

DOI: 10.13382/j.jemi.B2306511

基于 FCN 的阀门内泄漏声发射信号识别方法

张 杰 陈世利

(天津大学精密测试技术及仪器国家重点实验室 天津 300072)

摘 要:针对石化工业中输气管道阀门的内泄漏故障,将声发射检测技术与深度学习技术相结合,提出了一种基于全卷积神经网络(FCN)的阀门内泄漏声发射信号识别方法。该方法利用声发射技术采集阀门内泄漏的声发射信号,基于 FCN 搭建阀门内泄漏分类诊断模型,充分发挥了声发射技术在阀门内泄漏检测领域的优越性,以及 FCN 在时间序列分类任务上的高性能。该方法相较于传统的识别方法,无需对原始采集数据进行特征提取或繁重复杂的预处理,而是将特征提取的任务也交于神经网络模型来学习和完成,可实现端到端的阀门内泄漏声发射信号分类识别。搭建阀门内泄漏检测实验平台,采集并制作阀门内泄漏声发射信号数据集,建立了基于 FCN 的阀门内泄漏声发射信号的二分类模型,实验结果表明,该模型的分类识别准确率可达 98.72%,相比较于其他先进的分类模型在数据集上表现出了更加优越的分类识别性能和训练效率,同时对环境噪声具有良好的抗干扰性能。

关键词: 全卷积神经网络;阀门内泄漏;声发射;分类识别

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Identification method of valve internal leakage acoustic emission signal based on FCN

Zhang Jie Chen Shili

(State Key Laboratory of Precision Measuring Technology and Instruments, Tianjin University, Tianjin 300072, China)

Abstract: Aiming at internal leakage failures of gas transmission pipeline valves in petrochemical industry, this paper proposes an identification method of acoustic emission signal of valve internal leakage based on full convolutional neural network (FCN) by combining acoustic emission detection technology with deep learning technology. The method uses acoustic emission technology to collect acoustic emission signal of valve internal leakage and builds a valve internal leakage classification and diagnosis model based on FCN, which fully exploits the superiority of acoustic emission technology in the field of valve internal leakage detection and the high performance of FCN in time series classification tasks. Compared with traditional identification methods, this method does not require any feature extraction or complex preprocessing of the original collected data. Instead, the task of feature extraction is also handed over to the neural network model to learn and complete, which can realize end-to-end classification and identification of valve internal leakage acoustic emission signal. The data sets of valve internal leakage acoustic emission signal are collected and produced through the experimental platform of valve internal leakage detection, and the binary classification model of valve internal leakage acoustic emission signal based on FCN is established as well. The experimental results show that the accuracy of classification and recognition of the model can reach 98.72%. Compared with other advanced classification models, the model shows more superior recognition performance on the data sets and has higher training efficiency, which also has good anti-interference performance against environmental noise at the same time.

Keywords: full convolutional neural network; valve internal leakage; acoustic emission; classification and identification

0 引言

阀门作为一种重要的流体控制设备,在现代电力、石化工业中应用广泛,主要用于控制流体的流量和压力、控制流体的温度、控制流体的流向、控制流体的混合、控制流体的污染等,其密封性的好坏会直接影响所用于的工业系统的安全、稳定和高效运行。在工业应用中,由于阀门的长期频繁使用以及所处的高温、高压环境,同时其控制传输的流体可能具有腐蚀性,这些都易造成阀门泄漏,从而形成重大工业生产事故的安全隐患^[1]。阀门泄漏主要分为内泄漏和外泄漏两类,启闭件与阀座两密封面接触泄漏为内泄漏,即当阀门处于关闭状态时管路中仍有介质流通,它影响阀门阻断介质的能力。填料与阀杆和填料函结合处、阀体中法兰连接处漏为外漏,即介质从阀门内泄漏到阀门外。相比于阀门外泄漏,阀门内泄漏更难于发现,由阀门内泄漏造成的突发性工业生产安全事故的风险很高,当前不少的石油石化工业当中爆发的中毒、爆炸、污染等事故都与阀门的内泄漏有关^[2]。

目前,针对阀门泄漏故障的检测方法主要有气泡法^[3]、负压波检测法^[4]、超声波检测法^[5]、声发射检测法^[6]、阀门完整性超声相控阵检测^[7]等。其中,声发射检测法相比于其他检测方法,具有检测方便、可实现无损在线检测的优点,国内外一些研究学者也针对基于声发射技术的阀门泄漏检测展开了一系列研究:高倩霞等^[8]探究了阀门泄漏率与泄漏时的声发射信号的特征参数——均方根值之间是否存在定量关系,结合理论和实验结果,发现阀门泄漏率与泄漏声发射信号的均方根值成高次方正比;刘志超^[9]研发了一套适合天然气站场的阀门内漏检测仪器,针对阀门内漏声信号的特点,提出了基于小波阈值的阀门内泄漏信号降噪技术,并建立了基于支持向量机的阀门内泄漏量化回归模型,检测效果的误差可达3.46%,但缺少良好的泛化能力;Jafari 等^[10]针对内燃机阀门的探伤检测,利用声发射技术采集阀门的声发射信号,并提取声发射特征参数以训练人工神经网络,识别阀门泄漏准确率可达92%以上。

近年来,随着深度学习技术的不断发展与广泛应用,越来越多的学者开始引入深度学习技术来进行阀门泄漏声发射信号的识别,以提高阀门泄漏的检测效率和识别准确率。如吴文凯等^[11]建立了一种阀门泄漏声发射信号特征量与泄漏等级的支持向量机分类模型,模型的识别准确率可达93%;Sim 等^[12]以往复压缩机的阀门为研究对象,利用离散小波变换对声发射信号进行时频分析,采用 KNN 和 SVM 分类算法对不同的阀门工况进行分类,建立回归模型来估计阀门的流量,再利用声发射信号的特征参数(均方根值)计算被测阀门与正常阀门流量

之间的差值,进而估算被测阀门泄漏率。

以上研究在阀门内泄漏检测及其声发射信号识别上取得了进展,但是大都需要对声发射信号进行复杂的人工预处理,无法实现端到端的阀门内泄漏识别。考虑到阀门内泄漏声发射信号是一类时间序列,可以使用时间序列分类模型对阀门内泄漏声发射信号进行有效识别。目前研究学者已经提出一系列适用于时间序列分类任务的分类模型,例如深度残差网络^[13](ResNet)、多层感知机^[14](multilayer perceptron, MLP)、全卷积神经网络^[15](fully convolutional networks, FCN)等,其中 FCN 相比较于其他模型,在时间序列分类任务中展现出了更加优越的性能,同时无需特征提取等复杂的预处理工作,能够实现端到端的时间序列分类。因此,针对阀门内泄漏检测识别的数据预处理过程复杂的问题,提出了基于 FCN 的阀门内泄漏声发射信号识别方法,综合利用声发射技术在阀门内泄漏检测以及 FCN 在时间序列分类任务中的优势,预期能以较高的准确度实现端到端的阀门内泄漏声发射信号识别。

1 阀门内泄漏检测原理

阀门的内泄漏相较于外泄漏更加不易被发现,它发生于阀门内部,为了能够在不对阀门进行拆卸的情况下实现对待测阀门的在线检测,运用声发射技术来评估阀门的泄漏状态。

1.1 声发射检测技术

声发射是固体材料表面受到力的作用而迅速释放能量并形成机械波的一种物理现象^[16]。固体材料在使用过程中,因断裂、碰撞、热胀冷缩等都会产生声发射现象^[17]。

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],其基本原理如图1所示。固体材料的表面受损伤或力作用时便会形成声发射源,声发射源使材料表面产生弹性振动从而传播声发射信号,这种声发射信号非常微弱,一般需要由高灵敏度、频率范围合适的声发射传感器来采集并转换为电信号,再经放大器放大后输入到上位机系统中,最后通过对其进行分析处理,以评估待测材料是否存在缺陷或泄漏情况。

1.2 阀门内泄漏声发射检测原理

阀门在长期使用过程中,可能受到传输流体介质的腐蚀或外界环境的影响,使得其内部发生泄漏。而阀门发生内泄漏时,流体与阀门内壁的碰撞会导致阀门表面产生弹性振动,并会沿其表面传播。该振动信号携带阀门泄漏的有效信息,可以使用声发射传感器来采集该信




图 1 声发射检测技术基本原理

Fig. 1 Basic principles of acoustic emission detection technology

号,进而评估阀门泄漏情况。图 2 所示为声发射传感器采集的阀门在不同工况下的声发射信号。

图 2(a)所示为阀门在一般噪声背景下没有发生内泄漏时采集的声发射信号,图 2(b)所示为阀门在一般噪声背景下发生内泄漏时采集的声发射信号,图 2(c)所示为阀门在敲击噪声背景下没有发生内泄漏时采集的声发射信号,图 2(d)所示为阀门在敲击噪声背景下发生内泄漏时采集的声发射信号。相比于没有发生内泄漏时的声发射信号,内泄漏时的声发射信号峰值更大,包含的频率成分更加复杂。同时,敲击会引起所采集的声发射信号产生更大的峰值波动。可见,阀门的声发射信号为一类时间序列,图 2(a)和(c)两种情况可归为“没有内泄漏”类别,图 2(b)和(d)两种情况可归为“发生内泄漏”类别,对阀门的内泄漏情况的判定可视为对其声发射信号这一时间序列的分类识别。

2 全卷积神经网络原理

卷积神经网络(convolutional neural network, CNN)是一类包含卷积运算的前馈神经网络,一般由输入层(input layer)、卷积层(convolutional layer)、池化层(pooling layer)、全连接层(FC layer)所组成^[19],有时为了规避过拟合化和提高网络模型的泛化能力,也会加入批归一化层^[20](BN layer)。其中输入层用于输入特征,并控制输入特征的维度;卷积层一般由多个卷积核所组成,卷积核以一定的步长来遍历输入数据并进行特征提取和特征映射^[21]。池化层一般堆叠在卷积层后面,用于实现下采样降维,以减少后续网络层的参数,同时能够在一定程度上防止过拟合和提高泛化能力^[22]。全连接层用于在网络的底部将提取的所有局部特征综合成为全局特征,一般在分类任务中按照类别数量输出分类结果。

FCN 在传统 CNN 的基础上摒弃了全连接层,并将其替换为卷积层,可以接受任何尺寸大小的输入,并实现端到端的训练。FCN 是由 Long 等^[15]于 2015 年提出的一




图 2 阀门的各类声发射信号

Fig. 2 Various types of acoustic emission signals of valve

种深度学习框架,在语义分割任务处理展现出了比 CNN 更为先进的性能。

Wang 等^[14]则将 FCN 模型应用到时间序列的分类任务当中,选取了 UCR 时间序列数据集集中的 44 类不同的数据集完成了测试,并与其他分类模型进行了比较,实验结果表明运用 FCN 模型可以实现对时间序列进行端到端的训练和识别,同时能够达到较高的识别准确度,展现出了优越的性能。由于阀门的声发射信号也是一类时间序列,对其进行分类识别即是一种时间序列的分类任务,因此 FCN 模型适用于本研究的应用场景。

3 全卷积神经网络模型建立

针对本研究的分类识别任务,所建立的 FCN 模型如图 3 所示。该模型主要由输入层、卷积层、批归一化层、全局池化层和输出层构成。其中在输入层中输入采集到的声发射数据;卷积层和批归一化层构成网络的基本块,共有 3 组,每组的卷积核尺寸不同,基本块用于实现模型对声发射数据的特征提取和学习。卷积运算计算如式(1)所示^[23]:

$$y_i^j = \sum_{k=1}^{n_{j-1}} \text{conv}(w_{i,k}^{j-1}, y_k^{j-1}) + b_i^j \quad (1)$$

式中: y_i^j 表示 FCN 结构中第 j 层的第 i 个神经元的输出, n_{j-1} 表示第 $j-1$ 层的神经元数量,conv 为卷积算子, $w_{i,k}^{j-1}$ 表示连接第 $j-1$ 层的第 k 个神经元与第 j 层的第 i 个神经元的核权重值, y_k^{j-1} 表示第 $j-1$ 层的第 k 个神经元的输出, b_i^j 表示第 j 层的第 i 个神经元的偏置。




图 3 FCN 模型结构

Fig. 3 The structure of the FCN model

该模型不同于一般的 CNN 结构或 FCN 结构,并没有在每步卷积后加入池化操作,一方面是为了防止训练过程中丢失过多数据,另一方面是所建立的模型规模不大,需要训练参数量较小,可以舍弃每步卷积后的池化操作。为了防止过拟合,加快收敛速度,提高模型的泛化能力,在每个卷积层后,都加入了批归一化层,该层中引入了可学习的参数 δ, α , 计算原理如式(2)所示:

$$\begin{aligned} \mu_B &= \frac{1}{m} \sum_{i=1}^m y_i \\ \sigma_B^2 &= \frac{1}{m} \sum_{i=1}^m (y_i - \mu_B)^2 \\ \hat{y}_i &= \frac{y_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \\ s_i &= \alpha \hat{y}_i + \delta = BN_{\alpha, \delta}(y_i) \end{aligned} \quad (2)$$

其中, y_i 表示批归一化层的输入, μ_B 和 σ_B^2 分别表示样本子集(mini batch)中神经元输出的均值和方差,

m 表示样本子集的大小,引入参数 ε 是为了防止除数为 0, s_i 表示批归一化层的输出。

在所有基本块之后,舍弃全连接层而引入了全局平均池化层,进一步减少可训练的权重参数的数量,加快训练速度。在输出层中引入激活函数,输出每个类别(发生内泄漏、没有内泄漏)的概率。一般使用 sigmoid 或 softmax 函数作为分类问题中神经网络输出层的激活函数,sigmoid 和 softmax 函数的计算原理分别如式(3)和(4)所示:

$$p_i = \text{sigmoid}(y_i) = \frac{1}{1 + e^{-y_i}} \quad (3)$$

$$p_i = \text{softmax}(y_i) = \frac{e^{y_i}}{\sum_{g=1}^h e^{y_g}} \quad (4)$$

其中, p_i 表示输出类别的概率(范围是 $[0, 1]$), y_i 表示前面全平均池化层的第 i 个节点的输出值, h 表示输出层节点的个数,即分类类别的个数。sigmoid 激活函数一般搭二元交叉熵(binary cross entropy)损失函数使用,softmax 激活函数则一般搭配合分类交叉熵(categorical cross entropy)损失函数使用,都适用于处理分类任务。

4 实验与结果分析

在实验室搭建了阀门气体内泄漏检测实验平台,如图 4 所示,主要由空气压缩机、储气罐、管道、阀门等组成。选用美国 PAC 公司生产的 Nano-30 型声发射传感器采集阀门的声发射信号。由于采集到的声发射信号较微弱,使用 40 dB 前置放大器对其进行放大,以便后续对信号进行分析处理。




图 4 阀门气体内泄漏检测实验平台

Fig. 4 Experimental platform of valve gas internal leakage

实验时使用耦合剂将声发射传感器固定在待测阀门下游旁,以增强传感器对信号的感知,通过打开并旋转阀门开关至某一开度,模拟不同压力下、不同流量的内泄漏。

4.1 数据集建立

采用声发射传感器采集阀门的声发射信号,经前置放大器放大后,由 NI 公司生产的 NI USB-6366 型信号采集卡以 1 MSPS 的采样率采集 1 s 时间内的声发射数据,并发送到上位机。

由于现场输气管道阀门工作环境可能存在风声、管道敲击等噪声干扰,因此分别采集阀门在一般环境噪声背景下(不含敲击和风声)、管道敲击噪声背景下、风吹

噪声背景下泄漏和没有泄漏情况下的声发射信号,“发生内泄漏”类的样本标签定义为“1”,“没有内泄漏”类的样本标签定义为“0”。将数据集制作为 txt 文本文件,其每一行均为“标签(0 或 1),特征(声发射信号序列)”的数据结构。将数据集划分为 4 600 个训练集样本、1 710 个验证集样本、1 800 个测试集样本,其中训练集用于模型的训练以及确定参数,验证集用于调整模型的超参数,测试集则用于检验模型的泛化能力。数据集的结构如表 1 所示。

表 1 数据集结构

Table 1 Structure of the data set

数据集	一般噪声样本数量		风吹噪声样本数量		敲击噪声样本数量		合计
	发生内泄漏	没有内泄漏	发生内泄漏	没有内泄漏	发生内泄漏	没有内泄漏	
训练集	1 000	900	900	0	900	900	4 600
验证集	450	360	300	0	300	300	1 710
测试集	0	0	0	600	600	600	1 800

图 5 所示为模型的识别过程。输入特征为 1×200 的声发射信号序列,经 FCN 模型进行分类识别后,输出标签为“1”的概率值 (P(0)) 和标签为“0”的概率值 (P(1))。若 P(0)更接近 100%,则表明模型判断出输入的特征是阀门没有发生内泄漏时采集的声发射信号;若 P(1)更接近 100%,则表明模型判断出输入的特征是阀门发生内泄漏时采集的声发射信号。




图 5 模型识别过程

Fig. 5 Identification process of the model

4.2 模型的训练与评价

在模型的训练过程中,需要根据训练集和验证集的损失函数 (Loss) 以及准确率 (Accuracy) 来不断调节 FCN 模型的超参数,模型的一些重要训练参数设置如表 2 所示。

表 2 模型训练参数配置

Table 2 Configuration of training parameters of model

模型训练参数	参数值
Epoch	2 000
Batch size	32
Min Learning rate	0.000 1
Factor	0.5
Patience	50
Optimizer	Adam

其中 Epoch 表示训练的总轮次,所有的样本输入到模型中完成一次前向计算和误差反向传播的过程称为一个训练轮次。在训练过程中,将所有的样本划分为若干个 Batch(一批样本),分块训练,Batch size(批尺寸)即表示一批样本的大小。学习率 (learning rate) 是模型训练过程中更新权重时的一个十分重要的超参数,学习率越低,训练过程越缓慢,模型达到收敛所需要的时间就越长,而学习率过高则易发生梯度爆炸。采取学习率优化机制,设置最小学习率 (min learning rate) 为 0.000 1,定义 Patience 参数值为 50,即当经过 50 个训练轮次后,监控的损失函数 (Loss) 仍未下降,将触发学习率以 Factor 因子衰减。采用自适应矩估计 (adaptive moment estimation, Adam) 算法作为优化器 (Optimizer),来进行 FCN 模型训练过程中的神经网络权重值的迭代、更新。

表 3 所示为模型的评价参数设置。模型所使用的损失函数为二元交叉熵 (binary cross entropy, BCE) 函数和分类交叉熵 (categorical cross entropy, CCE) 函数,两者都是常用于深度学习中分类任务的损失函数。二元交叉熵函数的计算原理如式 (5) 所示,分类交叉熵函数的计算原理如式 (6) 所示:

$$loss_{BCE} = - [z_i \log p_i + (1 - z_i) \log (1 - p_i)] \tag{5}$$

$$loss_{CCE} = - z_i \log p_i \tag{6}$$

其中, z_i 为第 i 个类别对应的真实标签,对于式 (5), p_i 为式 (3) 中 sigmoid 函数的输出,对于式 (6), p_i 为式 (4) 中 softmax 函数的输出。

表 3 模型评价参数配置

Table 3 Configuration of evaluation parameters of model

模型评价参数	参数值
Loss	Categorical cross entropy/Binary cross entropy
Metrics	Accuracy

采用“准确率 (Accuracy)”作为模型的性能指标 (Metrics),用于衡量模型输出的标签与对应的真实标签之间的差距,是评估模型性能的重要依据。准确率表示模型的正确预测结果的数量占其所有预测结果数量的比例,该值越大,表明模型的分类效果越好,准确率也是在分类任务中常用的评估指标之一。

4.3 实验结果分析

本研究是利用深度学习技术处理分类任务,输出层的激活函数以及交叉熵损失函数的选择会对模型的分类能力产生重要影响。在分类任务中,一般会选用 sigmoid 激活函数搭配二元交叉熵函数或 softmax 搭配分类交叉熵函数的组合,为了确定最适合于本研究的参数配置,在统一数据集和模型结构上对该两种组合进行了比较。同时,实验对比了 FCN、MLP、AlexNet 和 ResNet 模型在本研究数据集上的性能指标,以验证 FCN 模型在本研究上的适用性和先进性。此外,分别在一般环境噪声背景下的测试集、风吹噪声背景下的测试集、管道敲击噪声背景下的测试集上对 FCN、MLP、AlexNet 和 ResNet 模型的抗干扰性能进行了评估和比较。


1) BCE+sigmoid 与 CCE+softmax 组合性能对比

在深度学习的分类任务中,通常将 sigmoid 或 softmax 函数作为神经网络最后一层的激活函数,输出分类类别的概率值,同时配以二元交叉熵函数或分类交叉熵函数。在 FCN 模型其他结构参数不变的条件下,分别引入 BCE+sigmoid 与 CCE+softmax 两种组合,在同一数据集上进行训练,通过训练结果验证哪一类组合更适用于阀门内泄漏声发射信号的分类识别任务。


图 6(a)所示为两类组合的 FCN 模型在训练集上的损失函数随训练轮次增加而变化的训练日志,图 6(b)所示为两类组合的 FCN 模型在训练集上的准确率随训练轮次增加而变化的训练日志。

由图 6(a)可见,在训练过程中,配置了 CCE+softmax 组合的 FCN 模型(以下简称 CCESOF_FCN)相较于配置了 BCE+sigmoid 组合的 FCN 模型(以下简称 BCESIG_FCN),其损失函数下降的速度更快,两者的损失函数稳定最终在 0.002 左右。由图 6(b)可以看出,CCESOF_FCN 的准确率曲线比 BCESIG_FCN 上升更快,震荡幅度也更小,两者的准确率最终稳定在 0.999 左右。因此可以得出结论,针对本研究中的阀门内泄漏声发射信号分类识别任务,CCESOF_FCN 的收敛速度比 BCESIG_FCN 更快。

为了更加全面地评价模型的分类识别性能,除了准确率外,还分别计算了 CESOF_FCN 和 BCESIG_FCN 在测试集上的召回率、精确率以及 F1 分数,同时对比了两者训练效率,如表 4 所示。其中召回率是指在实际为正的样本中被预测为正的样本所占的比例,精确率是指在



(a) 两类组合的 FCN 模型的损失函数训练日志



(b) 两类组合的 FCN 模型的准确率训练日志

(b) Accuracy log of FCN model with two types of combinations

图 6 两类组合的 FCN 模型的训练日志

Fig. 6 Training logs of FCN model with two types of combinations

所有被预测为正的样本中实际为正的样本所占的比例, F1 分数则是对召回率和精确率的调和平均数,该值越大,模型的综合性能越好。

表 4 两类组合的 FCN 模型的性能对比

Table 4 Comparison of performance of FCN model with two types of combinations

模型	准确率/%	召回率	精确率	F1 分数	训练时间/s
CCESOF_FCN	98.72	0.993 3	0.969 1	0.981 1	1 726.33
BCESIG_FCN	98.94	0.999 5	0.973 9	0.984 3	1 810.75

由表 4 可见,CCESOF_FCN 和 BCESIG_FCN 在测试集上的准确率均达到了 98% 以上,召回率均达到 0.99 以上,精确率均在 0.97 左右,F1 分数均达到了 0.98 以上,两者在以上性能指标上差距很小。但是,CCESOF_FCN 的训练时间仅需 1 726.33 s,而 BCESIG_FCN 则需要 1 810.75 s,因此 CCESOF_FCN 的训练效率更高。综合以上性能对比分析,本研究采用了 CCE+softmax 组合,应用于 FCN 模型以及用于对比实验的其他深度学习模型当中。

2) 4 类模型的性能对比

FCN、MLP 和 ResNet 模型在时间序列分类任务当中均展现出了良好的性能,且都能够实现端到端的学习和分类识别,但还未被应用于阀门内泄漏声发射信号的端到端的分类识别领域当中;基于改进 AlexNet 的 CNN 模

型则已经被提出应用于阀门泄漏的超声信号识别^[24],但是需要人工进行特征提取,未能实现端到端的学习和分类识别,本研究则在其模型基础上进一步改进了 AlexNet 模型架构,以适应本研究的分类识别任务;为了验证以上 4 类模型中哪一类更适用于阀门内泄漏声发射信号的端到端的分类识别任务,使用统一的训练集,分别输入 FCN、MLP、AlexNet 和 ResNet 模型中进行训练,保存各类最优模型,再输入测试集,综合比较各类模型的性能。MLP 和 AlexNet 模型的训练参数配置(表 1)除了批尺寸改为 16 外,其余均与 FCN 模型一致,而 ResNet 模型的训练参数配置只在训练轮次上做了改变,设置为 1 500。

图 7(a)所示为 FCN、MLP、AlexNet 和 ResNet 这 4 类模型在阀门内泄漏声发射数据训练集上的损失函数随训练轮次的增加而变化的曲线图;图 7(b)所示为以上 4 类模型在训练集上的准确率随训练轮次的增加而变化的曲线图。





图 7 4 类模型的训练日志
Fig. 7 Training logs of four models

从图 7(a)中可以看出,ResNet 模型的损失函数曲线下降速度最快,AlexNet 模型和 FCN 模型则次之,MLP 模型最慢;ResNet 模型和 FCN 模型的损失函数值最终稳定在 0.002 左右,AlexNet 模型和 MLP 模型则分别为 0.150 和 0.200 左右。从图 7(b)中可以看出,ResNet 模型的准确率曲线最快达到稳定状态,AlexNet 模型和 FCN 模型次之,MLP 模型的速度最慢;ResNet 模型和 FCN 模型的

准确率最终稳定在 0.999 左右,AlexNet 模型和 MLP 模型则分别为 0.950 和 0.935 左右。通过对比 4 类模型在训练集上的表现,可见 ResNet 模型的收敛速度最快,其后依次是 AlexNet 模型和 FCN 模型,MLP 模型的收敛速度最慢;同时,ResNet 模型和 FCN 模型的损失函数值和准确率最为优异。

为了比较所述 4 类模型的分类识别性能和计算效率,将测试集分别输入到训练好的 4 类最优模型当中,分别计算它们的性能指标,如表 5 所示。

表 5 4 类模型的性能对比

Table 5 Comparison of performance of four models

模型	准确率/%	召回率	精确率	F1 分数	训练时间/s
FCN	98.72	0.993 3	0.969 1	0.981 1	1 726.33
MLP	97.17	0.920 0	0.984 0	0.951 0	1 784.38
AlexNet	98.22	0.978 3	0.968 6	0.973 5	2 495.71
ResNet	98.17	0.993 3	0.953 6	0.973 1	3 039.41

由表 5 可知,在准确率指标上,FCN 模型最高,达到了 98.72%,AlexNet 和 ResNet 模型则略低于 FCN 模型,分别达到了 98.22%和 98.17%,MLP 模型最低,只有 97.17%;在召回率指标上,FCN 模型和 ResNet 模型最高,均达到了 0.993 3,AlexNet 模型为 0.978 3,而 MLP 模型仅有 0.920 0;在精确率指标上,MLP 模型最高,达到了 0.984 0,FCN 模型和 AlexNet 模型次之,分别达到了 0.969 1 和 0.968 6,而 ResNet 模型最低,仅有 0.953 6;在 F1 分数指标上,FCN 模型最高,达到了 0.981 1,AlexNet 和 ResNet 模型次之,分别达到了 0.973 5 和 0.973 1,MLP 模型最低,仅有 0.951 0;在训练过程中,FCN 模型的用时最短,仅需 1 726.33 s,MLP 模型用时略长于 FCN 模型,需要 1 784.38 s,AlexNet 模型和 ResNet 模型用时则以较大的幅度超过了 FCN 模型,分别用时 2 495.71 和 3 039.41 s。

综上所述,在 4 类模型当中,FCN 模型的准确率、召回率、F1 分数指标均达到了最高,其精确率也仅次于 MLP 模型;MLP 模型虽然在精确率上表现最好,但其准确率、召回率以及 F1 分数均处于 4 类模型中最低水平。此外,FCN 模型相比于其他 3 类模型,拥有更高的训练效率。由此可见,FCN 模型相较于其他 3 类模型拥有更加优越的分类识别性能,更适用于所研究的阀门内泄漏声发射信号的端到端的分类识别任务。

3) 环境噪声影响

为了展示环境噪声对 FCN、MLP、AlexNet 和 ResNet 模型分类识别性能的影响,又分别制作了一般环境噪声背景下的测试集(记为 Test_0)、风吹噪声背景下的测试集(记为 Test_1)、管道敲击噪声背景下的测试集(记为 Test_2),以上 3 类测试集均等量含有“发生内泄漏”和

“没有内泄漏”类共 1 800 个样本,分别输入到训练好的 4 类模型中进行测试,结果分别如表 6~8 所示。

表 6 4 类模型在 Test_0 上的性能对比
Table 6 Performance comparison of four models on Test_0

模型	准确率/%	召回率	精确率	F1 分数
FCN	100.00	1.000 0	1.000 0	1.000 0
MLP	95.72	0.898 9	1.000 0	0.946 8
AlexNet	99.89	0.997 8	1.000 0	0.998 9
ResNet	99.83	1.000 0	0.996 7	0.998 3

表 7 4 类模型在 Test_1 上的性能对比
Table 7 Performance comparison of four models on Test_1

模型	准确率/%	召回率	精确率	F1 分数
FCN	100.00	1.000 0	1.000 0	1.000 0
MLP	97.22	0.921 1	1.000 0	0.958 9
AlexNet	99.89	0.997 8	1.000 0	0.998 9
ResNet	99.89	1.000 0	0.997 8	0.998 9

表 8 4 类模型在 Test_2 上的性能对比
Table 8 Performance comparison of four models on Test_2

模型	准确率/%	召回率	精确率	F1 分数
FCN	99.94	1.000 0	0.998 9	0.999 4
MLP	94.28	0.895 6	0.964 1	0.928 6
AlexNet	99.00	0.994 4	0.985 7	0.990 0
ResNet	99.94	1.000 0	0.998 9	0.999 4

由表 6~8 可以看出,FCN 模型在 3 类测试集上的准确率、召回率、精确率以及 F1 分数均处于 4 类模型中的最高水平,相较于其他 3 类模型表现更好。可见,FCN 模型相较于其他 3 类模型对环境噪声的抗干扰性能更好。

5 结 论

针对石化工业中的管道阀门内泄漏故障,提出了一种基于声发射技术和全卷积神经网络算法相结合的方法,利用声发射传感器采集阀门的声发射信号,搭建全卷积神经网络模型,对声发射信号进行分类识别,从而有效判断阀门是否发生泄漏。该方法不同于传统识别方法中需要人为对采集到的声发射信号进行特征提取等复杂的预处理工作,而是将特征提取的任务也交于神经网络模型去学习和完成,从而缩减了人工预处理的过程,实现端到端的训练及检测。

通过实验对比了 sigmoid 激活函数搭配二元交叉熵函数、softmax 激活函数搭配分类交叉熵函数的两种通用组合对模型性能的影响,结果表明 softmax 搭配分类交叉熵函数更适合于本研究的分类任务。在统一的阀门内泄

漏声发射数据集上分别测试了 FCN 模型、MLP 模型、AlexNet 模型和 ResNet 模型的性能指标,结果表明 FCN 模型的准确率相较于其他 3 类模型更高,达到了 98.72%,同时拥有更加优越的综合分类识别性能以及更高的训练效率。此外,在含有一般噪声、风吹噪声、管道敲击噪声的测试集上分别测试了以上 4 类模型的抗干扰性能,结果表明 FCN 模型对以上噪声的抗干扰性能更好。所提出的方法分类识别性能优越,训练效率高,能够实现端到端的训练和分类识别,对环境噪声的抗干扰性能良好,适合于阀门内泄漏的检测。

参考文献

[1] 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.
LYU F. Design and implementation of valve leak detection portable device based on acoustic emission [D]. Chongqing:Chongqing University, 2021.

[2] 胡国晶. 基于温度测量的阀门内泄漏检测方法研究[D]. 哈尔滨:哈尔滨工业大学,2022.
HU G J. Research on detection method of valve internal leakage based on temperature measurement[D]. Harbin: Harbin Institute of Technology, 2022.

[3] 李文强,刘艳芳. PBT 生产装置真空系统的检漏操作[J]. 聚酯工业,2019,32(6): 53-55.
LI W Q, LIU Y F. Leak detection operation of vacuum system in PBT production plant[J]. Polyester Industry, 2019, 32(6): 53-55.

[4] ZHANG G M, HO S C, HUO L SH, et al. Negative pressure waves based high resolution leakage localization method using piezoceramic transducers and multiple temporal convolutions [J]. Sensors (Basel, Switzerland), 2019, DOI:10.3390/s19091990.

[5] 吴建平,庄法坤,蹇健,等. 基于超声波的阀门泄漏综合检测技术应用[J]. 设备管理与维修,2020(7): 143-145.
WU J P, ZHUANG F K, QU J, et al. Application of comprehensive detection technology of valve leakage based on ultrasonic wave [J]. Plant Maintenance Engineering, 2020(7): 143-145.

[6] 韩正海. 石油化工装置阀门在线检测技术探析[J]. 石化技术,2021,28(10): 93-94.
HAN ZH H. On-line testing technology of valve in petrochemical plant [J]. Petrochemical Industry Technology, 2021, 28(10): 93-94.

[7] 张海龙. 综述长输管道阀门内泄漏在线检测的几种方法[J]. 石化技术,2020,27(7): 230-231.
ZHANG H L. An overview of several methods for online

- detection of internal leakage of long-distance pipeline valves [J]. *Petrochemical Industry Technology*, 2020, 27(7): 230-231.
- [8] 高倩霞,李录平,饶洪德,等. 阀门泄漏率的声发射测定技术研究[J]. *动力工程学报*, 2012, 32(1): 42-46.
GAO Q X, LI L P, RAO H D, et al. Acoustic emission theory and testing technology for quantitative diagnosis of valve leakages [J]. *Journal of Chinese Society of Power Engineering*, 2012, 32(1): 42-46.
- [9] 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(北京), 2016.
LIU ZH CH. Research on valve leakage detection instrument development and internal leakage rate quantitative regression analysis [D]. Beijing: China University of Petroleum (Beijing), 2016.
- [10] JAFARI S M, MEHDIGHOLI H, BEHZAD M. Valve fault diagnosis in internal combustion engines using acoustic emission and artificial neural network [J]. *Shock & Vibration*, 2014, 2014(1): 1-9.
- [11] 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 modeling for acoustic emission detection of valve internal leakage [J]. *Acta Metrologica Sinica*, 2021, 42(8): 1018-1025.
- [12] 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.
- [13] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[J]. *arXiv preprint arXiv: 1512.03385*, 2015.
- [14] WANG Z G, YAN W Z, OATES T. Time series classification from scratch with deep neural networks: A strong baseline [J]. *International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2017:1578-1585.
- [15] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [16] 李红军,方剑青,何元磊. 声发射检测技术在复合结构安全监测中的应用[J]. *声学技术*, 2013, 32(S1): 259-260.
LI H J, FANG J Q, HE Y L. Application of acoustic emission detection technology in composite structure security monitoring [J]. *Technology Acoustics*, 2013, 32(S1): 259-260.
- [17] 饶庆华,姚力,马学荣. 在役含缺陷加氢反应器声发射监测[C]. 2012 远东无损检测新技术论坛, 2012: 5.
RAO Q H, YAO L, MA X R. Acoustic emission monitoring in the hydrogenation pressure vessel containing defects [C]. 2012 Far East New Technology Forum on NDT, 2012: 5.
- [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] 沈国皓,鲁昌华,王涛,等. 心电信号的卷积神经网络二分类方法[J]. *电子测量与仪器学报*, 2021, 35(3): 43-48.
SHEN G H, LU CH H, WANG T, et al. Convolutional neural network binary classification method for electrocardiogram signal [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(3): 43-48.
- [20] SAINATH T, KINGSBURY B, SAON G, et al. Deep convolutional neural networks for large-scale speech tasks[J]. *Neural Networks*, 2015, 64: 39-48.
- [21] 刁宁昆,马怀祥,刘锋. 一种改进 LeNet5 结合 LightGBM 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 LeNet5 and LightGBM [J]. *Foreign Electronic Measurement Technology*, 2022, 41(1): 140-145.
- [22] 杨玲,高军伟. 基于 FCN 的轮对踏面检测技术[J]. *电子测量技术*, 2022, 45(1): 117-121.
YANG L, GAO J W. FCN-based wheelset tread detection technology [J]. *Electronic Measurement Technology*, 2022, 45(1): 117-121.
- [23] INCE T, KIRANYAZ S, EREN L, et al. Real-time motor fault detection by 1D convolutional neural networks [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(11): 7067-7075.
- [24] 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.

作者简介



张杰, 2021 年于合肥工业大学获得学士学位, 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: lishunshengzj@163.com

Zhang Jie received his B. Sc. degree from Hefei University of Technology in 2021. Now he is a M. Sc. candidate in the School of Precision Instruments and Opto-Electronics Engineering at Tianjin University. His main research interest includes the technology for detection of valve internal leakage.



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、基于声学及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.