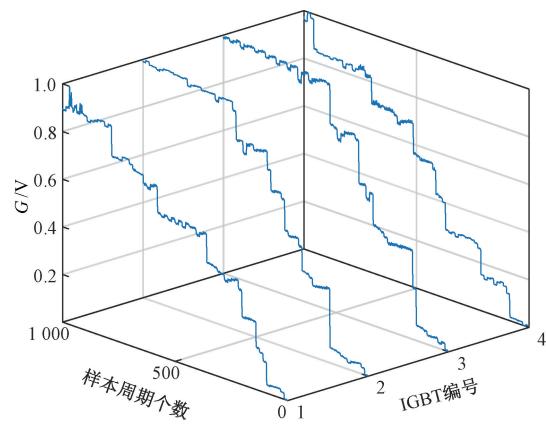


图 7 4 个 IGBT 的归一化综合指标

### 3.2 IDBO 寻优迭代对比

为验证引入改进 Circle 映射、Levy 飞行策略和自适应权重因子后的 IDBO 搜索算法的可行性。将嵌入改进 Circle 映射初始化后的算法记作 DBOS1; 嵌入 Levy 飞行后的算法记作 DBOS2; 嵌入自适应权重因子后的算法记作 DBOS3。并与原始 DBO 算法、灰狼搜索算法(grey wolf optimizer, GWO)<sup>[23]</sup>和粒子群搜索算法(particle swarm optimization, PSO)<sup>[24]</sup>进行寻优迭代对比试验。所选测试函数如表 3 所示,各个算法的种群数量均设置为 30,寻优迭代次数 500 次。实验环境为 Intel Core i5-9300H CPU; 操作系统: Windows 11; 处理器速度: 2.40 GHz; 内存: 8 GB; 编程环境: MATLAB R2020a 版本。

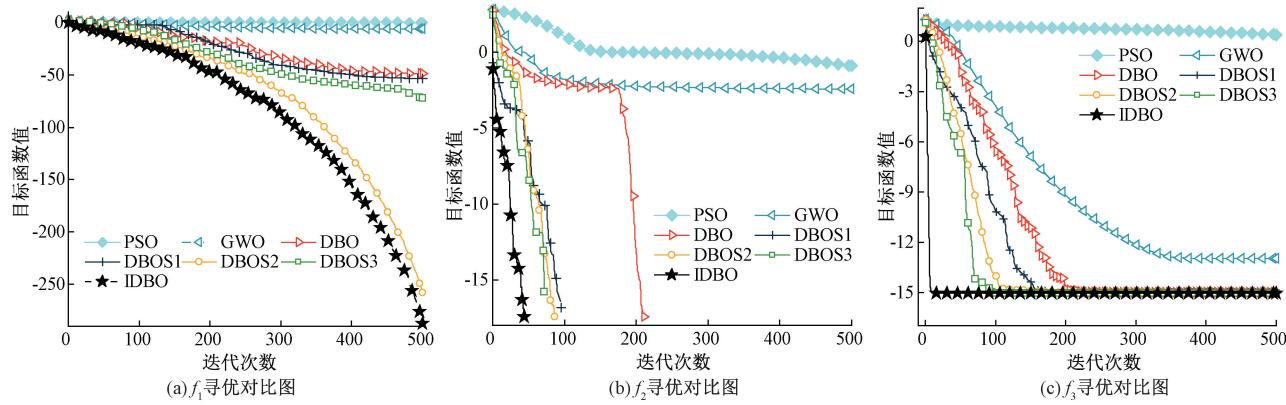


图 8 寻优对比图

由图 8 知,对于单峰函数  $f_1$ ,DBOS1 与原始 DBO 的迭代曲线较为接近,但寻优精度有微小提升,对于多峰函数  $f_2$  和  $f_3$ ,改进 Circle 映射初始化的均匀分布有助于提升寻优效率。DBOS2 相较于原始的 DBO 算法收敛速度和寻优精度均有了大幅度提升,说明引入 Levy 飞行扩大搜索范围的可行性。DBOS3 在单峰测试函数的寻优结果虽然不如 DBOS2,但在多峰测试函数上的收敛速度超过了 DBOS2,并且仅次于 IDBO,这是因为自适应权重因子在迭代前期权值较小兼顾了算法的搜索全局性,在迭代后期权值大加快收敛速度。因此所提 3 种改进策略都有助于提升算法的寻优能力,并且综合了 3 种改进策略的 IDBO 算法兼顾了算法的收敛速度和全局开发能力,能够提升寻优效率,有利于提升 IGBT 老化模型的预测精度。

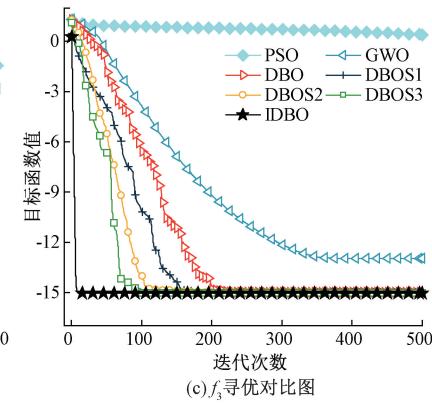
### 3.3 老化预测模型横向对比

为验证所提 IDBO-BiLSTM 老化预测模型的可行性,分别建立 BiLSTM 模型、DBO-BiLSTM 模型进行横向对比。首先将 IGBT1、IGBT2 和 IGBT3 的归一化综合指标前 10 个数据作为输入,第 11 个数据作为输出,采用滑动时间窗构建 990 组时间序列。其次随机选取 75% 的时间序列作为训练集,剩下 25% 作为测试集。模型训练完成后利用测试集进行预测,多次试验后的预测误差评价指标平均

表 3 测试函数

目标函数	搜索范围	最小值
$f_1(x) = \max_i\{ x_i , 1 \leq i \leq n\}$	$[-100, 100]$	0
$f_2(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	$[-600, 600]$	0
$f_3(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	$[-32, 32]$	0

PSO 参数为  $\omega_{\max} = 0.9, \omega_{\min} = 0.4, c_1 = c_2 = 2$ , GWO 参数  $a \in [0, 2]$ 。表中  $f_1$  为单峰测试函数,  $f_2$  和  $f_3$  为多峰值试函数,实验结果如图 8 所示。



值如表 4 所示。

表 4 横向对比模型预测误差

器件 编号	预测模型	误差评价指标		
		RMSE/V	MAE/V	MAPE/%
IGBT1	BiLSTM	0.012 8	0.005 9	0.058 3
	DBO-BiLSTM	0.009 7	0.006 8	0.028 4
	IDBO-BiLSTM	0.008 2	0.004 7	0.019 2
IGBT2	BiLSTM	0.013 2	0.006 0	0.016 7
	DBO-BiLSTM	0.009 3	0.006 7	0.017 2
	IDBO-BiLSTM	0.007 7	0.004 5	0.014 2
IGBT3	BiLSTM	0.011 3	0.006 2	0.016 5
	DBO-BiLSTM	0.008 9	0.004 2	0.023 1
	IDBO-BiLSTM	0.007 7	0.003 1	0.009 5

分析表 4 所示数据可知,所提 IDBO-BiLSTM 老化预测模型的误差评价指标均小于 BiLSTM 老化预测模型。计算 3 个 IGBT 的整体误差评价指标,基于 IDBO-BiLSTM 的 IGBT 老化预测模型与 BiLSTM 老化预测模型相比, RMSE 平均下降 36.42%、MAE 平均下降 31.77%、MAPE 平均下降 41.03%。充分证明了所提出的老化预测模型能

够用于 IGBT 的老化预测，并且相较于基础 BiLSTM 模型有所提升。与基于 DBO-BiLSTM 的 IGBT 老化预测模型相比，IDBO-BiLSTM 模型 RMSE 平均下降 15.38%，MAE 平均下降 29.94%、MAPE 平均下降 36.2%，证明了针对 DBO 搜索算法所提出的 3 个改进策略有助于提升老化预测精度。

箱线图可以进一步反应预测误差的分布情况，如图 9 所示，基于 IDBO-BiLSTM 的 IGBT 老化预测模型的误差分布范围最小，且误差分布更加集中，整体分布范围相较于其他模型更接近 0。综上，使用 IDBO 搜索算法选取超参数相比依赖经验选取避免了随机性和偶然性，并且能提升模型的整体预测精度，具有可行性。

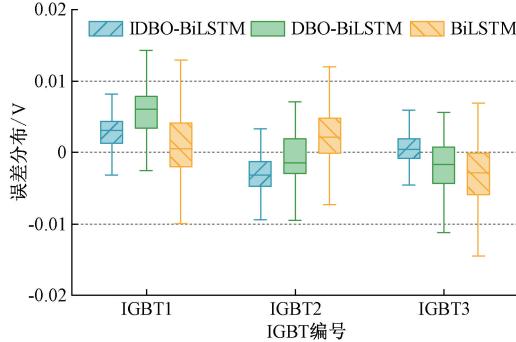


图 9 横向预测结果误差分布图

### 3.4 老化预测模型纵向对比

为验证所提 IDBO-BiLSTM 老化预测模型的优越性，构建 GWO-BiLSTM 老化预测模型，PSO-BiLSTM 老化预测模型进行纵向对比，采用 3.3 节的处理方式，预测结果评价指标如表 5 所示。

表 5 纵向对比模型预测误差

器件编号	预测模型	误差		
		RMSE/V	MAE/V	MAPE/%
IGBT1	PSO-BiLSTM	0.008 8	0.006 4	0.062 7
	GWO-BiLSTM	0.009 3	0.006 1	0.033 8
	IDBO-BiLSTM	0.008 2	0.004 7	0.019 2
IGBT2	PSO-BiLSTM	0.011 3	0.008 4	0.042 4
	GWO-BiLSTM	0.009 2	0.005 7	0.043 5
	IDBO-BiLSTM	0.007 7	0.004 5	0.014 2
IGBT3	PSO-BiLSTM	0.009 2	0.004 9	0.034 3
	GWO-BiLSTM	0.009 7	0.005 9	0.015 3
	IDBO-BiLSTM	0.007 7	0.003 1	0.009 5

由表 5 可知，在 3 个老化预测模型中，IDBO-BiLSTM 老化预测模型的误差评价指标均最小，说明相较于其他模型，所提预测方法预测精度最高。绘制部分预测结果对比图和整体误差分布图进行可视化分析如下所示：

从图 10~12 可以看出对于 IGBT1，IDBO-BiLSTM 与

PSO-BiLSTM 预测残差都很小，但 PSO-BiLSTM 模型对于 IGBT2 和 IGBT3 的预测结果较差，不具有稳定性。对于 IGBT2 所提模型的预测残差分布在  $[-0.005, 0]$  之间，GWO-BiLSTM 模型残差在  $[0, 0.01]$  范围内波动，PSO-BiLSTM 残差集中在  $[0.005, 0.01]$  之间。对于 IGBT3 所提 IDBO-BiLSTM 模型的预测结果也优于其他模型。

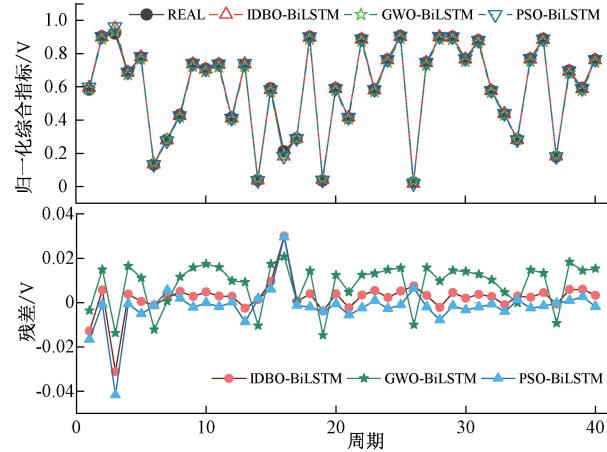


图 10 IGBT1 纵向预测结果对比

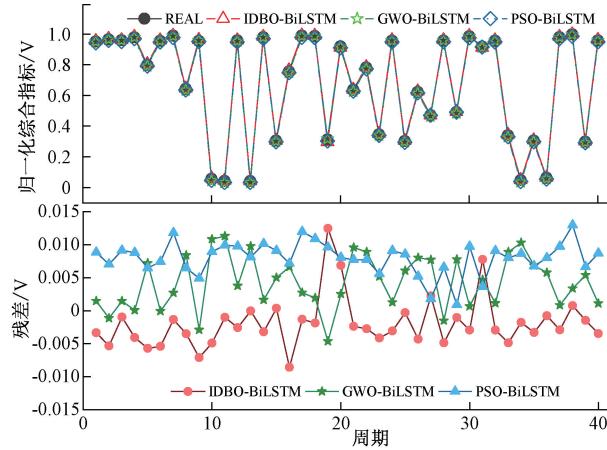


图 11 IGBT2 纵向预测结果对比

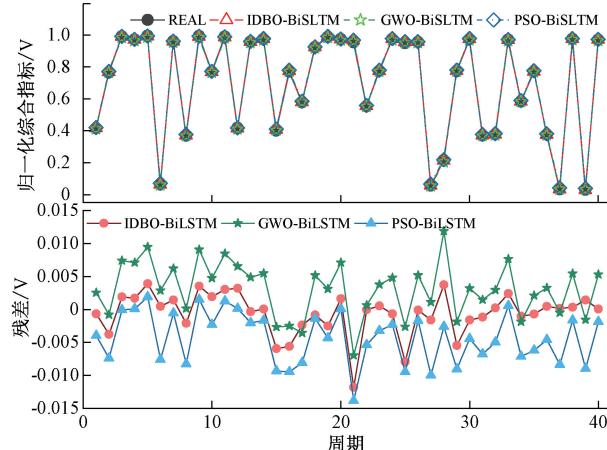


图 12 IGBT3 纵向预测结果对比

由图 13~15 知对于 IGBT1,3 个模型的 1.5IQR 范围长度相差不大,但 IDBO-BiLSTM 预测模型的预测误差整体分布更集中,误差绝对值最小,中位数更接近 0 异常值离群程度也更小。对于 IGBT2 其他两个模型预测误差整体偏上, IDBO-BiLSTM 模型预测误差虽然不以 0 刻度线为基准服从正态分布,但相较于其他两个模型更靠近 0 刻度线。对于 IGBT3 所提模型的 1.5IQR 范围长度、误差分布集中度、正态分布程度都优于其他两个模型。综上,证明了 IDBO-BiLSTM 老化预测模型的优越性。

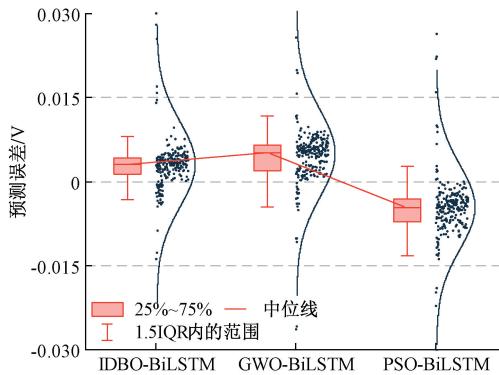


图 13 IGBT1 预测误差对比

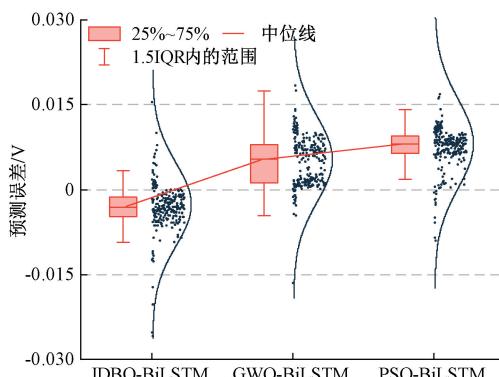


图 14 IGBT2 预测误差对比

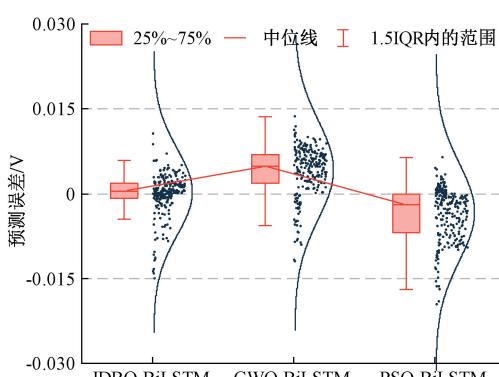


图 15 IGBT3 预测误差对比

### 3.5 不同预测模型性能对比

为进一步验证 IDBO 优化 BiLSTM 老化预测模型的

优越性,以 IGBT4 全生命周期做训练集,IGBT3 全生命周期做测试集,选用 LSTM 网络、支持向量回归(support vector regression, SVR)以及 BP 神经网络进行预测精度对比。LSTM 隐含层神经元个数设置为 10,初始学习率为 0.001。SVR 核函数选择径向基函数,设置惩罚参数  $C = 4, g = 1$ 。BP 误差阈值为  $1 \times 10^{-4}$ ,迭代 500 次,学习率 0.01。

4 种模型的预测误差对比如图 16 所示,图中为各个老化预测模型的 MAE、MAPE、RMSE 预测指标对比,可以看出所提 IDBO-BiLSTM 老化预测模型的各项指标均小于其他传统预测模型,具有显著优势。

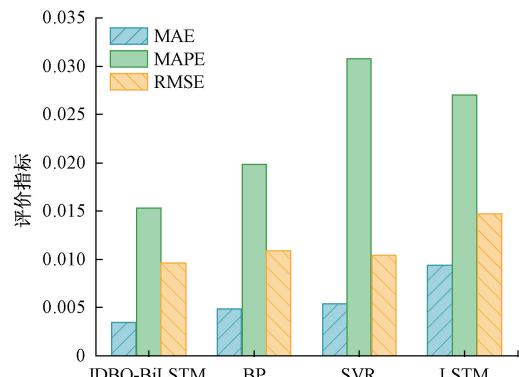


图 16 不同预测模型预测结果对比

## 4 结 论

本文针对 IGBT 老化趋势预测精度不高问题,提出了一种基于优化 BiLSTM 的 IGBT 老化预测模型。首先,针对传统 IGBT 老化预测模型超参数选取依靠经验法和试凑法等问题,使用 DBO 搜索算法对老化预测模型超参数间进行全局寻优。其次,针对 DBO 算法收敛速度慢易陷入局部最优等问题,引入改进 Circle 映射,Levy 飞行策略和自适应权重对 DBO 算法进行改进,使用改进后的 IDBO 算法对 IGBT 老化预测模型超参数进行寻优。最后,使用经过特征提取和 KPCA 降维处理的 IGBT 老化综合指标对本文所提模型进行验证,得出如下结论:

鉴于 DBO 算法存在收敛速度慢易陷入局部最优的不足,引入改进 Circle 映射,Levy 飞行策略和自适应权重策略对其进行改进,通过步长仿真验证和设计寻优对比实验,证明所提 IDBO 算法有利于提升 DBO 的收敛速度,不容易陷入局部最优,具有可行性和优越性。

所提出的基于 IDBO-BiLSTM 的 IGBT 老化预测模型预测精度较高,与 BiLSTM 模型相比 RMSE 平均下降 36.42%、MAE 平均下降 31.77%、MAPE 平均下降 41.03%。与 DBO-BiLSTM、GWO-BiLSTM、PSO-BiLSTM 老化预测模型相比预测误差更小,具有优越性,同时也低于典型的 LSTM、SVR、BP 预测模型。

## 参考文献

- [1] FANG X C, LIN SH, HUANG X Z, et al. A review of data-driven prognostic for IGBT remaining useful life[J]. Chinese Journal of Electrical Engineering, 2018, 4(3): 73-79.
- [2] 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.
- [3] YANG SH Y, BRYANT A, MAWBY P, et al. An industry-based survey of reliability in power electronic converters [J]. IEEE Transactions on Industry Applications, 2011, 47(3): 1441-1451.
- [4] 胡金宝. 基于机器学习的 IGBT 多参数性能退化预测方法研究[D]. 西安: 西安电子科技大学, 2020.
- [5] BUSCA C, TEODORESCU R, BLAABJERG F, et al. An overview of the reliability prediction related aspects of high power IGBTs in wind power applications [J]. Microelectronics Reliability, 2011, 51(9): 1903-1907.
- [6] 陈民铀, 陈一高, 高兵, 等. 计及焊料层疲劳累积效应的 IGBT 模块寿命评估[J]. 中国电机工程学报, 2018, 38(20): 6053-6061.
- [7] QIN F, BIE X R, AN T, et al. A lifetime prediction method for IGBT modules considering the self-accelerating effect of bond wire damage [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2020, 9(2): 2271-2284.
- [8] JIANG N, CHEN M Y, XU SH Y, et al. Lifetime evaluation of solder layer in an IGBT module under different temperature levels [C]. 2016 IEEE 8th International Power Electronics and Motion Control Conference(IPEMC-ECCE Asia), 2016, 3137-3141.
- [9] MENG L H, CHEN Y Q, ZHOU ZH W. Segmental degradation rul prediction of igt based on combinatorial prediction algorithms[J]. IEEE Access, 2022, 10(12): 7845-7852.
- [10] 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.
- [11] RAO ZH, HUANG M, ZHA X M. IGBT remaining useful life prediction based on particle filter with fusing precursor [J]. IEEE Access, 2020, 8 ( 15 ): 4281-4289.
- [12] 朱振宇, 高德欣. 基于 CNN-BiLSTM 网络的锂离子电池健康状态检测方法[J]. 电子测量技术, 2023, 46(3): 128-133.
- [13] 于飞, 樊清川, 宣敏. 基于蝗虫优化 Bi-LSTM 网络的电机轴承故障预测[J]. 电机与控制学报, 2022, 26(6): 9-17.
- [14] HU T Y, ZHANG H, ZHOU J T. Prediction of the debonding failure of beams strengthened with frp hrough machine learning models[J]. Buildings, 2023, 13(3): 608.
- [15] WANG W T, TIAN J, WU D. An improved crystal structure algorithm for engineering optimization problems[J]. Electronics, 2022, 11(24): 4109.
- [16] ZHANG R Z, ZHU Y J. Predicting the mechanical properties of heat-treated woods using optimization-algorithm-based bpnn[J]. Forests, 2023, 14(5): 935.
- [17] 白梁军, 黄萌, 饶臻, 等. 基于 GARCH 模型的 IGBT 寿命预测[J]. 中国电机工程学报, 2020, 40 ( 18 ): 5787-5796.
- [18] LI X Q, JIANG H K, XIONG X, et al. Rolling bearing health prognosis using a modified health index based hierarchical gated recurrent unit network[J]. Mechanism and Machine Theory, 2019, 133: 229-249.
- [19] 徐洲常, 王林军, 刘洋, 等. 采用改进回归型支持向量机的滚动轴承剩余寿命预测方法[J]. 西安交通大学学报, 2022, 56(3): 197-205.
- [20] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: Continual prediction with LSTM[J]. Neural Computation, 2000, 12(10): 2451-2471.
- [21] XUE J K, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization[J]. Supercomput, 2023, 79: 7305-7336.
- [22] 严帅, 熊新. 基于 KPCA 和 TCN-Attention 的滚动轴承退化趋势预测[J]. 电子测量技术, 2022, 45(15): 28-34.
- [23] 刘秀丽, 王鸽, 吴国新, 等. VMD 及 PSO 优化 SVM 的行星齿轮箱故障诊断[J]. 电子测量与仪器学报, 2022, 36(1): 54-61.
- [24] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [C]. Advances in Engineering Software, 2014, 69: 46-61.

## 作者简介

韩素敏, 博士, 教授, 主要研究方向为智能信息处理、智能故障诊断。

E-mail: hansumin@hpu.edu.cn

赵国帅(通信作者), 硕士研究生, 主要研究方向为逆变器故障诊断。

E-mail: 212207020087@home.hpu.edu.cn