

DOI: 10.19650/j.cnki.cjsi.202311499

# 基于多尺度加权形态网络的燃气流量计健康状态评估\*

胡凡<sup>1</sup>, 张永<sup>2</sup>, 谢林柏<sup>1</sup>

(1. 江南大学物联网工程学院 无锡 214000; 2. 武汉科技大学信息科学与工程学院 武汉 430081)

**摘要:**燃气流量计是天然气贸易计量的重要仪器,而其健康状态的改变会造成计量偏差。为了减少燃气企业的经济损失,本文提出了一种基于多模态数据扩充、形态学特征学习和多尺度自适应加权形态学网络的燃气流量计健康状态评估方法。首先,采用基于 Wasserstein 距离和谱归一化的 ACGAN 算法进行数据扩充。其次,针对燃气流量计振动信号数据的复杂性和噪声影响,提出了一种基于平均帽变换的形态学方法提取信号的正负脉冲信息。最后,针对非平稳、变工况的工业条件,引入多尺度自适应加权形态学网络,采用具有不同结构元素尺度的多个分量来分别提取脉冲信息,并利用自适应加权融合来增强提供强脉冲分量的尺度。通过实验结果表明,所提出的方法对燃气流量计健康状态评估的准确度超过 94%。该方法对实际燃气贸易计量有重要的应用价值。

**关键词:** 燃气流量计; 健康状态评估; 多模态数据增强; 形态学特征学习; 多尺度自适应加权网络

**中图分类号:** TH17 TP183 **文献标识码:** A **国家标准学科分类代码:** 520.20

## The health status assessment of gas flow meter based on multi-scale weighted morphology network

Hu Fan<sup>1</sup>, Zhang Yong<sup>2</sup>, Xie Linbo<sup>1</sup>

(1. College of Internet of Things Engineering, Jiangnan University, Wuxi 214000, China; 2. College of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081, China)

**Abstract:** Gas flow meters are important instruments for natural gas trade measurement, and changing of their health status can cause measurement deviation. To reduce economic loss for gas companies, this article proposes a gas flow meter health status assessment method based on multimodal data augmentation, morphological feature learning, and multiscale adaptive weighted morphological network. Firstly, data augmentation is performed by using the ACGAN algorithm based on Wasserstein distance and spectral normalization to achieve sample balance. Secondly, considering the complexity and noise impact of the gas flow meter vibration signal data, a morphological method based on average hat transform is proposed to extract the positive and negative pulse information from the signal. Finally, to address the non-stationary and variable operating conditions in industrial settings, a multiscale adaptive weighted morphological network is introduced. Multiple components with different structural element scales are used to extract pulse information, and adaptive weighted fusion is employed to enhance the scales that provide strong pulse components. The experimental results show that the proposed method has an accuracy of over 94% in the health status assessment of gas flow meters. This method has significant practical value for actual gas trade measurement.

**Keywords:** gas flow meter; health status assessment; multimodal data augmentation; morphology feature learning; adaptive weighted morphology network

## 0 引言

随着国家燃气工业的不断发展和人们对经济效益的

日益重视,作为供、用气双方贸易结算依据的计量问题日益突出起来。2021 年 9 月–2022 年 9 月期间,通过智能监测,无锡华润燃气有效排查出 5 家因走气不走表等故障原因导致的计量偏差,成功挽回价值 70 万的燃气损

失。由此可见,如何公正、准确地对燃气使用进行计量,成为燃气企业必须面对的一个重要问题。

燃气流量计作为燃气计量过程中的重要角色。在长期的使用过程中,其内部结构老化引发的健康状态变化会引起计量偏差,诱发经济纠纷和损失。因此,对燃气流量计在线监测及健康状态的准确评估和分类具有重要的意义。

目前传统的燃气流量计健康状态评估是基于压损异常的识别方法,该方法根据拟合得出流量计在正常工况下的气体压力损失(利用压差计测量得出)与流量之间的函数表达式<sup>[1]</sup>,通过对比压力损失计算值与压力损失实测值之间的相对误差对燃气流量计进行自诊断。刘兴伟等<sup>[2]</sup>提出通过实测压损比正常压损增大或减小的趋势判断燃气流量计存在的问题种类。文红燕<sup>[3]</sup>提出由流量计瞬时流量与温度、压力以及压损关系判断流量计是否正常运行。尽管基于压损异常的识别方法被不断改进和优化,但仍受到以下限制:大流量下的压损减小值不显著<sup>[3]</sup>,导致误判的风险增加;该方法要求在流量计出厂时确定压损与瞬时流量之间的关系曲线,且适用范围受限子特定类型的流量计。

近年来,基于数据驱动的健康状态评估方法得到广泛的运用,机器学习是基于数据驱动的主要方法之一,该方法从原始数据中手动提取和选择有用的特征,通过不同类别之间特征集的差异性实现区分。其中,Peng等<sup>[4]</sup>研究了支持向量机(support vector machines, SVM)在风力涡轮机齿轮箱状态分类中的应用。Shao<sup>[5]</sup>使用多通道振动信号的13个频域统计特征对行星齿轮箱进行故障状态分类。尽管上述方法在状态识别分类上已经显示其有效性,然而,领域知识对于其创建在分类方面具有竞争力的手工特征集至关重要。人为主观性的存在会给故障状态评估模型带来额外偏差,从而限制了基于机器学习诊断方法的准确性。

随着科技快速发展,深度学习(deep learning, DL)已经成为克服主观构建特征集的有效方法,大大提高了网络适应性<sup>[6-7]</sup>。其中,Wen等<sup>[8]</sup>提出了一种基于LeNet-5的新型卷积神经网络(convolutional neural networks, CNN)用于故障状态评估。Zhang等<sup>[9]</sup>通过长短期记忆(long short-term memory, LSTM)网络模型有效地检测和识别四旋翼机叶片故障。Yang等<sup>[10]</sup>提出了一种基于图论的频谱分析实现旋转机械故障监测诊断。Cheng等<sup>[11]</sup>提出了一种基于连续小波变换局部二进制卷积神经网络(continuous wavelet transform-local binary convolutional neural network, CWT-LBCNN)模型的旋转机械(rotating machinery, RM)故障状态评估方法。Iqbal等<sup>[12]</sup>提出了一种基于卷积神经网络的轴承故障诊断方法,来实现数控机床的故障状态识别。Xu等<sup>[13]</sup>提出了一个基于CNN和

深度森林(multi-grained cascade Forest, gcForest)的混合深度学习模型。Surendran等<sup>[14]</sup>提出了一种利用残差网络优化起始模型进行智能工业状态监测评估的方法。针对精密的燃气流量计设备,安装侵入式传感器监测计量设备的健康状态会影响现有计量装置的结构设计,增加费用支出。为此基于上述方法,设计安装非侵入式的加速度传感器,收集计量装置工作过程中的振动信号数据并利用深度学习有效地提取振动信号的抽象特征,从而实现对不同状态的流量计进行精确分类。

然而,在实际的燃气流量计工作环境中,计量装置的工作负荷是变化的,振动信号数据采集的过程是在非平稳环境下进行的,加之信号的噪声干扰,传统的深度学习方法在实际应用中存在一定的限制。为了克服这些限制,本文对此提出了一种基于多尺度加权融合形态学网络(multi-scale weighted morphological network, MSWMN)的燃气流量计状态评估方法。首先,利用基于Wasserstein距离和谱归一化改进辅助分类器生成对抗网络(Wasserstein-spectral auxiliary classifier GAN, WS-ACGAN)算法对燃气流量计状态数据进行扩充,达到样本均衡的目的。然后,通过基于形态学的一维时序信号特征学习方法提取信号的有效特征。最后,引入多尺度自适应加权形态学网络,从不同尺度的特征中提取更加准确的信息,实现对燃气流量计健康状态的精确分类。

## 1 相关理论

### 1.1 基本ACGAN算法

ACGAN是生成对抗网络(generative adversarial network, GAN)的监督改进模型,可以生成多模式和高质量的样本<sup>[15]</sup>,由生成器 $G$ 和鉴别器 $D$ 组成,用于相互训练。与无监督GAN不同,ACGAN将标签信息嵌入到生成器的随机噪声输入中,其鉴别器不仅可以区分样本来源,还可以区分样本类别。此外,ACGAN可以通过在对抗性训练中引入真实样本和生成样本的分类损失来学习相应的类别信息。ACGAN的监督目标函数由2部分组成,分别为式(1)和式(2)。

$$L_{Source} = E_{x \sim P_{data}} [\log(D(x))] + E_{z \sim P(z)} [\log(1 - D(G(z, c)))] \quad (1)$$

$$L_{Class} = E_{x \sim P_{data}} [\log p(C = c | x)] + E_{z \sim P(z)} [\log p(C = c | G(z, c))] \quad (2)$$

其中, $L_{Source}$ 表示用于测量区分样本与真实样本的有效性的目标函数, $L_{Class}$ 表示用于测量样本类别的有效性的目标函数, $P_{data}$ 表示真实的样本分布, $P(z)$ 是噪声向量的先验分布, $D(x)$ 表示 $x$ 来自真实数据而不是生成数据的概率, $E_{x \sim P_{data}}$ 表示真实数据对 $x$ 的期望值, $E_{z \sim P(z)}$ 从噪声中采

集的  $z$  的期望值,  $G(z, c)$  是生成器  $G$  生成的样本。对于生成器  $G$  来说, 训练的目标是最大化  $L_{Class} + L_{Source}$ , 然而对于判别器  $D$  的目标则是最大化  $L_{Class} + L_{Source}$ 。

## 1.2 形态学方法介绍

基本的形态学算子包括膨胀 (dilation)、腐蚀 (erosion)、开运算 (opening) 和闭运算 (closing)。腐蚀能够使边界向内部收缩, 消除小且无意义的物体。膨胀能够将与物体接触的所有背景点合并到该物体中, 使边界向外部扩张, 填补物体中的空洞。开运算则是先腐蚀后膨胀的过程, 是一种用于去除噪点、缩小物体和分离连接物体的处理操作。闭运算是先膨胀后腐蚀的过程, 是一种用于填充空洞、连接物体和填充缺失特征的处理操作。表达式如下:

$$Dilation(x \oplus s): y_j^d = \max \{x_i + s_{ij}^d\} \quad (3)$$

$$Erosion(x \ominus s): y_j^e = \min \{x_i - s_{ij}^e\} \quad (4)$$

$$Opening(x \circ s): y_j^o = x \ominus s \oplus s \quad (5)$$

$$Closing(x \cdot s): y_j^c = x \oplus s \ominus s \quad (6)$$

其中,  $x$  是输入信号,  $x_i$  是第  $i$  通道中的输入,  $y_j$  是第  $j$  通道中的输出。  $s^d$  和  $s^e$  表示形态核 SE。

## 2 燃气流量计健康状态评估模型

针对如今燃气流量计健康状态监测困难的问题, 本文提出了利用 WS-ACGAN 和 MSWMN 进行燃气计量装置健康状态评估。首先, 提出了利用基于 Wasserstein 距离和谱归一化的 ACGAN 算法实现多模态数据扩充的方法, 然后提出利用平均帽变换 (average-hat transform, AVGH) 的形态学方法提取一维时序信号的有效特征。最后, 提出建立多尺度加权融合形态学网络实现燃气流量计健康状态的评估。

### 2.1 基于 Wasserstein 距离和谱归一化的 ACGAN 算法

在对燃气流量计振动信号数据进行数据扩充的过程中, 由于 ACGAN 的损失函数是用 JS 散度 (jensen shannon divergence, JSD) 设计的, 在训练过程中容易出现不稳定和梯度消失<sup>[16]</sup>。为此引入 Wasserstein 距离<sup>[17]</sup>来改进损失函数。Wasserstein 距离比 JSD 度更平滑, 当 2 个分布在高维空间中不重叠时, 它也可以提供有意义的梯度。Wasserstein 距离方程如下:

$$W(P_{r(x)}, P_{g(y)}) = \inf_{\gamma \sim \Pi(P_{r(x)}, P_{g(y)})} E_{(x,y) \sim \gamma} [\|x - y\|] \quad (7)$$

其中,  $P_{g(y)}$  表示生成样本  $y$  的分布,  $\gamma \sim \Pi(P_{r(x)}, P_{g(y)})$  表示真实样本和生成样本所有可能的联合分布的集合,  $E_{(x,y) \sim \gamma} [\|x - y\|]$  表示联合样本  $\gamma$  下样本对距离的期望值。因此 Wasserstein 距离被定义为在所有可能的联合分布中真实样本和生成样本之间对距离期望值取到的下确

界。为了方便求解, 根据 Kantorovich-Rubinstein 对偶性定理<sup>[18]</sup>将公式转变为式(8)。

$$W(P_{r(x)}, P_{g(y)}) = \sup_{\|f\|_L \leq 1} E_{x \sim P_{r(x)}} [f(x)] - E_{y \sim P_{g(y)}} [f(y)] \quad (8)$$

其中,  $f(\cdot)$  需满足 1-Lipschitz 连续, 即  $\|f(x) - f(y)\| \leq \|x - y\|$ 。另外, 将一组参数  $\omega$  来定义一系列可能的函数  $\{f_\omega\} \in w$ 。式(8)经验近似估计为式(9)。

$$W(P_{r(x)}, P_{g(y)}) = \max_{\omega \in w} E_{x \sim P_{r(x)}} [f_\omega(x)] - E_{y \sim P_{g(y)}} [f_\omega(y)] \quad (9)$$

为了使  $\omega$  位于一个紧凑的空间, 满足 Lipschitz 连续性条件, 因此将判别器的权重参数限制在一个恒定的范围内 (例如  $w = [-0.01, 0.01]^l$ ), 即权重裁剪<sup>[17]</sup>。

然而, 权重裁剪过程仍存在 2 个主要问题<sup>[19]</sup>。1) 经过多次权重裁剪操作后, 网络参数将收敛到裁剪的边界值, 无法获得所需的函数映射。2) 权重裁剪不稳定, 不当的权重裁剪边界值可能导致多层前向传播后梯度消失 (边界值过低) 或梯度爆炸 (边界值过高)。

为了提高稳定性, 引入谱归一化 (spectral normalization, SN) 来代替权值裁剪<sup>[20]</sup>。其实现过程是通过控制判别器中每一层权重矩阵的谱范数。具有权重矩阵  $W$  的线性层  $f(h) = W \times h$  的 Lipschitz 范数的定义如下:

$$\|f\|_{Lip} = \sup_h \sigma(\nabla f(h)) = \sup_h \sigma(W) = \sigma(W) \quad (10)$$

$$\sigma(W) = \max_{\|h\|_2 \leq 1} \|W \times h\|_2 \quad (11)$$

其中,  $\sigma(W)$  是矩阵  $W$  的最大奇异值, 为使  $f(x)$  满足 Lipschitz 约束, 使  $\sigma(W)$  的值接近于 1, 因此最终的 SN 表示如下:

$$W_{SN}(W) = \frac{W}{\sigma(W)} \quad (12)$$

### 2.2 基于形态学的处理

对于复杂的燃气工业环境, 噪声影响会干扰深度学习的特征学习过程, 为此引入 AVGH 形态学算子对一维时序信号数据进行处理。

基于基本的形态学算子, 可以分别定义 2 个形态梯度算子, 如下所示:

$$MG_{D\&E}(x) = (x \oplus s) - (x \ominus s) \quad (13)$$

$$MG_{C\&O}(x) = (x \cdot s) - (x \circ s) \quad (14)$$

其中,  $MG_{C\&O}$  表示自互补礼帽, 可改写为式(15)。

$$MG_{C\&O}(x) = (x \cdot s) - (x \circ s) = (x - x \circ s) + (x \cdot s - x) = WTH(x) + BTH(x) \quad (15)$$

其中,  $WTH(x)$  表示白色礼帽, 而  $BTH(x)$  表示黑色礼帽。  $WTH$  和  $BTH$  可以分别从振动信号中提取正脉冲和负脉冲。  $BTH$  的另一种形式可以定义如下:

$$PBTH(x) = x - x \cdot s \quad (16)$$



$AVGH$  可以用  $WTH$  和  $PBTH$  的总和来表示。

$$AVGH = WTH(x) + PBTH(x) = (x - x \circ s) + (x - x \circ s) = 2x - (x \circ s + x \circ s) \quad (17)$$

$AVGH$  可以同时从振动信号中提取正负脉冲特征,并有效地实现噪声抑制。

### 2.3 多尺度加权形态学网络

在燃气流量计的工业环境中,工业用户的工作负荷是时刻变化的,所有的样本采集过程都是在非平稳、变工况下进行的。为了提取更多有效的特征信息,采用多尺度形态学的特征学习。然而不同尺度的形态学层起到的效果是不一样的。其中大尺度的形态学层在特征学习过程能够很好的降低燃气流量计振动信号数据中的噪声影响;小尺度的特征学习可以更多的挖掘燃气流量计数据的细节信息。为此,引入一种自适应加权融合的方法,该方法通过网络模型端到端学习方式,自适应的确定不同尺度权重。

其中,假设是标度为  $\lambda$  的结构元素,可以得到式(18)。

$$\lambda s = s \oplus_{\lambda-1 \text{ times}} s \quad (18)$$

因此,多尺度  $AVGH$  可以表示如下:

$$AVGH(x_{\lambda s}) = 2x - (x \circ \lambda s + x \circ \lambda s) \quad (19)$$

为了选择有效尺度,提出运用一种自适应加权融合方法。首先,通过级联融合来自不同尺度的滤波信号。其次,每个通道的最大值和平均值被用来计算通道描述符。最后,在网络中嵌入一个完全连接的层,以生成用于尺度融合的权重。

对于滤波信号  $F$  的  $C$  通道,通过混淆全局平均池和全局最大池来构造包含全局空间信息的信道描述符。平均池化描述符  $F_{avg}^c$  和最大池化描述符  $F_{max}^c$  如下所示:

$$F_{avg}^c = \frac{1}{L} \sum_{l=1}^L F_c(l) \quad (20)$$

$$F_{max}^c = \max_{1 \leq l \leq L} F_c(l) \quad (21)$$

其中,  $F_c$  表示第  $c$  个通道的信号信息,  $L$  表示输入信号的长度。将这 2 个描述符输入到全连接层中以生成选择性权重。可按如下方式生成选择性权重:

$$\omega = \text{Sigmoid}(W_2, \text{ReLU}(F_{avg}^c + F_{max}^c, W_1)) \quad (22)$$

其中,  $W_1$  和  $W_2$  分别是 2 个全连接层的神经节点。最后,如式(23)所示生成经过形态学层的特征信号。

$$\tilde{F} = \omega \cdot F \quad (23)$$

选择性权重是根据信号本身自适应生成的,其中不需要任何专家知识。因此,它是一种完全自适应的加权方法。

### 2.4 燃气流量计健康状态评估的网络结构

根据多尺度自适应加权形态学的特征学习,搭建相应的 DNN 结构。燃气流量计健康状态评估的网络结构由多尺度加权形态学层、卷积层和最大池化层以及残差

块组成。利用多尺度加权形态学层来提取脉冲并滤除噪声,经过滤波后的信号,采用多层卷积和最大池化层进行进一步的特征学习和降维,最终实现燃气流量计健康状态的评估。该网络具体的训练过程如算法 1 所示。

#### 算法 1:训练过程

基于 WS-ACGAN 算法的多模态数据扩充

输入:训练样本  $X$  和标签  $Y$

设置网络参数并初始化

If 训练次数  $< N$ :

正向传播:

1) 多尺度加权形态网络生成形态学特征  $P$

2) 将  $P$  输入分类器以输出标签  $Y$

3) 计算交叉熵损失

反向传播:

4) 计算分类器的梯度,然后更新

5) 计算最大池化层的梯度,然后更新

6) 计算卷积核  $K_n$  和偏置  $b$  的梯度,然后更新

7) 计算  $SEs$  的梯度,然后更新

结束

## 3 实验及结果分析

为了验证燃气流量计健康状态评估网络的有效性,本节对华润燃气 G100 罗茨流量计进行仿真实验。通过可视化分析说明网络内部特征的学习过程。设置对比实验,将识别精度与其他现有深度学习方法进行比较。主要框架由 Pytorch 编写。所有实验均在一台装有 i5-9300H 中央处理器和 NVIDIA GeForce GTX1050 GPU 的计算机上运行。

### 3.1 数据集描述

本实验使用的数据集来自无锡华润燃气计量检定中心试验台。如图 1 所示,加速度传感器放置在流量计靠近转子腰轮的外壳处,用于收集振动信号。传感器选用的是 KISTR 公司的陶瓷剪切微型三轴加速度传感器,型号是 8763B050BB,其中灵敏度和分辨率分别为  $100 \pm 15 \text{ mV/g}$  和  $0.001 \text{ g}$ 。使用动态信号采集模块(即 KiDAQ)对信号实现数字化。燃气计量装置由无锡华润燃气提供的天信集团 G-100 型号气体罗茨流量计。如图 2 所示,计量范围为  $0.66 \sim 160 \text{ m}^3/\text{h}$ 。

实验选用 20 个来自不同工业用户的罗茨流量计表进行数据采集,采样频率设置为  $1 \text{ kHz}$ 。采集流量计在燃气流通过程中流速为  $80 \sim 160 \text{ m}^3/\text{h}$  的振动信号数据。采集的计量表中,一共有 3 种不同的健康状态,分别是健康状态、亚健康状态、异常状态。图 3 记录了  $160 \text{ m}^3/\text{h}$  流量条件下,罗茨流量计 3 种状态的表现。其中,健康状






图 1 燃气流量计检定试验台

Fig. 1 Gas flowmeter calibration test rig




图 3 160 m<sup>3</sup>/h 流量下罗茨流量计的振动信号

Fig. 3 Vibration signal of a roots flowmeter with a flow rate of 160 m<sup>3</sup>/h




图 2 燃气流量计

Fig. 2 Gas flow meter

态是正常工况下运行的流量计,其加速度振动信号表现相对平稳,出现少量低幅值尖峰,如图 3(a) 所示;亚健康状态是流量计在运行过程中腰轮出现卡顿延迟现象,其加速度信号的尖峰数量与健康状态相比有增多,且幅值变大,如图 3(b) 所示;异常状态是流量计内部腰轮转动缓慢卡壳,严重影响流量计内部运转。其加速度信号出现大量高幅值尖峰,如图 3(c) 所示。

此外,从采集的振动信号数据集中,选择不同流量计在 160 和 120 m<sup>3</sup>/h 流量下的数据,利用信号时域分析方法提取时域指标,如表 1~2 所示。结果表明,燃气流量的变化,会使得流量计在相同健康状态下的信号发生改变。

| 表 1 160 m <sup>3</sup> /h 流量罗茨流量计不同状态的性能指标                                                             |       |       |       |      |       |
|--------------------------------------------------------------------------------------------------------|-------|-------|-------|------|-------|
| Table 1 Performance indicators of 160 m <sup>3</sup> /h flow rate roots flow meter in different states |       |       |       |      |       |
|                                                                                                        | 峰峰值   | 均方根值  | 平均幅值  | 尖峰数量 | 波形指标  |
| 健康状态                                                                                                   | 1.676 | 0.255 | 0.294 | 10   | 1.342 |
| 亚健康状态                                                                                                  | 3.438 | 0.548 | 0.428 | 16   | 1.258 |
| 异常状态                                                                                                   | 8.032 | 0.868 | 0.623 | 24   | 1.394 |

| 表 2 80 m <sup>3</sup> /h 流量罗茨流量计不同状态的性能指标                                                             |       |       |       |      |       |
|-------------------------------------------------------------------------------------------------------|-------|-------|-------|------|-------|
| Table 2 Performance indicators of 80 m <sup>3</sup> /h flow rate roots flow meter in different states |       |       |       |      |       |
|                                                                                                       | 峰峰值   | 均方根值  | 平均幅值  | 尖峰数量 | 波形指标  |
| 健康状态                                                                                                  | 0.734 | 0.108 | 0.151 | 14   | 1.299 |
| 亚健康状态                                                                                                 | 0.895 | 0.120 | 0.223 | 18   | 1.305 |
| 异常状态                                                                                                  | 3.236 | 0.456 | 0.326 | 22   | 1.425 |

3.2 参数设置

表 3 给出了 WS-ACGAN 中判别器和生成器的结构、参数和激活函数。

表 4 给出了 MSWMN 的参数设置和结构。形态学算子的 SE 长度设置为 7,最大尺度设置为 7。

3.3 基于 WS-ACGAN 的数据扩充

由于异常状态的表具数量有限,采集的 8 700 个样本中,健康状态,亚健康状态和异常状态的 3 种类别的样本比例为 5:4:1。使用 WS-ACGAN 算法扩充样本容量使比例达到 1:1:1。

为了验证数据扩充对燃气流量计健康状态评估的影响,使用 CNN 网络对原始数据、基于 ACGAN 以及基于

表 3 WS-ACGAN 中判别器和生成器的参数设置和结构

Table 3 Parameter setting and structure of the discriminator and generator in WS-ACGAN

| 网络  | 结构及参数         | 激活函数       |
|-----|---------------|------------|
| 判别器 | 卷积层 (4×64)    | Leaky ReLU |
|     | 卷积层 (4×128)   | Leaky ReLU |
|     | 卷积层 (4×256)   | Leaky ReLU |
|     | 卷积层 (4×512)   | Leaky ReLU |
|     | 全连接层 (1)      | Sigmoid    |
| 生成器 | 全连接层 (3)      | LogSoftmax |
|     | 转置卷积层 (4×512) | ReLU       |
|     | 转置卷积层 (4×256) | ReLU       |
|     | 转置卷积层 (4×128) | ReLU       |
|     | 转置卷积层 (4×64)  | ReLU       |
|     | 转置卷积层 (4×1)   | ReLU       |
|     |               |            |

表 4 MSWMN 的参数设置和结构

Table 4 Parameter setting and structure of the MSWMN

| 结构    | 参数                 |
|-------|--------------------|
| 开运算   | 长度=7, 步长=2         |
| 闭运算   | 长度=7, 步长=2         |
| 卷积层 1 | 核尺寸及数量=64×64, 步长=2 |
| 卷积层 2 | 核尺寸及数量=64×64, 步长=1 |
| 最大池化层 | 核尺寸=2, 步长=1        |
| 全连接层  | 1 024-64-3         |

WS-ACGAN 的燃气流量计健康状态评估。如表 5 所示的诊断结果表明,使用基于 WG-ACGAN 进行样本多类别扩充后,深度网络对燃气流量计健康状态的评估能力有所提升。

表 5 CNN 网络基于不同数据处理的燃气流量计健康状态评估

Table 5 Health status evaluation of gas flowmeters based on different data processing in CNN networks %

| 数据类型            | 准确度      |
|-----------------|----------|
| 原始数据            | 85.890 6 |
| 基于 ACGAN 的数据    | 87.541 6 |
| 基于 WG-ACGAN 的数据 | 88.062 5 |

3.4 特征可视化和评估

本节执行特征可视化,以说明燃气流量计健康状态评估网络的内部操作。首先,网络接收到健康状态的信号,并在图 4 中的多尺度形态层中进行滤波处理。其中,  $y$  轴表示振幅,  $x$  轴表示振动信号的采样点。滤波后的信




图 4 燃气流量计健康状态评估网络中不同 SE 尺度的信号

Fig. 4 Signals of different SE scales in the gas flow meter health state assessment network

号比原始信号更平滑,并且使用形态学算子 AVGH 可以有效地提取正负脉冲特征。此外,不同 SE 尺度的滤波信号的幅度和频率也不同,信号幅度会随着 SE 尺度的增加而增加。大尺度的 SE 可以滤除噪声,但会忽略脉冲的详细信息,而小尺度的 SE 能够保留脉冲的细节,但不能有

效地抑制噪声。因此,使用多尺度形态滤波器可以在多个尺度上提取与故障相关的特征。为了得到更准确的结果,需要对不同 SE 尺度滤波后的信号进行融合。

本文使用自适应加权方法确定信号融合的权重。图 5 显示了燃气流量计不同健康状态下每种尺度的权重,x 轴表示 SE 尺度,y 轴表示相应尺度的权值。其中,健康状态下,尺度 6 获得较大的权重,而尺度 3 得到的权重较小。此外,不同健康状态下特征融合的权重也不同,说明该网络的特征融合方法能够根据信号自适应地确定权重。通过应用形态学滤波和加权融合技术,可以有效提取原始信号中的隐含的特征分量,并消除噪声。




图 5 用于特征融合的不同尺度的权重

Fig. 5 Weights of different scales for feature fusion

此外,在本节中,实现了对学习特征的低维可视化。通过使用 t 分布随机邻居嵌入算法<sup>[21]</sup> (t-distributed stochastic neighbor embedding, t-SNE),将这些通过燃气流量计健康状态评估网络的最后一层网络结构学习到的特征从高维投影到 2-D 空间。t-SNE 的可视化结果如图 6 所示,x 标签表示低维空间的维度 1,y 标签表示低维度空间的维度 2。




图 6 t-SNE 特征可视化

Fig. 6 t-SNE feature visualization

3.5 燃气流量计健康状态评估

图 7 在混淆矩阵中显示了基于 WS-ACGAN 和 MSWMN 的燃气流量计健康状态评估网络对每种健康状

态的识别率。该网络对异常状态的识别率达到 100%,对健康状态和亚健康的识别率也能达到 94%。网络的良好性能表明,多尺度形态层可以有效地从振动信号中提取脉冲特征并滤除噪声。




图 7 燃气流量计健康状态评估网络在混淆矩阵中的识别率

Fig. 7 Recognition rate of the gas flow meter health state assessment network in the confusion matrix

3.6 与传统方法的比较

本节与其他 DNN 进行比较,例如 ResNet、DenseNet、1-D CNN、DBN 和反向传播网络(back propagation network, BPN),以验证燃气流量计健康状态评估的网络性能。设置比较实验的详细参数如表 6 所示。其中卷积层,内核大小设置为 3,步长设置为 2;最大池化层,步幅设置为 2。DenseNet 中使用了 2 个密集连接块(即 dense)。ResNet 中使用了 2 个残差学习块(即 Res)。1-D CNN 中使用 3 个卷积层(即 Conv)和最大池化层(即 Pool)。DBN 和 BPN 使用网络结构“2048-1024100-11”来实现健康状态分类。批量大小和学习率均设置为 64 和 0.001。

| 表 6 传统 DNNs 的参数设置                             |                              |
|-----------------------------------------------|------------------------------|
| Table 6 Parameter setting of traditional DNNs |                              |
| 深度神经网络                                        | 结构                           |
| ResNet                                        | Conv-2×Res-Pool-Classifier   |
| DenseNet                                      | 2×dense-Conv-Pool-Classifier |
| 1-D CNN                                       | 3×[ Conv-Pool ]-Classifier   |
| DBN                                           | 2048-1024-3                  |
| BPN                                           | 2048-1024-3                  |

注:批量大小:64;学习率:0.001

表 7 列出了基于 WS-ACGAN 和 MSWMN 的燃气流量计健康状态评估网络与其他传统网络之间的比较结果。诊断结果表明,使用基于 WG-ACGAN 算法进行样本多类别扩充后,深度网络的效果有所提升;本文提出的方法拥有最佳的诊断性能。



表 7 不同网络的诊断结果

Table 7 Diagnostic results of different networks

%

| 网络模型              | 准确率    | 精确率    | 召回率    | F1 分数  |
|-------------------|--------|--------|--------|--------|
| BPN               | 73.603 | 62.292 | 56.241 | 56.517 |
| DBN               | 74.999 | 65.224 | 62.556 | 63.457 |
| 1-D CNN           | 85.891 | 86.906 | 83.129 | 84.834 |
| WG-ACGAN-DENSENet | 87.630 | 91.301 | 89.004 | 89.743 |
| WG-ACGAN-RESNet   | 91.145 | 92.142 | 90.618 | 91.353 |
| WG-ACGAN-MSWMN    | 94.921 | 95.944 | 95.962 | 95.337 |

为了进一步验证所提出网络的有效性,使用基于 WS-ACGAN 和 MSWMN 的燃气流量计健康状态评估网络与其他深度网络的训练过程如图 8 所示。结果表明,该网络比其他深度网络具有更好的训练效率,可以更为准确地识别样本。




图 8 燃气流量计健康状态评估网络与其他 DNNs 的训练过程

Fig. 8 Training process of gas flow meter health status assessment network compared to other DNNs

另外,本文使用连续块和随机子集交叉验证方法,消除训练样本和测试样本的时间依赖性,进一步验证模型的有效性,如表 8 所示。结果表明,本文提出的网络具有更好的泛化性能。

3.7 添加噪声的模拟实验

为验证所提出方法的鲁棒性,添加高斯噪声,其功率  $P$  变化范围为每个原始信号功率  $P_0$  的 0% ~ 500% (见图 9(a) ~ (c))。同样,将得到的整个预处理数据集随机分为 2 部分:90%用于训练,其余 10%用于测试。随着噪声功率的增加,3 种分类模型的准确率发生变化(如图 9(d)所示)。当噪声比小于等于 80% 时,基于

表 8 不同网络的交叉验证结果

Table 8 Cross-validation results of different networks

%

| 网络模型              | 随机子集  | 连续块    |        |        |        |
|-------------------|-------|--------|--------|--------|--------|
|                   |       | 10%测试集 | 20%测试集 | 30%测试集 | 40%测试集 |
| WG-ACGAN-DENSENet | 89.57 | 89.84  | 88.28  | 90.56  | 87.41  |
| WG-ACGAN-RESNet   | 91.16 | 91.53  | 89.01  | 91.67  | 90.75  |
| WG-ACGAN-MSWMN    | 94.66 | 94.27  | 94.01  | 95.93  | 93.35  |




图 9 原始信号添加噪声的模拟实验

Fig. 9 Simulation experiment of adding noise to the original signal

WS-ACGAN 和 MSWMN 的燃气流量计健康状态识别的网络识别精度均超过 90%。燃气流量计健康状态评估全过程如图 10 所示。




图 10 燃气流量计健康状态评估全过程

Fig. 10 The entire process of health status assessment for gas flow meters

4 结 论

本文对燃气流量计健康状态评估的全过程进行了探讨。传统的压损异常识别方法在大流量下可能存在误判的问题,且需要确定特定型号流量计的压损与瞬时流量的关系曲线。机器学习方法需要人工提取和选择特征,存在主观性,影响了故障状态诊断的准确性。而基于一般的深度学习方法能有效地克服了主观构建特征集的缺点,具有更好的适应性和准确性,但是无法有效对非平稳环境以及噪声干扰的复杂工业条件。因此,本文提出基于多尺度加权形态网络的燃气流量计健康状态评估方法,实验结果表明,该网络具有良好的脉冲分量提取和降噪性能,比其他 DNN(如 1-D CNN、DenseNet、ResNet)表现得更好,能够更为准确地判断燃气流量计的健康状态,具有更广泛的适用性和更高的准确性。未来的研究可以进一步探究深度学习在燃气流量计在线监测及故障诊断方面的应用。

参考文献

[1] 刘建华,杨霖,王奕中. 罗茨流量计故障原因及解决对

策[J]. 化工设计通讯, 2021, 47(10):74-81.  
LIU J H, YANG L, WANG Y ZH. Causes and solutions of roots flowmeter malfunctions [J]. Chemical Engineering Design Communications of China, 2021, 47(10):74-81.  
[2] 刘兴伟,王凡,柴家风,等. 燃气涡轮流量计压损异常辨识实验研究[J]. 煤气与热力,2023,43(1):4-8.  
LIU X W, WANG F, CHAI J F, et al. Experimental study on identification of abnormal pressure loss in gas turbine flowmeter [J]. Gas & Heat of China, 2023, 43(1):4-8.  
[3] 文红燕. 涡轮流量计在线监测系统研究[D]. 杭州: 中国计量大学, 2016:16-27.  
WENG H Y. Research on the online monitoring system for turbine flow meters [D]. Hangzhou: China Jiliang University, 2016:16-27.  
[4] PENG Y, QIAO W, CHENG F, et al. Wind turbine drivetrain gearbox fault diagnosis using information fusion

- on vibration and current signals[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-11.
- [5] SHAO D. A novel approach of multisensory fusion to collaborative fault diagnosis in maintenance [J]. Information Fusion, 2021, 74(1):65-76.
- [6] 唐波,陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3):88-93.
- TANG B, CHEN SH SH. Method of bearing fault diagnosis based on deep convolutional neural network[D]. Chinese Journal of Electronic Measurement and Instrumentation, 2020, 34(3):88-93.
- [7] WEI Z, LI C, PENG G, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load [J]. Mechanical Systems & Signal Processing, 2018, 100:439-453.
- [8] WEN L, LI X, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7):5990-5998.
- [9] ZHANG X, ZHAO Z, WANG Z, et al. Fault detection and identification method for quadcopter based on airframe vibration signals[J]. Sensors, 2021, 21(2):581.
- [10] YANG C, ZHOU K, LIU J. Supergraph: Spatial-temporal graph-based feature extraction for rotating machinery diagnosis[J]. IEEE Transactions on Industrial Electronics, 2022, 69(4):4167-4176.
- [11] CHENG Y, LIN M, WU J, et al. Intelligent fault diagnosis of rotating machinery based on continuous wavelet transform-local binary convolutional neural network [J]. Knowledge Based Systems, 2021, 216(15):106796.
- [12] IQBAL M, MADAN A K. CNC machine-bearing fault detection based on convolutional neural network using vibration and acoustic signal [J]. Journal of Vibration Engineering & Technologies, 2022, 10(5):1613-1621.
- [13] XU Y L, ZHI X W, SHU Q L, et al. A hybrid deep-learning model for fault diagnosis of rolling bearings[J]. Measurement, 2021, 169(6):108502.
- [14] SURENDRAN R, KHALAF O I, ROMERO C. Deep learning based intelligent industrial fault diagnosis model[J]. Computers, Materials & Continua, 2022, 70(3):6323-6338.
- [15] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier GANs [J]. Proceedings of the 34th International Conference on Machine Learning, 2016. DOI:10.48550/arXiv:1610.09585.
- [16] LI W, ZHONG X, SHAO H, et al. Multi-mode data augmentation and fault diagnosis of rotating machinery using modified ACGAN designed with new framework[J]. Advanced Engineering Informatics, 2022, 52:101552-101568.
- [17] 高闻霁,杨波,闵琳孜. 低分辨率红外感知系统的人体行为数据增强[J]. 仪器仪表学报, 2023, 44(1):163-171.
- GAO W P, YANG B, MING L Z. Human behavior data augmentation for the low resolution infrared perception systems[D]. Chinese Journal of Scientific Instrument, 2023, 44(1):163-171.
- [18] CEDRIC V. Optimal transport: Old and new [J]. Grundlehren Der Mathema-Tischen Wissenschaften, 2009, 47(4):723-727.
- [19] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein GANs [J]. Proceedings of 31st Conference of Neural Information, 2017. DOI:10.48550/arXiv:5767-5777.
- [20] MIYATO T, KATAOKA T, KOYAMA M, et al. Spectral normalization for generative adversarial networks [J]. ArXiv Preprint, 2018. DOI:10.48550/arXiv:1802.05957.
- [21] MAATEN L V D, HINTON G E. Visualizing high-dimensional data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9:2579-2605.

## 作者简介



胡凡, 2021年于山东理工大学获得学士学位, 现为江南大学硕士研究生, 主要研究方向为设备故障诊断。

E-mail: hnyz\_hufan@163.com

**Hu Fan** received his B.Sc. degree from Shandong University of Technology in 2021. He is currently a



master student at Jiangnan University. His main research interest is equipment fault diagnosis.



**张永**, 2001 年于江苏师范大学获得学士学位, 2007 年于三峡大学获得硕士学位, 2010 年于华中科技大学获得博士学位, 现为武汉科技大学教授, 主要研究方向为机电设备的故障诊断与剩余使用寿命预测。

E-mail: zhangyong77@wust.edu.cn

**Zhang Yong** received his B. Sc. degree from Jiangsu Normal University in 2001, received his M. Sc. degree from China Three Gorges University in 2007, and received his Ph. D. degree from Huazhong University of Science and Technology in 2010. He is currently a full professor at Wuhan University of Science and Technology. His main research interests include fault diagnosis and remaining service life prediction



**谢林柏** (通信作者), 1996 年于湖南师范大学获得学士学位, 2001 年于西南交通大学获得硕士学位, 2004 年于华中科技大学获得博士学位, 现为江南大学教授, 主要研究方向为过程建模和控制、智能检测和系统安全。

E-mail: xie\_linbo@jiangnan.edu.cn.

**Xie Linbo** (Corresponding author) received his B. Sc. degree from Hunan Normal University in 1996, received his M. Sc. degree from Southwest Jiaotong University in 2001, and received his Ph. D. degree from Huazhong University of Science and Technology in 2004. He is currently a full professor at Jiangnan University of Science and Technology. His main research interests include process modeling and control, intelligent detection and systems safety.