

DOI: 10.13382/j.jemi.B2104077

基于改进型 LSTM 的电力设备温度预测方法研究

张羽飞¹ 孟凡勇¹ 王永千^{1,2} 吴越² 李红^{1,3}

(1. 北京信息科技大学光电测试技术及仪器教育部重点实验室 北京 100192; 2. 北京信息科技大学光纤传感与系统北京实验室 北京 100016; 3. 北京信息科技大学北京市光电测试技术重点实验室 北京 100192)

摘要:实现电力设备温度的准确预测对于保障电力系统安全和提高维修效率具有重要意义。传统预测方法无法满足高精度的预测要求,提出一种基于改进型长短期记忆(long short-term memory, LSTM)神经网络的电力设备温度预测方法,利用去池化的卷积神经网络(convolutional neural networks, CNN)对时间序列进行局部特征提取,然后利用 LSTM 设计的循环递归层对时间序列进行长期特征提取,实现电气设备温度预测。在首都国际机场的供电设备运行状态监测数据集的实验结果表明,温度预测值在 20~60 min 内预测精度优于 1 °C,且均方根误差(RMSE)0.12 均小于其他温度预测模型,可以有效实现电气设备温度预测。

关键词:卷积神经网络;长短期记忆神经网络;温度预测;电力设备

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Research on temperature prediction method of power equipment based on improved LSTM

Zhang Yufei¹ Meng Fanyong¹ Wang Yongqian^{1,2} Wu Yue² Li Hong^{1,3}

(1. Key Laboratory of the Ministry of Education for Optoelectronic Measurement Technology and Instrument, Beijing University of Information Technology, Beijing 100192, China; 2. Beijing Laboratory of Optical Fiber Sensing and Systems, Beijing University of Information Technology, Beijing 100016, China; 3. Beijing Key Laboratory of Optoelectronic Measurement Technology, Beijing University of Information Technology, Beijing 100192, China)

Abstract: It is of great significance to realize the accurate prediction of the temperature of power equipment to ensure the safety of the power system and to improve maintenance efficiency. Traditional forecasting methods cannot meet the requirements of high-precision forecasting. A temperature prediction method for power equipment based on an improved long short-term memory (LSTM) neural network is proposed, which uses de-pooling convolutional neural networks (CNN) to extract local features of time series, and then use the recursive layer designed by LSTM to extract the long-term features of the time series to realize the temperature prediction of electrical equipment. Experimental results on the Power monitoring temperature data set of Capital International Airport show that the prediction accuracy of the temperature prediction value is better than 1 °C within 20 to 60 minutes, and the root mean square error (RMSE) 0.12 is smaller than other temperature prediction models.

Keywords: CNN; LSTM; temperature prediction; power equipment

0 引言

电力是国家发展经济的命脉。近年来我国经济发展迅速,电力系统逐渐庞大且结构复杂,不同区域之间的互联也越来越紧密。这就对电力系统的稳定安全运转提出

更严格的要求。然而由于复杂因素的影响,故障出现又是不可避免的。目前电力设备大都通过简单阈值判定设备是否存在故障。这种故障诊断的方式,往往发现异常时,设备已经损坏比较严重,或已经造成损失。如果能在有故障征兆时,就能预测到最可能发生故障的地点或者设备,并能进行针对性的预防维护,将有效解决被动的事

后维护以及计划维修中存在的维修不足及过度维修的问题。因此,对电力设备进行在线温度实时监测和预测温度未来变化趋势,可以对设备状态更好地掌握,有效防止电气设备过热等事故发生,对电力系统的稳定性、安全性和降低维护成本具有重要意义^[1]。

目前温度数据的预测方法主要包括时间序列分析法^[2]、支持向量机(SVM)^[3]和神经网络^[4]等。Shirvani等^[5]使用差分自回归综合移动平均模型预测波斯湾海面温度异常,指出该方法对于时间平稳性高的序列具有很好的预测效果。时间序列等传统方法无法准确进行复杂的预测。樊浩等^[6]提出粒子群优化-支持向量机(PSO-SVM)算法对电缆接头温度进行预测,指出大小不一样的数据样本会对预测结果精度造成明显影响。机器学习方法虽然能够处理复杂的非线性问题,但是在处理大规模数据方面存在一定困难。孙为钊等^[7]提出利用卷积神经网络提取输入数据特征进行温度预测,指出卷积神经网络(CNN)在学习非线性序列的数据方面准确率更高。然而,当数据波动性和不稳定性较大时,单一的卷积神经网络模型难以较好学习数据的变化规律。杨洪富等^[8]基于长短时记忆网络(LSTM)建立的 EGT 的预测模型,并说明了 LSTM 方法在 EGT 的预测问题上比循环神经网络(RNN)与支持向量机更加准确。李和明^[9]提出卷积神经网络与长短时神经网络结合在同步电机励磁绕组匝间短路故障预警中的应用,并指出不同模型结合在训练速度和拟合效果上要强于单独的 CNN 或 LSTM 模型。

电力设备温度变化规律受多种因素影响,如时间序列等传统方法无法准确进行复杂的预测。机器学习方法虽然能够处理复杂的非线性问题,但是在处理大规模数据方面存在一定困难。单一的 CNN 模型难以较好学习时序数据的变化规律。当利用 LSTM 的模型预测提取数据特征时,输入序列过长容易丢失信息,从而一定程度上影响预测准确度。针对 LSTM 等预测方法存在的问题,本文通过分析温度数据变化特点,提出一种卷积神经网络和长短时记忆神经网络相结合方法构建温度预测模型。最后,通过实例分析,将本文提出方法与典型方法进行比较,指出本文所提方法具有更高的预测精度。

1 数据采集及预处理

1.1 数据采集

基于光纤传感器的温度监测系统主要用于监测电力系统中的变压器、开关柜、母排等主要设备的温度变化情况。通常情况下电力系统中大多数变压器与开关柜均会独立放置,且数量较少,所以通常会在变压器与开关柜内部设置 6~9 个温度监测点。母排常常因为距离长,数量多,所以通常会利用分布式光纤设置多个温度监测点。

本文研究使用数据来自北京首都国际机场供电设备运行状态监测项目的温度监测数据。该监测系统以光纤光栅传感器^[10]为基础研究开发了 8 通道、每通道 23 单元的光纤光栅温度传感系统^[11],布设于首都机场 T3 航站楼行李供电系统进行全天候、长期温度监测。光纤光栅温度传感系统主要由光纤温度传感器、光纤解调仪、数据服务器、主机构成。如图 1 所示,主要监测地下廊道的母排节点、开关柜触点、变压器触点温度,温度精度为 $\pm 0.5\text{ }^{\circ}\text{C}$ 。

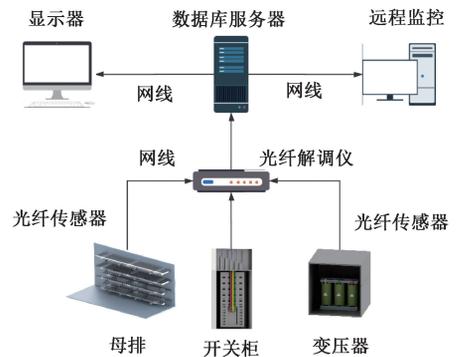


图 1 温度监测系统结构

Fig. 1 Temperature monitoring system structure diagram

1.2 温度数据描述

电力设备温度变化在时间上具有两种重复模式,长期和短期。长期模式是根据四季、白天和夜晚、甚至小时、分钟之间的联系,具有一定规律性变化,大周期内包含小周期。短期则反应设备功率变化、天气等的影响,可能会出现震荡变化现象,波动的幅度也因影响因素的不同而存在不同。

以北京首都国际机场供电设备运行状态监测系统采集的数据为例,数据采集间隔为 1 min,采集了从 2019 年 8 月~2020 年 6 月的 432 000 条数据,该时间段包括一年四季 24 h 连续数据,这些数据能很好反映监测节点的温度变化规律。数据曲线如图 2 所示。

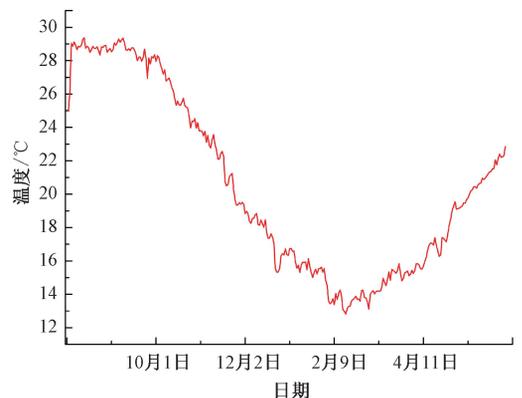


图 2 温度曲线

Fig. 2 Temperature curve

2 数据处理

2.1 数据预处理

监测系统采集的数据包括测点 ID、测点温度值、测点时间、测点状态等。由于仪器故障、数据库存储和外部干扰等不可控因素会导致采集到的数据存在缺失值、异常值等异常情况^[12],因此对数据集进行了缺失值填充、异常值替换、数据归一化^[13]等预处理。

2.2 数据集划分

样本数据为北京首都国际机场供电设备运行状态监测系统 2019 年 8 月 1 日~2020 年 6 月 14 日的现场温度监测数据,采用频率为 1 min。以 2019 年 8 月~2020 年 3 月的数据集作为训练集,用于温度预测模型的拟合。以 2020 年 4 月~2020 年 5 月的数据集作为验证集,用于使用各个模型对验证集数据进行预测,调整超参数并监控模型是否发生过拟合,从而选出最优模型。以 2020 年 5 月~2020 年 6 月的数据集作为测试集,用于评估最终模型泛化能力。

3 模型构建

本节介绍了建立温度预测模型的基本理论和方法。首先,给出了温度预测模型的结构,在此基础上给出温度预测模型的学习方法。

3.1 模型结构

温度预测模型由 CNN 组件的卷积层、GRU (Unit) 组件的递归层以及 LSTM 设计的循环层 3 部分组成,如图 3 所示。

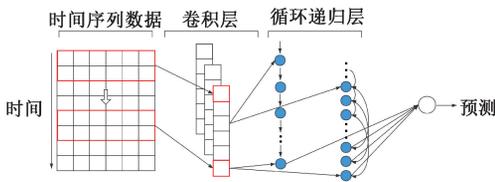


图 3 模型结构

Fig. 3 Model structure

1) 卷积层

温度预测模型的第 1 层是一个去池化的一维卷积网络。

CNN 属于典型前馈神经网络,具有稀疏连接和权值共享的特性^[14],可以很好地识别出数据中的简单模式,然后使用这些简单模式在更高级的层中生成更复杂的模式。一维卷积网络优势在于从整体数据集较短的片段中获取目标特征且该特性在该数据片段的位置不具有高度

相关性。一维卷积网络可以很好地应用于传感器数据的时间序列分析;同样也可以很好地用于分析具有固定长度周期的信号数据(比如音频信号)。此外,还能应用于自然语言处理的任务中^[15]。

对于温度时间序列数据,温度预测模型通过卷积层提取时间维度上的短期模式以及变量的相关特征。卷积层由宽度是 2 高度是 1 的多个滤波器组成。第 K 个滤波器扫描输出矩阵 \mathbf{x} 并产生:

$$h_k = \text{RELU}(W_k * \mathbf{x} + b_k) \quad (1)$$

式中: w 表示过滤器的宽度,高度为 n (高度设置与变量个数相同),本文设置为 1, $*$ 是卷积运算,RELU 函数是 $\text{RELU}(\mathbf{x}) = \max(0, \mathbf{x})$ 。

2) 递归层

卷积层的输出同时输入到具有 GRU 的递归层和 LSTM 设计的循环层中,目标是捕获长期和非常长的信息。

递归层是由 GRU 组成,使用 RELU 函数作为隐藏的更新激活函数^[16]。 t 时刻递归层单元的隐藏状态可以表示为,

$$\begin{aligned} r_t &= \sigma(x_t W_{xr} + h_{t-1} W_{hr} + b_r) \\ u_t &= \sigma(x_t W_{xu} + h_{t-1} W_{hu} + b_u) \\ c_t &= \text{RELU}(x_t W_{xc} + r_t \odot (h_{t-1} W_{hc}) + b_c) \\ h_t &= (1 - u_t) \odot h_{t-1} + u_t \odot c_t \end{aligned} \quad (2)$$

其中, \odot 是元素积, σ 是 sigmoid 函数, x_t 是输入以及卷积层在时间戳 t 的输出。

3) 循环层

递归层通过记忆历史信息,从而识别到相对长期的信息。在实际应用中,因为梯度消失的原因,GRU 组成的递归层往往无法捕捉到非常长期的相关性特征。基于上述原因,可以通过加入一个重新设计的 LSTM 结构^[17]作为一个新的循环跳跃组件,来识别非常长期的模式。

在温度时间序列数据中,每天的温度呈现明显的规律。如果温度预测模型想预测今天 t 时刻的温度值,除了用最近的温度记录值外,还可以利用历史上 t 时刻的温度记录值。但是由于历史跨度周期可能较长,例如一天、两天甚至更长时间,这种依赖性很难被递归层捕捉到。所以在温度预测模型中加入重新设计的 LSTM,即在 LSTM 的当前隐藏单元格中和相邻时段的同一阶段的隐藏单元格之间添加跳过链接。更新过程如下:

$$\begin{aligned} r_t &= \sigma(x_t W_{xr} + h_{t-p} W_{hr} + b_r) \\ u_t &= \sigma(x_t W_{xu} + h_{t-p} W_{hu} + b_u) \\ c_t &= \text{RELU}(x_t W_{xc} + r_t \odot (h_{t-p} W_{hc}) + b_c) \\ h_t &= (1 - u_t) \odot h_{t-p} + u_t \odot c_t \end{aligned} \quad (3)$$

其中该层的输入为卷积层的输出, p 是跳过的隐藏单元数,对于温度时间序列数据,可以将周期调整为 1 d 或者 1 周,从而更好去预测温度的未来值。

3.2 模型训练

1) 模型参数

深度学习算法通常有几个超参数需要调整以获得最佳结果。本文模型有许多超参数需要确定,如学习速率、CNN 过滤器的个数、LSTM 网络层数、GRU 单元个数、跳过周期等。利用训练集样本构建模型,将模型学习速率设置为 0.01, LSTM 网络层数为单层。

本文采用网格搜索法^[18]确定其余超参数。网格搜索算法(grid search)的基本原理是在给定参数的变化范围内,按照不同的增长方向,以设定好的步长遍历范围内的所有点,相当于形成了一个多维的网格,并验证网格中的每个参数以选择最佳网络结构参数。

首先,需要确定每个超参数的范围。预测模型主要分为 2 个部分,卷积神经网络和循环递归部分。卷积神经网络部分实现对短期特征的提取,循环递归层部分实现对序列时间长期依赖性的特征提取。时间输入序列为 $X_n = [x_1, x_2, \dots, x_t]$,在 t 时刻将 x_t 作为模型输入并输入到卷积神经网络中,多层网络可以具有更深的特征抽取能力,因此模型设置一维卷积层数为 5 层。由于模型参量较少,过滤器数目过多,容易造成过度拟合,过滤器个数为 10~40。不同的 GRU 层在空间相连,时间序列数据从上层输出到下一层。每层 GRU 都包含许多 GRU 神经元,以提取数据的时间依赖性。在每层 GRU 中,神经元之间进行彼此信息的交换,实现时间性的实现时间性的连接。此外,每个神经元的输出不仅要在下一刻循环进入自身,还要与其他神经元共享。要提高模型精确性。因此将 GRU 的隐含层数设置为 80~120。对于 LSTM 层跳过隐藏单元的个数,由于温度变化的周期表现,本文将周期设置为 1、3 d 和 1 周。表 1 为用于网格搜索的每个超参数的范围。

表 1 LSTNet 超参数范围

Table 1 LSTNet hyperparameter range

参数	范围
CNN 过滤器	[10, 40]
GRU 单元	[80, 120]
跳过隐藏单元	[1 440, 10 080]

2) 模型损失函数

本文温度预测模型选取 432 000 个样本数据,按 7:3 的比例分为训练集和测试集。批大小设置为 50。训练 500 个周期保存训练模型,记录训练过程中损失函数的变化,并在测试集中记录均方根误差(RMSE)。模型损失函数如图 4 所示。

3.3 模型预测流程

本文所用模型的预测流程具体描述如下。

1) 数据预处理。

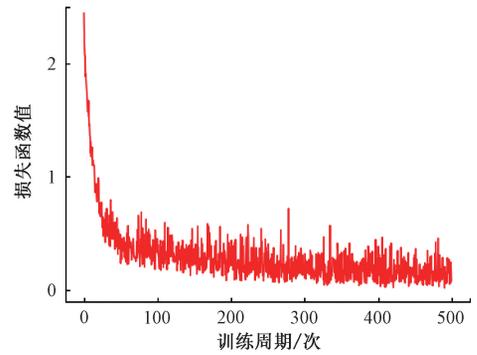


图 4 loss 值随训练周期变化曲线

Fig. 4 Loss value changes with training times

2) 模型训练,将训练集的数据输入模型进行训练,由 CNN 层识别短期模式,之后将输出同时输入到门控制单元设计的递归层和 LSTM 设计循环层,用于捕捉长期模式。

3) 预测结果输出。

4 实例分析

本文在模型训练完成后,选取北京首都国际机场母排电力设备的 2020 年 5 月 1 日~6 月 15 日监测数据作为输入对训练模型进行测试,并与实测值进行对比分析。温度预测模型运行时首先通过 MySQL 的数据库服务器读取历史温度数据,并通过数据预处理生成时间序列数据,进而通过卷积层和循环递归层进行预测,并输出预测结果。

4.1 性能评估

本文使用 RMSE、均方误差(mean square error, MSE)作为评价温度预测模型精度的指标^[19],两个指标的方程式如下:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad (4)$$

4.2 时间窗口和预测间隔

电力设备发热现象往往是渐进式发热,温度会在出现故障后逐渐升高。因此温度预测模型需要预测未来 20~60 min 的温度变化。由于传感器数据在不同地区的特征不同,因此温度预测模型需要确定模型输入数据的窗口大小和输出的预测时间间隔,从而达到预测要求。本文使用不同的窗口大小和预测时间间隔来选择在 MSE 和 RMSE 准则下表现良好的参数。

对于本文所选取的母排节点,根据该地区的位置,散热,环境等因素,选取输入时间窗口为 60、120、180 等不

同情况进行预测,以确定最终的参数组合。实验实例如表 2 所示,说明如何确定选取节点温度预测模型的窗口大小和预测间隔。

表 2 时间窗口和预测间隔

Table 2 Time window and forecast interval

时间窗口/min	预测时间步长/min	MSE	RMSE
60	20	0.014 4	0.12
60	30	0.022 5	0.15
60	40	0.072 9	0.27
120	20	0.016 9	0.13
120	30	0.014 4	0.12
120	40	0.102 4	0.32
180	20	0.010 0	0.10
180	30	0.016 9	0.13
180	40	0.072 9	0.27

表 2 中,本文选择了 180 min 的窗口大小和 20 min 的预测时间步长。这是因为参数组合在 RMSE 和 MSE 表现良好,输入参数的数量相对较少(随着窗口的增加,数据量也会变大,这将导致模型预测性能的下降)。

4.3 实验测试

以 5 月 1 日~6 月 15 日监测数据作为输入,并与实

表 3 各种预测方法的结果

Table 3 Results of various forecasting methods

预测方法	60 min 固定窗口预测时间			120 min 固定窗口预测时间			180 min 固定窗口预测时间		
	20	30	40	20	30	40	20	30	40
自回归移动模型 RMSE	0.14	0.13	0.33	0.21	0.23	0.43	0.24	0.25	0.45
三次平滑指数模型 RMSE	0.13	0.13	0.35	0.16	0.21	0.45	0.21	0.25	0.41
长短时记忆模型 RMSE	0.12	0.14	0.29	0.14	0.15	0.36	0.13	0.13	0.31
支持向量机模型 RMSE	0.13	0.14	0.31	0.15	0.16	0.39	0.20	0.23	0.39
改进型 LSTM 模型 RMSE	0.12	0.15	0.27	0.13	0.12	0.32	0.1	0.13	0.27

由表 3 可知,温度预测模型在 120、180 min 的固定窗口条件下,无论是在预测时间为 20 min、30 min、40 min 时,温度预测模型 RMSE 均小于其余 4 种方法的 RMSE,此模型仅在 60 min 的固定窗口条件下预测 30 min 时, RMSE 为 0.15 大于其余 4 种方法的 RMSE,总体来看温度预测模型的效果要好于其余 4 种方法,证明对母排节点温度预测有效,可以对设备进行预防性维护。

5 结论

随着我国经济高速发展,电力能源是重中之重,提前及时进行电力设备的温度预测及故障预警,可以有效降低设备运行维护成本以及故障引起的经济损失。本文主要利用电力系统温度传感数据进行分析和挖掘,构建一种基于深度学习的电力设备温度预测模型,为达到预测温度精度更高的效果,本文实现将 CNN 与 LSTM 进行结

测值对比如图 5 所示。从图 5 可以看到,温度预测值能够很好的跟踪此时间段内母排节点的温度实测值。

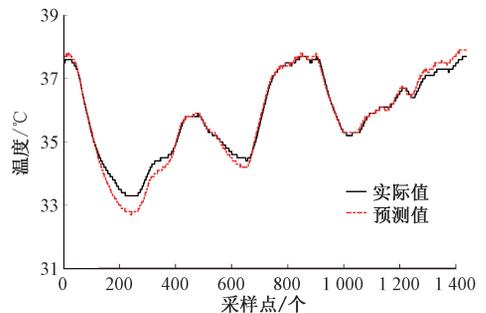


图 5 预测值与实测值对比

Fig. 5 Comparison of predicted value and measured value

4.4 实验对比

为了验证温度预测模型的有效性,本文选择自回归移动平均模型^[20]和 3 次指数平滑模型^[21]、长短时记忆模型、支持向量机作为对照基准模型。并采用 RMSE 指标作为定量评定预测结果的优劣,5 种模型所对应的结果如表 3 所示。

合的预测策略。

本文以北京首都国际机场供电设备运行状态监测的温度数据为数据源,通过分析数据得出长期和短期的变化特点。考虑到数据波动较大时,CNN 难以准确学习数据特征;当输入序列过长,LSTM 会发生丢失序列现象,所以本文,使用 CNN 与 LSTM 相互结合来对预测模型进行改进,并通过机场实际母排编号为 9-2-9 的实际监测数据进行模型训练,测试验证。结果表明,母排节点温度未来 20~60 min 的温度预测值能够很好跟踪实测值。

本文提出的基于改进型 LSTM 的温度预测模型可以在故障发生之前获得设备的预测温度。而预测结果可以帮助经验丰富的人员根据过去的经验设置警报阈值,以便及时准确地预测故障,并预测可能的故障位置和故障原因,这将有效帮助采取有效措施并排除故障,节约经济,节省人力。因此对于具有温度监测系统的众多领域,关于设备的温度预测将会是很好的研究方向。

参考文献

- [1] 杨江,赵伟哲. 电力设备状态监测与故障诊断[J]. 科技风,2019(34):177.
YANG J, ZHAO W ZH. Power equipment status monitoring and fault diagnosis [J]. Science and Technology Wind, 2019(34): 177.
- [2] 刘帅,朱永利,张科,等. 基于误差修正 ARMA-GARCH 模型的短期风电功率预测[J]. 太阳能学报,2020,41(10):268-275.
LIU SH, ZHU Y L, ZHANG K, et al. Short-term wind power prediction based on error-corrected ARMA-GARCH model[J]. Acta Solar Energy, 2020, 41(10): 268-275.
- [3] 宁琦,耿读艳,王晨旭,等. 基于多尺度排列熵及 PSO-SVM 的输电线路故障判别[J]. 电子测量与仪器学报,2019,33(7):173-180.
NING Q, GENG D Y, WANG CH X, et al. Transmission line fault diagnosis based on multi-scale permutation entropy and PSO-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (7) : 173-180.
- [4] 陈亮,张媛媛,刘韵婷. 基于改进的 LSTM 的药品温湿度预测方法[J]. 电子测量与仪器学报,2019,33(1):106-112.
CHEN L, ZHANG Y Y, LIU Y T. Prediction method of drug temperature and humidity based on improved LSTM [J]. Journal of Electronic Measurement and Instrument, 2019,33 (1) : 106-112.
- [5] SHIRVANI E. Analyses of the persian gulf sea surface temperature; Prediction and detection of the climate change signals [J]. Arabian Journal of Geosciences, 2015, 8(4):2121-2130.
- [6] 樊浩,宁博扬,何森. 基于 SVM 改进 PSO 算法的电缆接头温度预测分析[J]. 电子测量技术,2019,42(21):53-56.
FAN H, NING B Y, HE S. Prediction and analysis of cable joint temperature based on SVM improved PSO algorithm [J]. Electronic Measurement Technology, 2019, 42(21): 53-56.
- [7] 孙为钊,周俊. 基于卷积神经网络的平面磨削温度预测[J]. 计算机系统应用,2020,29(2):248-253.
SUN W ZH, ZHOU J. Surface grinding temperature prediction based on convolutional neural network [J]. Computer Systems & Applications, 2020, 29 (2) : 248-253.
- [8] 杨洪富,贾晓亮. 基于 LSTM 的航空发动机排气温度预测[J]. 航空计算技术,2018,48(4):65-69.
YANG H F, JIA X L. Aero-engine exhaust temperature prediction based on LSTM [J]. Aeronautical Computing Technology, 2018, 48 (4) : 65-69.
- [9] 李和明,李俊卿. 电机中温度计算方法及其应用综述[J]. 华北电力大学学报,2005,32(1):1-5.
LI H M, LI J Q. Summary of temperature calculation methods and applications in electric motors [J]. Journal of North China Electric Power University, 2005, 32(1): 1-5.
- [10] 周湛,张志坤,赵振刚,等. 基于光纤传感的输电线路悬垂绝缘子风偏角监测研究[J]. 电子测量与仪器学报,2020,34(3):81-87.
ZHOU ZH, ZHANG ZH K, ZHAO ZH G, et al. Research on wind deflection angle monitoring of transmission line suspension insulator based on optical fiber sensor [J]. Journal of Electronic Measurement and Instrumentation, 2020,34 (3) : 81-87.
- [11] 张翠,陶渊,童杏林,等. 基于全同弱光纤 Bragg 光栅阵列的铁路轨道监测系统[J]. 红外与激光工程,2019,48(6):379-385.
ZHANG C, TAO Y, TONG X L, et al. Railway track monitoring system based on identical weak fiber Bragg grating array [J]. Infrared and Laser Engineering, 2019,48 (6) : 379-385.
- [12] 苏卫星,朱云龙,胡琨元,等. 基于模型的过程工业时间序列异常值检测方法[J]. 仪器仪表学报,2012,33(9):2080-2087.
SU W X, ZHU Y L, HU K Y, et al. Model-based outlier detection method for process industry time series [J]. Chinese Journal of Scientific Instrument, 2012, 33 (9) : 2080-2087.
- [13] 张海涛,汤儒峰,李祝莲,等. 基于阵列探测技术的激光测距数据预处理方法[J]. 红外与激光工程,2020,49(8):89-98.
ZHANG H T, TANG R F, LI ZH L, et al. Laser ranging data preprocessing method based on array detection technology [J]. Infrared and Laser Engineering, 2020, 49 (8) : 89-98.
- [14] 唐波,陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报,2020,34(3):88-93.
TANG B, CHEN SH SH. Bearing fault diagnosis method based on deep convolution neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34 (3) : 88-93.
- [15] 吴丹,梁琪瑛,王民意. 基于卷积神经网络的英语口语打分[J]. 信息技术,2020,44(11):34-38,44.
WU D, LIANG Q Y, WANG M Y. Spoken English based on convolutional neural network [J]. Information

- Technology, 2020, 44(11): 34-38, 44.
- [16] 尹诗, 侯国莲, 胡晓东, 等. 风力发电机组发电机前轴承故障预警及辨识[J]. 仪器仪表学报, 2020, 41(5): 242-251.
YIN SH, HOU G L, HU X D et al. Early warning and identification of front bearing failure of wind turbine generators[J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 242-251.
- [17] 裴晓敏, 范慧杰, 唐延东. 多通道时空融合网络双人交互行为识别[J]. 红外与激光工程, 2020, 49(5): 211-216.
PEI X M, FAN H J, TANG Y D. Two person interaction behavior recognition in multi-channel space-time fusion network [J]. Infrared and Laser Engineering, 2020, 49(5): 211-216.
- [18] 施皓晨, 肖海鹏, 周建江. 一种双线性分段二分网格搜索 SVM 最优参数方法[J]. 计算机与数字工程, 2020, 48(9): 2179-2184.
SHI H CH, XIAO H P, ZHOU J J. A bilinear piecewise bipartite grid search for optimal parameters of SVM[J]. Computer and Digital Engineering, 2020, 48(9): 2179-2184.
- [19] 郑宝芬, 苏宏业, 罗林. 无监督特征选择在时间序列数据挖掘中的应用[J]. 仪器仪表学报, 2014, 35(4): 834-840.
ZHENG B F, SU H Y, LUO L. The application of unsupervised feature selection in time series data mining[J]. Chinese Journal of Scientific Instrument, 2014, 35(4): 834-840.
- [20] 陈庆堂, 宋一然, 黄宜坚. 基于 ARMA 模型的磁流变振动系统精确建模与性能研究[J]. 仪器仪表学报, 2015, 36(5): 1014-1022.
CHEN Q T, SONG Y R, HUANG Y J. Accurate modeling and performance research of magnetorheological vibration system based on ARMA model [J]. Chinese Journal of Scientific Instrument, 2015, 36(5): 1014-1022.
- [21] 黄伟建, 张一帆, 黄远. 动态三次指数平滑法的火电厂发电量预测研究[J]. 现代电子技术, 2020, 43(17): 147-150, 154.
HUANG W J, ZHANG Y F, HUANG Y. Research on power generation forecast of thermal power plant based on dynamic cubic exponential smoothing method [J]. Modern Electronic Technology, 2020, 43(17): 147-150, 154.

作者简介



张羽飞, 2016 年于河北师范大学获得学士学位, 现为北京信息科技大学硕士研究生, 主要研究方向为人工智能技术和数据分析。

E-mail: 1921747075@qq.com

Zhang Yufei received his B. Sc. degree from Hebei Normal University in 2016. He is a M. Sc. candidate at Beijing Information Science and Technology University now. His main research interests include artificial intelligence technologies and data analysis.