

DOI:10.19651/j.cnki.emt.2210227

海上平台电气温度监控系统及预测模型研究*

梁玉真 张仕海 汝承印 朱冶诚

(天津职业技术师范大学机械工程学院 天津 300222)

摘要: 针对海上平台电气设备温度监控的现实需求,以无线红外温度传感器及数据采集终端为基础,构建了海上平台电气设备温度分布式监控系统,配套开发了系统应用软件,实现了平台电气设备温度的持续监控。针对传统温度预测难以应对大量波动性数据且对时间序列处理能力有限的问题,提出贝叶斯优化与长短时记忆网络(LSTM)组合预测方法。以所监测的海上平台变压器为研究对象,分析变压器运行过程中的温度特征,采用时序性较强的 LSTM 网络预测模型,引入贝叶斯优化算法,用于训练和更新 LSTM 参数。实践表明,基于贝叶斯优化的 LSTM 模型对海上平台变压器温度具有良好的预测效果,其均方根误差为 0.139、预测准确率为 98.56%。通过对支持向量机、BP 神经网络、LSTM、Bayesian-LSTM 四种预测模型的分析,证实了贝叶斯优化的 LSTM 模型对海上平台变压器温度预测的优势。

关键词: 海上平台;电气设备;温度监控;贝叶斯优化;Bayesian-LSTM;温度预测

中图分类号: TM762 **文献标识码:** A **国家标准学科分类代码:** 470.4054

Research on electric temperature monitoring system and prediction model of offshore platform

Liang Yuzhen Zhang Shihai Ru Chengyin Zhu Yecheng

(School of Mechanical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China)

Abstract: Based on wireless infrared temperature sensor and data acquisition terminal, a distributed temperature monitoring system for offshore electrical equipment was constructed to meet the actual requirements of temperature monitoring for offshore electrical equipment. The system application software was developed to realize continuous temperature monitoring for offshore electrical equipment. Aiming at the problem that traditional temperature prediction is difficult to deal with a large amount of fluctuating data and has limited ability to deal with time series, a combined prediction method of Bayesian optimization and LSTM was proposed. The temperature characteristics of the transformer during operation were analyzed by taking the transformer monitored offshore platform as the research object. The LSTM network prediction model with strong timing was adopted and the Bayesian optimization algorithm was introduced to train and update THE LSTM parameters. The practice shows that the LSTM model based on Bayesian optimization has good prediction effect on transformer temperature of offshore platform, and its root mean square error is 0.139 and prediction accuracy is 98.56%. Through the comparative analysis of four prediction models including support vector machine, BP neural network, LSTM and Bayesian LSTM, the advantages of Bayesian optimized LSTM model for offshore transformer temperature prediction are confirmed.

Keywords: offshore platform; electrical equipment; temperature monitoring; Bayesian optimization; Bayesian-LSTM; temperature prediction

0 引言

海上平台电气设备长时间运行于高湿、高盐、空间狭小而散热不良等恶劣环境下,电气设备易产生异常发热现象,

金属部件发生“蠕变”,绝缘部件易老化失去绝缘性等都会导致设备严重损坏,从而发生电网事故^[1-3]。实践表明,电气设备故障是设备局部温度不断升高,绝缘逐步老化、漏电逐渐增加,进而发生击穿的一个量变到质变的过程^[4]。因

收稿日期:2022-06-06

* 基金项目:天津市自然科学基金(19JCQNJC04200)、天津市津南区科技计划项目(20210101)资助

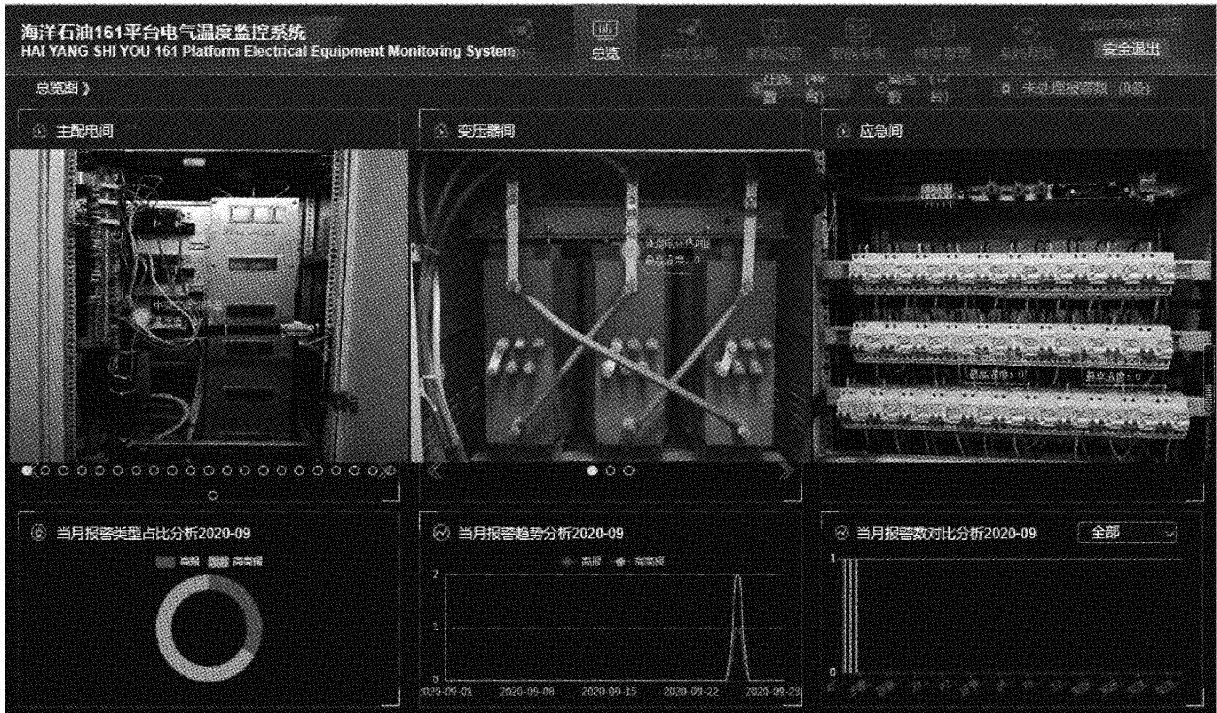


图 2 系统软件典型应用界面




图 3 海上平台 2# 照明变压器温度变化曲线

2 海上平台电气设备温度预测模型的构建

电气设备故障通常为早期缺陷的恶化及不同隐患累积叠加的结果,是一个量变到质变的过程,而这一过程通常可以反映在电气设备温度的异常变化上。除了电流、导体材料及接触电阻等自身因素外,环境条件也是影响电气设备温度变化的重要因素。海上平台电气设备长时间运行于高湿、高盐等恶劣环境下,易产生异常发热现象,统计海上平台电气设备温度数据可知,设备正常运行时平均温度在 20 °C~25 °C 之间,温度升高或降低一定程度时,均会影响电气设备的正常运转,缩短其使用寿命。因此,通过对平台电气设备运行过程中的温度预测,可以对电气设备的早期缺陷进行预判,减少平台电气设备的故障率,提高

平台运营及作业的安全性。为此,论文在比较分析的基础上,提出将贝叶斯优化与长短时记忆网络相结合的海上平台电气设备温度预测模型,并将训练好的模型嵌入到所开发的系统软件,取得了良好的温度预测效果。

2.1 长短时记忆网络的构建

循环神经网络 (recurrent neural network, RNN) 被广泛应用于时序性领域。原始的 RNN 对案例数据的记忆没有选择性,存在梯度消失的问题^[17]。长短时记忆网络 (long short-term memory, LSTM) 作为改良的 RNN,在时间步设有记忆细胞,使得 LSTM 网络模型具备自由选择记忆信息的能力,用 LSTM 单元代替 RNN 中的神经元,并设置门控单元^[18],在输入、输出、遗忘过去信息过程中分别加入输入门、输出门、遗忘门来控制信息的通过,使网络具备长时记忆的能力^[19],LSTM 网络模型结构如图 4 所示。




图 4 LSTM 网络模型

图 4 中,设 LSTM 在 t 时刻的输入为 $x_t=(x_1, x_2, \dots, x_n)$, 输出为 y_t , 上一时刻的输出为 y_{t-1} , 上一时刻隐藏状态 C_{t-1} , 神经元记忆状态为 C_t , 输入门为 i_t 、遗忘门为 f_t 、输出门为 o_t 。门控单元由 sigmoid 神经网络层和逐点乘法运算组成。sigmoid 激活函数能够将输入映射到 $[0, 1]$ 的输出范围, 1 表示上一时刻单元的信息全部保留, 0 表示上一时刻单元的信息全部丢弃^[20]。

遗忘门(forget gate): 控制从上一个隐藏状态保留或丢失的信息。根据上一时刻输出 y_{t-1} 和当前输入 x_t 决定对上一个隐藏状态信息的保留程度, 表达式为:

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

式中: δ 为 sigmoid 激活函数, W_f 表示遗忘门的权重, b_f 代表偏置。

输入门(input gate): 控制当前流入的信息。根据上一时刻输出 y_{t-1} 和当前输入 x_t 决定对新信息的保留程度, 通过 sigmoid 激活函数确定增加的新信息 i_t , 通过 tanh 激活函数确定候选矢量 \tilde{C}_t , 表达式为:

$$i_t = \delta(W_i \cdot [y_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [y_{t-1}, x_t] + b_c) \quad (3)$$

式中: W_i 表示输入门的权重, W_c 表示 \tilde{C}_t 的权重矩阵, b_i 、 b_c 为偏置。

输出门(output gate): 控制进入下一个隐藏状态的信息。决定着上一时刻输出 y_{t-1} 和当前输入 x_t 经过输出门后保存在输出 y_t 中的信息。根据细胞状态的不断更新, 利用输出门的输出信息 o_t 和当前神经元记忆状态 C_t 确定网络模型的输出^[21], 表达式为:

$$o_t = \delta(W_o \cdot [y_{t-1}, x_t] + b_o) \quad (4)$$

$$y_t = o_t * \tanh(C_t) \quad (5)$$

式中: W_o 表示输出门的权重, b_o 为偏置。

在 LSTM 模型中, 输入门、遗忘门、输出门表达式类似, 却有不同参数和功能, 以不同的方式控制着记忆单元^[22]。LSTM 网络的输出由上一时刻的隐藏状态和当前输入决定, 上一层的输出信息可作为下一层的输入信息, 网络各处的权重和偏置不断更新, 通过递归完成模型训练^[23]。

2.2 贝叶斯优化算法的建立

神经网络在预测过程中通常有很多超参数需要优化, 以获得最佳的模型性能。LSTM 网络模型需要优化的超参数包括隐藏层节点数目、初始学习率的大小、 L_2 正规化参数等, 常见的调参方法有网格搜索、随机搜索、贝叶斯优化等^[24]。网格搜索的计算量较大且易发生组合爆炸, 参数调优不具备高效性; 随机搜索的随机性较强, 优化结果差异较大, 可能会影响最终预测结果; 网络搜索和随机搜索在优化参数时, 会忽略前面的信息, 导致优化结果较差, 比较而言, 贝叶斯优化算法会充分利用前面的参数信息, 不断地更新数据, 迭代次数少, 优化性能更好, 被广泛应用于

神经网络超参数调优^[25]。

贝叶斯优化是在函数关系未知的情况下根据现有数据对函数进行预估的算法, 使用高斯过程回归模型估测目标函数分布, 不断迭代获得最优解, 计算公式为^[26]:

$$x^* = \operatorname{argmax}_{x \in X} f(x) \quad (6)$$

式中: x^* 表示目标函数 $f(x)$ 在区域 X 内的全局最优解。

贝叶斯优化过程如图 5 所示, 将超参数记为 $\{x_1, x_2, \dots, x_n\}$, 模型结果为 $\{y_1, y_2, \dots, y_n\}$, 贝叶斯优化是利用已知的先验数据 (x, y) 拟合概率代理模型, 表示超参数与模型间的函数关系, 利用采集函数选择下一个最优的 (x, y) , 并用新的 (x, y) 来优化概率代理模型。经过一定数量的迭代, 获得最优超参数值^[27]。




图 5 贝叶斯优化过程

2.3 贝叶斯优化 LSTM 网络模型训练流程

LSTM 网络模型由隐含层、ReLU(rectified linear unit) 激活层和全连接层组成。LSTM 隐含层提取电气设备温度的时间序列特征; 激活函数 ReLu 用于隐含层神经元的输出, 将非线性因素引入 LSTM 网络, 提高模型的表达能力; 全连接层进行特征综合, 实现温度预测。

LSTM 网络层包含很多记忆存储单元, 通过存储单元记忆有用信息, 遗忘无用信息, 但在参数较多时, 直接对原始参数进行处理, 会极大占用模型算力, 降低预测精度。故引入贝叶斯优化算法, 对模型参数进行训练更新, 提高模型可靠性, Bayesian-LSTM 模型训练流程如图 6 所示。

1) 数据预处理。对数据进行划分处理, 确定目标函数和参数范围, 组成先验数据集;

2) 超参数优化。使用高斯代理模型估测目标函数分布; 利用采集函数控制模型采样方向, 选取下一个观测点; 不断迭代更新高斯代理模型, 输出最优参数组合;

3) 模型训练。最优参数组合输入 LSTM 网络模型进行训练, 不断更新网络权重和偏置, 对平台电气设备进行温度预测。

3 基于 Bayesian-LSTM 的海上平台电气设备温度预测实验

以现场采集的图 3 温度数据为例, 将 1~6 日的温度数据作为训练集, 用来训练温度预测模型; 将 7 日的的数据作

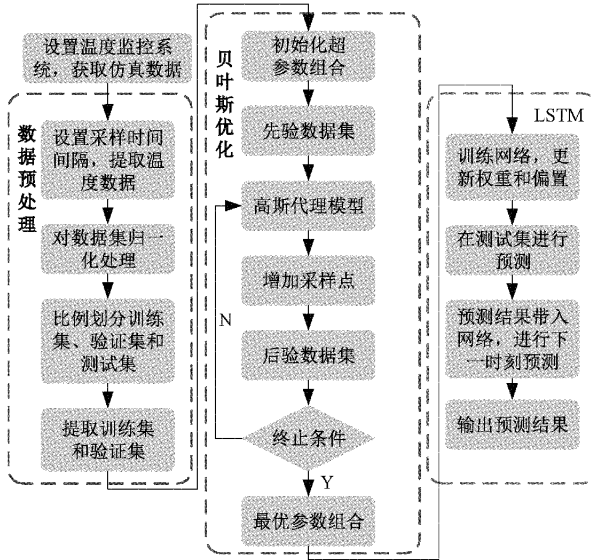


图 6 Bayesian-LSTM 模型训练流程

为验证集,用来验证模型的可靠性;将 8~10 日的数据作为测试集,用来测试优化后模型的精度。在模型训练阶段,首先对数据进行归一化处理,提升模型的收敛速度和拟合精度。

3.1 Bayesian-LSTM 实验评价指标

为了验证 Bayesian-LSTM 模型预测的性能,采用均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE)、拟合优度 R^2 作为评估指标,计算公式分别如下^[26]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \in [0, +\infty) \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \in [0, +\infty) \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \in [0, 1] \quad (9)$$

式中: n 为样本数, y_i 和 \hat{y}_i 分别为第 i 个数据的真实值和预测值。

3.2 Bayesian-LSTM 实验分析

使用训练集和验证集的数据作为输入,为贝叶斯优化器创建目标函数,目标函数进行 LSTM 网络训练,并在验证集上返回分类误差。通过最小化验证集上的分类误差来执行贝叶斯优化。设置首次迭代次数为 30,网络隐藏层节点数为 10~50,初始学习率为 0.001~1。贝叶斯优化结果如图 7 所示。

分析图 7 可知,随着迭代次数的增加,验证集的分类误差逐渐减小,最小观测值和最小估计值误差趋近于 0,交叉验证损失降低,模型可靠性增加。贝叶斯优化后,最佳观测可行点和最佳估计可行点的对比结果如表 1 所示。




图 7 超参数调优的迭代过程和结果

表 1 最佳估计可行点和最佳观测可行点对比

| 对比值 | 最佳观测可行点 | 最佳估计可行点 |
|----------|-----------|-----------|
| 优化器函数 | Adma | Adma |
| 迭代次数 | 27 | 11 |
| 准确率 | 0.916 8 | 0.985 6 |
| 目标函数值 | 0.010 008 | 0.010 153 |
| 函数评估时间/s | 121.393 2 | 99.756 5 |

由表 1 可以看出,经贝叶斯超参数调优后,预测准确率由 91.68% 增加到 98.56%,约提高了 7.5%,函数评估时间约降低了 21 s,表明贝叶斯优化算法可以增加预测模型的精度,提高模型可靠性。

LSTM 网络在训练时存在耗时、过拟合的现象,容易导致局部最优解,为了保证预测准确性,调整迭代和优化次数,选取最优的结果,模型训练过程中各参数变化如表 2 所示。

分析表 2 可知,优化次数为 2 500 时训练结果基本趋于稳定且误差明显变大,为节省计算资源并保证训练精度,选取优化次数为 2 000,迭代次数为 30 作为最终训练结果,LSTM 网络隐藏层节点数为 42,初始学习率为 0.033, L_2 正规化系数为 1.024×10^{-10} 。训练集预测值与真实值对比如图 8 所示,图中预测值与真实值拟合程度较高,此时训练集 RMSE 为 0.124, MAE 为 0.101, R^2 为 0.998,表明模型预测误差较小,预测可靠性较高。故 Bayesian-LSTM 网络模型对电气设备温度有一定的预测作用。

基于优化后的超参数及模型训练结果,利用测试集的数据对模型精度进行测试,结果如图 9 所示,该模型测试集的 RMSE 为 0.139,误差控制在 ± 0.1 ,能很好的预测此时间段的温度值。

如图 9 所示,Bayesian-LSTM 网络模型的整体预测趋势和平台变压器真实温度序列的变化趋势基本一致,中间除峰值外波动较小,预测精度较高。与图 8 相比,训练集与测试集的整体预测趋势一致,表明该预测模型有较强的泛化能力,模型预测误差较小,达到了很好的预测结果。

表 2 优化过程中各参数变化

| 优化次数 | 迭代次数 | 隐藏层节点数 | 初始学习率 | L_2 正规化系数/ $\times 10^{-10}$ | RMSE | MAE | R^2 |
|-------|------|--------|-------|--------------------------------|-------|-------|-------|
| 1 000 | 25 | 18 | 0.004 | 1.009 | 0.131 | 0.102 | 0.993 |
| | 30 | 13 | 0.111 | 5.031 | 0.132 | 0.105 | 0.992 |
| | 35 | 42 | 0.065 | 1.041 | 0.142 | 0.118 | 0.990 |
| 1 500 | 25 | 50 | 0.031 | 1.649 | 0.143 | 0.108 | 0.997 |
| | 30 | 32 | 0.005 | 1.026 | 0.145 | 0.111 | 0.997 |
| | 35 | 37 | 0.025 | 3.315 | 0.137 | 0.098 | 0.997 |
| 2 000 | 25 | 11 | 0.027 | 1.022 | 0.133 | 0.106 | 0.992 |
| | 30 | 42 | 0.033 | 1.024 | 0.124 | 0.101 | 0.998 |
| | 35 | 11 | 0.034 | 6.691 | 0.163 | 0.117 | 0.984 |
| 2 500 | 25 | 38 | 0.075 | 4.828 | 0.138 | 0.109 | 0.983 |
| | 30 | 50 | 0.008 | 1.289 | 0.145 | 0.102 | 0.983 |
| | 35 | 16 | 0.023 | 1.381 | 0.141 | 0.112 | 0.992 |




图 8 训练集预测值与真实值对比






图 9 测试集预测值与真实值对比

3.3 Bayesian-LSTM 模型实验对比

为了验证 Bayesian-LSTM 模型预测的优越性,选取 BP 神经网络、支持向量机、长短时记忆网络模型进行预测对比分析,4 种方法的预测值与实际值对比如图 10 所示。

对比图 10,在训练样本和参数均相同的前提下,支持向量机的预测效果最差,主要是支持向量机在样本数量过大时容易产生过拟合现象且时序性差,预测误差较大。BP

神经网络处理时序性数据的能力较差,不能很好的学习电气设备温度的变化规律,预测精度较低。传统 LSTM 时序性较强,预测误差比支持向量机和 BP 神经网络小,但由于贝叶斯优化具有更新和优化网络参数的能力,可以使网络得到更高的预测精度,比较而言,Bayesian-LSTM 预测效果最优,预测误差最小,模型可靠性最高,表 3 为不同模型评价指标的对比结果。






图 10 4 种方法的预测值与实际值对比

表 3 4 种预测模型均方根误差对比

| 指标 | BP 神经网络 | 支持向量机 | LSTM | Bayesian-LSTM |
|----------------|---------|-------|-------|---------------|
| RMSE | 0.186 | 0.205 | 0.175 | 0.139 |
| MAE | 0.124 | 0.134 | 0.111 | 0.091 |
| R ² | 0.971 | 0.963 | 0.981 | 0.998 |

分析表 3 可知, Bayesian-LSTM 模型 RMSE 为 0.139, MAE 为 0.091, 均小于其他模型预测结果。相对于传统 LSTM 网络模型, Bayesian-LSTM 模型 RMSE 从 0.175 减小到 0.139, 减小了 20.57%; MAE 从 0.111 减小到 0.091, 减小了 18.02%。Bayesian-LSTM 模型的 R² 为 0.998, 预测值与真实值的符合程度最高, 表明 Bayesian-LSTM 模型误差值范围较小, 能够更好地预测变压器温度的变化趋势。

4 结 论

围绕海上平台电气设备所开发的分布式无线红外温度监控系统具有非接触测量、连续实时监控、配线少、覆盖范围广等方面的特点, 实现了海上平台电气设备温度信息采集、分析、预/报警、预测、管理等功能。

围绕海上平台电气设备温度预测预判需求, 提出了基于贝叶斯优化的 LSTM 温度预测模型, 基于海上平台变压器温度数据验证及同类分析方法的比较分析, 证实了 Bayesian-LSTM 可以解决时间序列中长期依赖的问题, 具备自我学习的能力, 模型可靠性较高。相对于时序性较强的 LSTM 网络模型, Bayesian-LSTM 预测效果更优, 其中均方根误差减小了 20.57%, 平均绝对误差减小了 18.02%, 拟合优度高达 0.998, 证明该预测模型对电气设备的温度预测有效, 对提高电气设备的使用寿命及减少电气设备的维修成本具有重要意义。

参考文献

[1] 许志浩, 郑诗泉, 康兵, 等. 基于三相自搜寻比较法的电气设备过热故障识别方法[J]. 红外技术, 2021,

43(11):1112-1118.

[2] DU W, LUO X J, LI X, et al. Reliability evaluation of offshore oil platform power system[C], 2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia), 2019: 2754-2759.

[3] ADNAN S, FAISAL K, LESLEY J, et al. Integrated offshore power operation resilience assessment using object oriented bayesian network [J]. Ocean Engineering, 2018, 167: 257-266.

[4] 唐文虎, 牛哲文, 赵柏宁, 等. 数据驱动的人工智能技术在电力设备状态分析中的研究与应用[J]. 高电压技术, 2020, 46(9):2985-2999.

[5] 王亚舟, 严玉婷, 陈正强, 等. 反射镜像法应用于电力设备红外检测的研究[J]. 高压电器, 2020, 56(2): 202-209.

[6] 陈达, 唐文虎, 牛哲文. 基于深度学习的电力设备红外图像故障诊断方法[J]. 广东电力, 2021, 34(1): 97-105.

[7] 梁兴, 严居斌, 尹磊. 基于红外图像的输电线路故障识别[J]. 电测与仪表, 2019, 56(24):99-103.

[8] 刘益岑, 杨琳, 王杨宁, 等. 基于高光谱与红外技术融合的绝缘子污秽程度检测方法[J]. 电工电能新技术, 2022, 225(3):55-62.

[9] 黄新波, 蒋卫涛, 朱永灿, 等. 基于时间序列和支持向量机的变压器故障预测[J]. 高电压技术, 2020, 332(7): 2530-2538.

[10] AHMED T. Time series forecasting using artificial neural networks methodologies: A systematic review[J]. Future Computing and Informatics Journal, 2018, 3(2): 334-340.

[11] MOURA M C, ZIO E, LINS I D, et al. Failure and reliability prediction by support vector machine[J]. Reliability Engineering & System Safety, 2011, 96(11): 1527-1534.

[12] 于建国, 岳占岐, 边辉, 等. 基于 BP 神经网络的风力发

- 电机温升故障诊断研究[J]. 微电机, 2020, 53(2): 32-36.
- [13] 廖才波, 阮江军, 蔚超, 等. 基于改进支持向量机的变压器实时热点温度预测方法研究[J]. 高压电器, 2018, 54(12): 174-179.
- [14] 陈伟根, 奚红娟, 苏小平, 等. 广义回归神经网络在变压器绕组热点温度预测中的应用[J]. 高电压技术, 2012, 38(1): 16-21.
- [15] 侯勇严, 郑恩让, 郭文强, 等. 基于长短期记忆循环神经网络的开关柜设备温度预测[J]. 陕西科技大学学报, 2021, 39(4): 148-155.
- [16] 赵欢, 阳浩, 何亮, 等. 高精度配电网电气设备故障识别检测方法[J]. 沈阳工业大学学报, 2021, 43(6): 614-618.
- [17] RAMAKRISHNA A, VENKATA N R P. Predicting the success rate of a start-up using LSTM with a swish activation function [J]. Journal of Control and Decision, 2022, 9(3): 355-363.
- [18] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法[J]. 仪器仪表学报, 2021, 42(4): 111-120.
- [19] 王科, 苟家萁, 彭晶, 等. 基于 LSTM 网络的变压器油中溶解气体浓度预测[J]. 电子测量技术, 2020, 43(4): 81-87.
- [20] 姚栋方, 吴瀛, 罗磊, 等. 基于深度学习的短期电力负荷预测[J]. 国外电子测量技术, 2020, 39(1): 44-48.
- [21] 孙俊峰, 李志斌. 基于 LSTM 的滚动预测算法的电缆缆芯温度的研究[J]. 电子测量技术, 2021, 44(21): 84-88.
- [22] 张羽飞, 孟凡勇, 王永千, 等. 基于改进型 LSTM 的电力设备温度预测方法研究[J]. 电子测量与仪器学报, 2021, 35(12): 167-173.
- [23] 孙俊峰, 李志斌. 基于 LSTM 的滚动预测算法的电缆缆芯温度的研究[J]. 电子测量技术, 2021, 44(21): 84-88.
- [24] 李斌, 王卫星. NCA 降维和贝叶斯优化调参对分类模型的改进[J]. 计算机应用与软件, 2019, 36(8): 281-287, 299.
- [25] LI H Q. Automatic electrocardiogram detection and classification using bidirectional long short-term memory network improved by Bayesian optimization [J]. Biomedical Signal Processing and Control, 2022, 73.
- [26] 孙斌, 储芳芳, 陈小惠. 基于贝叶斯优化 XGBoost 的无创血压预测方法[J]. 电子测量技术, 2022, 45(7): 68-74.
- [27] 曲朝阳, 王冲, 潘峰. 智能用电环境下的家庭电力能效评估方法[J]. 电工电能新技术, 2015, 148(10): 61-67.
- [28] 黄骏, 唐慧, 柴利. 基于卷积神经网络的 5G 无线信道参数学习方法[J]. 武汉科技大学学报, 2022, 45(2): 149-154.

作者简介

梁玉真, 硕士研究生, 主要研究方向为电力设备在线监测与故障诊断。

E-mail: lyznszbd1117@163.com

张仕海, 博士, 教授, 主要研究方向为电力设备在线监测与故障诊断。

E-mail: zshky77@163.com