

DOI: 10.13382/j.jemi.B2508280

边缘云端协同的阀门内漏检测方法

张昶安¹ 吴佳轩² 陈世利¹

(1. 天津大学精密测试技术及仪器国家重点实验室 天津 300072; 2. 内蒙古工业大学化工学院 呼和浩特 010051)

摘要:传统的声发射阀门内漏检测场景中,便携巡检式仪器检测存在实时性不足、数据存储与管理效率低、环境适应性受限等问题,而无线采集云端处理的方式受到电池寿命、和云端算力成本的制约。针对以上问题提出一种边缘-云端协同的阀门内泄漏声发射信号识别方法。首先构建轻量化的识别模型,在复频域内引入残差块和多头注意力机制,自适应关注不同频率成分之间的全局关系,增强模型对关键特征的聚焦能力。在残差结构中使用深度卷积,在注意力机制中对K、V做了维度分割实现压缩注意力机制,以此保证模型轻量化。映射回时域后,将原始输入与频域重构信号相加,避免频域处理过程中的信息丢失,同时缓解梯度消失问题。在训练阶段将编码器、解码器与识别模型一起训练,部署阶段将编码器部署在无线检测设备中,降低无线传输的功耗,解码器与识别模型部署在云端。实验结果表明,所提神经网络仅需 10.1×10^3 参数即可取得较好的表现,该方法在压缩比为8,准确率由99.5%降至98.9%的情况下,可将设备每次工作的功耗由0.49 mAh降低至0.15 mAh,有效延长电池使用寿命或提高检测频率。为阀门内泄漏长期在线监测和阀门内漏识别模型的低成本部署提供了解决方案。

关键词:声发射检测;阀门内漏;边缘-云端协同;压缩感知;神经网络

中图分类号: TP391.4; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.60

Edge-cloud collaboration for valve internal leakage detection

Zhang Chang'an¹ Wu Jiakuan² Chen Shili¹

(1. State Key Laboratory of Precision Measuring Technology and Instruments, Tianjin University, Tianjin 300072, China;

2. College of Chemical Engineering, Inner Mongolia University of Technology, Hohhot 010051, China)

Abstract: In the traditional acoustic emission valve internal leakage detection scenario, the portable inspection type instrument detection exists problems such as lack of real-time, low efficiency of data storage and management, and limited environmental adaptability, while the wireless acquisition and cloud processing are constrained by the battery life, and the cost of cloud computing power. To address the above problems, we propose an edge-cloud collaborative acoustic emission signal recognition method for valve internal leakage. Firstly, a lightweight recognition model is constructed, and residual blocks and multiple attention mechanisms are introduced in the complex frequency domain to adaptively focus on the global relationship between different frequency components and enhance the model's ability to focus on key features. Deep convolution is used in the residual structure, and dimensional splitting of K and V is done in the attention mechanism to realize the compressed attention mechanism, so as to ensure the model lightweight. After mapping back to the time domain, the original input is summed with the reconstructed signal in the frequency domain to avoid information loss during frequency domain processing and to alleviate the problem of gradient vanishing. The encoder, decoder and recognition model are trained together in the training phase, the encoder is deployed in the wireless detection device to reduce the power consumption of wireless transmission in the deployment phase, and the decoder and recognition model are deployed in the cloud. The experimental results demonstrate that the proposed neural network model requires a mere 10.1×10^3 parameters to achieve optimal performance. This method, when implemented with a compression ratio of 8, reduces the accuracy from 99.5% to 98.9%, while concurrently reducing the energy consumption of the device from 0.49 mAh to 0.15 mAh. This enhancement not only prolongs the battery's operational lifespan but also facilitates the enhancement of the detection frequency. This solution offers a cost-effective approach for the online monitoring and identification of leakage in valves.

Keywords: acoustic emission detection; valve internal leakage; edge-cloud collaboration; compressed sensing; neural network

收稿日期: 2025-04-03 Received Date: 2025-04-03

0 引言

阀门是石油化工生产中的重要流体控制器件,其泄漏容易引发安全隐患。阀门泄漏形式主要有内漏外漏两种,内漏更隐蔽不易发现。声发射方法作为一种非侵入式检测方法,适用于易燃易爆等危险环境,已被广泛用于阀门内泄漏检测。

已有研究表明,声发射信号的特征提取与去噪技术是实现内泄漏识别的关键环节。Juhani 等^[1]使用统计手段与傅里叶频域分析研究了阀门的声发射信号在不同泄漏阶段的特征。Ye 等^[2]研究分析了声发射信号的标准差与泄漏量之间的回归关系;Shi 等^[3]使用小波包阈值去噪,利用相关系数法选取与泄漏相关的特征参数,建立了泄漏率与特征参数之间的数学模型;张海峰等^[4]针对 3in 球阀气体泄漏进行实验,提出使用小波包熵对泄漏量进行量化评价;宗福兴等^[5]针对油库阀门内漏提出一种使用双传感器互相关和小波变换去噪的方法。随着机器学习技术的发展,声发射信号的识别算法逐步从传统信号处理转向数据驱动的智能识别方法。SIM 等^[6]使用支持向量机、K 最近邻方法探索了声发射信号在评估往复压缩机阀门泄漏损失方面的潜力;李美瑜等^[7]使用特征提取和支持向量机,针对 DN50 闸阀 5 L/min 气体泄漏率识别率可达 97.2%;吴文凯等^[8]针对直径 50 mm 的液体阀门泄漏,提取泄漏信号的特征量组成特征矩阵,使用支持向量机的方法达到 93% 准确率。近年来,深度学习技术在该领域展现出更强的识别能力。宁方立等^[9]使用气体泄漏信号的时频图像作为输入数据,修改了卷积神经网络中卷积核的形状,相比传统卷积神经网络取得了更好的效果;黄鑫等^[10]使用卷积注意力机制模型,对高温高压下的水蒸气进行实验,在内漏率为 26 L/h 时,识别准确率高达 98%;余吉超等^[11]针对 DN8 球阀气体泄漏,采用门控循环神经网络,在 0.2 ~ 0.7 MPa 下对 0.2 L/min 泄漏率识别准确率可达 83.32%;张杰等^[12]验证了全卷积神经网络在阀门内泄漏声发射信号识别中的优越性;李颖等^[13]针对往复压缩机气阀的故障诊断提出结合时频图像的诊断模型;吕昉^[14]、刘治超^[15]、孙毅^[16]、梁乐乐^[17],设计了便携式内漏检测仪器,要在现场配合上位机的泄漏识别算法使用。

尽管上述研究在声发射信号分析与泄漏识别算法上取得显著进展,识别准确率与可检测的最小泄漏量均有突破,但是算法复杂度也显著提高,模型参数量往往高达数十万至数千万,给仪器或检测系统的实现带来困难。虽然有便携式的巡检仪器的设计迭代,但这类仪器依赖人工操作与现场上位机配合,存在诸多固有局限性,如实时性不足,无法实时监控;数据存储与管理效率低。环境

适应性受限,危险作业环境中(如高温高压区),设备安装与人工操作易引发二次风险。而基于无线通信的检测仪器能够解决便携仪器的局限性,但是面临电池寿命与算力的制约。无线检测仪器多点组网的特点又会放大电池寿命带来的维护负担和算法部署成本。

为解决算法复杂度与识别能力的矛盾,以及无线设备的电池寿命问题,本文提出一种边缘-云端协同的阀门内漏声发射检测方法。首先通过频域注意力机制在复频域提取特征调整频率成分,映射回时域后与原时域信号融合,实现轻量高效的检测模型。在电池供电的边缘设备上部署编码器,降低声发射信号的数据量,再通过窄带物联网(narrow band internet of things, NB-IoT)传输声发射信号,以此降低设备功耗,提高其电池使用寿命(或在同等寿命下提高检测频率)降低维护成本。在云端部署识别模型实现对阀门泄漏状态的长期在线监测。

1 原理

1.1 声发射原理

声发射检测技术不同于传统的无损检测技术,无需外部激励,能够实时获取待测材料结构损伤的相关信息,具有在线监测的优点^[18]。研究表明,阀门泄漏声发射信号主要湍流或空气动力学发声引起^[19]。湍流产生的声发射信号,其大小与阀门类型、口径、阀门进口压力、密封面材料、流体的速度、流量、泄漏孔的形状、大小以及流体的粘度有关。

1.2 神经网络

卷积神经网络(convolutional neural network, CNN)在故障诊断领域得到了广泛的应用, CNN 通过重复卷积和池化过程学习数据的特征分布,再通过全连接层进行分类,此为前向传播过程。通过梯度反向传播逐层向前更新参数再进行前向传播。重复上述过程,直至模型收敛^[20]。Xu 等^[21],提出的频率插值时间序列模型(frequency interpolation time series analysis baseline, FITS)模型是一种轻量化的用于时间序列预测任务的模型。输入信号经过傅里叶变换后在复频域内进行低通滤波,通过复线性层学习幅值缩放和相移,在频域进行插值,再用逆傅里叶变换映射至时域。该模型仅需 5 000 ~ 10 000 参数即可取得其他时间序列模型数十万甚至数千万参数的效果。

本文在 FITS 结构上进行改进,提取复频域特征的同时保留时域原始信号特征。在复频域内引入带有残差结构的一维卷积网络和多头注意力机制,提取频域特征。并通过深度卷积、压缩注意力维持模型的轻量化。频域信息映射回时域后与原信号进行残差连接,通过线性层

调整输出形状以适应分类任务。命名为时频注意力机制网络(temporal spectral attention network, TSAN)。

模型具体结构如图 1 所示。通过傅里叶变换将输入信号变换至复频域,将频域的实数部分和虚数部分作为两个通道。在频域输入层中堆叠一维卷积层、批量归一化层、激活函数,并使用残差连接。残差块中的卷积层采用深度卷积以降低参数量。分割特征向量后引入多头注意力机制。在频域输出层中将通道数压缩成 2,通过上采样调整频域特征向量长度,以保证映射回频域后的信号与原始信号长度相同。映射至时域后与输入向量进行残差连接,之后通过线性层调整输出向量形状。各层的输出尺寸与参数量如表 1 所示。

1.3 压缩感知

在边缘设备的工作过程中,无线信号的发送过程消耗了大量电能,极大影响了电池使用寿命,也影响了维护成本。朱一凯等^[22]、付强等^[23]采用了压缩感知的方式对原始数据进行压缩再对信号进行处理,验证了压缩感知在建筑结构健康检测、轴承故障诊断中的可行性。

压缩感知采用观测矩阵压缩原始信号的长度。

$$Y = \Phi X \tag{1}$$

其中, X 是原始信号, Φ 是观测矩阵。压缩感知要求原始信号 X 是稀疏的, X 可以分解为:

$$X = \Psi \omega \tag{2}$$

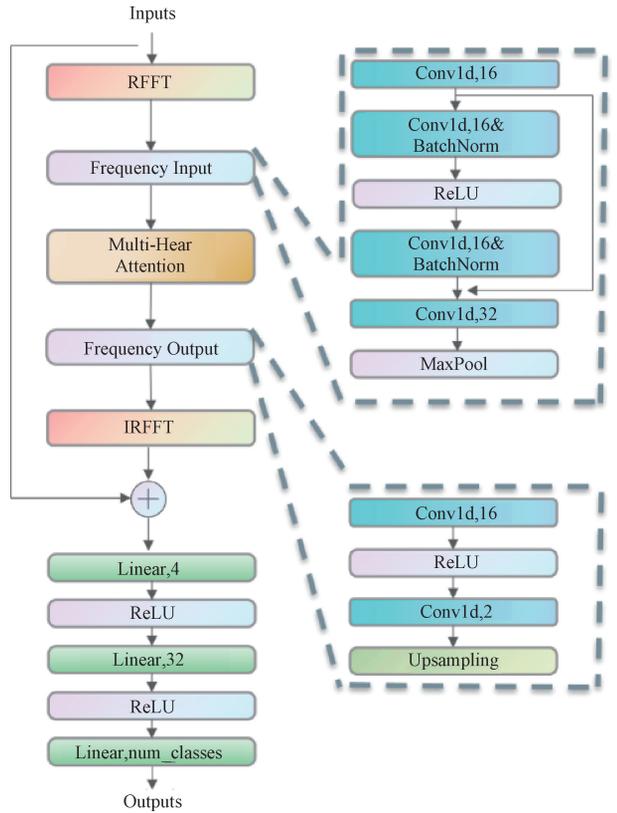


图 1 TSAN 模型结构

Fig. 1 TSAN model structure

表 1 TSAN 模型结构
Table 1 TSAN model structure

序号	层类型	输出尺寸	可训练参数量	说明
1	RFFT	[batch_size, 2, 513]	0	傅里叶变换
2	Conv1d	[batch_size, 16, 513]	176	一维卷积
3	Conv1d	[batch_size, 16, 513]	64	一维卷积
4	BatchNorm	[batch_size, 16, 513]	32	批量归一化
5	ReLU	[batch_size, 16, 513]	0	激活函数
6	Conv1d	[batch_size, 16, 513]	64	一维卷积
7	BatchNorm	[batch_size, 16, 513]	32	批量归一化
8	Conv1d	[batch_size, 32, 513]	1 568	一维卷积
9	MaxPool	[batch_size, 32, 256]	0	最大池化
10	Multi-HeadAttention	[batch_size, 32, 256]	3 200	多头注意力机制层
11	Conv1d	[batch_size, 16, 2 256]	528	一维卷积
12	ReLU	[batch_size, 16, 2 256]	0	激活函数
13	Conv1d	[batch_size, 2, 256]	34	一维卷积
14	Up Sampling	batch_size, 2, 512]	0	上采样层
15	IRFFT	[batch_size, 1, 1024]	0	逆傅里叶变换
16	Linear	[batch_size, 1, 4]	4 100	线性层
17	ReLU		0	激活函数
18	Linear	[batch_size, 1, 32]	160	线性层
19	ReLU		0	激活函数
20	Linear	[batch_size, 1, numclasses]	132	线性层

式中: Ψ 是稀疏矩阵; ω 是稀疏系数。若 ω 中大部分元素均为 0 则 X 在 Ψ 上是稀疏的, 若 ω 中有 K 个非零元素则称稀疏度为 K 。由压缩信号 Y 求解稀疏系数 ω 进而恢复出原始信号 X 的过程即为信号重构的过程。当观测矩阵与信号之间满足受限等距性质 (restricted isometry property, RIP) 时稀疏系数的解是唯一的。RIP 条件表述为存在 $\delta_k < 1$ 满足式(3)。

$$(1 - \delta_k) \|\omega\|_2^2 \leq \|\Phi\Psi\omega\|_2^2 \leq (1 + \delta_k) \|\omega\|_2^2 \quad (3)$$

受压缩感知启发, 在边缘设备上部署观测矩阵对原始信号进行压缩再做数据传输, 以降低设备的功耗。观测矩阵 Φ 通常会选择高斯矩阵、伯努利矩阵等随机矩阵以满足 RIP 条件。但这些观测矩阵可能有着非常庞大的数据量, 不利于数据存储。考虑将长度 n 的原始信号 X 压缩为长度 m 的信号 Y , 取 $n = 1\ 024, m = 256$ 此时观测矩阵参数量为 256 000, 如果在数字系统中存储为 float32 类型则有 1 MB, 即便不考虑精度损失, 量化为 Int8 类型仍有 256 KB。在没有外部存储器的情况下, 这对于许多常见的低功耗 MCU 是不可接受的。因此将原始信号分段处理, 将原信号视为两次独立采样所得, 则观测矩阵只需取原观测矩阵对角线附近的两个分块矩阵, 继续对原信号分段, 观测矩阵成为带状矩阵。若将带状矩阵中的每一行都取相同的参数, 则观测矩阵退化为卷积运算(此时未必满足 RIP 条件)可以视为一种特征提取手段。

2 实验系统

2.1 阀门内泄漏实验装置

在实验室内搭建阀门内漏检测实验台。试验台结构如图 2 所示。通过压缩机向系统内注入空气, 用压力表和气体流量计确认需要模拟的工况, 通过调节阀门开度产生不同泄漏状态下的数据。

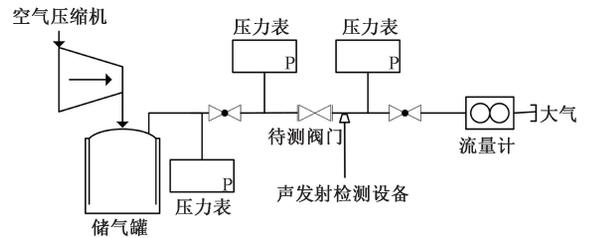


图 2 实验装置结构示意图

Fig. 2 Schematic diagram of the structure of the experimental device

2.2 阀门内泄漏检测系统

检测系统的实现流程如图 3 所示。在神经网络模型训练阶段, 将观测矩阵视为编码器, 将编码器、解码器、TSAN 模型一体化训练。实验中采用卷积层和带状矩阵两种编码器。

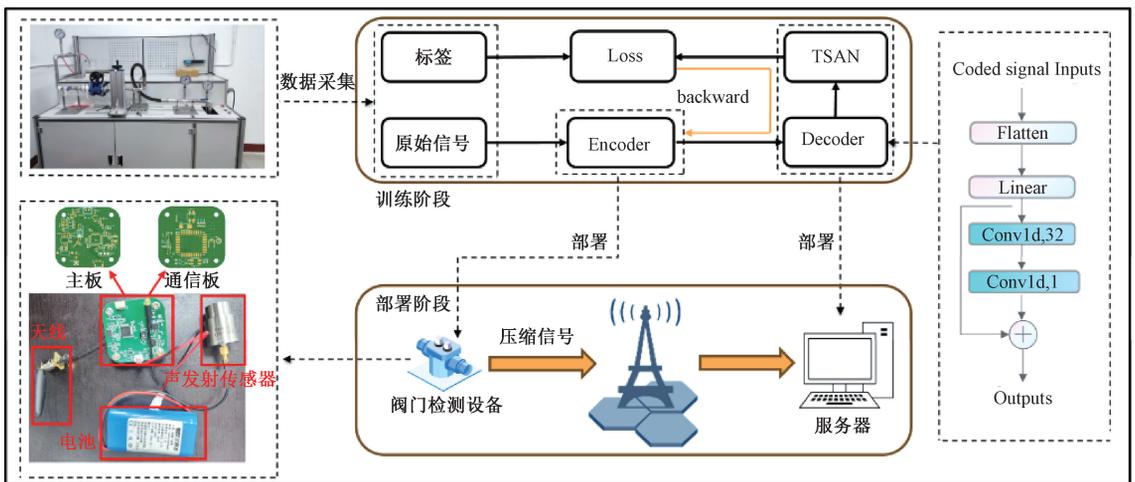


图 3 检测系统实现流程

Fig. 3 Inspection system realization process

训练完成后将编码器部署在阀门检测设备, 网络的其余部分部署在云端, 给出阀门泄漏状态的判别结果。阀门检测设备是电池供电的低功耗设备, 通过 NB-IoT 模组使用 MQTT 协议将压缩后的数据上传至云服

务器。

检测设备具体配置如下: 主控芯片选用 STM32L431CCT6, 通信模组使用 MN316-DLVD。主要参数如表 2 所示。

表 2 硬件设备主要参数

Table 2 Main parameters of hardware equipment

STM32L431CCT6			MN316-DLVD		
Flash	RAM	主频	休眠电流	待机电流	工作电流
256 KB	64 KB	80 MHz	1.0 μ A	0.4 mA	220 mA

表 3 数据集构成

Table 3 Data set composition

标签	泄漏量/(L/min)	数量	合计
0	0	14 400	14 400
	0.6	4 800	
	0.8	4 800	
	1.0	4 800	
2	1.4	4 800	14 400
	1.6	4 800	
	1.8	4 800	
3	2.4	4 800	4 800

3 实验数据分析

3.1 数据集构成

采集 DN50 蝶阀在 0.25、0.3 MPa 下不同泄漏量的数据。数据集构成如表 3 所示,将未泄漏数据标签设置为 0;将 0.8、0.9、1.0 L/min 的数据标签设置为 1;将 11.4、1.6、1.8 L/min 的数据标签设置为 2;将 2.4 L/min 的数据标签设置为 3。采样率 1 MHz,每条数据长度为 1 024。

3.2 消融实验

为验证本文算法的有效性,对不同组件进行消融实

验。通过移除频域输入层、多头注意力机制、时域残差连接以及仅保留多层感知机(multilayer perceptron, MLP)4 种情况验证各组件的效果。其中,仅保留 MLP 的情况下,为了弥补参数数量的差距,MLP 3 个线性层的神经元数量分别为 256、128、class_num。实验结果如表 4 所示。

表 4 消融实验

Table 4 Ablation experiment

TSAN	No Frequency Input	No Attention	No time-domain residual	MLP Only	参数量/($\times 10^3$)	准确率/%
✓					10.10	99.53
✓	✓				8.25	93.65
✓		✓			6.89	96.42
✓			✓		10.10	99.49
				✓	295.81	95.12

3.3 模型对比

将数据集随机划分为 10 等份,轮流取其中一份作为测试集,其余 9 份作为训练集,对 TSAN、Resnet18、FCN、CBAM 4 种模型分别进行十折交叉验证,得到 4 种模型的 10 个准确率,以评价各模型在该任务上的准确率和稳定性。箱型图如图 4 所示。TSAN 模型的中位数最高,且数据分布最为集中,表明其性能最好且稳定性较高。FCN 模型的中位数最低,且数据分布也较为集中。Resnet18 模型的中位数在两者之间,表明其性能较好,虽然数据分布较为分散,但整体高于 FCN。CBAM 模型中位数介于 Resnet18 与 FCN 之间。

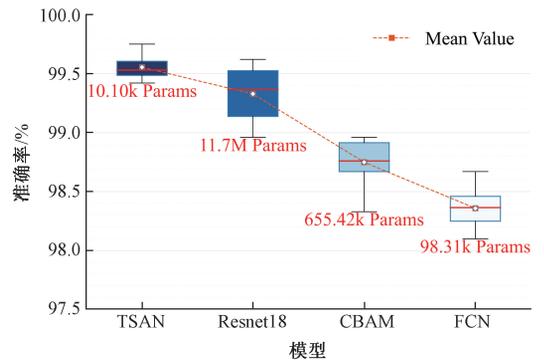


图 4 模型准确率及参数数量对比

Fig. 4 Comparison of model accuracy and number of parameters

这 4 种模型准确率均能达到 98% 以上,但 TSAN 模型仅需 10.10×10^3 参数,相比 Resnet 的 11.17×10^6 、CABM 的 655.42×10^3 、FCN 的 98.31×10^3 展现出巨大的轻量化优势,更适合低成本部署。

3.4 数据压缩对模型准确率的影响

分别采用带状矩阵、卷积层、截断原始数据 3 种方式改变数据长度。调整带状矩阵行数、卷积核的步长与卷积核的大小,可以实现不同的压缩比。所使用卷积核的具体尺寸如表 5 所示;带状矩阵的具体形状由式(4)给出,

带状矩阵参数数量如表 6 所示。

$$W_{ij} = \begin{cases} \text{Trainable}, & 0 < i^* \frac{N}{M} - j < L \\ 0, & \text{其他} \end{cases} \quad (4)$$

其中, $W \in \mathbf{R}^{M \times N}$, N 是输入数据长度, M 是输出数据长度, L 用来限制每行可训练参数的最大数量,以下取 $L = 25$ 。

表 5 卷积核尺寸与压缩长度

Table 5 Convolution kernel size and compression length

压缩比	卷积步长	卷积核大小	压缩长度
2.04	2	24	501
3.07	3	25	334
4.08	4	24	251
5.09	5	24	201
6.13	6	28	167
8.13	8	24	126
12.19	10	24	84
14.22	12	28	72
16.25	14	30	63
33.03	32	64	31

表 6 带状矩阵参数量

Table 6 Number of banded matrix parameters

压缩比	压缩长度	参数量
2	512	12 144
4	256	6 078
8	128	3 045
16	64	1 527

对比带有编解码器的 TSAN 模型在不同压缩方式、不同数据长度下的表现,如图 5 所示。

由图 5 可知,从整体趋势来看,无论采用何种方式,数据长度过低时都不可避免对准确率造成影响。但在数据长度不低于 256(压缩比不大于 4)时,采用卷积编码器或是带状矩阵能够将准确率维持在 99%附近,在降低数

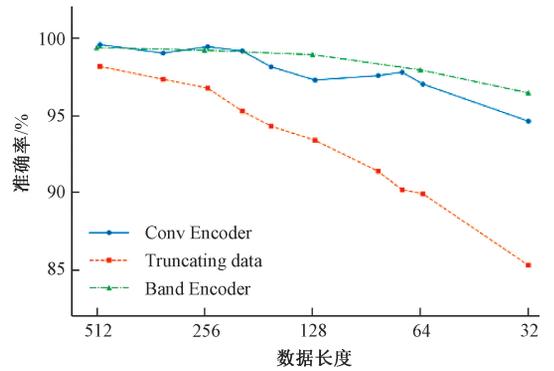


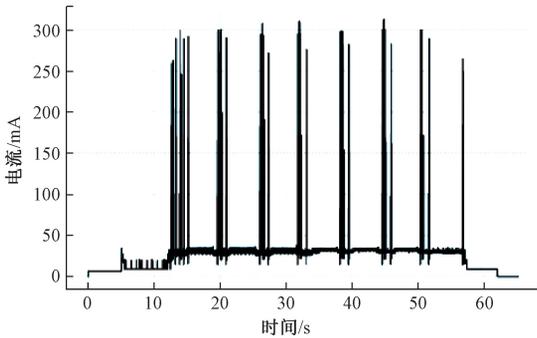
图 5 不同压缩长度与识别准确率的关系

Fig. 5 Relationship between different compression lengths and recognition accuracy

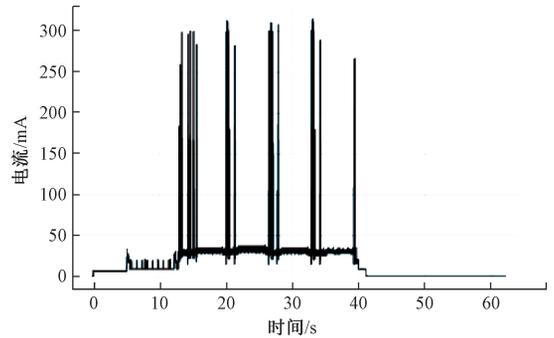
据长度的同时很好的维持了识别准确率。此时卷积层仅需 24~25 个参数,而带状矩阵需要 6 000~12 000,卷积编码器有着巨大的参数优势。数据长度低于 256 以后,带状矩阵相比卷积编码器能更好的维持准确率。两种方式均明显优于直接降低采样长度。

3.5 数据压缩对设备功耗的影响

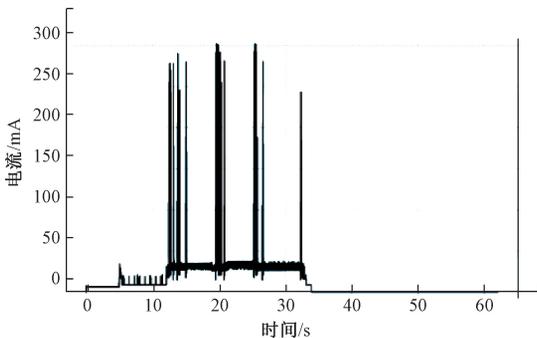
取两种编码器各自的优势区间,在单片机内部署数据长度 501、251 的卷积层,以及数据长度 128 的带状矩阵,与直接传输长度 1 024 的数据进行功耗对比。单片机上电完成初始化、数据采集、压缩、传输后进入休眠状态。记录不同数据长度下的功耗曲线,如图 6 所示。



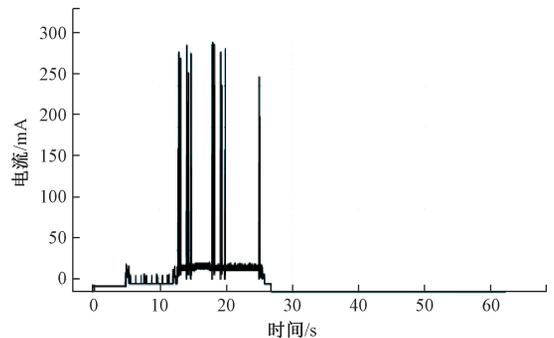
(a) 传输数据长度 1 024
(a) Transmission data length 1 024



(b) 卷积层-压缩长度 501
(b) Convolutional layers-compressed length 501



(c) 卷积层-压缩长度 251
(c) Convolutional layers-compressed length 251



(d) 带状矩阵-压缩长度 128
(d) Strip matrix-compressed length 128

图 6 不同数据长度下的功耗曲线

Fig. 6 Power consumption curves for different data lengths

通过计算设备在工作期间的平均电流和工作时间的乘积得到工作期间的电量消耗,在相同条件下重复 10 次测量取均值。不同压缩长度的功耗、参数量和准确率如图 7 所示。在使用卷积编码器的情况下,压缩长度 251 相比 501 能够在参数量不变、维持准确率的同时有效降低功耗。而带状矩阵相比直接传输原始数据,准确率由 99.5% 降至 98.9%,且边缘端的参数量大幅提高。但是在 MCU 容量足够的情况下,参数量的提升不足以成为劣势。

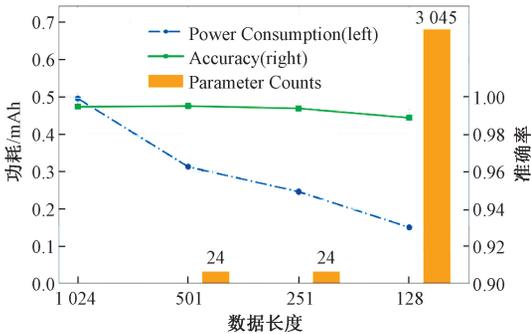


图 7 压缩长度与准确率、功耗、参数数量的关系

Fig. 7 Relationship between compression length and accuracy, power consumption, and number of parameters

取压缩数据长度 251 的卷积编码器、128 的带状矩阵和传输原始数据 3 种情况,设电池容量 6 400 mAh,电池自放电每 30 d 5% (当前电量),计算设备休眠周期与使用寿命的关系曲线,如图 8 所示。

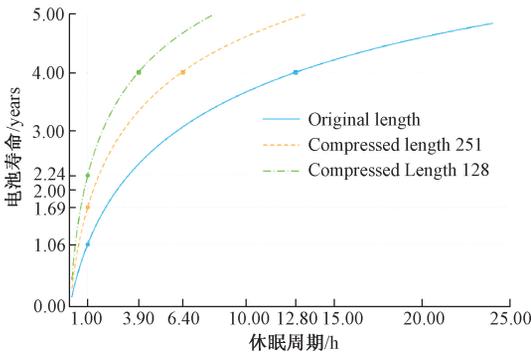


图 8 休眠时长与设备使用年限的关系

Fig. 8 Relationship between hibernation duration and equipment life expectancy

由图 8 可知,每次休眠时长 1 h 的情况下,相比原长度直接传输,压缩长度 128 可将使用年限由 1.06 年提高至 2.24 年;或在维持使用年限 4 年的情况下将休眠时长由 12.8 h 缩短至 3.9 h,检测频率提高为原来的 3.2 倍。

4 结 论

本文针对声发射阀门内漏检测中无线检测仪器的电

池寿命与计算成本问题,提出了一种边缘-云端协同的声发射信号识别方法。本文方法提出的神经网络模型在复频域内引入残差块和多头注意力机制,自适应关注不同频率成分之间的全局关系,增强模型对关键特征的聚焦能力。通过深度卷积与压缩注意力机制保证了模型的轻量化。在训练阶段将编码器、解码器与识别模型一起训练,部署阶段将编码器部署在无线检测设备中,降低无线传输的功耗,解码器与识别模型部署在云端。实验表明所提模型能够在 10.1×10^3 参数量下取得比现有的一些较大模型更好的识别效果;该方法能够在尽可能不影响识别准确率的情况下有效降低功耗(或提高检测频率)。值得注意的是,使用本文方法搭建的检测系统会丢失原始的声发射信号,编码后的信号可能不适用于其他检测算法的研究工作。

参考文献

- [1] JUHANI J B M, Ibrahim R B. Acoustic emission technique for early leakage detection of in-service control valve [C]. 2016 6th International Conference on Intelligent and Advanced Systems (ICIAS). IEEE, 2016: 1-5.
- [2] YE G Y, XU K J, WU W K. Standard deviation based acoustic emission signal analysis for detecting valve internal leakage[J]. Sensors and Actuators A: Physical, 2018, 283: 340-347.
- [3] SHI M, LIANG Y, QIN L, et al. Prediction method of ball valve internal leakage rate based on acoustic emission technology[J]. Flow Measurement and Instrumentation, 2021, 81: 102036.
- [4] 张海峰, 杨森, 张一峰, 等. 基于小波包熵的天然气管道阀门内漏分析方法[J]. 油气储运, 2017, 36(11): 1308-1314.
ZHANG H F, YANG M, ZHANG Y F, et al. A new analysis method for the internal leakage of gas pipeline valves based on wavelet packet entropy [J]. Oil & Gas Storage and Transportation, 2017, 36(11): 1308-1314.
- [5] 宗福兴, 税爱社, 汪辉, 等. 基于 CCA 和 WT 的油库阀门内漏声发射信号去噪[J]. 仪器仪表学报, 2014, 35(9): 2004-2011.
ZONG F X, SHUI AI SH, WANG H, et al. Denoising method for acoustic emission signal in oil depot internal valve leakage inspection based on CCA and WT [J]. Chinese Journal of Scientific Instrument, 2014, 35(9): 2004-2011.
- [6] SIM H Y, RAMLI R, SAIFIZUL A, et al. Detection and estimation of valve leakage losses in reciprocating compressor using acoustic emission technique [J]. Measurement, 2020, 152: 107315.

- [7] 李美瑜, 成思搏, 湛泉, 等. 基于声发射参数和支持向量机的天然气站场阀门内漏诊断[J]. 管道技术与设备, 2024, (5): 33-36, 52.
LI M Y, CHENG S B, CHEN X, et al. Diagnosis of internal leakage in natural gas station valves based on acoustic emission parameters and support vector machine[J]. Pipeline Technology and Equipment, 2024, (5): 33-36, 52.
- [8] 吴文凯, 徐科军, 叶国阳. 面向阀门内漏声发射检测的支持向量机分类建模[J]. 计量学报, 2021, 42(8): 1018-1025.
WU W K, XU K J, YE G Y. Support vector machine classification modelling for acoustic emission detection of valve internal leakage [J]. Acta Metrologica Sinica, 2021, 42(8): 1018-1025.
- [9] 宁方立, 韩鹏程, 段爽, 等. 基于改进 CNN 的阀门内漏超声信号识别方法[J]. 北京邮电大学学报, 2020, 43(3): 38-44.
NING F L, HAN P CH, DUAN SH, et al. Identification method of valve leakage ultrasonic signal based on improved CNN[J] Journal of Beijing University of Posts and Telecommunications, 2020, 43(3): 38-44.
- [10] 黄鑫, 屈文忠, 肖黎. 基于卷积注意力机制的阀门内漏声发射识别方法[J]. 振动与冲击, 2024, 43(9): 105-114.
HUANG X, QU W ZH, XIAO L. Acoustic emission recognition method for valve internal leakage based on convolutional attention mechanism [J]. Journal of Vibration and Shock, 2024, 43(9): 105-114.
- [11] 余吉超, 姚燕, 欧阳航. 基于门控循环神经网络的阀门内漏检测方法[J]. 中国计量大学学报, 2021, 32(2): 161-169.
YU J CH, YAO Y, OUYANG H. Valve leakage detection method based on gated recurrent neural networks[J]. Journal of China Jiliang University, 2021, 32(2): 161-169.
- [12] 张杰, 陈世利. 基于 FCN 的阀门内泄漏声发射信号识别方法[J]. 电子测量与仪器学报, 2023, 37(8): 84-93.
ZHANG J, CHEN SH L. Identification method of valve internal leakage acoustic emission signal based on FCN[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 84-93.
- [13] 李颖, 吴仕虎, 杨鑫杰, 等. 基于 GLCM-HOG 和 WOA-ELM 的往复压缩机气阀故障诊断方法[J]. 电子测量技术, 2023, 46(20): 156-163.
LI Y, WU SH H, YANG X J, et al. Fault diagnosis method based on GLCM-HOG and WOA-ELM for reciprocating compressor valve [J]. Electronic Measurement Technology, 2023, 46(20): 156-163.
- [14] 吕昉. 基于声发射的阀门泄漏检测便携装置的设计与实现[D]. 重庆: 重庆大学, 2021.
LU F. Design and implementation of valve leak detection portable device based on acoustic emission [D]. Chongqing: Chongqing University, 2021.
- [15] 刘治超. 阀门内漏检测仪器开发及内漏率回归量化研究[D]. 北京: 中国石油大学, 2016.
LIU ZH CH. Research on valve leakage detection instrument development and internal leakage rate quantitative regression analysis [D]. Beijing: China University of Petroleum, 2016.
- [16] 孙毅. 基于卷积神经网络的阀门内漏检测技术研究[D]. 北京: 中国石油大学(北京), 2019.
SUN Y. Research on valve inner leakage detection technology based on convolutional neural network [D]. Beijing: China University of Petroleum, 2019.
- [17] 梁乐乐. 阀门内漏仪器集成开发及实验研究[D]. 北京: 中国石油大学, 2018.
LIANG L L. Development of internal valve leakage detection instrument and experimental research [D]. Beijing: China University of Petroleum, 2018.
- [18] 王奕首, 王明华, 刘德博, 等. 声发射在复合材料贮箱上的应用研究进展[J]. 仪器仪表学报, 2022, 43(4): 1-17.
WANG Y SH, WANG M H, LIU D B, et al. Research progress on the application of acoustic emission to composite tanks [J]. Chinese journal of Scientific Instrument, 2022. 43(4): 1-17.
- [19] 韩明. 基于声发射技术的阀门内漏检测实验研究和数据分析[D]. 合肥: 合肥工业大学, 2017.
HAN M. Experimental study and data analysis of valve leakage detection based on acoustic emission technology [D]. Hefei: Hefei University of Technology, 2017.
- [20] 刁宁昆, 马怀祥, 刘锋. 一种改进 Le Net5 结合 Light GBM 的滚动轴承故障诊断方法[J], 国外电子测量技术, 2022, 41(1): 140-145.
DIAO N K, MA H X, LIU F. Bearing fault diagnosis method based on improved Le Net5 and Light GBM[J]. Foreign Electronic Measurement Technology, 2022, 41(1): 140-145.
- [21] XU Z J, ZENG A L, XU Q. FITS: Modeling time series with 10k parameters [C]. Proceedings of the twelfth International Conference on Learning Representations (ICLR), 2024.
- [22] 朱一凯, 陈安妮, 余哲帆, 等. 采用 BP 神经网络优化的振动信号压缩感知方法[J]. 振动工程学报, 2023, 36(5): 1234-1243.

ZHU Y K, CHEN AN N, YU ZH F, et al. An approach for compressive sensing of vibration signal using BP neural network optimization [J]. Journal of Vibration Engineering, 2023, 36(5): 1234-1243.

[23] 付强,胡东,杨童亮,等. 基于改进压缩感知与深度多核极限学习机的轴承故障诊断方法[J]. 机械强度, 2025, 47(6): 48-56.

FU Q, HU D, YANG T L, et al. Bearing fault diagnosis method based on improved compressed sensing and deep multi-kernel extreme learning machine [J]. Journal of Mechanical Strength, 2025, 47(6): 48-56.

作者简介



张昶安, 2023 年于天津大学获得学士学位, 现为天津大学精密仪器与光电子工程学院硕士研究生, 主要研究方向为阀门内泄漏检测技术。

E-mail: zca_2023@tju.edu.cn

Zhang Chang'an received his B. Sc. degree from Tianjin university in 2023. Now he is M. Sc. candidate in the School of Precision Instruments and Opto-Electronics Engineering at Tianjin University. His main research interests include the technology for detection of valve internal leakage.



吴佳轩, 现为内蒙古工业大学本科生。

E-mail: 753251463@qq.com

Wu Jiaxuan now is an B. Sc. candidate at Inner Mongolia University of Technology.



陈世利(通信作者), 分别在 1997 年和 2003 年于天津大学获得学士学位和博士学位, 现为天津大学精密仪器与光电子工程学院副教授, 主要研究方向为管道智能检测技术、基于声学与磁记忆技术的结构健康检测技术、基于相控阵的超声无损探伤技术。

E-mail: slchen@tju.edu.cn

Chen Shili (Corresponding author) received his B. Sc. and Ph. D. degrees both from Tianjin University in 1997 and 2003, respectively. Now he is an associate professor in the School of Precision Instruments and Opto-Electronics Engineering at Tianjin University. His main research interests include pipeline intelligent inspection technology, structural health detection technology based on acoustic and magnetic memory technology and ultrasonic non-destructive flaw detection technology based on phased array.