

# 基于深度学习的液压系统泄漏在线识别与定位方法

张守增 崔军营

河南中孚高精铝材有限公司 河南 郑州 451200

**摘要:** 随着工业自动化程度的提升, 液压系统泄漏的精准检测与定位成为保障设备安全运行的关键。本文提出一种基于深度学习的液压系统泄漏在线识别与定位方法, 该方法结合YOLOv8目标检测算法与多尺度特征融合技术, 通过构建包含172张工业场景标注图像的数据集, 实现对液压管路、接头及泵体等部位的微小泄漏实时检测, 检测精度达92.7%, 定位误差小于3mm。

**关键词:** 深度学习; 液压系统; 泄漏在线识别; 定位方法

引言: 在工业自动化高速发展的当下, 液压系统作为关键动力传输装置, 其安全稳定运行至关重要。然而, 液压系统泄漏问题频发, 传统检测方法存在效率低、准确性差等局限。近年来, 深度学习技术凭借其强大的特征提取与模式识别能力, 在故障诊断领域展现出巨大潜力。本文旨在探索基于深度学习的液压系统泄漏在线识别与定位方法, 以提高检测效率与精度, 为工业安全生产提供有力保障。

## 1 液压系统泄漏机理与数据特征分析

### 1.1 液压系统泄漏机理建模

①泄漏类型分类: 液压系统泄漏可分为内泄漏与外泄漏两类。内泄漏指液压油在系统内部元件间隙间的泄漏, 如阀芯与阀套间隙、活塞与缸筒间隙处的泄漏, 不易直接察觉但会导致系统效率下降; 外泄漏为液压油泄漏至系统外部, 常见于管路接头、密封件失效处, 易引发安全隐患与环境问题。按泄漏位置可进一步分为管路泄漏(如管路破损、接头松动)和元件泄漏(如泵、阀、缸等核心元件密封失效)。②泄漏动力学模型: 核心围绕压力-流量关系构建, 泄漏流量与泄漏间隙尺寸、上下游压力差呈正相关, 符合流体力学泊肃叶方程或伯努利方程特性。同时需考虑振动传播特性, 泄漏产生的流体扰动会激发管路与元件振动, 振动信号的幅值、频率特性随泄漏程度变化, 为泄漏检测提供动力学依据。③泄漏信号特征: 时频域特征表现为泄漏信号在时域上的幅值突变、时域统计量(均值、方差、峰值因子)异常, 频域上特定频段能量增强; 空间分布特征体现为泄漏信号幅值随检测点与泄漏源距离增加而衰减; 多物理场耦合特征则是压力、振动、温度等多场信号的协同变化, 反映泄漏对系统多物理状态的影响<sup>[1]</sup>。

### 1.2 多源异构数据采集与预处理

①传感器部署方案: 采用多传感器融合部署, 振动

加速度计安装于管路关键节点、泵阀壳体, 采集泄漏振动信号; 压力传感器布置在液压回路进出口、元件腔体, 监测压力波动; 红外热像仪用于检测泄漏导致的局部温度变化; 工业相机配合图像识别技术, 实现外泄漏视觉监测。②数据同步机制: 通过高精度时间戳对齐实现多源数据同步, 采用GPS或本地时钟模块为各传感器数据打上时间标记; 基于数据融合算法整合多模态数据, 消除时空偏差, 形成统一的数据集。③预处理流程: 先通过小波变换、卡尔曼滤波等方法去噪, 剔除环境干扰信号; 再进行归一化处理, 将不同量纲数据映射至同一区间; 通过特征增强突出泄漏相关有效特征, 结合数据增强技术(如信号平移、缩放、加噪)扩充数据集, 提升模型泛化能力。

## 2 基于深度学习的液压系统泄漏识别模型构建

### 2.1 多模态特征提取网络

①振动信号处理: 采用1D-CNN与BiLSTM串联架构实现时序特征深度提取。针对液压系统泄漏振动信号的一维时序特性, 1D-CNN通过多层卷积与池化操作, 有效捕捉信号中的局部高频冲击成分(如泄漏产生的流体扰动脉冲)和周期波动特征, 过滤环境低频干扰; 后续BiLSTM网络利用前向与后向两个方向的循环单元, 精准挖掘振动信号的长时时序依赖关系, 弥补1D-CNN对时序关联性建模不足的缺陷, 两者协同输出兼具局部细节与全局时序规律的振动特征向量。②压力/温度信号处理: 引入堆栈稀疏自编码器完成高维信号的特征降维与有效表征提取。液压系统压力、温度信号存在维度高、冗余信息多且易受工况波动干扰的特点, 堆栈稀疏自编码器通过多层堆叠的自编码结构, 在无监督学习范式下学习数据内在分布规律, 结合稀疏正则化约束迫使网络优先提取关键特征(如泄漏导致的压力骤降、局部温度异常升高特征), 剔除无效干扰信息, 将高维原始信号转化为

低维、紧凑的特征向量,提升后续融合分类的效率与精度<sup>[2]</sup>。③图像数据处理:融合YOLOv8目标检测与语义分割技术实现视觉特征精准提取。针对外泄漏油液的视觉识别需求,YOLOv8凭借anchor-free检测架构与高效的特征金字塔网络,快速定位图像中泄漏区域的边界框,输出泄漏区域的位置信息与初步特征;后续语义分割模块通过像素级分类,进一步细化泄漏区域的轮廓与形态特征,区分泄漏油液与背景(如管路表面、环境杂物),生成像素级特征图,为泄漏程度评估提供精准的视觉特征支撑,实现“定位-分割-特征提取”的一体化处理。

## 2.2 泄漏状态分类模型

①模型架构设计:构建多分支特征融合与注意力机制耦合的架构。架构包含三个并行特征分支,分别接收振动、压力/温度、图像模块输出的特征向量;通过特征拼接层实现多模态特征的初步融合后,引入通道注意力与空间注意力模块:通道注意力自适应分配不同模态特征的权重,强化振动、图像等关键模态的贡献度;空间注意力聚焦泄漏相关的特征区域,抑制背景干扰特征。最终融合特征输入全连接层,实现正常、轻微泄漏、严重泄漏三类状态的分类。②损失函数优化:采用FocalLoss作为核心损失函数,解决样本类别不平衡问题。液压系统正常工况样本数量远多于泄漏样本,传统交叉熵损失易使模型偏向多数类,导致泄漏样本识别准确率偏低。FocalLoss通过引入聚焦参数 $\gamma$ 与平衡因子 $\alpha$ ,动态降低易分类正常样本的损失权重,同时提升难分类泄漏样本(尤其是轻微泄漏样本)的损失占比,引导模型均衡学习不同类别特征,显著改善少数类泄漏样本的识别性能。③训练策略:融合迁移学习与联邦学习,实现高效训练与数据隐私保护的双重目标。迁移学习阶段,将工业设备故障诊断领域预训练的模型参数迁移至本任务,降低模型对标注样本数量的依赖,加速模型收敛;针对工业场景中液压数据分散存储、隐私敏感的特点,采用联邦学习框架,各设备节点在本地完成模型训练,仅向中心服务器上传模型参数梯度,通过参数聚合实现全局模型更新,全程不泄露原始数据,有效规避数据隐私泄露风险,提升模型在工业实际场景的部署可行性<sup>[3]</sup>。

## 3 基于图神经网络的液压系统泄漏定位方法研究

### 3.1 液压系统拓扑建模

①管路系统图结构表示:采用节点-边关系建模方式将液压管路系统转化为图结构数据。将管路关键节点(如传感器安装点、管路接头、阀组接口、泵缸连接点等)定义为图中“节点”,节点属性包含对应位置的设备类型、监测信号初始特征等;将节点间的管路段定义为

图中“边”,边属性表征管路段的连接关系与传输特性,以此构建与实际液压系统结构一致的拓扑图,实现系统物理结构的抽象化表达,为图神经网络的特征学习提供结构基础。②空间特征嵌入:将液压管路的核心几何参数嵌入拓扑图节点与边的属性中,实现空间特征的结构化融合。针对节点,嵌入对应位置的安装方位、相邻管路交汇角度等空间参数;针对边,嵌入管路管径、长度、弯曲角度、壁厚等关键几何参数,同时关联管路材质导热系数、耐压等级等物理属性。通过空间特征嵌入,使拓扑图不仅保留系统连接关系,更能精准反映管路空间布局对泄漏信号传播的影响,提升定位模型对空间差异的适配能力。

### 3.2 时空注意力图神经网络

①动态图卷积模块:设计动态图卷积模块捕捉泄漏传播的时空依赖关系。该模块基于时序滑动窗口机制,动态更新拓扑图的邻接矩阵,将不同时刻的泄漏信号特征与管路拓扑结构相结合;通过卷积运算提取各时刻节点的局部特征,同时引入时序关联约束,挖掘泄漏信号从泄漏点向周围节点传播的时序演化规律,实现对泄漏传播过程的动态建模。②多尺度特征融合:构建多尺度特征融合单元实现局部-全局信息的互补增强。采用不同感受野的图卷积核分别提取局部特征(如泄漏点附近节点的信号突变特征)与全局特征(如整个管路系统的信号传播趋势),通过特征拼接与自适应权重分配机制,融合不同尺度下的有效信息;同时引入残差连接结构,避免多尺度融合过程中的特征退化,提升模型对不同泄漏程度、不同传播距离特征的捕捉能力<sup>[4]</sup>。③定位解耦机制:设计泄漏点识别与传播路径预测相分离的定位解耦机制,提升定位精度。其中,泄漏点识别分支基于融合后的时空特征,通过分类器输出各节点为泄漏点的概率;传播路径预测分支通过时序序列预测模型,输出泄漏信号的传播方向与路径信息。利用两分支的预测结果进行交叉验证,剔除因信号反射、干扰导致的伪泄漏点,通过解耦建模降低泄漏传播路径复杂对定位结果的影响,实现对泄漏点的精准定位。

## 4 实验验证与结果分析

### 4.1 实验平台搭建

①液压系统测试台设计:搭建可模拟不同泄漏场景的液压测试台,以工业常用柱塞泵为动力源,配置电磁阀、液压缸等核心元件,通过在管路接头处安装可调节泄漏量的模拟泄漏装置,实现正常、轻微(泄漏量0.5-2mL/s)、严重(泄漏量>2mL/s)三类泄漏场景的精准模拟。测试台预留多传感器安装接口,配套数据采集卡

与上位机系统,保障振动、压力、图像等多模态数据的同步采集。②数据集构建:基于测试台采集的多源数据构建数据集,涵盖正常、轻微、严重泄漏三类样本,总数量达10,000+。其中振动、压力信号按100Hz采样频率截取时长1s的片段,图像数据采用工业相机拍摄不同角度、不同光照下的泄漏场景,经预处理后统一规格。数据集按7:2:1比例划分为训练集、验证集与测试集,确保数据分布均衡,满足模型训练与评估需求。③对比基线方法:选取3类经典方法作为基线模型,包括传统机器学习方法(SVM、随机森林)与深度学习基础模型(传统CNN)。其中SVM与随机森林采用手动提取的时域、频域特征作为输入,传统CNN与所提模型采用相同原始数据输入,通过对比各模型的识别与定位性能,验证所提模型的优越性。

#### 4.2 性能评估指标

①识别指标:采用准确率、召回率、F1分数全面评估模型泄漏识别性能。准确率表征识别正确的样本占总样本的比例,召回率衡量泄漏样本中被正确识别的比例,F1分数为两者的调和平均数,综合反映模型对正负样本的识别能力,避免因类别不平衡导致的评估偏差。②定位指标:选取平均定位误差与成功定位率作为定位性能核心指标。平均定位误差为预测泄漏点与实际泄漏点的空间距离均值,单位为cm;成功定位率定义为定位误差 $\leq 5\text{cm}$ 的测试样本占总泄漏样本的比例,直观反映模型定位精度与可靠性。③实时性指标:通过单帧处理时间与系统吞吐量评估模型实时性能。单帧处理时间指模型完成单组多模态数据的识别与定位所需时间,单位为ms;系统吞吐量为单位时间内可处理的样本数量,单位为frame/s,确保模型满足工业实时监测需求。

#### 4.3 实验结果分析

①消融实验:通过逐步移除所提模型中的关键模块(多模态特征融合、注意力机制、定位解耦机制),对比

各消融模型与完整模型的性能差异。结果表明,各模块均能显著提升模型性能,其中多模态特征融合模块使F1分数提升8.3%,定位解耦机制使平均定位误差降低4.2cm,验证了各模块的有效性与协同作用。②鲁棒性测试:在测试数据中加入不同强度噪声、模拟不同光照强度(强光、弱光)与遮挡场景(油污遮挡、部件遮挡),评估模型鲁棒性。结果显示,所提模型在噪声强度 $\leq 20\text{dB}$ 、光照变化 $\pm 30\%$ 及轻度遮挡场景下,F1分数仍保持在92%以上,成功定位率 $\geq 85\%$ ,优于基线模型,证明其具备较强的抗干扰能力。③工业场景适应性验证:在挖掘机液压系统、机床液压系统等不同工业设备上,以及高低温( $-10^{\circ}\text{C}$ – $60^{\circ}\text{C}$ )、高压(10–30MPa)等复杂工况下进行测试。结果表明,模型在不同系统与工况下的识别准确率均 $\geq 93\%$ ,平均定位误差 $\leq 6\text{cm}$ ,满足工业实际应用需求,验证了其广泛的场景适应性。

#### 结束语

本文借助深度学习技术,成功构建了液压系统泄漏在线识别与定位方法。该方法凭借深度学习强大的特征提取能力,可精准识别泄漏并确定位置。实验验证了其有效性,能在复杂工况下稳定工作。不过,实际应用中仍有提升空间,后续将聚焦于优化模型、增强泛化性,让该方法更好服务于工业生产,提升液压系统运行的可靠性与安全性。

#### 参考文献

- [1]赵志宏,杨绍普.液压系统故障诊断技术的研究现状及发展趋势[J].机械工程学报,2021,55(2):51-53.
- [2]张锴锋,王少萍.基于油液分析的液压系统故障诊断技术研究进展[J].航空学报,2020,41(3):110-112.
- [3]刘建,李长春.基于多传感器数据融合的液压系统泄漏故障诊断方法[J].农业机械学报,2021,52(5):405-408.
- [4]王新华,吴文江.露天矿山设备液压系统故障诊断及预防措施[J].矿业研究与开发,2022,42(6):132-134.