

基于CAE-XGBoost模型的 燃气调压器故障诊断研究

王 强¹, 李泽明¹, 周梦琪²

1.无锡华润燃气有限公司; 2.润智科技有限公司

摘 要: 燃气调压器是燃气输配系统中的关键设备, 其安全稳定运行一直受到广泛关注。本文提出了一种基于CAE-XGBoost的中低压调压器故障诊断方法。首先, 使用卷积自编码器(CAE)网络对调压器出口压力信号进行无监督学习, 在重构误差允许范围内, 通过编码器部分的输出, 提取出口压力信号的深层次特征; 再使用梯度提升集成学习模型(XGBoost)对提取的特征进行故障分类。使用121台在线调压器设备进行验证, 针对正常、内漏、喘振和关闭压力过高4种故障类型进行识别。结果表明, 基于CAE-XGBoost模型的故障识别准确率均达到95%以上, 验证了模型的有效性。

关 键 词: 燃气调压器; 卷积自编码器; XGBoost; 故障诊断

1 概述

燃气调压器在燃气输配系统中承担着压力调节的重要作用, 其运行状态直接影响到燃气供应的安全和

稳定。然而, 由于设备运行环境复杂, 燃气调压器在长期工作后可能会出现各种故障, 如阀门卡死、弹簧失效、膜片破裂等。因此, 对燃气调压器的故障进行及时准确的诊断, 对于保障燃气供应的安全和稳定具

5 结论

随着城市化进程加快以及燃气用户的不断增多, 燃气工程规模与数量持续扩大, 传统管理模式已难以满足需求, 信息化系统应用成为提升燃气工程管理水平必然选择。

在人员设备管理方面, 通过设置相应模块, 实现了对参建单位资质证书有效期的自动提醒、人员区域签到考勤以及设备检验周期提醒等功能, 便于规范管理。

在质量管理上, 建立施工过程工序报验控制流程以及焊接关键质量控制点的相关功能模块, 实现了影

像资料采集与质量隐患的信息化闭环管理, 有效解决焊接质量控制难点。

在成本管理模块中, 具备签证审批、结算及转资管控等功能, 有助于提升项目管理水平、实现项目转资提速及公司资产增值。

参考文献

- [1]蒋积雪,李燕云.燃气工程建设信息化管理系统研究与优化[J].越野世界,2024,19(14):167-168.
- [2]石阳,孙皓,詹一鸣,等.燃气工程项目管理中质量与安全的信息化管理[J].户外装备,2022(7):109-111.

[第一作者简介] 王强, 男, 硕士, 高级工程师, 主要从事燃气工程技术、城市燃气智能化研究工作。

有重要意义。

出口压力是监测调压器运行状态的重要指标,从出口压力信号中提取有效特征,以判别其健康状态,是燃气调压器故障诊断的主要研究内容。文献^[1]采用小波包分解技术,将调压器出口压力信号按频带分解,计算各频带信号能量占比,提取不同故障状态下信号特征,再使用BP神经网络对信号特征进行分类学习,有效识别出调压器3种运行状态。文献^[2]将经验模态分解和贝叶斯网络相结合,先通过经验模态分解法将出口压力信号分解为各IMF分量,利用频谱特征法和能量值法对各IMF分量进行阈值划分,提取故障特征,再使用贝叶斯网络计算部件故障概率,提高了故障识别准确率。这类方法往往依赖专家经验并需具备一定的信号处理知识,以设计特定的特征提取器,诊断效果很大程度受限特征提取器的设计。深度学习能够将样本数据经过多步非线性转换,自适应地学习得到更高层次、更抽象的特征表示,减少人为经验的依赖,被越来越多地应用到故障诊断领域^[3-4]。文献^[5]使用VAE-LSTM混合的无监督深度学习模型,避免了人工标注样本,实现异常监测,但未给出具体的故障类别。文献^[6]利用EMD进行特征提取并计算IMF分量能量矩,作为故障诊断模型的输入,综合对比了深度学习模型LSTM、DNN网络和机器学习模型SVM的诊断效果,证明了深度学习的优势。

本文采用卷积自编码器(Convolutional Auto-encoder, CAE)进行特征提取。CAE是一种深度神经网络,能够自适应地提取调压器出口压力信号的深层特征,无需依赖特定的专家经验;在故障分类器设计上,使用极端梯度提升(eXtreme gradient Boosting, XGBoost)分类算法^[7]。XGBoost是一种集成学习算法,具备高性能、可解释性强的优点,考虑到其参数对分类性能的影响,采用贝叶斯优化算法对XGBoost关键参数进行优化。基于CAE-XGBoost建立调压器故障诊断模型,以验证模型的有效性。

2 相关理论

2.1 卷积自编码器(CAE)

卷积自编码器是结合自编码器和卷积运算的无监督的神经网络学习算法,包括编码器和解码器两个部

分。编码器部分由卷积层和池化层堆叠而成,本文使用一维卷积运算,其运算过程如式(1)。

$$z_j^{l+1} = f(\sum_i x_i^l * w_{ij}^l + b_j^l) \quad (1)$$

其中,*为卷积核运算; x_i^l 为第 l 层的第 i 个卷积核输出; w_{ij}^l 和 b_j^l 为第 l 层第 i 个卷积核的权重与偏置; z_j^{l+1} 为第 $l+1$ 层第 j 个卷积核的输出; $f(\cdot)$ 为激活函数Sigmoid、ReLU等。

池化层通过对卷积层输出进行下采样减小特征尺寸,其运算公式如式(2)。

$$x_j^{l+1} = \text{down}(x_j^l) \quad (2)$$

其中, $\text{down}(x_j^l)$ 为池化函数,如最大池化、均值池化等; x_j^l 和 x_j^{l+1} 为池化层输入和输出。

卷积自编码器的解码器部分由转置卷积层堆叠而成,实现由低维特征到高维特征的映射,转置卷积的计算同式(1)类似,其卷积核的权重由式(1)中权重 w_{ij}^l 经转置得到。




图1 CAE网络结构

图1是卷积自编码器的网络结构,自编码器通过卷积运算将高维输入信号映射到低维特征空间,并期望通过解码器以合理的误差重构出原始输入信号。卷积运算通过局部连接和参数共享,有效降低了CAE网络的可训练参数数量,避免过拟合。编码器输出的低维特征编码被认为是原始输入信号的有效特征表达,既尽可能多的保留原始信号的信息,同时,良好的特征表达有利于提高分类器的故障识别效果。

2.2 XGBoost模型及优化

XGBoost算法是基于多个基学习器的集成学习模型,通过不断学习前面基学习器的结果与真实类别的偏差,持续提升模型的学习效果。基学习器一般是CART决策树,模型串联多个决策树共同输出最终结

果。假设共构造了K棵决策树，则对第i个样本 x_i 的预测值如式（3）。

$$\hat{y}_i = F_{K-1}(x_i) + f_k(x_i), f_k \in \mathcal{F} \quad (3)$$

其中， $\mathcal{F}$ 空间是包含了所有决策树的函数集合， $F_{K-1}(x_i)$ 是前K-1棵树的预测结果之和； f_k 是第k棵决策树的预测结果，学习的是 F_{K-1} 与真实值的残差。

需要定义一个目标函数 $L(\phi)$ 来确定模型训练和优化的方向，如式（4）。

$$L(\phi) = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (4)$$

式中， $\hat{y}_i$ 为模型预测值， y_i 为样本真实值； $l(\hat{y}_i, y_i)$ 为损失函数，如交叉熵； $\Omega(f_k)$ 是第k棵树的复杂度，可表示正则项。

XGBoost模型采用递推训练方式，当第k棵树优化时，前k-1棵树已经优化完成，涉及到前k-1棵树的参量或函数可表示为常数，结合式（3）和式（4），目标函数 $L(\phi)$ 可进一步改写为式（5）。

$$L^{(k)} = \sum_{i=1}^N l(y_i, \hat{y}_i^{(k-1)} + f_k(x_i)) + \Omega(f_k) + C \quad (5)$$

根据二阶泰勒展开式，可对式（5）近似转换，得到如式（6）的结果。

$$\tilde{L}^{(k)} \cong \sum_{i=1}^N [g_i f_k(x_i) + \frac{1}{2} h_i f_k^2(x_i)] + \Omega(f_k) \quad (6)$$

其中， g_i 是损失函数的一阶导数， h_i 是损失函数的二阶导数。

XGBoost模型在训练前，需要事先确定若干超参数的取值，这些超参数的选取直接影响模型的性能表现。表1列出了XGBoost模型中主要的超参数类型。

为了寻找最优的超参数组合，以使模型达到最佳

表1 XGBoost模型的超参数

超参数类型	默认值	说明
learning_rate	0.3	学习率，（0，1]
n_estimators	100	基学习器数目
max_depth	6	决策树深度
min_child_weight	1	叶子结点最小权重
gamma	0	惩罚项系数
reg_alpha	1	L1正则项系数
reg_lambda	1	L2正则项系数

性能，本文使用贝叶斯优化算法^[8]，对XGBoost模型中的主要超参数进行寻优。该算法通过构建目标函数在给定输入空间上的高斯过程，结合贝叶斯公式进行优化，具有迭代次数少，寻优速度快的特点。

3 基于CAE-XGBoost的调压器故障诊断模型

3.1 模型建立

本文所构建的基于CAE-XGBoost的调压器故障诊断模型包括CAE特征提取和XGBoost故障分类两个部分。CAE网络的编码器部分是对输入信号进行特征提取，将其保留作为特征提取器。CAE网络的特征提取能力受网络深度和卷积核尺寸的影响，通过设置不同的CAE网络层数和卷积核尺寸，同时保持分类器不变，计算模型在测试集上的准确率指标，如表2所示，当编码器或解码器层数为3，各层卷积核尺寸为64、32、16时，实验所得故障识别准确率为96.2%，为模型最佳。

表2 不同参数的CAE模型对比分析

编码器（解码器）层数	各层卷积核尺寸	准确率（%）
2	（128，64）	91.1
3	（256，128，64）	92.2
3	（128，64，32）	93.7
3	（64，32，16）	96.2
3	（32，16，8）	95.1
4	（128，64，32，16）	93.6

根据表2的分析，本文分别堆叠了3层卷积池化层和转置卷积层结构；卷积核尺寸则反映了特征提取的细腻程度，编码器第一层设置较大的卷积核，用于提取全局特征，其他各层依次减小。表3是本文设置的CAE网络结构参数。

XGBoost模型作为故障分类器，使用CAE提取的特征作为其输入。考虑到XGBoost模型超参数对其故障分类性能的影响，本文选取关键的4个参数，利用贝叶斯优化算法进行超参数寻优，最终确定的超参数取值如表4所示。

表3 CAE模型参数设置

结构	网络层	卷积参数	池化/上采样
编码器	卷积层1	64, 20, 1	MaxPooling kernel_size=2
	卷积层2	32, 10, 2	
	卷积层3	16, 1, 1	
解码器	转置卷积层1	16, 10, 1	Upsample, size=313
	转置卷积层2	32, 20, 1	Upsample, size =657
	转置卷积层3	64, 1, 1	Upsample, size =1 377

表4 XGBoost模型超参数最优值

超参数类型	取值
learning_rate	0.46
n_estimators	4
max_depth	4
gamma	0.06

3.2 故障诊断流程

本文提出的基于CAE-XGBoost的调压器故障诊断模型,其故障诊断的流程如图2所示,主要步骤包括:




图2 基于CAE-XGBoost的调压器故障诊断流程

(1) 数据预处理,对原始出口压力数据中值小于0的异常值和压力值突变的噪声值,影响后续数据分析,使用相邻数据的平均值替换;对调压器出口压力样本数据进行Z-Score标准化处理;按比例划分为训练集和测试集;

(2) 构建CAE网络,在训练集上利用反向传播

算法进行无监督学习,并保留其编码器部分作为特征提取器,输出训练集的特征数据集;

(3) 构建XGBoost模型,将训练集的特征数据集作为其输入,使用贝叶斯优化方法确定模型的最佳超参数;

(4) 训练XGBoost模型;将训练好的CAE编码器和XGBoost模型组合,作为最终的故障诊断模型;

(5) 使用测试集输出故障分类结果,进行模型评估。

4 工程应用分析

4.1 应用案例

模型应用于无锡市某燃气公司民用调压器故障分析,从SCADA系统采集2023年4月至2024年3月期间内共121台调压器出口压力数据。出口压力数据按自然日划分,不同采集频率做线性插值处理,每分钟一次采集,样本数据的特征为1 440维。经过CAE编码器特征提取后,特征维数下降到156,将其输入到XGBoost模型进行故障分类;通过检修记录,整理了正常、内漏、喘振和关闭压力过高4种故障类型,使用0、1、2、3代表各自类别标签,各故障类型样本统计如表5所示。

表5 数据集统计

运行状态	训练集	测试集	标签
正常	1 930	485	0
内漏	1 756	430	1
喘振	1 623	406	2
关闭压力过高	1 815	455	3

4.2 模型故障诊断结果分析

使用训练后的CAE-XGBoost模型分析测试样本运行故障。首先使用CAE网络提取出口压力信号特征,CAE网络对原始出口压力信号的重构误差越小,说明模型提取的特征越具有代表性。图3是在测试样本上,针对4种故障类型,模型对每个样本的重构误差曲线,重构误差使用均方误差(MSE)计算。重构信号不会和原始输入完全一致,我们期望误差在允许的范围内,在模型训练时,通过不断迭代减小重构误差,本文控制重构误差在0.07以内,使模型达到良好




图3 故障样本重构误差

的特征提取效果。

进一步使用训练完成的XGBoost分类器对输入特征进行故障分类,结果如表6所示,计算模型故障识别准确率。其中对调压器正常、喘振和关闭压力过高3种故障类型的识别准确率分别达到95.4%、95.3%和96.5%,对内漏故障的识别准确率达到98.1%,说明本文提出的模型具有较高的故障识别能力。调整设置不同的XGBoost模型超参数,其故障识别准确率略有不同,本文通过贝叶斯超参数寻优,设置了与训练

数据匹配的最佳超参数,使分类器性能实现最优。

5 结论

本文主要研究了燃气调压器的故障诊断问题,提出了基于CAE-XGBoost的调压器故障诊断方法。首先建立了CAE网络,使用其编码器部分提取信号深层特征,再使用XGBoost模型对提取的特征信号做故障分类。

本文的研究可应用于城燃公司对燃气调压设备的运维实践,故障诊断的结果可及时发现设备潜在隐患,提前安排处置,防止隐患发展为故障和事故,提升安全管理水平;同时,根据不同工况下调压设施的健康状况,合理缩短或延长维护保养周期,弹性化维护保养,也能合理的降低不必要的维护成本。对于燃气调压设备诊断及时性的研究,是未来该领域的一个研究方向,尽早的识别故障风险,对于提升运维效率意义重大,仍然具有很大的研究空间。

表6 模型故障识别准确率

故障类型	测试样本数	正确识别样本数	准确率 (%)
正常	485	463	95.4
内漏	430	422	98.1
喘振	406	387	95.3
关闭压力过高	455	439	96.5

doi:10.3969/j.issn.1671-5152.2025.06.003

燃气设计在“双碳”目标下的角色

江 涛

合肥合燃华润燃气有限公司

摘 要：本文旨在探讨“双碳”目标与能源转型背景下，燃气设计与城镇燃气企业如何通过技术创新和管理优化实现转型升级，以支持国家碳中和目标及可持续能源战略。从燃气设计的低碳化、智能化和协同化3大方向展开，重点研究天然气与氢能的协同利用、输配管网的优化布局、低碳材料的应用以及智能化燃气系统的实现。同时，通过实验平台和算法模型验证掺氢技术的可行性与经济性，并分析优化燃气灶和管网设计的具体措施。研究结果表明，掺氢天然气技术能够有效减少碳排放并提升能源安全性；优化管网设计和采用智能调度技术可以显著提高输配效率；使用高强度低碳材料能降低全生命周期的碳足迹。此外，实验和仿真结果验证了各项设计方案的可行性与效益，为燃气企业提供了科学依据和技术指导。通过低碳化和智能化转型，城镇燃气企业能够在“双碳”目标下实现绿色发展，并为能源结构优化和生态文明建设作出重要贡献，而燃气设计在未来的能源战略中将发挥关键的作用，是实现碳达峰和碳中和目标的重要环节。

关 键 词：城燃企业；能源转型；燃气设计；“双碳”目标

1 引言

随着城市化的迅速推进和人口规模的持续扩大，

城镇燃气规划设计作为城市基础设施的核心组成部分，在保障能源供给、改善居民生活条件以及推动可持续发展等方面具有不可替代的地位。然而，在“双

参考文献

- [1]杨蒙.燃气调压器故障诊断研究[D].北京建筑工程学院,2012.
- [2]李琪.中低压燃气调压器智能预警技术应用与优化[D].北京建筑大学,2020.
- [3]彭成,李凤娟,蒋金元.基于深度学习的故障诊断与预测方法综述[J].现代电子技术,2022,45(03):111-120.
- [4]盛永健.燃气调压器性能检测与故障诊断研究[D].江南大学,2021.

- [5]张锦玉,陈小辉,彭超龙,等.基于VAE-LSTM的中低压燃气调压器异常检测无监督模型研究[J].城市燃气,2022(11):24-31.
- [6]姜赛赛.中低压燃气调压器故障智能诊断模型与模拟研究[D].哈尔滨工业大学,2020.
- [7]Tianqi Chen,Carlos Guestrin. XGBoost: A Scalable Tree Boosting System.[J]. CoRR,2016,abs/1603.02754.
- [8]Frazier P I .A Tutorial on Bayesian Optimization[J]. 2018. DOI:10.1287/educ.2018.0188.

[第一作者简介] 江涛，高级工程师，从事燃气管道设计工作。