

基于长短期记忆网络汽轮机振动幅值预测

段彩丽¹, 呼浩¹, 郭前鑫¹, 赵勇纲¹, 马驰², 张建生², 郭晋东³

(1. 国家能源集团 国神技术研究院, 陕西 西安 710000;

2. 国家能源集团 国源电力有限公司, 陕西 西安 710000;

3. 华北电力大学 国家火力发电中心, 北京 102200)

摘要:火电机组的主轴振动幅值具有非线性、非平稳、时序相关, 且与当前历史状态密不可分的特征, 而实际火电厂所提取数据往往呈现无规则, 长时间, 数据量庞大的特点。提出了由麻雀搜索算法 (SSA) 进行优化的长短期记忆网络 (LSTM) 相结合构建深度学习预测模型, 对汽轮机主轴的振动幅值进行更高精度的预测模拟。相较于非时序神经网络模型和无优化时序神经网络模型预测性能大大提高。

关键词:SSA-LSTM; 汽轮机振动幅值; 结合方法; 高精度预测

中图分类号: TK39

文章编号: 1000-0682(2024)02-0118-06

文献标识码: B

DOI: 10.19950/j.cnki.CN61-1121/TH.2024.02.021

Prediction of turbine vibration amplitude based on long short-term memory network

DUAN Caili¹, HU Hao¹, GUO Qianxin¹, ZHAO Yonggang¹, MA Chi², ZHANG Jiansheng², GUO Jindong³

(1. Guoshen Technology Research Institute of National Energy Group, Shannxi Xi'an 710000, China;

2. National Energy Group Guoyuan Power Co., Ltd., Shannxi Xi'an 710000, China;

3. North China Electric Power University, Beijing 102200, China)

Abstract: The main axis vibration value of thermal power unit is non-linear, non-stable, sequentially related, and is inseparable from the current historical state. The data extracted by actual thermal power plants often show irregularities. For a long time, the data volume is huge. A long-term memory network (LSTM) that is optimized by the sparrow search algorithm (SSA) is proposed to build a deep learning predictive model, and the vibration amplitude of the spherical spindle of the steam turbine is made of higher accuracy and simulation. Compared with non-time-order neural network models and no optimized timing neural network model prediction performance greatly improved.

Keywords: SSA-LSTM; vibration amplitude; combined method; high-precision prediction

0 引言

技术迅速更迭的今天, 汽轮机的状态监测和故障诊断是应广大电厂方需求而备受关注的研究课题。作为世界工业化程度较高的国家之一, 我国汽轮机装机容量在世界首屈一指, 在汽轮机方面有着大量的数据技术的累积, 汽轮机状态监测系统记录了汽轮机转子大量的振动、转速、偏心、轴向位移

等机械参数, 通过对海量数据的数据分析, 我们可以从中提炼出汽轮机运行情况并指出可能产生的转轴碰摩、转子弯曲、转子(轴系)质量不平衡等故障问题。

发展指导现实工业生产, 在深度学习广泛应用的今天, 可以实现对汽轮机转子振幅预测的高精度建模, 这一目标的达成需要更适合的算法对基本模型进行优化, 满足工业生产需要。近些年来, 李劲松^[7]等用鲸鱼优化算法 (WOA) 对 LSSVM 模型参数进行优化, 改善了支持向量机的泛化能力并简化了训练过程, 但复杂的计算程度所造成的较长训练时间和较大计算资源限制了其应用;

收稿日期: 2023-11-16

第一作者: 段彩丽 (1973—), 女, 山西朔州人, 本科, 高级工程师, 研究方向为火电热工自动化、智能电站。

吴昕^[1]等用 K 近邻算法、高斯径向基函数、支持向量回归以及随机森林算法对供热工况下汽轮机振动预测结果进行了分析,对于随机森林算法在汽轮机振动预测的优秀泛化能力进行了阐述;Boul-anouar Saadat^[5]等提出了一种基于模糊预测系统开发的决策方法,基于不同安装传感器获得的实时信息对燃气轮机进行振动监测,以保证能从不完全数据重构全数据的方法来考虑可能频繁发生的不完全数据的情况。

然而,传统的随机森林算法预测振幅时,虽然在一定程度上能处理长期依赖问题,但是由于其模型结构相对简单,难以进一步优化,更倾向于处理局部规律,对于长时间,大量数据处理和预测具有局限性;同样,基于模糊逻辑的预测方法通常基于一些简单规则和经验,复杂度相对较低,对于大型数据集的处理上可能因为模型复杂度过大导致效率低下。相对而言,LSTM 在时序预测中模型结构更加优秀,可以面向更多的数据类型和大型时序数据集^[2-4],而且由于 LSTM 可以利用 GPU 加速计算的特性,显著提高学习效率,可以更好地应用于实时预测、在线学习领域,建立更好的交互式、在线的用户系统。基于 LSTM 与汽轮机振幅预测数据集的适配性^[11-12],该文给出了 SSA-LSTM 的预测模型对长时间,大数据量的火电机组汽轮机轴系振动幅值进行更准确有效的预测。

1 理论基础和模型建立

1.1 SSA 算法

麻雀搜索算法 (Sparrow Seacher Algorithm, SSA)^[8]是一种新型的群体智能算法,其灵感来源于麻雀优秀的飞行策略和行为。SSA 以一种自然简单兼具效率的方式对麻雀觅食及反捕食行为进行模拟,以此对目标函数进行迭代优化。其算法核心思想是通过领袖——即发现并报警的个体,和追随者——即收到警报并加入搜索的个体的协作以及个体进行的局部搜索,同时对探索和利用过程进行行动开展,从而实现全局而非局部的最优解搜索。在此过程中,追随者在得到领袖的警报后也会转化为领袖发出警报吸引更多的追随者参与觅食,当发现危险——即较差解法时,又通过同样的流程使族群远离向安全区域靠拢,即反捕食行为。

由 n 只虚拟麻雀组成的族群以数学模型表示如式 1:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{21} & \cdots & x_{m1} \\ x_{12} & x_{22} & \cdots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n} & x_{2n} & \cdots & x_{mn} \end{bmatrix} \quad (1)$$

其中, m 表示待优化问题变量的维数, n 代表麻雀的数量,那么所有麻雀的适应度可以以式(2)形式表达:

$$\mathbf{F}_x = \begin{bmatrix} f([x_{11} \ x_{12} \ \cdots \ x_{1n}]) \\ f([x_{21} \ x_{22} \ \cdots \ x_{2n}]) \\ \vdots \\ f([x_{m1} \ x_{m2} \ \cdots \ x_{mn}]) \end{bmatrix} \quad (2)$$

其中: f 所得即适应度的值。

在 SSA 中,获取食物处于优先位置的麻雀即领袖,领袖发出警报引导族群加入觅食方向,每次迭代中,发现者的位置更新描述如式(3):

$$\mathbf{x}_{i,j}^{i+1} = \begin{cases} \mathbf{x}_{i,j}^i \cdot \exp\left(-\frac{i}{a \cdot iter_{\max}}\right) & \text{if } R < ST \\ \mathbf{x}_{i,j}^i + QL & \text{if } R \geq ST \end{cases} \quad (3)$$

其中, t 代表当下迭代次数, $j = 1, 2, 3, \dots, d$ 。 $iter_{\max}$ 是一个常数,表示迭代峰值。 $\mathbf{x}_{i,j}^i$ 表示第 i 个麻雀在第 j 维中的位置信息,其中 α 为 $(0,1)$ 之间的随机数, $R^2 \in (0,1)$ 和 $ST \in (0.5,1)$ 分别表示预警值和安全值。 Q 则是服从正态分布的随机数, L 是一个单位矩阵,通过 R^2 和 ST 的大小关系判断环境是否安全,应扩大搜索范围或放弃当前环境前往安全区域。

加入者位置按公式(4)进行更新:

$$\mathbf{X}_{i,j}^{i+1} = \begin{cases} Q \cdot \exp\left(\frac{\mathbf{x}_{\text{worst}}^i - \mathbf{x}_{i,j}^i}{i^2}\right) & \text{if } i > \frac{n}{2} \\ \mathbf{X}_p^{i+1} + |\mathbf{X}_{i,j}^i - \mathbf{X}_p^{i+1}| \cdot \mathbf{A}^+ \cdot L & \text{otherwise} \end{cases} \quad (4)$$

其中, \mathbf{X}_p 是目前发现者所处的最优位置, $\mathbf{X}_{\text{worst}}$ 表示当前全局最差位置。 \mathbf{A} 表示一个形状为 $1 \cdot d$ 的矩阵,矩阵内元素 1 或 -1 随机分布,且 $\mathbf{A}^+ = \mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1}$ 。当 $i > \frac{n}{2}$ 时表示适应度较低的第 i 个加入者没有获得食物,处于饥饿状态,此时需要转换目的地觅食获得能量。

当“麻雀”察觉到威胁时,麻雀种群会开展反捕食行为,转向别处能量获取地,公式(5)如下:

$$\mathbf{X}_{i,j}^{i+1} = \begin{cases} \mathbf{X}_{\text{best}}^i + \beta \cdot |\mathbf{X}_{i,j}^i - \mathbf{X}_{\text{best}}^i| & \text{if } f_i > f_g \\ \mathbf{X}_{\text{best}}^i + K \cdot \frac{|\mathbf{X}_{i,j}^i - \mathbf{X}_{\text{best}}^i|}{(f_i - f_w) + \varepsilon} & \text{if } f_i = f_g \end{cases} \quad (5)$$

在式(5)中, X_{best} 是当下全局最优的位置, β 作为控制步长的参数, 服从均值为 0, 方差为 1 的正态分布的随机数; $K \in (-1, 1)$ 是一个随机数和步长控制系数, 表示麻雀转移的方向; f_i 则是当前麻雀个体的适应值; f_g 和 f_w 分别是当前全局最佳和最差的适应度值; 是最小的常数, 无限小但不能等于 0。 $f_i > f_g$ 时表示此时麻雀处于种群边缘, 容易受到捕食者的袭击, 当 $f_i = f_g$ 时表示处于种群中间的麻雀也受到了危险, 此时领袖会发出警报警示种群转移。

因为麻雀搜索 (SSA) 优化算法在搜索过程中引入了随机因素, 所以在复杂的状况下不容易陷入局部最优, 由于其简单、灵活高效而被用作解决全局优化的主要技术, 具有实际意义。

1.2 多层感知机模型

多层感知机 (MLP, Multilayer Perceptron)^[6] 是一种广泛应用于各行各业的人工神经网络模型, 由数个层级构成, 每个层级以多个神经元作为底层, 其特点为相连神经元节点全连接, 同层神经元节点无连接。MLP 通过多层非线性转换将输入信号映射到目标输出^[13-14], 使其能够应对非线性输入的预测任务。训练集导入后利用一层或多层的隐藏层对输入数据进行初步拟合, 达到输出预测结果的效果, 并可以通过适配各种优化算法对损失进行控制。




图1 多层感知机原理示意图

1.3 LSTM 模型

相对于传统的循环神经网络 (RNN), 长短期记忆网络 (LSTM) 是一种通过引入遗忘门、输入门和输出门并改进门单元和明确定义的记忆单元来解决长序列训练过程中“梯度消失”和“梯度爆炸”的特殊神经网络系统。相对于普通的 RNN, LSTM 可以在更宽广的时间序列中有良好的表现。LSTM 的结构如图 2 所示。

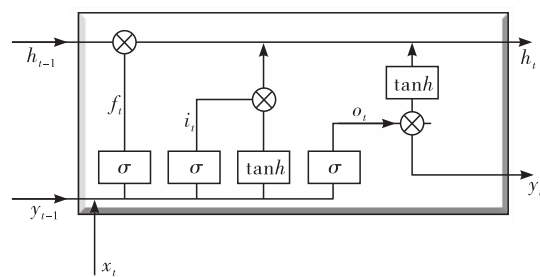


图2 长短记忆神经网络原理示意图

LSTM 引入了特殊的记忆单元 y , 不同于传统神经网络的是, 引入激活函数 \tanh 后, 通过结合神经元中信息和上一时刻的单元状态 y_{t-1} 进行放缩, 使其显示即时状态, w_c, b_c 为权重矩阵, 如公式 (6) 所示:

$$C_t = \tanh(w_c x_t + b_c y_{t-1})$$

$$C_t = f_t y_{t-1} + i_t y_t \quad (6)$$

图中, h_{t-1} 表示前个细胞的细胞层内部状态; y_{t-1} 是上一个细胞的细胞层输出; x_t 为输入函数; σ 表示 LSTM 的遗忘门、输入门和输出门 sigmoid 函数, \tanh 是更新细胞层状态的函数值。

首先是遗忘门, 作用是将废弃信息从旧的细胞层状态中剥离舍弃, 其计算公式 (7) 为:

$$f_t = \sigma(W_f[y_{t-1}, x_t]) + b_f \quad (7)$$

其次是输入门, 作用是更新并存储细胞层中的信息, 其中各个变量的计算公式 (8~10) 为:

$$i_t = \sigma(W_i[y_{t-1}, x_t] + b_i) \quad (8)$$

$$h_t = \tanh(W_c[y_{t-1}, x_t] + b_c) \quad (9)$$

$$h_t = f_t h_{t-1} + i_t h_t \quad (10)$$

而后是输出门, 作用是决定输出细胞层的信息, 其计算公式 (11~12) 为:

$$O_t = \sigma(W_o[y_{t-1}, x_t] + b_o) \quad (11)$$

$$y_t = O_t \times \tanh(h_t) \quad (12)$$

其中, 下标 f, i, o 分别表示遗忘门、输入门和输出门, W, b 分别表示激活函数的权重度量和对应的偏差; i_t, h_t 和 y_t 分别表示输入门的输出, 当下细胞层状态和当下细胞整体的输出。

1.4 SSA-LSTM 模型构建

汽轮机主轴振动幅值因其在时间序列上呈现相关性, 适用于时序预测, 为了得到更好的预测效果, 使用 LSTM 模型作为基础的预测模型。此外, 因其复杂的工作环境故对其产生影响的因素很多, 在模型函数超参数选取存在困难, 故而采用局部搜索能力突出, 收敛速度迅速的 SSA 算法对其进行超参数寻优优化。SSA 对 LSTM 基础模型局部调优, 自动选择最优超参数解, 达到更好的模型性能, 从而快

速得到精确的汽轮机主轴振动幅值预测。

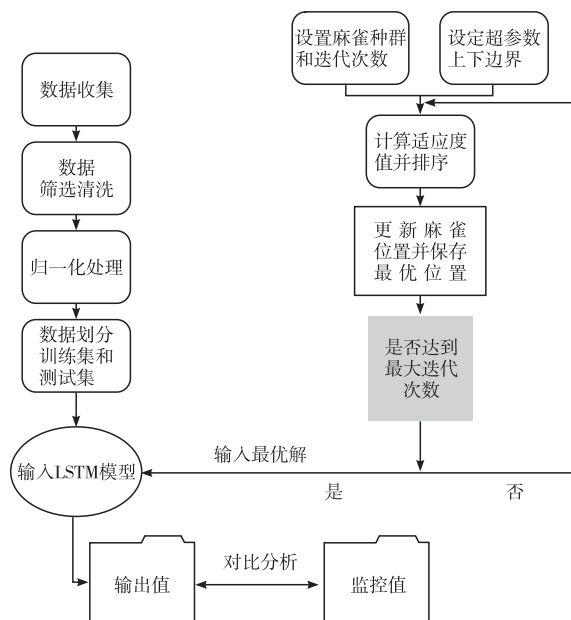


图3 麻雀优化算法对 LSTM 优化过程原理示意图

2 理论基础和模型建立

2.1 数据获取

选取西北某电厂 1 号机组汽轮机 1,2 号轴承的振动幅值数据进行研究。与中、低压缸和发电机相比,汽轮机高压缸内部结构工作情景复杂、转子受多个方面因素影响,故而选取 2023 年 1 月 1 日至 1 月 3 日的 1 号轴高压缸前振动监测数据,时间间隔约为 0.4 min,在 x 方向上取样 4987 个。在该时间序列分解,取前 4000 行数据为训练集,后 987 行数据为预测集。该文采用某电厂所采集的发电机有功功率,汽机直流油泵电流,高、中、低压差胀,中压汽封蒸汽压力,主汽流量,高、中、低压轴承前、后瓦温度,主汽门进口处蒸汽温度,汽机低压汽封供汽温度、压力,转子偏心,轴向位移,锅炉负荷信号,各处汽封蒸汽温度、压力,高压前后轴承回油温度等 28 个相关数据作为特征参数。

2.2 预测模型的建立

2.2.1 多层感知机模型

用 python 以 MLP 原理搭建算法主体模型,输入归一化处理后的数据集信息^[9],多次拟合后得出合适的最大迭代次数为 40,隐藏层维度为 (30,30),定义学习率为 0.01,将测试数据输入训练后的模型进行拟合,并同步进行反归一化处理(模型性能由反归一化后的数据与原始数据比对得出)MLP 模型预测结果如图 4 所示。




图4 多层感知机(MLP)模型对振动幅值的监测值和预测值

用 python 搭建一个隐藏层的 RNN 模型,设置神经元为 50,而后将输出定义权重后再次输入神经元为 50 的第二隐藏层,形成多层 LSTM 单元堆叠的全连接层输出序列,对超参数定义为:学习率=0.01,迭代次数=10,batch_size=16,第一、第二神经元数均为 50。对归一化后的数据进行预测后结果如图 5 所示。

2.2.2 长短期记忆网络模型

用 python 搭建一个隐藏层的 RNN 模型,设置神经元为 50,而后将输出定义权重后再次输入神经元为 50 的第二隐藏层,形成多层 LSTM 单元堆叠的全连接层输出序列,对超参数定义为:学习率=0.01,迭代次数=10,batch_size=16,第一、第二神经元数均为 50。对归一化后的数据进行预测后结果如图 5 所示。




图5 长短期记忆神经网络(LSTM)模型对振动幅值的监测值和预测值

可见 LSTM 模型所得预测与实际情况更为贴合,相较于结构简单的神经网络,使用长短期记忆网络对于时间序列的数据预测效果更好,在汽轮机振动方面更广阔的时间区域和大范围、大容量的数据上泛化程度更高。但在更高精度要求下,其超参数寻找依赖于经验指导和大量调参,可以使用优化算法改善这个状况。

2.2.3 SSA-LSTM 网络模型

将 LSTM 模型的超参数使用 SSA 网络进行优化,将数据进行归一化处理,而后进行适应度计算,

以找到一组超参数,用以使网络误差最小为期望,验证数据集均方根误差为适应度函数,种群数量设置为 10,训练 20 轮,将搜索维度设置为 4 项,学习率上下限为 $[0.001, 0.01]$,迭代次数上下限为 $[10, 100]$,其余两个维度是两个隐藏层节点数,上下限为 $[1, 100]$ 。设置 $r_2 = 0.8$ 为预警值,小于预警值则

说明捕食者没有出现,否则种群则需要迁徙觅食。SSA 算法优于搜索能力,收敛速度较快,使用 SSA 算法优化超参数,可以有效对 LSTM 繁琐的调参步骤和训练试验进行简化,提高预测模型性能,SSA - LSTM 模型对汽轮机主轴振幅预测效果优化如图 6 所示。




图 6 麻雀优化算法对 LSTM 模型优化参数过程

可知该课题的 SSA 对 LSTM 优化性能的超参数搜索结果为:迭代 60 次,适应度 1.88,学习率为 0.008 9 时,模型达到最大效果。一、二隐藏节点下

节点值优化情况如下:该数据集下优化时间为 1700 s,约合 28 min,仍有较大的提升速度的优化空间。




图 7 麻雀优化算法对 LSTM 模型优化两个隐藏层节点数优化结果

将优化后的超参数输入 LSTM 神经网络,优化后的预测效果如图 8 所示。

模型预测效果在长时间,大容量的数据输入下预测效果明显好于结构简单的神经网络模型,而 SSA 可以简化 LSTM 寻优步骤并给出相对更合理的超参数参考值。




图 8 SSA - LSTM 模型对振动幅值的监测值和预测值

2.3 预测模型的评估与分析

上文所述的三种模型预测效果对比如图 9 所示。明显看出三种预测方式存在性能差异,LSTM




图 9 三种模型对振动幅值预测值结果与监测值相对误差的对比

将以上三种不同模型得出的预测值与实际监测值进行误差计算,并作图显示(图 9),可对与 SSA - LSTM 相对于 LSTM 模型和 MLP 模型性能的改善有更直观的认识。

在深度学习预测模型领域,常用均方根误差 δ_{RMSE} 、决定系数 R^2 、绝对平均百分比误差 δ_{MAPE} 以及平均绝对误差 δ_{MAE} 作为评估不同模型预测性能的参数,其中决定系数越大,均方根误差、平均绝对误差以及绝对平均百分比误差越小,则模型性能越好,这些评价指标的计算公式为:

$$\delta_{\text{MAPE}} = \frac{1}{N} \sum_{k=1}^N \frac{|P_k - O_k|}{O_k} \times 100\% \quad (13)$$

$$\delta_{\text{RMSE}} = \sqrt{\frac{\sum_{k=1}^N (P_k - O_k)^2}{N}} \quad (14)$$

$$\delta_{\text{MAE}} = \frac{\sum_{k=1}^N |P_k - O_k|}{N} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{k=1}^n (P_k - O_k)^2}{\sum_{k=1}^n (P_k - \bar{O})^2} \quad (16)$$

式中: N, P_k, O_k, \bar{O} 分别对应数据总数,第 k 个预测值,第 k 个监测值和所有监测值的平均值。

将以上所有模型的评价指标汇总,如表 1 所示。

表 1 不同模型对振动幅值预测值效果评价指标汇总

模型	$\delta_{\text{MAPE}}/\%$	δ_{RMSE}	δ_{MAE}	R^2
MLP	0.007 9	0.85	0.71	0.949 31
LSTM	0.002 7	0.31	0.24	0.993 83
SSA - LSTM	0.000 7	0.071	0.06	0.999 68

由表 1 可知,从数学计算的角度验证,使用麻雀算法优化的长短期记忆网络预测精度相较于多层感知机和单纯长短期记忆网络模型的预测精度得到了显著性提高,均方根误差降低了 77.9%,绝对平均误差降低了 65%,绝对平均百分比误差降低了 0.007 2%,决定系数增长 0.005 037,精度得到了显著提高,通过 SSA 方法在可行范围内对超参数进行了合理优化,发挥出最优的预测性能。

3 结论

大容量汽轮机组振动幅值变化与汽轮机运行的各项参数广泛存在联系,经归一化处理后输入多层感知模型,长短期记忆神经网络模型,用麻雀优化算法优化超参数的长短期记忆神经网络模型中,把输出值汽轮机转子振动幅值作为输出目标对模型作评估处理,可得出以下结论:

(1) 汽轮机转子主轴振动幅值预测属于非线性时间序列问题^[15-16],非时间序列神经网络拟合程度低,不适宜进行该项目问题的求解。

(2) SSA 优化算法可以大大简化对 LSTM 超参数选取,在相同情形下均方根误差降低了 77.9%,绝对平均误差降低了 65%,绝对平均百分比误差降低了 0.007 2%,决定系数增长 0.005 037,精度得到了显著提高,这有利于更复杂,更长时间段的数据集改造,大大提高了预测模型的泛化能力,对汽轮机转子主轴振幅精确监控提供参考。

(3) 该文建立的 SSA - LSTM 耗时较长,仍需进一步优化,可以采用对数据集进一步预处理,特征提取选择或预先学习等方式达到更快反应兼具准确性的预测模型。

参考文献:

- [1] 吴昕,刘双白,郝向中,等. 供热工况下的汽轮机振动长周期预测与分析[J]. 热能动力工程,2022,37(03): 72-80.
- [2] 王军,马小越,张宇航,等. 基于 SSA - LSTM 模型的黄河水资源调度研究[J/OL]. 人民黄河:1-5[2023-09-07]. <http://kns.cnki.net/kcms/detail/41.1128.TV.20230816.1346.010.html>.
- [3] 国洪立,陈时熠,唐寅,等. 基于 PCA - SSA - LSTM 的余热锅炉状态监测模型[J/OL]. 热力发电:1-9[2023-09-07]. DOI: 10.19666/j.rld.202212289.
- [4] 冷丽英,付建哲,宁波. 基于 SSA - LSTM 模型的 IGBT 时间序列预测研究[J]. 半导体技术,2023,48(01): 66-72.
- [5] SAADAT B, HAFIFA A, BELHADEF R, et al. Fuzzy prognosis system for decision making to vibrations monitoring in gas turbine[J]. Strojnicky Časopis - Journal of Mechanical Engineering, 2021, 71(2): 239-256.
- [6] 徐翠翠,杨淑娟,许卫晓. 基于多层感知机的仪器地震烈度评估方法研究[J]. 防灾减灾工程学报,2023,43(05): 979-986.
- [7] 李劲松,张双,董泽,等. 基于 VMD - WOA - LSSVM 的汽轮机轴承振动趋势预测[J]. 山东电力技术,2021, 48(12): 61-67.
- [8] 薛建凯. 一种新型的群智能优化技术的研究与应用[D]. 上海: 东华大学, 2020.
- [9] 张贵强. 350 MW 汽轮发电机组振动故障诊断及处理[J]. 汽轮机技术, 2019, 61(6): 461-464.
- [10] DIGALAKIS J G, MARGARITIS K G. On benchmarking functions for genetic algorithms[J]. International Journal of Computer Mathematics, 2001, 77(4): 481-506.

(下转第 142 页)

- 1135.
- [6] 陈丽娟,王致杰. 基于改进下垂控制的微电网运行控制研究[J]. 电力系统保护与控制,2016,V44(4):16-21.
- [7] 彭克,咸日常,张新慧. 多端互联交直流配电网的潮流分层控制策略及算法[J]. 电力系统自动化,2016,40(14):72-77.
- [8] 吴争,孔力,袁晓冬,等. 基于电力电子变压器的交直流混合可再生能源关键技术[J]. 电工电能新技术,2019,38(02):1-10.
- [9] 郝晓弘,胡开伟,裴婷婷,等. 风电接入交直流混联电网外送消纳能力研究[J]. 太阳能学报,2021,42(10):195-201.
- [10] 衣立东,摆世彬,张文朝,等. 综合能源交直流混联外送系统暂态过电压分析与快速估算[J]. 太阳能学报,2023,44(06):122-129.
- [11] 丁明,潘浩,张晶晶. 分布式电源接入交直流混合微电网群优化规划研究[J]. 太阳能学报,2021,42(06):54-62.
- [12] 周建萍,薛亚林,徐征. 基于功率交互和充放速率优化的交直流混合微网控制策略研究[J]. 太阳能学报,2018,39(12):3558-3567.
- [13] 麻秀范,崔换君. 改进遗传算法在含分布式电源的配电网规划中的应用[J]. 电工技术学报,2011,26(3):175-181.
- [14] 戴上,张焰,祝达康. 含有微电网的配电网规划方法[J]. 电力系统自动化,2010(22):41-45.
- [15] 盛四清,范林涛,李兴,等. 基于帕累托最优的配电网多目标规划[J]. 电力系统自动化,2014,38(15):51-57.
- [16] 肖峻,张婷,张跃,等. 基于最大供电能力的配电网规划理念与方法[J]. 中国电机工程学报,2013,33(10):106-113.
- [17] 李高望,陈锐智,陈艳波. 考虑网络划分优化的交直流系统并行电磁暂态仿真研究[J]. 电力系统保护与控制,2021,49(04):72-80.
- [18] 陈汉雄,李婷,李奥. 提升电网运行的交直流系统协调控制策略研究[J]. 电力系统保护与控制,2021,49(10):123-134.
- [19] 李兴,杨智斌,颜远,等. 考虑换流站损耗特性的交直流系统多目标无功优化控制[J]. 电力系统保护与控制,2017,45(09):119-125.

(上接第 123 页)

- [11] JAMIL M, YANG X S. A literature survey of benchmark functions for global optimization problems[J]. International Journal of Mathematical Modelling and Numerical Optimisation, 2013, 4(2): 150-194.
- [12] 李中,路宇,王鑫,等. 基于 ABC-LSTM 的变压器表面振动基频幅值预测[J]. 工业控制计算机,2021,34(06):21-23+26.
- [13] 马宏忠,赵宏飞,陈楷,等. 基于振动的变压器铁心松动判定方法[J]. 电力系统自动化,2013,37(14):101-106.
- [14] 韩中合,焦宏超,徐搏超,等. 基于 EEMD 样本熵和 SVM 的振动故障诊断研究[J]. 汽轮机技术,2015,57(06):457-460.
- [15] 徐搏超. 基于 HVD 和相关向量机的转子多故障分类优化[D]. 保定:华北电力大学,2017.
- [16] 李浩瀚. 燃气轮机控制系统执行器的复合故障诊断研究[D]. 北京:华北电力大学(北京),2022.

(上接第 129 页)

- [8] CHEN S, GUO L, FAN J, et al. Bandwidth-aware adaptive chirp mode decomposition for railway bearing fault diagnosis[J]. Structural Health Monitoring, 2024; 23(2):876-902.
- [9] ALMONACID B, SOTO R. Andean condor algorithm for cell formation problems[J]. Natural Computing, 2019, 18: 351-381.
- [10] CICONI A, LIU J, ZHOU H. Adaptive local iterative filtering for signal decomposition and instantaneous frequency analysis[J]. Applied and Computational Harmonic Analysis, 2016, 41(2): 384-411.
- [11] LIU Y, YUAN D, GONG Z, et al. Adaptive spectral trend based optimized EWT for monitoring the parameters of multiple power quality disturbances[J]. International Journal of Electrical Power & Energy Systems, 2023, 146: 108797.
- [12] 李华,伍星,刘韬,等. 基于信息熵优化变分模态分解的滚动轴承故障特征提取[J]. 振动与冲击,2018,37(23):219-225.
- [13] JACEK D. Diagnosing of rolling element bearings using amplitude level based decomposition of machine vibration signal[J]. Measurement, 2018, 126: 413-153.
- [14] LI C, LIU Y, LIAO Y, et al. A VME method based on the convergent tendency of VMD and its application in multifault diagnosis of rolling bearings[J]. Measurement, 2022, 198: 111360.
- [15] 王建国,刘冀韬,张文兴. 自适应 MCKD 和 VMD 在行星齿轮箱早期故障诊断中的应用[J]. 机械设计与制造,2022(6):130-133.