

一种基于TCN的核电蓄电池异常检测方法

李吉生¹, 于艇², 岳鹏³, 周剑秋³, 徐鹏³

(1. 大亚湾核电运营管理有限公司, 广东深圳 518124;

2. 深圳中广核工程设计有限公司, 广东深圳 518172;

3. 南京工业大学能源科学与工程学院, 江苏南京 211816)

摘要: 在核电站的生产与运营中, 铅酸蓄电池组发挥着至关重要的作用, 能在反应堆正常关闭或发生紧急情况时关键阀门, 保障关键设备仪表及控制系统正常运作。由于蓄电池长期运行会导致可靠性下降, 但定期更换蓄电池组的维护成本较高。为此, 提出基于时间卷积网络的异常检测方法。首先, 结合大核深度卷积结构与深度逐点卷积, 对历史电压数据进行长跨度的特征提取; 其次, 加入残差卷积层跨层连接特征, 以加快模型训练速度, 避免层数过深造成的梯度爆炸等问题。实验表明, 当卷积核大小为2 048时, 模型性能最优, 准确率、精确率、召回率和F1值分别为96.5%、93.5%、80.2%、86.3%, 可并行处理长时间窗口内的电池关键数据, 准确识别异常电池进行单节更换, 实现了降低维护成本、提升经济效益的目的。

关键词: 蓄电池; 异常检测; 机器学习; 工业安全

DOI: 10. 11907/rjdk. 241190

中图分类号: TP393

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)005-0040-06



An Anomaly Detection Method for Nuclear Power Storage Batteries Based on TCN

LI Jisheng¹, YU Ting², YUE Peng³, ZHOU Jianqiu³, XU Peng³

(1. Daya Bay Nuclear Power Operation and Management Co., Ltd., Shenzhen 518124, China;

2. China Nuclear Power Engineering Company, Ltd., Shenzhen 518172, China;

3. School of Energy Science and Engineering, Nanjing Tech University, Nanjing 211816, China)

Abstract: In the production and operation of nuclear power plants, lead-acid battery packs play a vital role, which can ensure the normal operation of key equipment instruments and control systems when the reactor is shut down normally or in the event of an emergency. Due to the long-term operation of the battery, the reliability will be reduced, but the maintenance cost of replacing the battery pack regularly is high. Therefore, an anomaly detection method based on temporal convolutional network was proposed. Firstly, the long-span feature extraction of historical voltage data was carried out by combining the large-kernel depth convolution structure and the deep point-by-point convolution. Secondly, the cross-layer connection feature of the residual convolutional layer is added to speed up the model training speed and avoid the gradient explosion caused by too deep layers. Experiments show that when the size of the convolutional kernel is 2 048, the model has the best performance, with the accuracy, precision, recall and F1 values of 96.5%, 93.5%, 80.2% and 86.3%, respectively, which can process the key data of the battery in the long-term window in parallel, accurately identify the abnormal battery for single-cell replacement, so as to reduce the maintenance cost and improve the economic benefit.

Key Words: lead-acid batteries; anomaly detection; machine learning; industrial safety

收稿日期: 2024-03-01

扫描二维码阅读全文:



基金项目: 江苏省科技厅前瞻性联合研究项目(BY2016005); 江苏省自然科学基金项目(BK20190374); 中央军委装备发展部装备预先研究项目(61407200302)

作者简介: 李吉生(1975-), 男, 大亚湾核电运营管理有限公司高级工程师, 研究方向为电气系统设备改进; 于艇(1986-), 男, 硕士, 深圳中广核工程设计有限公司高级主管设计师, 研究方向为核电厂电气系统设计; 岳鹏(1996-), 男, 硕士, 南京工业大学能源科学与工程学院科研助理, 研究方向为电气系统设备改进; 周剑秋(1972-), 男, 博士, 南京工业大学能源科学与工程学院教授、博士生导师, 研究方向为先进能源材料及装备等; 徐鹏(1986-), 男, 博士, 南京工业大学能源科学与工程学院教授, 研究方向为先进能源系统及装备运行安全。

0 引言

在当今能源行业中,核电站扮演着至关重要的角色,不仅提供了大规模、稳定的电力供应,也是实现清洁能源目标的关键组成部分^[1]。在核电站的多个关键组件中,蓄电池组可提供不间断的电源,既保障了核电站关键设备在计划停堆和特殊情况下的安全运行,还确保了在电网断电或其他紧急情况下,控制系统、安全系统和关键仪表能持续运作。为此,蓄电池的可靠性问题成为一个不容忽视的问题,特别是其在长期运行后可能发生安全隐患^[2]。

在此背景下,及时准确地根据长期电压数据监测与分类蓄电池的异常至关重要。尽管,传统方法在蓄电池电压监测方面发挥了作用,但在处理长期数据、响应速度和检测准确性上存在一定的局限性^[3,4]。为此,本文引入一种基于时间卷积网络(Temporal Convolutional Network, TCN)的蓄电池电压异常检测方法,在处理长时间序列数据方面相较于传统方法更优秀,特别在高效处理和分析长期历史数据方面优势更明显^[5]。同时,TCN相较于循环神经网络和基于注意力机制的时序任务模型而言,卷积网络能利用并行运算来提升效率,并通过修改卷积核的扩张参数有效捕捉长序列的变化^[6,7]。

近年来,随着深度学习领域在时间序列任务上的深入探索,从早期的循环神经网络,到现在基于注意力机制的各种变体网络与回归多层感知机的时序编码网络。这些后期提出的网络在多项公共数据集上均取得了显著成绩^[8]。公共数据集是一种公开的、包含工业环境下多种数据的数据集,例如时序数据包括风力发电、旅客、河流水位和健康等数据^[9,10]。然而,在现实应用中,针对蓄电池电压这种不间断采样、变化量小且数据量大的数据,尚未有研究提出基于深度学习的蓄电池电压长序列故障检测方法。

为此,本文利用时间卷积网络增强铅酸蓄电池长序列数据中电压异常的监测能力,进而提升核电站运行的安全性和可靠性。首先,详细介绍研究方法、实验设计、结果分析及本文研究的实际应用价值和潜在影响;其次,通过实验证明本文方法在核电站铅酸蓄电池电压异常检测方面的性能和安全性。

2 本文方法

2.1 模型整体框架

本文方法基于电池电压历史数据进行训练,以识别潜在的故障或异常状态,整体框架如图1所示。首先,通过一个由多通道卷积层组成的嵌入层,将蓄电池电压的历史数据转换为更适合模型处理的多维格式^[11]。其次,数据通过一系列TCN块进行处理,每个块由深度逐点卷积(Dep-

thwise convolution, DWConv)和卷积前馈神经网络(Convolutional feedforward network, ConvFFN)组成,负责提取时间序列中的时间依赖特征,并进行特征转换^[12,13]。最后,由一个全连接层(Fully connect layer, FC)整合最终的特征,并输出判定结果。在TCN块中,大核DWConv和ConvFFN确保了模型能独立学习大尺度时间步的特征表示,并捕获跨时间步的依赖关系。本文方法的核心优势在于:既能有效处理长序列数据,又能通过深度学习模型强大的特征提取能力准确识别电压异常,为判断核电蓄电池的健康提供了一种高效的预警机制。




Fig. 1 Battery voltage anomaly detection method based on TCN

图1 基于TCN的蓄电池电压异常检测方法

2.2 时间卷积概念

时间卷积网络及其变体在时间序列分析中应用广泛。首先,在卷积操作中适当的添加因果卷积建模时间序列中的因果关系,以确保输出序列的时间索引与输入序列相对应;其次,使用扩张卷积增加模型感受野,以捕捉更长范围内的时间依赖关系^[14-17]。其中,扩张卷积在卷积核的元素之间插入空格,以增加卷积核覆盖的时间跨度,如图2所示。由此可见,在不额外增加参数的情况下,随着扩张(Dilation)增大,网络对时序数据特征的感受野也会增大^[18]。




Fig. 2 TCN expansion convolution

图2 TCN扩张卷积

此外,TCN网络通过残差连接来训练更深层次的网络,可避免在训练过程中出现的梯度消失或爆炸问题^[19]。由于每个卷积层的扩张因子不同,因此在构建网络结构时可堆叠多个卷积层来构建深度网络,以学习到不同时间尺

度上的特征,如图3所示。由此可见,加入残差连接后,可有效提升模型训练效果且无需额外增加运算开销。




Fig. 3 Residual connection convolutional layer

图3 残差连接卷积层

然而,TCN面临的一个主要挑战是感受野(Effective Receptive Field, ERF)受限,从而导致该方法在捕获长时间依赖性方面的能力较差。为此,提出了MICN、TimesNet等一系列新模型,通过不同的结构设计来扩充模型的感受野,解决长期序列预测中的复杂度问题^[20,21]。

随着注意力模型Transformer的发展,越来越多研究提出了N-BEATS、informer等基于注意力机制的时序任务网络,虽然此类模型捕捉序列历史信息的编码能力优于循环神经网络,但运算开销较大、训练相对困难,长期时序相关任务在720步左右,无法满足实时性需求^[22,23]。

2.3 深度逐点卷积

在图像任务领域,深度卷积(Depthwise Convolution, DWConv)和逐点卷积(Pointwise Convolution, PWConv)的目的是在有限的计算参数下提升模型特征提取能力。因此,将多通道卷积相加得到特征图,改进为先通过通道独立卷积,再利用逐点卷积得到特征图^[24]。由于在蓄电池历史采样电压数据中,共同学习长序列数据的跨时间单变量的依赖关系较难,因此通过传统的DWConv处理混合变量维度的信息不合适。为此,本文将传统的DWConv,改为先通过大卷积核处理数据,再对特征图进行逐点卷积运算,以独立学习每个长序列单变量时间序列的时间依赖性,如图4所示。其中,大卷积核可增加模型感受野,提升时间建模能力,既能有效划分时间信息和单变量特征增强的相关信息,又能扩展单变量的数据维度,使长序列时间数据任务更容易被模型学习,从而在一定程度上减少了模型计算复杂性。




Fig. 4 Large kernel depthwise separable convolution

图4 大核深度逐点卷积

此外,本文所提方法中的逐点卷积(PWConv)由卷积前馈神经网络(Convolutional feedforward network, ConvFFN)组成。ConvFFN是注意力机制模型(Transformer)架构的变体网络,旨在提升模型处理序列数据的效率和效果。在标准的Transformer模型中,前馈网络(FFN)通常由两层全连接层组成,用于处理自注意力机制的特征输出。在ConvFFN中,参数量较大的注意力机制被替换为适用性更好的卷积神经网络层,使模型能更有效捕捉序列数据中的局部特征,原因为卷积层更擅长处理空间或时间上的局部关联性。

3 实验环境与数据集

3.1 实验环境

本文方法基于Pytorch(版本1.12.1)实现,并在Intel(R) Xeon(R) Gold 6226R、NVIDIA GeForce GTX 3090的服务器上运行,操作系统为Ubuntu 20.04 LTS server。

3.2 数据采集与预处理

本文数据来源于某核电厂三回路机房中100组蓄电池(专家通过专业设备检测得到14组为故障电池,86组为健康电池),连续15天每秒采集一次工作电压,单位为伏(V)。由于生产环境不可控,各采集时间点均存在不同程度的数据缺失。为此,首先将5 min内采集成功的数据保留一组,通过聚合数据操作来提升样本质量;其次按照同等大小步数的滑动窗口分块原始数据,并与故障、健康电池的标签保存在一起;最后去掉蓄电池电压数据最后的一个窗口,如图5所示^[25]。例如当窗口为2 048时,去掉滑窗后尾部不足一个窗口的2 047个时间步,可获得19 834组无编号,每组包含2 048个时间步的蓄电池历史电压数据,然后以7:2:1的比例划分训练集、验证集和测试集。




Fig. 5 Preprocessing of voltage data

图5 电压数据预处理

3.3 蓄电池电压曲线分析

图6(彩图扫OSID码可见)为所有编号设备的蓄电池电压数据,不同颜色代表了不同编号的蓄电池,时间跨度为14天。由此可见,相同型号的电池工作电压略有不同,最高误差约为0.7 V,原因包括:电池自放电速率差异、电池老化程度、安装差异导致不同的充放电历史、生

产过程中的细微差异、温度对电池性能的影响及充电状态不同。

观察图 6 曲线可知,绝大多数电池电压波动特征并不明显,原因为核电蓄电池充放具有高度安全性和自身物理特性造成,从而对本文方法提出更高的要求。




Fig. 6 Battery voltage data
图 6 蓄电池电压数据

4 实验结果与分析

4.1 实验参数与过程

本文根据所提模型在验证集上的训练效果和计算开销设置参数。具体为,总训练迭代次数(epoch)设置为 100 次,以保证模型有效收敛;损失函数为二元交叉熵损失函数(Binary cross-entropy loss, BSELoss);每段输入时间段步数为 2 048,网络的 embedding 层输出维度为 2 048;卷积核大小为 8;stride 为 4;隐藏层中的大核 DWConv 卷积核大小为 51×51;TCN 模块数量为 2。

BSELoss 函数一般用于衡量模型预测的概率分布与真实标签之间的差异,主要通过独立计算每个样本的损失以更好地分离出故障样本,因此在处理不平衡数据集更有效,具体计算公式如式(1)所示。实验结果如图 1 所示。

$$BSELoss = -\frac{1}{N} \sum_{i=1}^N y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i)) \quad (1)$$

式中:每次迭代的 batchsize=N; y_i 为模型的单次输出; $p(y_i)$ 为输出属于 y_i 标签的概率。

由图 7 可见,随着迭代次数增加,损失逐渐下降直至模型收敛。

4.2 长序列故障分类实验

本文通过准确率、精确度、召回率和 F1 值来评估和比较模型性能。其中,准确率是指所有被模型正确分类的样本占总样本数的比例;精确率关注模型预测为正类中实际为正类的样本比例,反映了模型预测正类的准确性;召回率衡量所有实际为正的样本中,模型能正确预测的比例,反映了模型对正类样本的覆盖能力;F1 值是精确率与召回率的平衡值。




Fig. 7 Training process
图 7 训练过程

表 1 为蓄电池电压长序列实验正常与故障分类结果混淆矩阵。由此可知,本文模型准确度较高,能在大多数情况下正确分类样本。具体的,模型在正类样本的预测上表现较好,正确识别了大量正类样本(1 697 个),但也存在一定数量的正类被误判为负类(15 个)及负类被误判为正类(54 个)的现象存在,原因为较长历史的无编号设备电压数据特征存在一定相似性,或本文模型对某些情况的敏感度不足。同时,本文模型精确度为 0.965、召回率为 0.802,均处于较高水平,在识别正类样本的效率和有效性上存在明显优势;模型 F1 值为 0.863,在精确度与召回率之间达到了较好的平衡。

Table 1 Confusion matrix

表 1 混淆矩阵

标签	正	负
正	1 697	15
负	54	219

综上,本文模型性能较好,但仍存在许多提升空间,例如在减少误分类方面可调整模型参数、改善特征选择或考虑更复杂的网络结构。此外,深入分析样本来寻找误判的原因,也是提升模型性能的关键。

图 8 为无编号蓄电池长序列电压二分类实验结果,ROC 曲线下的面积(AUC 值)达到了 0.97,证明了模型区分正负类样本的能力较强。




Fig. 8 ROC curve
图 8 ROC 曲线图

在理想情况下,ROC 曲线会尽可能靠近左上角,表明模型能以较低的假正率实现较高的真正率。本文实验所得曲线与左上角的接近程度,表明了所提模型在保持较低假正率的同时真正率较高,即能有效区分不同类别的样本。此外,由于 ROC 曲线始终保持在对角线之上,且大部分时间都紧靠左边界和上边界,因此认为模型在各个阈值下均能保持较高的分类性能。

综上,本文所提方法在核电蓄电池长序列历史电压二分类任务中性能优越,具有一定的实用价值,未来可进一步探讨模型在不同操作点的表现,以及在实际应用中的稳定性和可靠性。

4.2 多尺度卷积比较

通常情况下,历史数据越长、采集精度和采集频率越高的数据蕴含的信息量越大。为了证明本文方法中大核时间卷积的有效性,将不同大小的卷积核在同一数据集下进行比较,实验结果如表 2 所示。由此可知,随着卷积核大小增加,模型准确率、精确率、召回率和 F1 值均有所提升。具体而言,当卷积核大小为 2 048 时,模型性能最优,准确率、精确率、召回率和 F1 值分别为 96.5%、93.5%、80.2%、86.3%;当卷积核大小为 128 时,准确率、精确率、召回率和 F1 值分别为 89.2%、96.0%、22.4% 和 36.3%。

Table 2 Comparative experimental results

表 2 比较实验结果

卷积核大小	准确率	精确率	召回率	F1 分数
2 048	0.965	0.935	0.802	0.863
1 536	0.901	0.675	0.599	0.635
1 024	0.844	0.445	0.292	0.353
512	0.910	0.695	0.562	0.622
256	0.889	1.000	0.255	0.407
128	0.892	0.960	0.224	0.363

对于 256 和 128 尺寸的卷积核,模型在某些性能指标上表现较好,例如 256 尺寸的卷积核准确率为 1.000,证明了小尺寸的卷积核能捕捉更细粒度的特征,在预测正类(即故障状态)情况时可精准识别正类样本,但模型可能更容易专注局部特征,或发生过拟合现象。较大的卷积核则更适合捕获更广泛的上下文信息,在提升准确率的同时降低误报率,实现了降低更换电池频率的维护目标。

综上,较大的卷积核尺寸因其具有较宽的视野,在捕捉全局特征方面更有效,能在维持召回率的同时保持较高的准确率。然而,在特定的故障分类任务中,局部特征可能包含对分类决策至关重要的细节信息,因此通过大尺寸卷积核与长时间序列的组合,能充分利用高质量的数据,降低蓄电池更换维护成本,提高经济效益。

5 结语

由于长期运行后的蓄电池可靠性会逐渐下降,但定期

更换蓄电池组会使维护成本急剧上升。为此,本文提出基于大核时间卷积网络的核电蓄电池电压异常检测方法。首先,结合大核深度卷积结构与深度逐点卷积,使模型对历史电压数据进行长跨度的特征提取;其次,加入残差卷积层跨层连接特征提升模型训练速度,避免层数过深造成的梯度爆炸等问题。

实验表明,本文模型的准确率、精确率、召回率和 F1 值较高,在处理核电蓄电池长序列电压数据时具有明显优势,为核电站安全运营提供了强有力的技术支撑;AUC 值高达 0.97,证明了该方法在区分电压正常与异常状态上的良好性能。

未来,将进一步提升模型的泛化能力和实时监测能力,使模型更好地适应核电站不断变化的运营环境。同时,考虑到蓄电池电压数据的特殊性和关键性,将探索更多数据融合技术和先进算法,取得更高的检测精度和更快的响应速度,以期在核电站等关键基础设施的安全监控领域发挥作用,为国家能源安全和清洁能源的发展目标贡献力量。

参考文献:

- [1] VOUMIK L C, ISLAM M A, RAY S, et al. CO₂ emissions from renewable and non-renewable electricity generation sources in the G7 countries: static and dynamic panel assessment[J]. *Energies*, 2023, 16(3): 1044.
- [2] DENG L, RUAN H, XU J, et al. Review of on-line monitoring and health assessment techniques for valve-controlled sealed lead-acid batteries[C]// 8th Asia Conference on Power and Electrical Engineering, 2023: 2180–2186.
- [3] HUANG C, LI N. Fast health state estimation of lead-acid batteries based on multi-time constant current charging curve[J]. *Electronics*, 2023, 12(21): 4552.
- [4] ZHANG Y, ZHANG Y, WANG P, et al. Monitoring and evaluation of the status of motor-operated valves in nuclear power plants[C]// 5th International Conference on Energy, Power and Grid, 2023: 12090.
- [5] HEWAGE P, BEHERA A, TROVATI M, et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station[J]. *Soft Computing*, 2020, 24: 16453–16482.
- [6] KOUTNIK J, GREFF K, GOMEZ F, et al. A clockwork RNN[C]// International Conference on Machine Learning, 2014: 1863–1871.
- [7] HUANG X, TANG J, SHEN Y. Long time series of ocean wave prediction based on PatchTST model[J]. *Ocean Engineering*, 2024, 301: 117572.
- [8] DAS A, KONG W, LEACH A, et al. Long-term forecasting with TiDE: time-series dense encoder[DB/OL]. <https://arxiv.org/abs/2304.08424>.
- [9] ZHANG R, CHEN J, SONG Y, et al. An effective transformation-encoding-attention framework for multivariate time series anomaly detection in IoT environment [EB/OL]. <https://link.springer.com/article/10.1007/s11036-023-02204-9>.
- [10] JI Z, GONG J, FENG J. A novel deep learning approach for anomaly detection of time series data[EB/OL]. <https://onlinelibrary.wiley.com/doi/10.1155/2021/6636270>.

- [11] CUI P, WANG X, PEI J, et al. A survey on network embedding[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 31(5): 833–852.
- [12] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251–1258.
- [13] YIN D, ZHAO Z, TANG C, et al. TridentSE: guiding speech enhancement with 32 global tokens[DB/OL]. <https://arxiv.org/abs/2210.12995>.
- [14] MA X N, ZHAO S J, LUAN H N, et al. Rolling bearing fault diagnosis method based on MTCN[J]. Software Guide, 2023, 22(3): 96–102.
马新娜,赵尚军,梁浩楠,等. 基于MTCN的滚动轴承故障诊断方法研究[J]. 软件导刊, 2023, 22(3): 96–102.
- [15] BRAZIL T J. Causal-convolution—a new method for the transient analysis of linear systems at microwave frequencies[J]. IEEE Transactions on Microwave Theory and Techniques, 1995, 43(2): 315–323.
- [16] LIN P, HE R H. An attention-based model for time-domain frequency speech enhancement[J]. Software Guide, 2024, 23(1): 63–68.
林攀,何儒汉. 基于注意力机制的时频域语音增强模型[J]. 软件导刊, 2024, 23(1): 63–68.
- [17] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[DB/OL]. <https://arxiv.org/abs/1511.07122>.
- [18] SHI A W, ZHANG Y X, HAN C, et al. Research on cluster resource prediction based on CEEMDAN-SE-TCN[J]. Software Guide, 2023, 22(4): 43–47.
史爱武,张义欣,韩超,等. 基于CEEMDAN-SE-TCN的集群资源预测研究[J]. 软件导刊, 2023, 22(4): 43–47.
- [19] TARG S, ALMEIDA D, LYMAN K. Resnet in Resnet: generalizing residual architectures[DB/OL]. <https://arxiv.org/abs/1603.08029>.
- [20] WANG H, PENG J, HUANG F, et al. MICN: multi-scale local and global context modeling for long-term series forecasting[EB/OL]. <https://openreview.net/pdf?id=zt53IDUR1U>.
- [21] WU H, HU T, LIU Y, et al. TimesNet: temporal 2D-variation modeling for general time series analysis [DB/OL]. <https://arxiv.org/abs/2210.02186>.
- [22] ORESHKIN B N, CARPOV D, CHAPADOS N, et al. N-BEATS: neural basis expansion analysis for interpretable time series forecasting [DB/OL]. <https://arxiv.org/abs/1905.10437>.
- [23] ZHOU H, ZHANG S, PENG J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 11106–11115.
- [24] DOU H, ZHANG L M, HAN F, et al. Survey on convolutional neural network interpretability [J]. Journal of Software, 2023, 35(1): 159–184.
窦慧,张凌茗,韩峰,等. 卷积神经网络的可解释性研究综述[J]. 软件学报, 2023, 35(1): 159–184.
- [25] GUO J Y, GUO J Y, LI Y. Fault detection based on variable moving window KLPP[J]. Journal of Dalian Dalian Polytechnic University, 2023, 42(6): 463–468.
郭金玉,郭佳燕,李元. 基于可变滑动窗口 KLPP 的故障检测[J]. 大连工业大学学报, 2023, 42(6): 463–468.

(责任编辑:刘嘉文)