

DOI: 10.19650/j.cnki.cjsi.202311398

基于深度迁移学习的变工况气体泄漏检测*

张立豪^{1,2,3}, 李鹏^{1,2,3}, 刘轩宇^{1,2,3}

(1. 南京信息工程大学江苏省大气环境与装备技术协同创新中心 南京 210044; 2. 无锡学院自动化学院 无锡 214105;
3. 南京信息工程大学江苏省气象探测与信息处理重点实验室 南京 210044)

摘要:压力容器气体泄漏智能检测识别技术易受多种因素干扰,且智能检测模型需要大量的监测数据训练。而在实际工业环境中,可用数据特别是数据标签十分稀缺,为了克服多工况干扰和数据缺少标签信息等问题,提出了一种利用迁移学习的无监督变工况智能检测技术。首先采集实验室环境下的多种泄漏的样本,选择3种不同压力工况下将数据分为有标签的源域和无标签的目标域;其次设计卷积特征提取器,针对两个域的边缘分布和条件分布,提出一种改进的联合分布适应机制,并进一步改进了分布差异度量,以增强邻域混淆。在6个迁移学习任务上的实验结果验证了该方法的有效性,对比经典域自适应算法有更高的准确率。

关键词: 迁移学习;联合域自适应;变工况;泄漏检测

中图分类号: TP391 TH49 **文献标识码:** A **国家标准学科分类代码:** 460.40

Gas leak detection for variable conditions based on deep transfer learning

Zhang Lihao^{1,2,3}, Li Peng^{1,2,3}, Liu Xuanyu^{1,2,3}

(1. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science & Technology, Nanjing 210044, China; 2. College of Automation, Wuxi College, Wuxi 214105, China;
3. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: Pressure vessel gas leakage intelligent detection and identification techniques are susceptible to interference from a variety of factors, and intelligent detection models require a large amount of monitoring data training. In the actual industrial environment, available data, especially data labels, are very scarce. To address the problems such as interference from multiple working conditions and lack of labeling information of data, this article proposes an unsupervised variable working condition intelligent detection technique by using transfer learning. Firstly, samples of multiple leaks are collected in laboratory environment and select three different pressure working conditions to divide the data into labeled source domain and unlabeled target domain. Secondly, a convolutional feature extractor is designed to propose an improved joint distribution adaptation mechanism for the edge distribution and conditional distribution of the two domains, and further improve the distribution difference metric to enhance the neighborhood confusion. Experimental results on six transfer learning tasks validate the effectiveness of the method, with higher accuracy than the classical domain adaptive algorithm.

Keywords: transfer learning; joint domain adaptive; variable operating condition; leak detection

0 引言

现代化工产业在气体产生、存储过程中多采用压力管道和容器。压力管道和容器一旦出现材料制造缺陷、

腐蚀和损伤等问题,将产生气体泄漏。如果泄漏气体易燃、易爆和有毒等危险存在,易对人的生命和财产、生态环境造成灾难性后果。用于检测压力管道和容器的传感器和设备类型,主要可分为:声学方法、光学方法、化学组分分析和光纤传感器等^[1]。在实际环境存在大量不确

定性背景噪声,信号频率在可听声范围内,一般的声学方法容易受到其他环境声信号干扰而发生虚警。而声学的超声检测法^[2-3]可以有效滤除大部分可听声频段内的噪声干扰,并且可以有效检测微小泄漏,随着信号处理、机器学习等技术发展,利用超声信号的检测泄漏方法逐渐成熟。近年来,以数据为驱动的深度学习方法在故泄漏检测领域成为了一个研究热点,也开始大量应用深度学习模型进行智能检测^[4]。不过传统机器学习或深度学习模型在泄漏检测中的良好性能是建立在数据标签丰富,且训练数据和测试数据独立同分布的假设上^[5-8]。在工程实际中,由于压力容器在运行中不容易获取到标签信息丰富的泄漏数据,且处于不同运行压力下,泄漏声信号会产生明显的分布差异。

近年来,深度迁移学习(deep transfer learning, DTL)受到国内外学者的广泛关注与研究,在机器视觉、自然语言处理、故障诊断领域^[9-11]有较多的应用。该方法旨在运用已有的知识对不同但相关领域问题进行求解,缩小已有领域和未知领域之间的数据分布差异。

通常,DTL将有标签的训练样本称为源域,没有标签测试样本称为目标域,通过域自适应(domain adaptation, DA)减少两个域之间的分布差异,并学习域不变特征。将DTL的思想应用于智能检测领域,其核心思路是,将不同工况即不同压力值下的数据集视为不同的领域,利用域自适应的方法将不同域的特征分布对齐,接着将在源域有标签的数据上训练好的分类器用于目标域无标签数据识别,最终实现智能检测。主流的DA方法可以分为基于对齐机制^[12-14]和基于对抗机制^[15-16]的。其中基于对齐方法只关注了目标域和源域之间的边缘分布对齐(marginal distribution alignment, MDA),而忽略了两个域的同类的条件分布对齐(conditional distribution alignment, CDA)。为了增强DA效果,Long等^[17]提出了联合分布适应(joint distribution adaptation, JDA),同时结合了MDA和CDA,但研究的条件概率分布被类条件概率分布近似取代,一定程度上影响了域混淆的性能。

通过上述分析,本文基于实验室采集的泄漏信号,通过有丰富的标签数据构建深度迁移模型去识别无标签下变压力工况下的泄漏信号。该方法将源域和目标域的频域信息通过一个卷积网络特征提取模块获得特征空间,利用所提改进的联合分布适应(improved joint distribution adaptation, IJDA)来对齐特征。在IJDA中,将CORAL^[13]和MMD^[12]结合起来作为一种新的分布差异度量(distribution discrepancy metric, DDM)来增强域混淆,以此形成深度迁移检测模型。本文利用实验室采集标签信息丰富的数据去识别变工况下未知标签的泄漏信号;提出IJDA机制

更好地对齐两个域的真实条件概率分布,设计DDM距离进一步减小分布差异。

1 基础理论

1.1 迁移学习

迁移学习主要用于解决源域和目标域数据分布不同和目标域数据缺少标签信息的问题。不同工况下的检测是从一组带标签的源域数据学到的分类参数通过迁移,应用到另一组未带标签的目标域数据。假设在实验室环境下,通过压力容器泄漏采集到泄漏信号 $\{\mathbf{x}_i^s, \mathbf{y}_i^s\}_{i=1}^{n_s}$,包含 n_s 个样本。 $\mathbf{y}_i^s \in \mathbf{Y}$ 为样本 $\mathbf{x}_i^s$ 的标签空间,其中 $\mathbf{Y} = \{1, 2, \dots, k\}$,含有 k 个标签。样本 $\mathbf{x}_i^s$ 属于样本空间 $\mathbf{X}^s$,数据生成服从边缘概率分布 $P(\mathbf{X}^s)$ 。再采集变工况下泄漏数据 $\{\mathbf{x}_i^t\}_{i=1}^{n_t}$,其中包含 n_t 个待打标的样本。由于采集信号的压力容器压力设置不一样,因此两者之间数据分布存在差异,从统计角度上分析,变工况泄漏数据 $\mathbf{x}_i^t \in \mathbf{X}^t$ 服从边缘概率分布 $Q(\mathbf{X}^t)$,且 $Q \neq P$ 。结合迁移学习术语^[18],本文中源域 $\mathbf{D}^s = \{\mathbf{X}^s, P(\mathbf{X}^s)\}$,是带有标签信息,为跨域识别提供迁移知识的。目标域 $\mathbf{D}^t = \{\mathbf{X}^t, P(\mathbf{X}^t)\}$ 是由无标签的变工况泄漏数据组成,是源域迁移知识的应用对象。通过由源域的样本空间 $\mathbf{X}^s$ 到标签空间 $\mathbf{Y}^s$ 的非线性映射关系 $f: \mathbf{X}^s \rightarrow \mathbf{Y}^s$,即为获取迁移知识。不过由于两域之间存在较大的分布差异,源域的迁移知识 f 不能准确识别目标域的无标签样本,此时如图1所示,构建分布适配,对齐源域和目标域之间的数据分布,使得源域迁移知识 f 可以识别到目标域的无标签样本。




图1 域适配示意图

Fig. 1 Domain adaptation diagram

1.2 联合分布适应

文献[17]将JDA定义为MDA(即 $P(\mathbf{X}^s) = Q(\mathbf{X}^t)$)和CDA($P(\mathbf{Y}^s | \mathbf{X}^s) = Q(\mathbf{Y}^t | \mathbf{X}^t)$)的组合。JDA的优化目标是学习一种特征表示 T ,要使两个域的边缘分布和条件分布的差异显著减小。从形式上来说,JDA是用 $P(\mathbf{X}^s)$ 和 $Q(\mathbf{X}^t)$ 之间的距离,以及 $P(\mathbf{Y}^s | \mathbf{X}^s)$ 和 $Q(\mathbf{Y}^t | \mathbf{X}^t)$ 之间的距离来近似两个领域之间的差异。假设类条件概率分布 $P(\mathbf{Y} | \mathbf{X})$ 等于条件概率分布

$P(\mathbf{X} | \mathbf{Y})$, 定义 JDA 的目标函数 L_{JDA} 为:

$$L_{JDA} = \| E_{P(\mathbf{X}^s)} [T(\mathbf{X}^s)] - E_{P(\mathbf{X}^t)} [T(\mathbf{X}^t)] \|^2 + \sum_{c=1}^C \| E_{P(\mathbf{X}^s | \mathbf{Y}^s=c)} [T(\mathbf{X}^s) | \mathbf{Y}^s=c] - E_{P(\mathbf{X}^t | \mathbf{Y}^t=c)} [T(\mathbf{X}^t) | \mathbf{Y}^t=c] \|^2 \quad (1)$$

其中, $P(\mathbf{Y}^t | \mathbf{X}^t)$ 由标记源域的迁移知识估计, 即打上伪标签, C 表示类别数量。

为了克服式(1)中 CDA 近似的负面影响, 提出改进的 CDA 来对齐两个域的条件概率分布。利用贝叶斯定理, 可以将条件概率分布转化为类条件概率分布的形式, 表示为:

$$P(\mathbf{Y} = c | \mathbf{X}) = \frac{P(\mathbf{Y} = c) \cdot P(\mathbf{X} | \mathbf{Y} = c)}{P(\mathbf{X})} \quad (2)$$

类条件概率分布 $P(\mathbf{X} | \mathbf{Y} = c)$ 可根据文献[17] 计算, $P(\mathbf{Y} = c)$ 表示类先验分布可计算为:

$$\begin{cases} P(\mathbf{Y}^s = c) = n_s^c / \sum_{i=1}^C n_s^i \\ P(\mathbf{Y}^t = c) = n_t^c / \sum_{i=1}^C n_t^i \end{cases} \quad (3)$$

其中, n_s^c 和 n_t^c 分别表示源域和目标域第 C 个类别的批次, 即:

$$\begin{cases} \sum_{c=1}^C n_s^c = n_s \\ \sum_{c=1}^C n_t^c = n_t \end{cases} \quad (4)$$

MDA 的目标是对齐边缘概率分布, 即 $P(\mathbf{X}^s) = P(\mathbf{X}^t)$ 。通过式(2)得改进的 CDA 机制表示为:

$$L_{CDA} = \sum_{c=1}^C \| E_{P(\mathbf{X}^s | \mathbf{Y}^s=c)} [T(\mathbf{X}^s) | \mathbf{Y}^s=c] P(\mathbf{Y}^s = c) - E_{P(\mathbf{X}^t | \mathbf{Y}^t=c)} [T(\mathbf{X}^t) | \mathbf{Y}^t=c] P(\mathbf{Y}^t = c) \|^2 \quad (5)$$

然后, 通过改进的 CDA 机制结合 MDA 机制, 最终的 IJDA 机制可以定义为:

$$L_{IJDA} = \| E_{P(\mathbf{X}^s)} [T(\mathbf{X}^s)] - E_{P(\mathbf{X}^t)} [T(\mathbf{X}^t)] \|^2 + \sum_{c=1}^C \| E_{P(\mathbf{X}^s | \mathbf{Y}^s=c)} [T(\mathbf{X}^s) | \mathbf{Y}^s=c] P(\mathbf{Y}^s = c) - E_{P(\mathbf{X}^t | \mathbf{Y}^t=c)} [T(\mathbf{X}^t) | \mathbf{Y}^t=c] P(\mathbf{Y}^t = c) \|^2 \quad (6)$$

1.3 分布度量

在迁移学习中, 用度量来衡量两个数据域的差异, 定义 IJDA 机制后, 需要找到一个分布距离度量来评估式(6)中的边缘分布和条件分布差异。由于采集的泄漏信号存在有大量的随机噪声, 收集到的声信号近似服从包含两个估计参数(均值和方差)的高斯分布。因此, 为了更好地实现 IJDA 机制, 同时进一步增强域混淆能力, 下面将对两个分布差异指标进行改进。

最大均值差异(maximum mean discrepancy, MMD)是迁移学习中最常用的衡量两个域分布差异的距离度量, 定义为:

$$MMD(\mathbf{X}^s, \mathbf{X}^t) = \left\| \frac{1}{n_s} \sum_{\mathbf{x}^s \in \mathcal{D}^s} \Phi(\mathbf{x}^s) - \frac{1}{n_t} \sum_{\mathbf{x}^t \in \mathcal{D}^t} \Phi(\mathbf{x}^t) \right\|_H^2 \quad (7)$$

式中: n_s 和 n_t 分别表示源域样本和目标域特征的小批次; $\| \cdot \|_H$ 表示再生核希尔伯特空间(reproducing kernel Hilbert space, RKHS); $\Phi(\cdot)$ 表示映射函数将特征空间投影到 RKHS 中。在实际应用中用核函数代替映射函数即核技巧, 本文使用高斯核作为核函数。

类似于 MMD 对齐 RKHS 中源域和目标域的平均值一样, 相关对齐(correlation alignment, CORAL)的目的是匹配数据的二阶协方差统计量:

$$CORAL(\mathbf{X}^s, \mathbf{X}^t) = \frac{1}{4d^2} \| \mathbf{Cov}_s - \mathbf{Cov}_t \|_F^2 \quad (8)$$

式中: $\| \cdot \|_F$ 表示 F 范数; $\mathbf{Cov}_s$ 和 $\mathbf{Cov}_t$ 表示协方差度量。

$$\begin{cases} \mathbf{Cov}_s = \frac{1}{n_s - 1} (\mathbf{D}^s \mathbf{D}^{sT} - \frac{1}{n_s} (\mathbf{I}^T \mathbf{D}^s)^T (\mathbf{I}^T \mathbf{D}^s)) \\ \mathbf{Cov}_t = \frac{1}{n_t - 1} (\mathbf{D}^t \mathbf{D}^{tT} - \frac{1}{n_t} (\mathbf{I}^T \mathbf{D}^t)^T (\mathbf{I}^T \mathbf{D}^t)) \end{cases} \quad (9)$$

式中: $\mathbf{I}$ 是一个所有元素都为 1 的行向量。

本文将特征提取后高维特征空间的均值差值度量 MMD 和协方差度量 CORAL 组合为新的分布差异指标 DDM(A, B):

$$DDM(\mathbf{A}, \mathbf{B}) = MMD(\mathbf{A}, \mathbf{B}) + CORAL(\mathbf{A}, \mathbf{B}) \quad (10)$$

将设计的 DDM 度量引入 IJDA 机制, 最终的 IJDA 损失函数可以改写为:

$$L_{IJDA} = DDM(T(\mathbf{X}^s), T(\mathbf{X}^t)) + \sum_{c=1}^C DDM[P(\mathbf{Y}^s = c) \cdot (T(\mathbf{X}^s) | \mathbf{Y}^s = c), P(\mathbf{Y}^t = c) \cdot (T(\mathbf{X}^t) | \mathbf{Y}^t = c)] \quad (11)$$

2 泄漏检测深度迁移学习模型

2.1 总体框架

本文算法原理如图 2 所示, 其整体诊断流程步骤如下:

1) 获取压力容器不同运行压力下的声信号数据, 选定 0.5 MPa 下的数据为源域, 其他压力下的数据为目标域, 其中源域数据是带标签的, 目标域数据是不带标签的。

2) 对原始时域数据做傅里叶变换得到频域数据, 将数据划分为训练数据和测试数据, 其中源域数据和 50% 的目标域数据参与训练, 构建以卷积神经网络为特征提取器的深度迁移学习模型。

- 3) 用训练数据对模型训练,根据本文所提改进的 IJDA 机制适配两个域,即找到特征表示 T 和分布度量 DDM。
- 4) 重复步骤 3), 到给定的迭代次数, 得到训练好的模型。
- 5) 用目标域数据测试训练好的模型, 得到检测结果, 并对模型的训练结果进行可视化分析。




图 2 算法原理

Fig. 2 Algorithm schematic

2.2 卷积神经网络(CNN)设计

本文采用 CNN 结构如图 3 所示。模型的输入是由采集到的泄漏声信号分帧后做傅里叶变换得到的频域信号。相比于时域信号,由于泄漏产生超声的特点,超声高频段可以滤去大部分现实场景的低频噪声。CNN 具有较强的特征学习能力,因此采用 CNN 作为特征提取器。网络参数如表 1 所示。由表 1 可知,该特征提取器包含 5 个 Conv1D 块,一个全局平均池化层(global average pooling, GAP)和两个全连接层(fully connected, FC)。

每个 Conv1D 块由一维卷积层、批归一化层(batch normalization, BN)和最大池化层组成。其中 GAP 和 BN 可以加速网络收敛,缓解过拟合现象。

2.3 全局损失

所提出的模型有两个优化目标:无监督训练优化 IJDA 损失,监督训练优化 Softmax 损失。

交叉熵损失应用于有标签的源域,用于学习分类特征。在迁移学习任务中,通过打伪标签的方式将 Softmax 损失应用于目标域样本。因此,整个分类损失定义为:

$$L_w = L_s + \mu L_T \tag{12}$$

式中: L_s 和 L_T 分别表示源域 Softmax 损失和目标域

表 1 特征提取网络详细参数

Table 1 Feature extraction network detailed parameters			
层类型	层结构	通道数/核尺寸/步长	输入尺寸
Conv1D_1	Conv1D	32/64/16	(1 024, 1)
	BN	—	
	最大池化	32/2/2	
Conv1D_2	Conv1D	64/3/1	(32, 32)
	BN	—	
	最大池化	64/2/2	
Conv1D_3	Conv1D	128/3/1	(16, 64)
	BN	—	
	最大池化	128/2/2	
Conv1D_4	Conv1D	256/3/1	(8, 128)
	BN	—	
	最大池化	256/2/2	
Conv1D_5	Conv1D	512/3/1	(4, 256)
	BN	—	
	最大池化	512/2/2	
	GAP	—	
FC1	1/ * /512	512	512
FC2	1/ * /5	512	5




图3 模型结构

Fig.3 Model architecture

Softmax 损失; μ 是权衡参数。将 IJDA 损失和 Softmax 损失相加, 全局损失为:

$$L_{all} = L_W + \lambda L_{IJDA} \quad (13)$$

其中, λ 为权衡参数, 利用 Adam 优化器更新训练参数, 最终本文模型将具有域不变和更多可分离特征。

3 实验验证

3.1 实验数据采集

在实验室搭建压力容器气体泄漏实验平台, 如图 4 所示。

实验平台主要包括一台 13 kW 的空气压缩机, 用于产生气体; 一个 20 L 容量的压力容器, 用于储存气体; 精调气压阀用于控制打开泄气阀时气体压力的调整, 最大支持表压 1.5 MPa, 实验表压在 0.8 MPa 以下; 气体流量计用于量化不同孔径气体泄漏的量级; 一组可拆卸安装拥有不同尺寸的圆形泄漏孔, 用于模拟不同程度的气体泄漏; 8 通道传感器圆形阵列选用杭州兆华声学传感器 CRY343, 其性能指标如表 2 所示, 由于气体泄漏时的超声特性, 对传感器的频响范围、灵敏度参数要求较高; 采集设备使用 NI 公司的 PXI5172 采集




图4 压力容器气体泄漏实验平台

Fig.4 Pressure vessel gas leakage test platform

设备, 可实现多通道实时同步采集, 满足皮秒级的混合信号采集。

根据文献[19-20]可知, 泄漏信号频谱主要集中在 30~100 kHz 的超声范围, 而本文设定的泄漏孔径和压力条件下主要集中在 40 kHz 左右。因此采集卡设置采样率为 500 kHz, 5 倍以上频程保证信号的质量。在实际采集阶段, 如图 5 所示, 将传感器设置在距离漏源 200 cm

表 2 传感器参数
Table 2 Sensor parameters

型号	灵敏度 /(mV·Pa ⁻¹)	±3 dB 频响/Hz	动态范围 /dB
CRY343	4	4~90 000	25~164



图 5 模拟泄漏信号采集
Fig. 5 Analog leak signal collection

的位置,将减压阀的压力控制在 0.4、0.5、0.6 MPa 用来模拟变工况下的产生泄漏时的声波。现场实际下,一个运行中的低压压力容器处于不断充放气状态下,其运行压力会有 0.1 MPa 的误差,所以本文选用 0.5 MPa 压力信号作为源域,0.4 和 0.6 MPa 压力下信号作为目标域。选用 0.2、0.4、0.6、0.8、1.0 mm 这 5 种不同的圆型穿孔模拟实际情况下的压力容器缺陷泄漏的不同严重程度。

采集数据划分成 A、B、C 3 个数据集,如表 3 所示。对于采集的信号分帧后,取 2 048 个点的时域数据,做傅里叶变换后取单边频谱即数据集每条样本长度为 1 024 个数据点。每类泄漏采集 1 196 条,每个子数据集有 5 980 条样本。将 5 种泄漏孔径的标签设为 0、1、2、3、4,每类标签的样本数为 1 196 条,同时对源域的标签记为 S_0,⋯,S_4,目标域的标签为 T_0,⋯,T_4。

实验共有 A、B、C 3 个数据集,以这 3 种变压力数据为基础,设置以下 6 种迁移任务 A→B、A→C、B→A、B→C、C→A 和 C→B,以 A→C 为例,“A”和“C”分别表示标记的源域和未标记的目标域,其时域和频域如图 6 所示。本文训练集包括源域和目标域样本,而测试集只包括目标域样本。考虑到伪标签不等于真实标签,将权衡参数 μ 设为 $\mu = 0.1\lambda$,该设置能够平衡训练过程中 IJDA 损失和目标域 Softmax 损失。优化器为 Adam,学习率设置为 0.001。训练 epoch 设置为 100, Batch size 设置为 256。本文在 Windows10 操作系统,32 G 内存, CPU 为 AMD R9-5900HS 的计算机平台上,通过 Python 3.8.13, Pytorch 1.13.0 框架实现本文所提算法。

表 3 变工况数据集
Table 3 Variable condition data set

名称	泄漏孔径/mm	泄漏压力/MPa	样本数
A	0.2	0.4	5 980
	0.4		
	0.6		
	0.8		
	1.0		
B	0.2	0.5	5 980
	0.4		
	0.6		
	0.8		
	1.0		
C	0.2	0.6	5 980
	0.4		
	0.6		
	0.8		
	1.0		

3.2 迁移任务测试

本文针对分类任务模型性能评估指标有准确率 (accuracy)、精确率 (precision)、召回率 (recall) 和平衡 F 分数 (F1_score),其公式如下:

$$\begin{aligned} accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \\ precision &= \frac{TP}{TP + FP} \\ recall &= \frac{TP}{TP + FN} \\ F1_score &= \frac{2 \times precision \times recall}{precision + recall} = \\ &= \frac{2TP}{2TP + FP + FN} \end{aligned} \tag{14}$$

式中: TP 表示将正样本预测为正类个数; FP 表示将负样本预测为正类个数; FN 表示将正样本预测为负类个数; TN 表示将负样本预测为负类个数。因此 F1_score 是综合了精确率和召回率的计算结果,用于最终评估模型对各个类别的性能, F1_score 越大说明模型质量越高。

首先发现大多数的运用迁移学习的故障诊断研究都是使用的时域振动信号,而本文的泄漏声学信号由于超声的特殊性,使用频域信号。下面通过本文设置的 6 个




图 6 A 和 C 数据集时域和频域图

Fig. 6 A and C data time-domain and frequency-domain




图 7 不同输入下的测试精度


Fig. 7 Test accuracy with different inputs

迁移任务的实验验证了频域比时域具有更高的准确率,实验结果如图 7 所示。

本文在 6 个任务里选取的域差异最大的两个任务,即 $A \rightarrow C$ 和 $C \rightarrow A$ 。两种任务的准确率和验证集上损失值的变化曲线如图 8 所示,这里的损失值是全局损失。从图 8 可以看出, $A \rightarrow C$ 是训练难度较大的任务,由于目标域是无标签数据,损失值的波动是较大的,不过在 60 轮之后,曲线逐渐收敛。

为了进一步检验本文方法的有效性和优越性,本文比较了 5 种经典的 DA 模型·MK-MMD^[21]、CORAL^[13]、JMMD^[14]、CDAN^[16] 和 DANN^[15]。其中 MK-MMD, CORAL, JMMD 是基于距离度量的 DA 模型, CDAN 和 DANN 是基于域对抗机制的 DA 模型。

图 9 及表 4 所示为本文方法与经典域适应方法的比较,每种方法在每个迁移任务中实验 5 次,因此使用准确率的平均值和 F1 分数平均值来评估最终的性能。在表 4 中列出了平均准确率和 F 分数,AVG 为所有迁移任务评价指标的平均值。可以看到在 $A \rightarrow B$ 、 $B \rightarrow A$ 、 $A \rightarrow C$ 、 $C \rightarrow A$ 这 4 个域差异不大的任务上,本文方法对比其他方法






图 8 训练过程准确率和损失值曲线

Fig. 8 Training process accuracy and loss curves

有更高的准确率,而在 $A \rightarrow C$ 和 $C \rightarrow A$ 这两个域差异较大的任务中,其他方法均出现了明显的负迁移的现象,而本文方法与其他方法相比提升巨大。




图 9 不同 DA 模型的准确性比较

Fig. 9 Accuracy comparison of different DA models

表 4 不同模型的实验结果

Table 4 Experimental results of different models

迁移任务	MK-MMD	CORAL	JMMD	CDAN	DANN	本文方法
	准确率/F1 分数	准确率/F1 分数	准确率/F1 分数	准确率/F1 分数	准确率/F1 分数	准确率/F1 分数
$A \rightarrow B$	99.16/99.1	78.85/78.36	99.33/99.13	73.83/73.55	98.49/98.45	99.85/99.85
$A \rightarrow C$	51.51/51.1	35.54/34.10	50.25/50.22	51.22/51.04	66.25/65.77	93.73/93.65
$B \rightarrow C$	90.22/90.13	65.89/64.96	97.66/97.64	69.57/69.19	97.16/97.06	99.30/99.30
$B \rightarrow A$	99.50/99.46	95.32/95.11	99.92/99.92	99.92/99.89	99.50/99.46	99.92/99.92
$C \rightarrow A$	39.80/38.65	39.21/39.06	58.70/58.10	43.23/42.11	61.54/61.44	97.26/97.16
$C \rightarrow B$	92.31/92.28	69.90/69.88	98.50/98.50	93.65/93.52	97.07/96.84	99.11/99.11
AVG	78.75/78.45	64.12/63.57	84.04/83.92	71.90/71.55	86.67/86.50	98.20/98.17

对比经典的对齐方法和基于对抗的方法,本文提出方法均具有最高的准确率,平均准确率超过了 90%,F1 分数也是优于其他模型,且 F1 分数综合考虑了模型查准率和查全率的计算结果,F1 分数越高说明模型质量越高。表 4 结果说明本文方法具有较优的泛化能力和鲁棒性。

此外,为了证明 IJDA 和 DDM 度量的有效性,进行了消融实验。对比了修改前的 JDA 算法和分别采用 IJDA (MMD)、IJDA (CORAL) 和 IJDA (JMMD) 进行迁移实验。实验结果如图 10 所示。可以看到改进的 IJDA 机制对比 JDA 提升巨大,说明本文优化的两个域之间的条件概率分布起到了效果。在差异分布度量上,MMD、CORAL 和 JMMD 的表现相似,本文选择结合两者表达构成 DDM 起到了效果提升,说明有效的增强了域混淆能力。在 $A \rightarrow C$ 和 $C \rightarrow A$ 这两个域差异大的迁移任务中,本文提出的改进度量距离 DDM 有效的度量了两个域的距离,结合 IJDA 使两个域的特征空间更好对齐,带来了准确率的提升。




图 10 消融实验结果

Fig. 10 Diagram of ablation experiments results

为了直观显示提出方法的有效性,利用 t-分布领域嵌入 (t-distribution stochastic neighbor embedding, t-SNE) 算法^[22]将本文模型和对比模型的输出特征降维映射到二维平面,并以散点图呈现。对于域差异较大的 $A \rightarrow C$ 任务,5 个模型及输入的原始数据的 t-SNE 映射如图 11 所示。可以看到对比算法在这个任务上通过迁移知识只能区分出较少的类,且类间距离比较小,混杂在一起。提出

的方法不仅可以区分出所有的类,并且保证了一定的类间距离。通过和原始数据分布比较,提出方法通过领域适配,将迁移特征的分布由 0.4 MPa 压力向 0.6 MPa 压力迁移,放大了泄漏气体声信号中隐含的相似特征信息,而抑制了差异性信息对智能检测过程的影响,使得实验室的变压力泄漏迁移知识能够识别气体泄漏不同量级,直观地解释了提出方法的有效性。




图 11 不同 DA 模型的特征 t-SNE 映射图

Fig. 11 The t-SNE mappings of features obtained by different DA models

4 结 论

本文提出了一种利用迁移学习领域自适应技术无监督学习的变工况压力容器气体泄漏检测技术。解决了工业环境因标签稀缺可用数据较少且多工况干扰而导致训练智能模型对实际泄漏情况识别泛化性低的问题并得出以下结论。

1) 提出了气体泄漏的迁移检测方法。在实际工业环境监测数据无健康标记信息,且难以有效训练智能诊断模型时,仍能迁移检测知识识别压力容器气体泄漏的量级。该方法在六个迁移任务中平均准确率超过 90%,并相较于同类表现最好的迁移方法,提出方法的诊断精度提高了 11.95%。

2) 提出了改进的 IJDA 机制,以及在该机制中 DDM 分布差异度量相较于原始 JDA 机制使源域和目标域的分

参考文献

[1] 尹渊博,袁辰,杜荟敏,等. 基于扰动响应的输油管道泄漏检测方法[J]. 振动与冲击, 2022, 41(23): 43-50.
YIN Y B, YUAN CH, DU H M, et al. Leakage detection method of oil pipeline based on disturbance response[J]. Journal of Vibration and Shock, 2022, 41(23): 43-50.
[2] LIAO P, CAI M. Study on compressed air leak detection using ultrasonic detection technology and instrument[C]. 2011 6th IEEE Conference on Industrial Electronics and

- Applications, IEEE, 2011.
- [3] 刘轩宇, 李鹏, 张立豪, 等. 联合 TCT 和 W-SpSF 的气体泄漏定位[J]. 电子测量与仪器学报, 2023, 37(5): 215-222.
- LIU X Y, LI P, ZHANG L H, et al. Gas leak location using TCT and W-SpSF [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (5): 215-222.
- [4] HU Z, TARIQ S, ZAYED T. A comprehensive review of acoustic based leak localization method in pressurized pipelines [J]. Mechanical Systems and Signal Processing, 2021, 161: 107994.
- [5] 孙洁娣, 王利轩, 温江涛, 等. 改进稠密块轻量化神经网络的管道泄漏孔径识别[J]. 仪器仪表学报, 2022, 43(3): 98-108.
- SUN J D, WANG L X, WEN J T, et al. Pipeline leakage aperture recognition based on lightweight neural network with the improve dense block [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 98-108.
- [6] 宁方立, 韩鹏程, 段爽, 等. 基于改进 CNN 的阀门泄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.
- [7] NING F, CHENG Z, MENG D, et al. Enhanced spectrum convolutional neural architecture: An intelligent leak detection method for gas pipeline[J]. Process Safety and Environmental Protection, 2021, 146: 726-735.
- [8] 陈里里, 何颖, 董绍江. 基于深度神经网络的液压泵泄漏状态识别[J]. 仪器仪表学报, 2020, 41(4): 86-94.
- CHEN L L, HE Y, DONG SH J. Recognition of hydraulic pump leakage status based on deep neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 86-94.
- [9] ZHANG Q, YANG Q, ZHANG X, et al. A multi-label waste detection model based on transfer learning[J]. Resources, Conservation and Recycling, 2022, 181: 106235.
- [10] 温江涛, 王涛, 孙洁娣, 等. 基于深度迁移学习的复杂环境下油气管道周界入侵事件识别[J]. 仪器仪表学报, 2019, 40(8): 12-19.
- WEN J T, WANG T, SUN J D, et al. Perimeter intrusion event identification of oil and gas pipelines under complex conditions based on deep transfer learning[J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 12-19.
- [11] 黄星华, 吴天舒, 杨龙玉, 等. 一种面向旋转机械的基于 Transformer 特征提取的域自适应故障诊断[J]. 仪器仪表学报, 2022, 43(11): 210-218.
- HUANG X H, WU T SH, YANG L Y, et al. Domain adaptive fault diagnosis based on Transformer feature extraction for rotating machinery[J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 210-218.
- [12] BORGWARDT K M, GRETTON A, RASCH M J, et al. Integrating structured biological data by kernel maximum mean discrepancy[J]. Bioinformatics, 2006, 22(14): 49-57.
- [13] SUN B, SAENKO K. Deep coral: Correlation alignment for deep domain adaptation[C]. Computer Vision-ECCV 2016 Workshops, Springer International Publishing, 2016: 443-450.
- [14] LONG M, ZHU H, WANG J, et al. Deep transfer learning with joint adaptation networks[C]. International Conference on Machine Learning, 2017: 2208-2217.
- [15] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. The Journal of Machine Learning Research, 2016, 17(1): 2030-2096.
- [16] LONG M, CAO Z, WANG J, et al. Conditional adversarial domain adaptation[J]. Advances in Neural Information Processing Systems, 2018, 31(1): 1640-1650.
- [17] LONG M, WANG J, DING G, et al. Transfer feature learning with joint distribution adaptation [C]. Proceedings of the IEEE International Conference on Computer Vision, 2013: 2200-2207.
- [18] TAN C, SUN F, KONG T, et al. A survey on deep transfer learning [C]. Artificial Neural Networks and Machine Learning-ICANN 2018: 27th International Conference on Artificial Neural Networks. Springer International Publishing, 2018: 270-279.
- [19] WANG T, PEI Y, XIAO H H, et al. Detection of small gas leaks based on neural networks and D-S evidential

- theory using ultrasonics [J]. *Insight-Non-Destructive Testing and Condition Monitoring*, 2014, 56 (4): 189-194(6).
- [20] LONG M, CAO Y, WANG J, et al. Learning transferable features with deep adaptation networks[C]. *International Conference on Machine Learning*, 2015: 97-105.
- [21] GUO X, TAN W, LIU L, et al. Experimental study of liquefied gas dynamic leakage behavior from a pressurized vessel[J]. *Process Safety and Environmental Protection*, 2021, 151(1): 20-27.
- [22] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008(9): 2579-2605.

作者简介



张立豪,2019年于南京大学获得学士学位,现为南京信息工程大学硕士研究生,主要研究方向为信号处理,故障诊断。

E-mail: 1205420359@ qq. com

Zhang Lihao received his M. Sc. degree from Nanjing University in 2019, Now he is currently a M. Sc. candidate at Nanjing University of Information Science &

Technology. His main research interests include signal processing, and fault diagnosis.



李鹏(通信作者),1990年于南京理工大学获得学士学位,2003年于中国矿业大学获得硕士学位,2008年于西安交通大学获得博士学位,现为南京信息工程大学教授,无锡学院自动化学院院长,主要研究方向为超声检测与成像技术、信号与信息处理、气象要素检测方法和仪器装备。

E-mail: lipengdey@ nuist. edu. cn

Li Peng (Corresponding author) received his B. Sc. degree from Nanjing University of Science and Technology in 1990, M. Sc. degree from China University of Mining and Technology in 2003, and Ph. D. degree from Xi'an Jiaotong University in 2008, respectively. He is currently a professor at Nanjing University of Nanjing University of Information Science & Technology and the dean of Automation School of Wuxi College. His main research interests include ultrasonic detection and imaging, signal and information processing and meteorological element measurement methods and instruments.