

基于深度学习的智慧校园电力设备故障检测研究

游 坤

(金陵科技学院软件工程学院, 江苏 南京 211169)

摘 要:深度学习技术对保障智慧校园电力系统的平稳运行有着至关重要的作用。通过主成分分析实现数据降维,将数据输入至长短时记忆(LSTM)神经网络和自编码(AE)神经网络进行性能分析和状态异常检测,为了减少误差使用 Adaboost 算法对模型进行微调。以深度学习为基础,构建了一种基于 LSTM 神经网络、AE 神经网络和 Adaboost 算法的智慧校园电力设备故障检测系统。仿真结果表明,算法能准确处理电力设备性能监控数据,提高了电力设备故障检测的精准性。

关键词:智慧校园;深度学习;LSTM 神经网络;AE 神经网络;Adaboost 算法

中图分类号:TP39

文献标识码:A

文章编号:1672-755X(2022)02-0009-06

Research on Fault Detection of Power Equipment in Smart Campus Based on Deep Learning

YOU Kun

(Jinling Institute of Technology, Nanjing 211169, China)

Abstract: Deep learning technology plays a vital role in ensuring the smooth operation of the smart campus power system. Data dimensionality reduction is achieved through principal component analysis, and the data is input into a long short-term memory(LSTM) neural network and an auto-encoding(AE) neural network for performance analysis and state anomaly detection. In order to reduce errors, the Adaboost algorithm is used to fine-tune the model. Based on deep learning, this paper constructs a fault detection system for smart campus power equipment based on LSTM neural network, AE neural network and Adaboost algorithm. The simulation results show that the algorithm can accurately process the performance monitoring data of power equipment and improve the accuracy of power equipment fault detection.

Key words: smart campus; deep learning; LSTM neural network; AE neural network; Adaboost algorithm

随着人工智能、大数据等技术的不断发展,智慧校园的优势开始不断显现,并对我国教育事业的发展起到了推进作用^[1]。智慧校园的建设极大地促进了校园网络、多媒体、消费系统等的发展,使校园管理水平得到了极大的提升。

智慧校园的建成依托于电力系统的平稳运行,已有诸多学者从网络安全和电力负荷方面进行研究,为

收稿日期:2022-05-20

基金项目:金陵科技学院高层次人才科研启动基金项目(jit-b-201705);教育部 2021 年第二批产学合作协同育人项目(202102172019)

作者简介:游坤(1982—),女,山西沁源人,高级工程师,博士,主要从事分布式计算、智能化系统研究。

智慧校园的电力系统提供保障。但由于学校教学的特殊性和智慧校园的不断发展,智慧校园系统需要的电力设备越来越多,传统的电力设备故障检测机制已经难以满足智慧校园系统的需要。为了保证智慧校园电力设备的平稳运行,急需一种新的智慧校园电力设备故障检测系统。人工智能中深度学习技术的不断发展使构建运行速度更快、故障检测更精准的电力设备检测系统成为可能,尤其是机器学习神经网络的不断发展为智慧校园电力设备故障检测模型的构建提供了更多的解决方案。现有电力设备故障检测模型的构建主要采用卷积神经网络、误差逆向传播(BP)神经网络、长短时记忆(LSTM)神经网络、自编码(AE)神经网络等。

卷积神经网络在嵌入式电力设备的故障检测方面发挥着重要作用^[2]。在风电设备的故障与性能检测中,已有学者发现 AE 神经网络可以更好地检测电力设备的运行和故障情况^[3]。以此为基础,有学者发现将 LSTM 神经网络与 AE 神经网络结合,可以进一步提高检测的准确性^[4]。在电网设备的故障检测中,稀疏自编码神经网络的应用,也使得检测的准确性和预测速度进一步提高^[5]。还有学者将 Adaboost(自适应增强)算法应用于电力设备故障检测中,提高了检测的准确性^[6];或将 Adaboost 算法应用于水力发电电力设备的故障检测研究中,使其比传统的检测系统具有更高的准确性^[7]。

在相关研究中,诸多学者认为深度学习在智慧校园建设中有着重要作用^[8],现有研究主要关注智慧校园的网络安全和电力负荷问题。刘诗鹏在研究智慧校园网络入侵远程检测时,基于遗传算法和 BP 神经网络,构建了一种 PCA-GA-BP 模型,简化了检测流程,提高了检测速度^[9]。孙颖一在研究电力负荷时,将变分模态分解(VMD)算法和 LSTM 神经网络结合,构建了一种短期电力负荷检测模型,为校园电力维护和调度提供保证^[10]。但是深度学习在有关智慧校园电力设备故障检测中的运用相对较少,有学者发现其对于提升智慧校园运维效率比较重要^[11],但并未给出解决方案;另有学者发现在智慧校园电力设备故障检测中使用 BP 神经网络,可以提高检测的准确率并简化检测流程^[12]。但是 BP 神经网络存在着过拟合、学习率低等问题,为了解决此类问题,并进一步提高智慧校园电力设备故障检测的精度,本文进行以下研究。

1 模型描述

本文基于主成分分析(PCA)方法和深度学习神经网络构建了一种智慧校园电力设备故障检测系统。主要由确定主成分、提取特征和特征处理三部分构成。首先,使用 PCA 方法判断数据的主成分,使用 LSTM 神经网络进行特征提取,接着使用 AE 神经网络进行数据处理和输出,最后基于 Adaboost 算法进行微调。完成上述步骤之后,利用这一系统对电力设备参数进行训练,根据所得结果完成智慧校园电力设备故障检测的全过程。具体流程如图 1 所示。

2 模型步骤

2.1 主成分分析

当智慧校园的电力设备处于正常运行状态时,系统采集性能数据,所有的数据都应处于正常状态;当有电力设备出现故障时,电力设备系统中的数据就会出现异常,需要根据不同的设备进行计算,由于采集到的数据一般为高维数据,需要采用 PCA 进行降维,具体如式(1)所示:

$$y_a = \frac{x - x_a}{z_a} \quad (1)$$

式中, y_a 为电力系统中存在的故障样本数据, x 为电力设备正常运行时的数据, x_a 为故障情况下的取值, z_a 为不同 x_a 之间的标准差值。

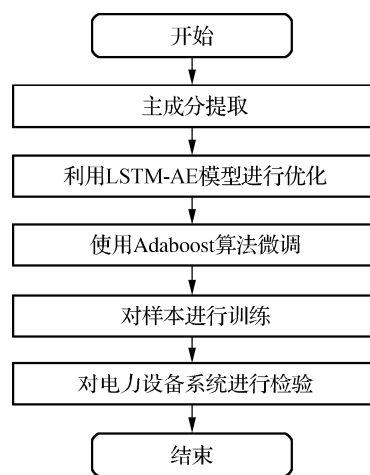


图 1 智慧校园电力设备故障检测系统的模型

通过特征值计算方法,在计算出 z_a 的特征值 λ_{z_a} 的同时计算出各个特征值的方差贡献率。根据 λ_{z_a} 的大小进行排序,当方差贡献率的值大于 100% 时排序停止,此时已经排序的特征值对应的故障样本 y_a 的集合 Y 就是选取的主成分,将 Y 作为下一步的输入。

2.2 特征提取

本文使用 LSTM 神经网络提取特征。LSTM 神经网络主要由遗忘层、输入层、细胞状态和输出层构成,在提取特征时公式如下:

$$r_l = s(\mathbf{W}_L \otimes Y + p_r) \quad (\text{遗忘层}) \quad (2)$$

$$c_l = s(\mathbf{W}_L \otimes Y + p_c) \quad (\text{输入层}) \quad (3)$$

$$b_l = r_l \otimes Y + c_l \otimes s(\mathbf{W}_L \otimes Y + p_b) \quad (\text{细胞状态}) \quad (4)$$

$$\omega_l = s(\mathbf{W}_L \otimes Y + p_w) \quad (\text{输出层}) \quad (5)$$

输出结果为:

$$h_l = \omega_l \otimes s(b_l) \quad (6)$$

式(2)~式(5)中, r 、 c 、 b 、 ω 分别代表遗忘层、输入层、细胞状态和输出层在各个节点的状态,其中 r_l 、 c_l 、 b_l 、 ω_l 分别代表当前的第 l 个样本的相应神经元在遗忘层、输入层、细胞状态、输出层时的状态;将 \mathbf{W}_L 设为 LSTM 神经网络的总体权重矩阵,将 p_r 、 p_c 、 p_b 、 p_w 分别设为遗忘层、输入层、细胞状态和输出层的偏置; $s(\cdot)$ 表示 sigmoid 激活函数;第 l 个样本的输出结果表示为 h_l 。

将某一时刻的测量数据代入输入门,并将结果代入激活函数;随后将细胞状态的数据代入遗忘层,将激活函数结果代入其中,得到这一时刻 LSTM 神经元的输出,并将此结果作为下一时刻 LSTM 神经元的输入。传递过程经过所有 LSTM 神经元时结束,最终得到的 h_l 为下一步的输入。

2.3 特征处理

本文使用 AE 神经网络进行特征处理。AE 神经网络由编码器和解码器两个部分构成,其原理是将数据导入编码器部分的输入层,经过分析将数据输出至编码器的隐藏层,随后将隐藏层中的数据导入解码器,由解码器分析后,将隐藏层导入的数据进行重塑后输出^[13]。该步骤的本质是将经编码和激活函数后的非线性结果再经权重、损失函数等进行解码,达到结果重构的目的,并以此进行输出。同样使用 sigmoid 激活函数作为自编码网络的激活函数,用 $s(\cdot)$ 表示。

输出至隐藏层的公式如下:

$$q_l = s(\mathbf{W}_e h_l + p_e) \quad (7)$$

式中, \mathbf{W}_e 代表编码器的权重, p_e 代表编码器的偏置。

将隐藏层计算结果 q_l 导入解码器,具体公式如下:

$$\hat{E}_l = s(\mathbf{W}_d q_l + p_d) \quad (8)$$

式中, \hat{E} 代表导入至解码器后的输出结果, \mathbf{W}_d 代表编码器的权重, p_d 代表编码器的偏置。

为了减少 AE 神经网络的误差,非常有必要设置损失函数,具体如下:

$$J = \frac{1}{2n} \sum_{i=1}^n (\hat{E}_i - h_i) \quad (9)$$

式中, n 表示电力设备样本的总数。

2.4 输出结果优化

为了减小 AE 神经网络运行过程中出现的局部最小值,解决收敛难以达到全局最优的缺点,本文使用 Adaboost 算法对输出结果进行微调。Adaboost 算法是一种被广泛使用的迭代学习算法^[14],可以通过赋予权重值来增强算法的准确性,并在此基础上较少拟合。将神经元及其对应的输出值作为输入的集合,并对其进行权重化,计算样本的误差、误差率和平均误差,最后更新权重值进行微调。

数据集的表现形式如下:

$$T = \{(u_1, v_1), (u_2, v_2), \dots, (u_l, v_l), \dots, (u_n, v_n)\} \quad (10)$$

式中, T 为 u_l 和 v_l 组成的集合, u_l 代表神经元, v_l 代表神经元对应的输出值。

为了进行循环, 将集合 T 进行权重化, 得到权重化后的集合 T_w , 公式如下:

$$T_w = T * \frac{1}{n} \quad (11)$$

所得结果的误差最大值的计算公式如下:

$$O_l = \max_i (v_i - s(u_i)) \quad (i=1, 2, \dots, n) \quad (12)$$

每个神经元之间的相对误差的计算公式如下:

$$O_{xl} = \frac{(v_l - s(u_l))}{O_l} \quad (13)$$

整体计算误差率的计算公式如下:

$$O_p = \sum_{l=1}^n \frac{1}{l} O_{xl} \quad (14)$$

式(12)~(14)中, 误差最大值记为 O_l , 相对误差记为 O_{xl} , 误差率记为 O_p , n 为电力设备样本数。

根据误差最大值、相对误差和误差率更新的权重值 W_g 计算公式如下:

$$W_g = \frac{1}{l * O_l} \left(\frac{1 - O_p}{O_p} \right)^{O_{xl} - 1} \quad (15)$$

2.5 模型构建

综上, 本文所构建的智慧校园电力设备故障检测的具体步骤如图 2 所示。

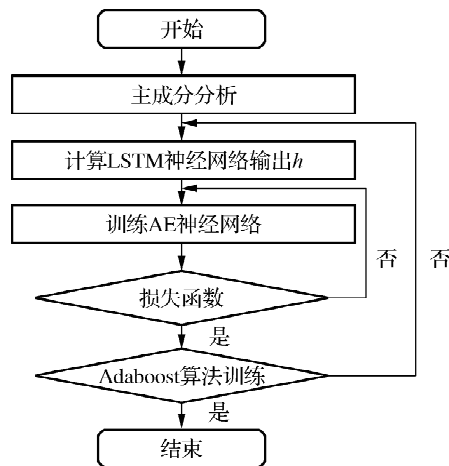


图 2 智慧校园电力设备故障检测的具体步骤

3 仿真实验及性能分析

3.1 环境设置与计算方法

本文通过 MATLAB 构建智慧校园电力设备故障检测模型, 使用该模型构建人工神经网络(ANN)、BP 神经网络、AE 神经网络, 与本文算法进行对比。

本文以收敛次数和收敛速度为基准, 以经常使用的学习率作为指标进行测试, 具体结果如表 1 所示。一般情况下, 学习率的取值为 $[0.01, 0.8]$ 。由表 1 可以看出, 在学习率为 0.01 时, 算法的收敛次数最高, 收敛速度最快。

经测试, 在迭代次数和损失函数相同的情况下, 不同隐藏层数和神经元数的损失值如表 2 所示。由表 2 可知, 神经元数为 11、隐藏层数为 5 时, AE 神经网络的损失值最少。

表 1 LSTM 学习率测试结果

学习率	收敛次数	收敛速度
0.6	112	较慢
0.5	141	较慢
0.1	168	较慢
0.01	197	较快

表 2 AE 神经网络损失值

神经元数	隐藏层数	迭代次数	损失值
15	10	1 000	0.76
12	6	1 000	0.31
11	5	1 000	0.25
11	3	1 000	1.04

结合表 1 和表 2 的结果,本文选用收敛速度最快、收敛次数最高和损失值最小时的数值作为仿真实验的基本参数,LSTM 神经网络和 AE 神经网络的部分参数如表 3 所示。

表 3 神经网络参数

项目	数值	项目	数值
神经元数	11	神经元状态大小	64
输入层维度	3	迭代次数	1 000
输出层维度	1	学习率	0.01
隐藏层数	5		

本文模型的评价指标为平均绝对百分比误差(MAPE)、百分比均方根误差(RMSE)、平均绝对误差(MAE)和均方误差(MSE)。在进行评价之前需对测量值和实际值进行归一化处理,具体如下:

$$g_{\text{norm}} = \frac{g - g_{\min}}{g_{\max} - g_{\min}} \quad (16)$$

式中, g 表示某一参数, g_{\max} 、 g_{\min} 、 g_{norm} 分别表示这一参数的最大值、最小值和归一化值。

MAPE、RMSE、MAE 和 MSE 越小,表示模型的精确度越好,具体计算公式如下:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{m}_i - m_i}{m_i} \right| \times 100\% \quad (17)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{\hat{m}_i - m_i}{m_i} \right)^2} \times 100\% \quad (18)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{m}_i - m_i| \times 100\% \quad (19)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{m}_i - m_i)^2 \times 100\% \quad (20)$$

式中, n 为电力设备数量, m_i 表示当前数据在第 i 个设备的实际值, \hat{m}_i 表示其在第 i 个设备的测量值。

3.2 结果与分析

通过迭代和实验后,ANN、BP 神经网络、AE 神经网络与本文算法在 MAPE、RMSE、MAE 和 MSE 上的性能对比如表 4 所示,LSTM-AE 表示本文构建的由 LSTM 神经网络和 AE 神经网络组成的模型。

表 4 四种模型的性能结果

模型	MAPE/%	RMSE/%	MAE/%	MSE/%
ANN	6.53	18.56	10.51	14.86
BP 神经网络	1.16	9.84	8.31	9.42
AE 神经网络	1.13	8.13	6.54	6.71
LSTM-AE	0.49	3.89	4.97	5.34

由表 4 可以看出,在 MAPE、RMSE、MAE 和 MSE 指标方面,LSTM-AE 模型的值均最低,与其他三个神经网络的最大值分别相差 6.04、14.67、5.54 和 9.52 个百分点。由此可见本文构建的智慧校园电力设备故障检测模型有着更高的精度。

与 Adaboost 算法作用相同的算法有支持向量机(SVM)和随机森林(RF)等,将本文构建的由 LSTM

神经网络、AE 神经网络和 Adaboost 算法组成的 LSTM-AE-Ada 模型中的 Adaboost 算法替换为 SVM 和 RF 算法后进行测试,MAPE、RMSE、MAE 和 MSE 数据如表 5 所示。由表 5 可以看出,相较于选用 SVM 和 RF 算法,选用 Adaboost 算法的本文模型具有更低的 MAPE、RMSE、MAE 和 MSE,说明本文所构建的 LSTM-AE-Ada 智慧校园电力设备故障检测系统具有更高的精度。

表 5 三种复合模型的性能结果

模型	MAPE/%	RMSE/%	MAE/%	MSE/%
LSTM-AE-SVM	0.41	3.23	4.56	5.19
LSTM-AE-RF	0.35	3.12	4.33	4.99
LSTM-AE-Ada	0.29	2.86	3.94	3.85

4 结 语

本文构建了一种基于深度学习的智慧校园电力设备故障检测模型,利用主成分分析法提取数据中的主成分,然后使用 LSTM 神经网络对数据中的特征进行提取,使用 AE 神经网络对数据进行分析、重塑后得到最终的数据输出,最后用 Adaboost 算法进行数据微调。本文构建的模型相较于其他神经网络模型在一定程度上提高了检测的精度,取得了较好的效果,可以应用于智慧校园的运行与维护中。随着人工智能的不断发展,在下一步研究中可以关注智能语义和深度学习神经网络在智慧校园运行与维护中的应用,可以将故障原因和结果的分类作为智慧校园电力设备故障检测下一步研究的方向。

参考文献:

- [1] 王涛.“互联网+”时代智慧化校园建设的分析[J].教育现代化,2016,3(27):200-201,204
- [2] 严利军,周欣荣,牛佳荣,等.基于嵌入式设备高效卷积神经网络的电力设备检测分析[J].信息与电脑(理论版),2021,33(23):39-41
- [3] 金晓航,许壮伟,孙毅,等.基于 SCADA 数据分析和稀疏自编码神经网络的风电机组在线运行状态监测[J].太阳能学报,2021,42(6):321-328
- [4] 柳青秀,马红占,褚学宁,等.基于长短时记忆—自编码神经网络的风电机组性能评估及异常检测[J].计算机集成制造系统,2019,25(12):3209-3219
- [5] 李晓宇,李书芳,李文启,等.基于堆稀疏自编码神经网络的电网安全预判[J].北京邮电大学学报,2017,40(6):43-49
- [6] 沈杰.基于堆栈自编码神经网络的自适应分类算法在变压器故障诊断中的应用[D].兰州:兰州理工大学,2020
- [7] 游仕豪,郑阳,闫懂林,等.基于 CEEMDAN-ELM-Adaboost 的水电机组故障诊断[J/OL].中国农村水利水电(2022-04-08)[2022-04-19].<http://kns.cnki.net/kcms/detail/42.1419.TV.20220408.0913.004.html>
- [8] 李刚.双一流背景下应用型院校智慧化校园建设 4.0 研究[J].云南科技管理,2020,33(5):37-43
- [9] 刘诗鹏.基于物联网的智慧校园网络入侵远程检测研究[J].自动化技术与应用,2022,41(2):64-68
- [10] 孙颖一.面向智慧校园的短期电力负荷预测研究[D].湘潭:湘潭大学,2021
- [11] 金鑫鑫.一种智慧校园运维平台的构建研究[J].德州学院学报,2017,33(2):58-62
- [12] 贾爽,李进,金鑫鑫,等.人工智能技术在智慧校园运维中的应用[J].贵阳学院学报(自然科学版),2019,14(4):53-55,70
- [13] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986,323(6088):533-536
- [14] AN X B, HU C, LI Z H, et al. Decentralized Adaboost algorithm over sensor networks[J]. Neurocomputing, 2022,479:37-46

(责任编辑:湛 江)