

文章编号:1671-5896(2026)04-0879-10

基于深度学习的长输管道泄漏检测技术综述

周怡娜^{a,c}, 谢俊竹子^a, 路敬祎^{b,c}, 闫文迪^a, 唐洁^a, 宋晓冉^a

(东北石油大学 a. 电气信息工程学院; b. 人工智能能源研究院;
c. 黑龙江省网络化与智能控制重点实验室, 黑龙江 大庆 163318)

摘要: 针对长输管道泄漏检测中非线性特征复杂、检测精度等问题, 系统探究了深度学习技术在长输管道泄漏检测中的应用价值与发展潜力。首先回顾了目前国内外深度学习在长输管道泄漏检测的研究现状, 然后探讨了基于深度学习的长输管道泄漏检测研究的关键技术, 并总结了现阶段难点问题。最后, 讨论了深度学习技术在长输管道泄漏检测领域的优势与局限性, 并对其未来研究方向进行了展望。

关键词: 深度学习; 泄漏检测; 长输管道

中图分类号: TP277; TE832 **文献标志码:** A

Review of Leak Detection Technology for Long-Distance Pipelines Based on Deep Learning

ZHOU Yina^{a,c}, XIE Junzhuzi^a, LU Jingyi^{b,c}, YAN Wendi^a, TANG Jie^a, SONG Xiaoran^a

(a. School of Electrical Information and Engineering; b. Artificial Intelligence Energy Institute;
c. The Heilongjiang Provincial Key Laboratory of Networking and Intelligent Control, Northeast Petroleum University, Daqing 163318, China)

Abstract: To address the challenges associated with complex nonlinear characteristics and limited detection accuracy in long-distance pipeline leak detection, the application value and development potential of deep learning technologies are systematically investigated. Firstly, the current research status of deep learning in long-distance pipeline leakage detection both domestically and internationally are reviewed. It analyzed key technologies in deep learning-based pipeline leak detection and summarized existing challenges. Finally, this study discussed the advantages and limitations of deep learning in the field and outlined future research directions for long-distance pipeline leakage detection technology.

Key words: deep learning; leak detection; long-distance pipelines

0 引言

近年来,随着管道运输的规模不断扩大,管道泄漏问题也愈发严重。其泄漏原因不仅包括管道长期埋于地下被土壤侵蚀或流体对其腐蚀、随着管道长时间使用会出现老化或磨损现象,还可能是因施工操作不当或是发生地震等自然灾害。由于管道内运输的物质通常具有较高风险,一旦泄漏,不仅会造成巨大的经济损失,还可能会引发严重的环境灾害和安全事故^[1-3]。例如,泄漏的天然气进入空气中可能会形成爆炸性混合气体,遇到火源会引发爆炸事故。因此,为了安全,应对管道泄漏事件进行实时有效检测。

收稿日期: 2025-08-21

基金项目: 国家自然科学基金资助项目(62473096); 东北石油大学人才引进科研启动经费基金资助项目(13051202301); 青年科学基金资助项目(C类)(6250021644)

作者简介: 周怡娜(1989—), 女, 安徽潜山人, 东北石油大学讲师, 主要从事管道泄漏检测技术研究, (Tel) 86-15164566748 (E-mail) bewonderfulzyn@163.com; 通讯作者: 路敬祎(1977—), 男, 黑龙江大庆人, 东北石油大学教授, 博士生导师, 主要从事油气管道设备检测、监测、工业故障诊断研究, (Tel) 86-18745977959 (E-mail) ljywdm@126.com。

目前随着计算机硬件和人工智能技术的迅速发展,深度学习作为人工智能领域的数据处理工具^[4],逐渐应用于管道泄漏检测领域。与传统的手动特征提取方法相比,深度学习能自动提取数据的抽象特征,包括一些难以识别的特征,从而显著提高了检测效率。王新颖等^[5]提出将卷积神经网络与 Softmax 分类器结合的管道泄漏检测模型,效果优于 BP(Back Propagation)神经网络的管道泄漏检测。Wang 等^[6]将稀疏自编码器与 SVM(Support Vector Machine)相结合进行管道泄漏检测,并利用 LFPSO(Leader-Follower Particle Swarm Optimization)进行参数优化,提高了检测的准确性。温江涛等^[7]通过将压缩感知与深度卷积网络相结合对泄漏孔径识别,识别效果优于传统分类方法。Liu 等^[8]提出一种基于卷积神经网络的迁移学习方法,进行多工况条件下的管道泄漏检测。Zadkarami 等^[9]提出一种基于多层感知器神经网络(MLPNN: Multi-Layer Perceptron Neural Network)的检测方法,对传输碳氢化合物的管道进行流量和压力的特征提取从而实现泄漏诊断。Kang 等^[10]提出将卷积神经网络与 SVM 相结合作用于一维信号进行泄漏检测,并利用图搜索法进行泄漏定位。Lee 等^[11]提出一种基于循环神经网络和长短期记忆网络(RNN-LSTM: Recurrent Neural Network-Long Short-Term Memory)结合的检测模型,对地下管道的泄漏进行检测。由于深度学习技术在管道泄漏检测领域展现出巨大的潜力,所以人们逐步利用深度学习技术代替传统方法,并通过融合先进的神经网络模型和传统检测方法,不断提升检测的准确性和效率,为管道安全运行提供有力保障。

笔者简单回顾近年国内外深度学习在长输管道泄漏检测的应用研究。首先对基于深度学习的管道泄漏检测相关技术进行阐述,并对研究成果和存在的问题进行总结;然后探讨管道泄漏检测的难点;最后对长输管道泄漏检测技术的前景及将来的研究方向进行展望。以此为中国长输管道泄漏检测技术的发展提供参考。

1 基于深度学习的管道泄漏检测关键技术

目前人们探索了多种深度学习策略用于管道泄漏检测。尤其是卷积神经网络^[12-14](CNN: Convolutional Neural Network)、长短期记忆网络^[15](LSTM: Long Short-Term Memory)和生成对抗网络^[16](GAN: Generative Adversarial Network)等深度学习模型,能自动从海量的传感器数据中提取有用特征,不仅能提高泄漏检测的准确性,还能处理复杂的非线性关系和高噪声数据。因其各自的特点和优势,已被广泛应用于管道泄漏检测领域。

1.1 基于 CNN 的泄漏检测

CNN 作为一种深度学习算法,在图像处理领域展现出了卓越的性能和广泛的应用潜力。CNN 是基于人类的视觉感知机制,通过卷积、池化和全连接层等结构,能有效地提取图像中的局部特征,并进行层次化的特征整合,使 CNN 广泛应用于图像识别、分类、检测和故障诊断等任务^[17]。在长输管道系统中,压力、流量、温度、振动等物理参数通常通过传感器实时采集,并以一维时序数据的形式呈现^[18]。CNN 在这种一维传感器数据的处理上表现出优异的特征提取能力。CNN 不仅能处理由传感器采集到的一维数据,还能处理由一维数据转换成的二维图像和由红外相机采集到的红外图像。通过 CNN 的强大特征提取和识别能力,可以精确地提取信号和图像中不同工况的特征,从而实现泄漏工况的特征提取和检测。笔者通过总结常见的基于 CNN 的泄漏检测方法,梳理结构并给出通用结构图。基于 CNN 的泄漏检测方法结构如图 1 所示。




图 1 基于 CNN 的泄漏检测方法结构

Fig. 1 Structure diagram of leak detection method based on CNN

由于深度学习模型在小样本场景下容易出现过拟合问题,因此在面对样本过少问题时,应结合集成迁移学习和粒子群优化算法等进一步提高 CNN 模型在小数据集条件下的性能。Zhou 等^[19]提出了一种基于1DCNN(One-Dimensional Convolutional Neural Network)的集成迁移学习方法(TL1DCNN: Transfer Learning One-Dimension Convolutional Neural Network),用于小样本条件下的管道泄漏检测与定位。首先利用源域数据对参数不同的1DCNN进行预处理,通过最小化相似度总和确定不同的集成策略,并进一步使用粒子群优化算法(PSO: Particle Swarm Optimization)优化权重,从而提高检测与定位的准确性。根据CNN的改进架构VGG(Visual Geometry Group),孙宗康等^[20]提出基于多掩码混合的数据增强方法,能有效解决在小样本数据不均衡情况下的供水管道泄漏检测。

面对小泄漏问题,惠泽国等^[21]在传统CNN模型中建立多个卷积和池化层。将收集声学信号转换到频域,利用改进的模型对信号做出识别,以实现环保气体小泄漏检测。李哲等^[22]采用多窗谱谱减法去除供水管道小泄漏声信号的噪声,并通过短时傅里叶变换获取去噪信号的图像,运用CNN进行检测,实现了平均识别率高达95.28%的微小泄漏孔径识别。郑书闽等^[23]利用变分模态分解(VMD: Variational Mode Decomposition)对数据进行降噪,构建CNN-GRU(Convolutional Neural Network-Gated Recurrent Unit)模型进行泄漏特征提取,能有效判断在常压、小尺度条件下管道的漏损状况。Li等^[24]提出一个具有多个卷积和合并层的CNN模型,在管道的少量泄漏检测中具有良好效果。

针对在实际故障诊断系统中没有足够的标记样本进行训练,Lu等^[25]提出基于深度卷积神经网络智能故障诊断的架构DAFDM(Domain Adaptation Based on Feature Distribution Matching),通过迭代动态调整优化目标,实现边缘和条件分布同时进行自适应。谭震等^[26]提出一种基于多尺度一维卷积神经网络(MS1DCNN: Multi-Scale One-Dimensional Convolutional Neural Network)的模型架构,利用多个不同卷积尺度的卷积通路,并行提取管道泄漏的特征,能在不同数据集情况下进行泄漏信息的分类预测。Meng等^[27]提出一种SE-CNN-Lite(Spectral Enhancement-Convolutional Neural Network-Lite)网络架构,其冗余比低于最先进的轻量级网络,还能在信噪比较低的环境中达到管道泄漏检测最佳准确性。

CNN主要用于提取空间特征,在处理声波信号的时频图或压力流量数据的二维表示时表现良好。然而,CNN对小泄漏的检测能力较弱,因为小泄漏信号通常较微弱,容易被复杂背景噪声掩盖。此外,CNN的局部感受野限制了其对时间依赖特征的捕捉能力,使CNN难以对泄漏信号的时序演变进行有效建模。

1.2 基于LSTM的泄漏检测

循环神经网络(RNN: Recurrent Neural Network)是一种具有循环结构的神经网络,允许信息在网络的不同时间步之间流动。每层的输出不仅依赖当前输入,还依赖于上一层的输出。前一时刻的记忆作为隐藏状态,成为信息的传递载体,随着时间的迭代不断更新,从而处理序列数据。而LSTM是RNN的一种改进,通过引入“门控机制”解决RNN的梯度消失问题。LSTM借助单元结构中的遗忘门决定上一时刻的记忆单元是否被保留^[41],能在更长的时间跨度上保留有效的记忆,更适用于处理时序数据。

在压力或流量信号泄漏检测的应用中,将管道内的信号转换为时间序列数据。通过将时间序列数据输入到LSTM模型中,从中提取出深入的特征。这些特征可能包括压力或流量的波动、趋势变化、周期性以及其他与泄漏相关的异常信号。LSTM模型将根据提取的特征进行泄漏判断。笔者通过总结常见的基于LSTM的泄漏检测方法,梳理结构并给出通用结构图。基于LSTM的泄漏检测方法结构如图2所示。

对微弱的泄漏信号,传统的信号处理方法通常难以对其有效捕捉和放大。Ullah等^[28]利用Savitzky-Golay滤波对声发射信号进行去噪处理,输入CNN-LSTM模型中,虽然该模型能忽略管道中的压力和泄漏尺寸,但仍存在模型计算负担大的问题。Shin等^[29]提出LSTM与自编码器结合的框架,通过集合学习技术增强,能对微弱的信号敏感,同时能处理噪声信号。针对小泄漏信号微弱且难以检测的特点,Zhang等^[30]将注意力机制与LSTM网络相结合,增强模型对微小泄漏信号的敏感度。针对强噪声环境,通过CNN提取空间特征和LSTM捕获时间序列中的动态特性,深度学习不仅能更好地监测小泄漏信号,还能提供实时响应,显著提高检测的敏感性。Guo等^[31]利用LSTM、门控递归单元(GRU: Gated Recurrent Unit)、CNN和SqueezeNet框架建立泄漏检测模型,并结合基于白鲨优化器(WSO: White Shark Optimizer)

算法的自适应改进变分模态分解,表现出在强噪声环境下对弱泄漏信号的输水管道中的小规模泄漏检测有良好效果。曹韵奇等^[32]提出了一种基于 LSTM 的分类模型,以实现强背景噪声运行工况下小泄漏信号的识别,提高了检测的准确性和可靠性。




图 2 基于 LSTM 的泄漏检测方法结构

Fig. 2 Structural diagram of leak detection method based on LSTM

LSTM 在时间序列建模方面表现优异,适用于捕捉泄漏信号的短时突变和长期趋势。然而, LSTM 对数据质量要求较高,容易受到传感器噪声和数据缺失的影响,导致模型性能下降。此外, LSTM 计算资源消耗较大,长时间序列的训练会带来梯度消失或爆炸问题,从而增加优化难度。

1.3 基于 GAN 的泄漏检测

GAN 是一种先进的深度学习模型,其由生成器和判别器组成。生成器的任务是创造出尽可能接近真实数据的图像,而判别器的任务则是区分生成的图像和真实图像。这两部分网络在训练过程中相互对抗,不断提升自己的性能,最终生成器能生成判别器难以区分的高质量图像。在管道泄漏检测的背景下泄漏信号增强和图像生成领域展现出了显著的优势。其通过模拟数据的分布,信息缺失的情况下进行高效且高质量的数据增强,或者能生成逼真的图像,以供检测模型训练和学习。笔者通过总结常见的基于生成对抗网络的泄漏检测方法,梳理结构并给出通用结构图。基于生成对抗网络的泄漏检测方法结构如图 3 所示。




图 3 基于 GAN 的泄漏检测方法结构图

Fig. 3 Structural diagram of leak detection method based on GAN

通过结合 GAN 等技术进一步增强对少数类样本的表达能力,从而改善模型对泄漏事件的识别。Rajabi 等^[33]提出了一种基于条件卷积生成对抗网络(CDCGAN: Conditional Deep Convolutional Generative Adversarial Network)的方法,通过水力模型和需求的不确定性生成无泄漏的训练数据实现了较好的数据增强效果,并将水力模型数据转换为图像形式,最后使用结构相似性指数(SSIM: Structural Similarity Index Measure)进行泄漏检测和定位。针对少量样本问题以及缺陷和非缺陷类别的不平衡,Chen 等^[34]提出了一种结合 Cycle GAN 和改进 YOLO v5(You Only Look Once version 5)的石化管道缺陷检测系统。通过 Cycle GAN 进行样本增强生成管道缺陷图像,并扩展数据集,引入 Transformer 注意机制精确检测模型,有效解决了石化管道缺陷识别中的数据不平衡和检测精度问题。

此外, GAN 可以通过其生成器网络, 对微弱信号进行放大和清晰化处理, 使原本难以察觉的泄漏信号变得更加明显。Chen 等^[35]基于 GAN 和 LSTM 提出利用神经网络辅助经验模式分解(EMDNN: Empirical Mode Decomposition Neural Network)的弱信号增强方法, 对弱信号进行重构并增强。曹鹏宇等^[36]提出基于 DAE-GAN(Denoising Autoencoder-Generative Adversarial Network)网络的雷达信号增强模型, 使噪声增强网络与信号增强网络进行对抗训练, 提升信号增强网络的降噪性能, 从而达到信号增强的效果。Wang 等^[37]构建基于 WTE-CGAN(Weak Target Enhancement-Complex-valued Generative Adversarial Network)的结构, 对弱目标具有显著的信号增强作用。利用生成模型与实时目标检测算法结合, 能实现高效、高精度的自动缺陷识别。Zhao 等^[38]使用非生成数据增强技术扩展了天然气管道微泄漏图像, 并设计了一种生成数据增强网络(DCWGAN: Deep Convolutional Wasserstein Generative Adversarial Network), 用于生成具有不同特征的天然气管道微泄漏图像以进行检测。

通过改进模型的损失函数, 也能达到增强数据集的目的。原始 GAN 使用 JS(Jensen-Shannon)散度衡量生成与真实分布的差异。当两者分布无重叠时, JS 散度会趋近于常数, 导致梯度消失, 生成器无法有效更新。Gao 等^[39]利用 Wasserstein 距离代替传统 GAN 中判别器的 JS 散度, 并在模型中添加梯度惩罚, 构建成 WGAN-GP(Wasserstein Generative Adversarial Network with Gradient Penalty)模型生成数据样本。在信噪比较低的环境中, 利用 GAN 对管道信号增强, 能有效减少噪声干扰。这种增强处理不仅提高了泄漏信号的强度, 还增强了信号的细节, 使检测系统能更加灵敏地识别出泄漏事件。Hu 等^[40]构建 U 型结构的 GAN 模型进行数据增强, 利用处理后的样本生成故障样本, 并利用 L1 和 L2 损失函数更新网络参数。Zhang 等^[41]提出了一种混合生成对抗网络, 通过设计多类型生成网络和集成粒子群优化算法, 有效提供和增强泄漏数据, 以解决泄漏与正常样本的数量不平衡问题。针对不同健康状态下的数据, Shang 等^[42]提出了一种多生成器交换对抗网络(MGSAN: Multi-Generator Switching Adversarial Network)的新型算法。通过设计一个多模式生成器增强管道数据, 并提出模式切换策略, MGSAN 能在生成器和鉴别器间实现平衡。Hu 等^[43]提出了一种三网络结构的生成对抗网络, 通过利用传感器数据的相似性恢复不完整数据, 并引入多视图感知策略增强时间和空间特征。最终结合双判别网络架构有效凸显泄漏特征, 从而提高泄漏检测的准确性。改进的生成模型与 CNN、LSTM 相结合, 对增强的数据集进行评估。胡磊磊等^[44]对预处理后的声发射信号小样本数据, 利用深度卷积深层对抗网络(DCGAN)进行增强, 达到数据集平衡, 输入 1DCNN 模型中进行训练并评估。

GAN 在小样本数据扩充方面发挥重要作用, 能生成逼真的合成泄漏数据, 缓解数据不平衡问题, 从而提高模型对小泄漏信号的检测能力。由于传统 GAN 训练过程不稳定, 生成器倾向于生成能稳定欺骗判别器的少数样本, 而非覆盖全部数据分布, 因此容易出现模式崩溃, 使生成的数据质量不均。此外, GAN 可能引入偏差或噪声。由于真实泄漏信号可能包含高频瞬态或低频振荡, 而生成器仅捕捉到部分特征, 从而导致合成数据与真实泄漏信号不完全匹配, 影响检测模型的泛化能力。

1.4 基于多模态特征融合的泄漏检测

管道系统通常涉及多种不同类型的数据, 如压力、流量、振动、声波、图像等, 这些数据通常具有不同的空间和时间特性。为了充分利用数据源信息, 多模态融合技术通过整合不同类型的数据或不同域的信息, 提升检测系统的准确性、鲁棒性和实时性。图像和信号数据可以分别通过独立的神经网络模型进行处理, 并通过共享隐层特征或联合训练, 在高层次的特征空间进行融合, 通过全连接层进行统一预测。笔者通过总结常见的基于多模态特征融合的泄漏检测方法, 梳理结构并给出通用结构图。基于多模态特征融合的泄漏检测方法结构如图 4 所示。

深度学习在多模态特征融合中进一步优化了管道泄漏检测的整体性能, 弥补单一模态可能导致的信息丢失。通过多模态特征融合, 深度学习综合利用不同传感器提供的信息, 以提高检测系统在复杂环境下的性能, 通过学习不同模态特征或数据之间的关联性, 补充丢失的信息, 确保能更准确地识别和定位管道泄漏, 为长输管道系统的安全运行提供有力保障。




图4 基于多模态特征融合的泄漏检测方法结构

Fig.4 Structure diagram of multimodal feature fusion

同源信号数据能通过不同的特征提取方法进行特征融合,增强对目标信号的识别能力。Zhang 等^[45]提出了一种基于深度森林集成学习模型的多模态深度特征融合系统。该系统通过从 AlexNet、ResNet-50 和 MobileNet 3 种卷积神经网络(CNN)的卷积层提取深度特征,并将这些特征与气体传感器的测量数据进行融合。将融合后的特征输入到深度森林分类模块中,用于判断气体泄漏。Wang 等^[46]通过融合磁通泄漏热图和磁通泄漏信号提高缺陷检测的准确性和鲁棒性。利用多模态特征间的相关性增强关键缺陷特征,提出的多模态特征融合注意模块(MMFFAM; Multi-Modality Feature Fusion Attention Module),对多模态特征进行深度动态集成。Zhang 等^[47]结合一维和二维卷积神经网络分别提取时域和频域特征,并引入自注意力机制融合这些多模态特征。该算法通过融合多模态特征信息,实现了更高的识别精度和泛化能力。刘志伟等^[48]提出了一种多维空间数据融合算法,利用分布式光纤振动传感系统监测管道泄漏,通过时空域平均和阈值设定提升泄漏监测报警性能。Ye 等^[49]提出混合深度学习模型 EMDet(Entropy blending and Multi-link parallel feature enhancement Detection),通过确定熵混合算法中最佳分解层数和多链路并行特征增强算法中的最佳本征模态函数特征表达。

图像和信号数据可以分别通过独立的神经网络模型进行处理,并通过共享隐层特征或联合训练,然后在高层次的特征空间进行融合,通过全连接层进行统一预测,从而达到准确识别和预防泄漏的目的。Narkhede 等^[50]提出了一种基于多模态人工智能的气体检测和识别方法,首先采用热像仪和气体传感器阵列的数据进行特征提取,并将特征进行融合,然后进行分类识别。Attallah^[51]提出了一种基于多任务深度学习的管道天然气泄漏检测方法,通过融合电子鼻(E-nose)和热成像的多种模态数据,实现了对天然气泄漏的准确检测和识别。在基于多模态融合的泄漏检测方法中,模型的核心优势在于其能整合来自不同传感器或检测手段的异构信息。Yan 等^[52]提出用于气体管道小泄漏检测的多模态特征融合的方法,通过将多个传感器获取的数据转换为二维时频图像,增强模型的特征表达能力,与多模态特征共同应用,有效识别管道中的小泄漏状况。

由于单一深度学习方法在管道泄漏检测中通常难以应对复杂工况,而基于多模态融合的管道泄漏检测方法通过融合不同模态的信息,不仅增强了模型对泄漏特征的识别能力,还能在检测复杂泄漏模式时,综合考虑不同数据源之间的相互作用,从而提升模型的整体性能。但多模态融合也面临特征对齐困难、数据同步问题以及计算复杂度较高的挑战。

2 基于深度学习的管道泄漏检测难点

在实际应用中,管道泄漏检测通常面临小样本、小泄漏、数据不平衡、低信噪比和强噪声等诸多

挑战。由于长输管道泄漏事件相对较少, 可获取的真实泄漏数据有限, 而深度学习模型通常依赖于大量高质量的标注数据, 导致模型在小样本条件下难以学习到有效特征; 同时, 小泄漏的信号幅度微弱, 容易被背景噪声掩盖, 影响模型对微弱信号的敏感度和区分能力, 进一步降低检测的准确性。小泄漏通常伴随微弱且复杂的信号变化, 单一方法又难以有效捕捉这些细节特征。

此外, 数据通常存在类别不平衡, 正常工况数据远多于泄漏数据。在复杂管网环境下, 不同类别样本数量差异显著, 泄漏数据稀缺可能导致传统方法过度偏向正常样本, 而忽视异常数据。从而导致模型对少数类别的泄漏事件识别能力不足。特别是在复杂工况下, 管道信号可能受到环境噪声、传感器误差等干扰, 导致信噪比低、噪声成分强, 进一步加剧模型的误判风险。

3 讨 论

与传统的泄漏检测方法相比, 基于深度学习的检测方法具有明显优势。CNN 通过多层卷积和池化操作, 在空间维度上提取局部和全局特征, 可有效识别噪声背景中的泄漏信号关键特征。而 LSTM 则通过其门控机制, 在时间序列中保留重要信息, 从长时间数据中提取稳健的泄漏特征, 减弱短时噪声的影响。这两种方法相结合, 不仅提升了模型在噪声较高数据中的识别能力, 还能通过 LSTM 对动态变化的捕捉, 检测管道泄漏信号特征。此外, 基于 GAN 的泄漏信号增强方法通过生成器网络放大和细节增强微弱泄漏信号, 不仅解决了数据不平衡和信噪比低的问题, 还增强了模型对复杂泄漏信号的检测能力, 提高了实际泄漏检测场景中的适用性和稳定性。GAN 的应用不仅限于数据去噪和增强, 它还能生成逼真的无噪声泄漏信号, 从而提升模型在复杂环境下的泛化能力。

同时, 多模态融合的深度学习方法能结合来自不同传感器的信息, 通过学习不同模态数据间的关联性, 补充丢失的信息, 综合判断管道状态, 达到准确识别和预防泄漏的目的。这种融合策略不仅增强了模型的鲁棒性, 还为模型提供了更全面的泄漏特征识别能力, 使深度学习技术在泄漏检测领域发挥出更大的潜力。

虽然深度学习在管道泄漏检测领域展现出巨大的潜力, 但其仍然面临诸多挑战。深度学习模型在不同管道系统和环境条件下的泛化能力仍需要提高。CNN 对小泄漏和时间依赖特征的捕捉能力有限; LSTM 对数据质量和计算资源要求较高; GAN 通过生成逼真的合成数据缓解数据不平衡问题, 为小泄漏检测提供更多样本支持, 但其训练不稳定, 生成数据可能存在偏差或噪声。深度学习模型的表现高度依赖于数据源的质量和数量, 而模型的复杂性对硬件的要求较高, 从而导致了硬件成本和训练周期的增加。

4 总结与展望

笔者主要研究了基于深度学习的长输管道泄漏检测相关技术: CNN、LSTM、GAN 和多模态特征融合。通过梳理其特点及结构, 阐述现有的研究成果并阐述其优点和不足; 总结长输管道泄漏检测的难点; 探讨相关技术存在的问题, 并分析影响检测精度和可靠性的因素。虽然目前人们对深度学习在长输管道的泄漏检测已经进行大量研究, 但仍然存在一些问题。为此, 笔者对未来的研究方向做出如下展望。

- 1) 通过模型压缩、轻量化设计和高效训练算法, 降低深度学习模型对计算资源的依赖。通过引入 Transformer 架构, 增强单一技术对时间依赖性特征的建模能力。结合自监督学习, 利用未标注数据, 模型能自主学习特征, 减少对大规模标注数据的依赖, 适应多样化的管道环境和泄漏模式。同时, 结合边缘计算技术, 在管道现场实现低延迟、高效率的实时泄漏检测。
- 2) 针对数据不平衡和信噪比低的问题, 利用 GAN 生成高质量的合成数据或进行时序数据增强, 扩充小泄漏样本, 提高模型在小样本条件下的泛化能力。同时优化 GAN 的生成稳定性和多样性。采用无监督或半监督方法, 让模型从未标注数据中自适应学习, 还能降低人工标注成本。
- 3) 利用跨模态注意力机制与图神经网络 (GNN) 进行跨模态特征对齐, 提高不同数据源的协同检测能力。借助物理模型, 将管道流体力学模型与深度学习相结合, 提高模型的物理一致性, 降低黑箱问题。采用数字孪生技术构建管道的实时仿真模型, 结合深度学习, 实现高精度预测与实时监测。

参考文献:

- [1] 杜颖, 李宏, 刘庆强, 等. PSO-VMD-SVD 的改进去噪方法研究 [J]. 吉林大学学报(信息科学版), 2021, 39(2): 142-151.
DU Y, LI H, LIU Q Q, et al. Research on Improved Method for Denoising of PSO-VMD-SVD [J]. Journal of Jilin University (Information Science Edition), 2021, 39(2): 142-151.
- [2] 杨丹迪, 路敬祎, 周怡娜, 等. 改进 VMD 算法在管道泄漏检测中的应用 [J]. 吉林大学学报(信息科学版), 2020, 38(4): 385-393.
YANG D D, LU J Y, ZHOU Y N, et al. Application of Improved VMD Algorithm in Pipeline Leakage Detection [J]. Journal of Jilin University (Information Science Edition), 2020, 38(4): 385-393.
- [3] 袁满, 高宏宇, 路敬祎, 等. 油气管道泄漏检测技术综述 [J]. 吉林大学学报(信息科学版), 2022, 40(2): 159-173.
YUAN M, GAO H Y, LU J Y, et al. Overview of Leakage Detection Technology for Oil and Gas Pipelines [J]. Journal of Jilin University (Information Science Edition), 2022, 40(2): 159-173.
- [4] 钟艳. 基于 CNN-LSTM 的复合神经网络在油田污水系统故障诊断中的应用 [J]. 吉林大学学报(信息科学版), 2024, 42(5): 817-828.
ZHONG Y. Application of Composite Neural Network Based on CNN-LSTM in Fault Diagnosis of Oilfield Wastewater System [J]. Journal of Jilin University (Information Science Edition), 2024, 42(5): 817-828.
- [5] 王新颖, 杨泰旺, 宋兴帅, 等. 城市燃气管道泄漏诊断方法 [J]. 消防科学与技术, 2018, 37(6): 834-838.
WANG X Y, YANG T W, SONG X S, et al. Leakage Diagnosis Method of Urban Gas Pipeline [J]. Fire Science and Technology, 2018, 37(6): 834-838.
- [6] WANG C, HAN F, ZHANG Y, et al. An SAE-Based Resampling SVM Ensemble Learning Paradigm for Pipeline Leakage Detection [J]. Neurocomputing, 2020, 403: 237-246.
- [7] 温江涛, 付磊, 孙洁娣, 等. 压缩感知结合卷积网络的天然气管道泄漏孔径识别 [J]. 振动与冲击, 2020, 39(21): 17-23.
WEN J T, FU L, SUN J D, et al. Recognition of Leakage Aperture of Natural Gas Pipeline Based on Compression Sensing and Convolution Network [J]. Journal of Vibration and Shock, 2020, 39(21): 17-23.
- [8] LIU P, XU C, XIE J, et al. A CNN-Based Transfer Learning Method for Leakage Detection of Pipeline under Multiple Working Conditions with AE Signals [J]. Process Safety and Environmental Protection, 2023, 170: 1161-1172.
- [9] ZADKARAMI M, SHAHBAZIAN M, SALAHSHOOR K. Pipeline Leakage Detection and Isolation: An Integrated Approach of Statistical and Wavelet Feature Extraction with Multi-Layer Perceptron Neural Network (MLPNN) [J]. Journal of Loss Prevention in the Process Industries, 2016, 43: 479-487.
- [10] KANG J, PARK Y J, LEE J, et al. Novel Leakage Detection by Ensemble CNN-SVM and Graph-Based Localization in Water Distribution Systems [J]. IEEE Transactions on Industrial Electronics, 2017, 65(5): 4279-4289.
- [11] LEE C W, YOO D G. Development of Leakage Detection Model and Its Application for Water Distribution Networks Using RNN-LSTM [J/OL]. Sustainability, 2021, 13(16): 9262 [2025-08-21]. <https://www.mdpi.com/2071-1050/13/16/9262>.
- [12] ABDEL-HAMID O, MOHAMED A, JIANG H, et al. Convolutional Neural Networks for Speech Recognition [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2014, 22(10): 1533-1545.
- [13] CAO J, CAO M, WANG J, et al. Urban Noise Recognition with Convolutional Neural Network [J]. Multimedia Tools and Applications, 2019, 78(20): 29021-29041.
- [14] 吴磊, 纪国宜. 卷积神经网络在在线结构健康监测中的应用 [J]. 噪声与振动控制, 2019, 39(4): 200-204.
WU L, JI G Y. Application of Convolutional Neural Network for On-Line Structural Health Monitoring [J]. Noise and Vibration Control, 2019, 39(4): 200-204.
- [15] SCHMIDHUBER J, HOCHREITER S. Long Short-Term Memory [J]. Neural Comput, 1997, 9(8): 1735-1780.
- [16] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks [J]. Communications of the ACM, 2020, 63(11): 139-144.
- [17] 王秀芳, 李月明. 基于 MSDS-CNN 的滚动轴承故障诊断方法 [J]. 吉林大学学报(信息科学版), 2022, 40(3): 354-361.
WANG X F, LI M Y. Bearing Fault Diagnosis Method Based on MSDS-CNN [J]. Journal of Jilin University (Information

- Science Edition), 2022, 40(3): 354-361.
- [18]王秀芳,崔琨雨. 管道泄漏检测传感器及应用综述[J]. 吉林大学学报(信息科学版), 2025, 43(2): 265-275.
WANG X F, CUI K Y. Overview of Pipeline Leakage Detection Sensors and Applications [J]. Journal of Jilin University (Information Science Edition), 2025, 43(2): 265-275.
- [19]ZHOU M, YANG Y, XU Y, et al. A Pipeline Leak Detection and Localization Approach Based on Ensemble TL1DCNN [J]. IEEE Access, 2021, 9: 47565-47578.
- [20]孙宗康,饶睦敏,曹裕灵,等. 基于小样本不平衡数据的供水管道泄漏智能检测算法[J]. 图学学报, 2022, 43(5): 825-831.
SUN K, RAO M M, CAO Y L, et al. Water Supply Pipeline Leakage Intelligent Detection Algorithm Based on Small and Unbalanced Data [J]. Journal of Graphics, 2022, 43(5): 825-831.
- [21]惠泽国,唐炳南. 基于深度学习的环保气体小泄漏检测技术[J]. 中国高新科技, 2024(9): 38-40.
HUI Z G, TANG B N. Small Leakage Detection Technology of Environmental Protection Gas Based on Deep Learning [J]. China High and New Technology, 2024(9): 38-40.
- [22]李哲,封皓,刘欣,等. 基于CNN的水管道小泄漏声信号识别[J]. 噪声与振动控制, 2021, 41(4): 66-72.
LI Z, FENG H, LIU X, et al. Acoustic Signal Identification of Small Leakage in Water Pipelines Based on CNN [J]. Noise and Vibration Control, 2021, 41(4): 66-72.
- [23]郑书闽,颜建国,郭鹏程,等. 基于VMD及深度学习的供水管道小尺度泄漏检测研究[J]. 水利学报, 2024, 55(8): 999-1008.
ZHENG S M, YAN J G, GUO P C, et al. Small-Scale Pipeline Leak Detection Based on VMD and Deep Learning [J]. Journal of Hydraulic Engineering, 2024, 55(8): 999-1008.
- [24]LI J, LIU Y, CHAI Y, et al. A Small Leakage Detection Approach for Gas Pipelines Based on CNN [C] // 2019 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS). [S. l.]: IEEE, 2019: 390-394.
- [25]LU N, XIAO H, SUN Y, et al. A New Method for Intelligent Fault Diagnosis of Machines Based on Unsupervised Domain Adaptation [J]. Neurocomputing, 2021, 427: 96-109.
- [26]谭震,郭新蕾,李甲振,等. 基于多尺度卷积神经网络的管道泄漏检测模型研究[J]. 水利学报, 2023, 54(2): 220-231.
TAN Z, GUO X L, LI J Z, et al. Multi-Scale Convolutional Neural Network Model for Pipeline Leak Detection [J]. Journal of Hydraulic Engineering, 2023, 54(2): 220-231.
- [27]MENG D, NING F, HAO M, et al. Efficient Convolutional Neural Networks with PWK Compression for Gas Pipelines Leak Detection [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-11.
- [28]ULLAH S, ULLAH N, SIDDIQUE M F, et al. Spatio-Temporal Feature Extraction for Pipeline Leak Detection in Smart Cities Using Acoustic Emission Signals: A One-Dimensional Hybrid Convolutional Neural Network-Long Short-Term Memory Approach [J/OL]. Applied Sciences, 2024, 14(22): 10339 [2025-08-21]. <https://www.mdpi.com/2076-3417/14/22/10339>.
- [29]SHIN Y, NA K Y, KIM S E, et al. LSTM-Autoencoder Based Detection of Time-Series Noise Signals for Water Supply and Sewer Pipe Leakages [J/OL]. Water, 2024, 16(18): 2631 [2025-08-21]. <https://www.mdpi.com/2073-4441/16/18/2631>.
- [30]ZHANG X, SHI J, YANG M, et al. Real-Time Pipeline Leak Detection and Localization Using an Attention-Based LSTM Approach [J]. Process Safety and Environmental Protection, 2023, 174: 460-472.
- [31]GUO P, ZHENG S, YAN J, et al. Leak Detection in Water Supply Pipeline with Small-Size Leakage Using Deep Learning Networks [J]. Process Safety and Environmental Protection, 2024, 191: 2712-2724.
- [32]曹韵奇,段天英,刘桂娟. 基于长短期记忆网络的钠冷快堆蒸汽发生器钠-水反应噪声探测技术研究[J]. 中国核电, 2024, 17(4): 461-467.
CAO Y Q, DUAN T Y, LIU G J. Study on Noise Detection of Sodium-Water Reaction in the Steam Generator of the Sodium Cooled Fast Reactor Based on Long-and Short-Term Memory [J]. China Nuclear Power, 2024, 17(4): 461-467.
- [33]RAJABI M M, KOMEILIAN P, WAN X, et al. Leak Detection and Localization in Water Distribution Networks Using Conditional Deep Convolutional Generative Adversarial Networks [J/OL]. Water Research, 2023, 238: 120012 [2025-08-

- 21]. <https://www.sciencedirect.com/science/article/abs/pii/S0043135423004487>.
- [34] CHEN K, LI H, LI C, et al. An Automatic Defect Detection System for Petrochemical Pipeline Based on Cycle-GAN and YOLO v5 [J/OL]. *Sensors*, 2022, 22(20): 7907 [2025-08-21]. <https://www.mdpi.com/1424-8220/22/20/7907>.
- [35] CHEN K, XIE K, WEN C, et al. Weak Signal Enhance Based on the Neural Network Assisted Empirical Mode Decomposition [J/OL]. *Sensors*, 2020, 20(12): 3373 [2025-08-21]. <https://www.mdpi.com/1424-8220/20/12/3373>.
- [36] 曹鹏宇, 杨承志, 石礼盟. 基于 DAE-GAN 网络的 LPI 雷达信号增强 [J]. *系统工程与电子技术*, 2021, 43(9): 2493-2500.
CAO P Y, YANG C Z, SHI L M. LPI Radar Singal Enhancement Based on DAE-GAN Network [J]. *Systems Engineering and Electronics*, 2021, 43(9): 2493-2500.
- [37] WANG Y, ZANG C, YU B, et al. WTE-CGAN Based Signal Enhancement for Weak Target Detection [J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 21: 1-5.
- [38] ZHAO Y, SU Z, ZHAO H. Micro-Leakage Image Recognition Method for Internal Detection in Small, Buried Gas Pipelines [J/OL]. *Sensors*, 2023, 23(8): 3956 [2025-08-21]. <https://www.mdpi.com/1424-8220/23/8/3956>.
- [39] GAO X, DENG F, YUE X. Data Augmentation in Fault Diagnosis Based on the Wasserstein Generative Adversarial Network with Gradient Penalty [J]. *Neurocomputing*, 2020, 396: 487-494.
- [40] HU X, ZHANG H, MA D, et al. Minor Class-Based Status Detection for Pipeline Network Using Enhanced Generative Adversarial Networks [J]. *Neurocomputing*, 2021, 424: 71-83.
- [41] ZHANG H, HU X, MA D, et al. Insufficient Data Generative Model for Pipeline Network Leak Detection Using Generative Adversarial Networks [J]. *IEEE Transactions on Cybernetics*, 2020, 52(7): 7107-7120.
- [42] SHANG R, DONG H, WANG C, et al. Imbalanced Data Augmentation for Pipeline Fault Diagnosis: A Multi-Generator Switching Adversarial Network [J/OL]. *Control Engineering Practice*, 2024, 144: 105839 [2025-08-21]. <https://www.sciencedirect.com/science/article/abs/pii/S0967066123004082>.
- [43] HU X, ZHANG H, MA D, et al. A TnGAN-Based Leak Detection Method for Pipeline Network Considering Incomplete Sensor Data [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 1-10.
- [44] 胡磊磊, 王新颖, 林振源, 等. 基于 DCGAN-1DCNN 的管道阀门内漏故障诊断研究 [J]. *工业安全与环保*, 2023, 49(12): 43-49.
HU L L, WANG X Y, LING Z Y, et al. Fault Diagnosis of Internal Leakage of Pipeline Valves Based on DCGAN and 1DCNN [J]. *Industrial Safety and Environment Protection*, 2023, 49(12): 43-49.
- [45] ZHANG E, ZHANG E. Development of A Multimodal Deep Feature Fusion with Ensemble Learning Architecture for Real-Time Gas Leak Detection [C] // 2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI). Mt Pleasant, MI, USA, 2024: 1-6.
- [46] WANG G, SU Y, LU M, et al. Multi-Modality Hierarchical Attention Networks for Defect Identification in Pipeline MFL Detection [J/OL]. *Measurement Science and Technology*, 2024, 35(11): 116107 [2025-08-21]. <https://iopscience.iop.org/article/10.1088/1361-6501/ad66f8>.
- [47] ZHANG H, GAO J, HONG B. Φ -OTDR Signal Identification Method Based on Multimodal Fusion [J/OL]. *Sensors*, 2022, 22(22): 8795 [2025-08-21]. <https://www.mdpi.com/1424-8220/22/22/8795>.
- [48] 刘志伟, 尚盈, 王晨, 等. 基于多维空间数据融合算法的分布式光纤振动管道泄漏监测技术 [J]. *激光与光电子学进展*, 2023, 60(9): 404-409.
LIU Z W, SHANG Y, WANG C, et al. Pipeline Leakage Monitoring Technology of Distributed Optical Fiber Vibration Based on Multi-Dimensional Spatial Data Fusion Algorithm [J]. *Laser & Optoelectronics Progress*, 2023, 60(9): 404-409.
- [49] YE L, WANG C, ZHOU X, et al. EMDet: An Entropy Blending and Multi-Link Parallel Feature Enhancement Detection Model for Gas Pipeline Weak Leakage Detection [J]. *Process Safety and Environmental Protection*, 2024, 186: 1580-1592.
- [50] NARKHEDE P, WALAMBE R, MANDAOKAR S, et al. Gas Detection and Identification Using Multimodal Artificial Intelligence Based Sensor Fusion [J/OL]. *Applied System Innovation*, 2021, 4(1): 3 [2025-08-21]. <https://www.mdpi.com/2571-5577/4/1/3>.
- [51] ATTALLAH O. Multitask Deep Learning-Based Pipeline for Gas Leakage Detection via E-Nose and Thermal Imaging Multimodal Fusion [J]. *Chemosensors*, 2023, 11(7): 364-364.
- [52] YAN W, LIU W, ZHANG Q, et al. Multisource Multimodal Feature Fusion for Small Leak Detection in Gas Pipelines [J]. *IEEE Sensors Journal*, 2023, 24(2): 1857-1865.