

DOI: 10.19650/j.cnki.cjsi.J2108890

# 改进稠密块轻量化神经网络的管道泄漏孔径识别\*

孙洁娣<sup>1,2</sup>, 王利轩<sup>1,2</sup>, 温江涛<sup>3</sup>, 肖启阳<sup>4</sup>

(1. 燕山大学信息科学与工程学院 秦皇岛 066004; 2. 燕山大学河北省信息传输与信号处理重点实验室 秦皇岛 066004; 3. 燕山大学河北省测试计量技术及仪器重点实验室 秦皇岛 066004; 4. 河南大学人工智能学院 郑州 450046)

**摘要:**深度神经网络的管道泄漏孔径识别方法虽然识别率高,但因结构复杂造成参数量大、内存占用大,极大地限制了其在资源有限的工业环境及实时处理中的应用。提出一种优化卷积改进稠密块的轻量化神经网络用于管道泄漏孔径识别。首先将深度可分离卷积与异构卷积结合,构造了新的多卷积稠密块实现泄漏信号的特征提取;之后采用卷积注意力机制对特征进行权重划分,实现特征的重要性区分;最后通过分类器获取结果。实验结果表明,本文方法识别准确率达到96.59%,参数量仅为781 KB。本文方法在保证高识别准确率的同时,参数量及浮点数大幅下降,训练时间也有所减少,改善了实时响应能力,对于实际工业监测应用有指导意义。

**关键词:**管道泄漏孔径识别;轻量化网络;深度可分离卷积;异构卷积;多卷积稠密块

**中图分类号:** TP391.4 TH865 **文献标识码:** A **国家标准学科分类代码:** 460.40

## Pipeline leakage aperture recognition based on lightweight neural network with the improved dense block

Sun Jiedi<sup>1,2</sup>, Wang Lixuan<sup>1,2</sup>, Wen Jiangtao<sup>3</sup>, Xiao Qiyang<sup>4</sup>

(1. School of Information Science and Engineering, Yanshan University, Qinghuangdao 066004, China; 2. Hebei Key Laboratory of Information Transmission and Signal Processing, Yanshan University, Qinhuangdao 066004, China; 3. Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Yanshan University, Qinghuangdao 066004, China; 4. School of Artificial Intelligence, Henan University, Zhengzhou 450046, China)

**Abstract:** The identification method of pipeline leakage aperture based on the deep neural network has a high identification rate. However, its application in industrial environment and real-time processing is greatly limited due to the large number of parameters and large memory consumption due to its complex structure. To address this issue, an optimized convolution improved dense block lightweight neural network is proposed for the pipeline leak aperture identification. Firstly, a new multi-convolutional dense block is constructed by combining the deeply separable convolution with the heterogeneous convolution to extract the features of leakage signals. Then, the convolutional attention mechanism is used to classify the weight of features to realize the importance distinction of features. Finally, the results are obtained by classifier. Experimental results show that the recognition accuracy of the proposed method is 96.59%, and the number of parameters is only 781 KB. While ensuring high recognition accuracy, the number of parameters and floating point numbers are greatly reduced, the training time is also reduced, and the real-time response ability is improved, which has guiding significance for practical industrial monitoring applications.

**Keywords:** pipeline leak aperture identification; lightweight neural network; depth separable convolution; hetconv; multi-convolution dense block

收稿日期: 2021-11-18 Received Date: 2021-11-18

\* 基金项目: 河北省自然科学基金(E2020203061, E2016203223)、河北省高等学校科学技术研究项目(QN2019133)、河南省青年人才托举计划(2021HYTP014)项目资助

## 0 引言

天然气是工业生产和人们生活的主要能源之一,我国天然气传输多数采用压力管道输送方式,由于管道老化等问题以及沿途复杂的自然环境影响,管道泄漏事故时有发生。管道泄漏会带来经济损失、人员伤亡和环境污染,因此研究管道泄漏孔径识别,对于快速准确判断泄漏规模,迅速制定抢修措施意义重大<sup>[1]</sup>。

传统的管道泄漏孔径识别主要采用特定特征结合分类器的方法,焦敬品等<sup>[2]</sup>通过分析泄漏信号的时域、频域及波形特点,提取出可用于泄漏信号表征的20种特征参数,构建了泄漏声信号BP神经网络识别系统。Sun等<sup>[3]</sup>提出了一种基于LMD包络谱熵及SVM的天然气管道微小泄漏孔径识别方法。张勇等<sup>[4]</sup>利用改进阈值函数的小波变换对管道泄漏信号进行去噪,实现泄漏定位。通过文献分析发现传统方法主要是通过傅里叶变换、小波变换、希尔伯特-黄变换、经验模态分解和局域均值分解等方法提取泄漏信号的特征进行分析;再通过聚类、前后向传播、支持向量机等方法进行泄漏识别。但这类方法过度依赖人工专业经验知识,通用性差且浅层模型无法全面反映泄漏信号的特征。

管道泄漏可视为管道的一种故障状态,因此泄漏孔径识别本质上是通过分析复杂泄漏信号而实现的故障诊断。近年来深度学习在故障诊断领域成为新的研究热点,取得了很多研究成果。Wen等<sup>[5]</sup>提出了基于深度卷积网络的故障诊断方法,将一维时域信号转换为二维灰度图像后,通过学习图像特征,消除手工特征的影响,实现了故障识别。Bai等<sup>[6]</sup>提出了一种多通道卷积神经网络结合数据增强技术的滚动轴承故障诊断方法。Deng等<sup>[7]</sup>提出基于多尺度特征融合的改进深度残差网络,用于旋转机械故障诊断。学者们把深度神经网络类方法也引入管道泄漏研究中,孙洁娣等<sup>[8]</sup>针对数据冗余、特征提取受主观因素的影响较大,结合压缩感知与深度学习提出一种在变换域进行泄漏信号的压缩采集,在压缩感知域进行自适应特征提取及识别的智能天然气管道泄漏孔径识别方法。温江涛等<sup>[9-10]</sup>将压缩感知与卷积网络结合进行特征提取,利用Softmax实现对泄漏孔径的分类;并引入迁移学习,提出了一种基于域不变特征深度迁移学习的管道入侵事件识别方法。通过分析文献发现虽然基于深度神经网络的方法识别准确率较高,但是主要通过构建复杂的网络模型、不断加深网络深度、层与层之间增加多种处理来实现诊断性能的提升,造成参数量庞大、对监测系统软硬件要求过高,训练和测试需要耗费大量的计算资源和更多的时间,难以满足实际管道泄漏监测要求的快速识别和及时响应的要求,极大地限制了此类方法在资源有限的工业环境及实时在线处理中的应用。

针对上述问题,为了改善深度神经网络类方法在诸如管道泄漏等实际应用中的快速识别和及时响应方面的不足,学者们在深度模型压缩方面进行了大量研究。目前常用的减少模型计算量的方法主要考虑从参数压缩及结构压缩两个方面<sup>[11-12]</sup>,参数压缩类主要有网络剪枝、网络量化、低秩分解和参数共享等;在结构压缩方面,主要有知识蒸馏、轻量级网络设计及基于神经网络结构搜索的方法。Wang等<sup>[13]</sup>提出在激活函数和权重上先后进行量化,稀疏率为75%时,准确率可达到94.49%。Yang等<sup>[14]</sup>提出用卷积滤波器表示的权重共享方法进行模型压缩,当参数量降为原来的60%时,识别准确率为97.19%。Jiang等<sup>[15]</sup>提出一种基于权值剪枝的压缩超分辨率网络的方法,准确率为96.1%,参数量仅为原来网络的41%。Cui等<sup>[16]</sup>提出将结构化剪枝和密集知识蒸馏技术结合的联合模型压缩方法,稀疏率为10%时,模型参数量为62.9M,识别准确率为93.3%;稀疏率为90%时,模型参数量为29.6M,识别准确率为90.7%,在模型精度牺牲不大的情况下,参数量实现了显著压缩。以上方法都在一定程度上降低了模型的参数量和计算量,但都是在对已有的网络模型进行压缩降低对计算量的需求。通过模型压缩减小参数量的方法取得良好的效果的前提是必须确保已有网络模型已经取得了较好的识别效果,此类方法过渡依赖于原模型。

为了降低训练网络模型对运行系统和设备的要求,同时减少存储空间占用量,设计更加精简、有效的网络,折中考虑模型的准确度和参数量是解决管道泄漏快速识别和及时响应问题的更好途径。为此,本文提出了一种基于多卷积稠密块轻量化神经网络的管道泄漏孔径识别方法。首先从优化特征学习入手,通过将深度可分离卷积和异构卷积模块进行密集连接构造了一种多卷积稠密块,实现了新的轻量级网络设计;为了改善管道泄漏特征的区分能力,引入注意力机制对特征权重进行划分;最后利用Softmax实现泄漏孔径分类。本文方法从深度神经网络结构单元的轻量化入手,实现从源头上的网络压缩。实验结果表明,本文提出的方法可以减少模型的参数量(parameters, Params)和浮点数(floating points, FLOPs)计算,同时减少网络训练所需时间,即能够在占用内存较小的同时,快速识别管道泄漏孔径大小,降低对运行系统的资源要求。

## 1 基于改进稠密块的特征学习

深度卷积神经网络(convolutional neural network, CNN)因其良好的性能已在机械故障信号特征提取中得到广泛应用,多种经典深度神经网络大都是以CNN为基础,通过深度堆叠卷积层,并添加一些其他的操作

构成,如:跳跃连接、密集连接等,通常存在冗余量大、参数量大和训练时间长等问题。稠密网络<sup>[17]</sup>因其密集连接的操作方式,使得大量的特征被复用,实现了较好的识别效果,但增加了模型的参数量,使得模型的占用内存变大,训练时间增加,对运行系统性能要求较高。本文从优化卷积操作方面改进稠密网络,通过将深度可分离卷积和异构卷积结合来改进稠密块,合理减少卷积核的数量、减少特征的通道数,设计更加高效的卷积操作方式<sup>[18]</sup>,从而在保证网络性能的前提下,减少网络模型的参数量和浮点数,实现管道泄漏孔径的快速识别。

### 1.1 多卷积稠密块的构造

针对目前深度神经网络冗余量大的问题,学者们提出用深度可分离卷积(depth separable convolution, DS-Conv)代替标准卷积以降低卷积操作中的参数量和空间存储,形成轻量级网络结构,如:Xception<sup>[19]</sup>、MobileNetV1<sup>[20]</sup>、MobileNetV2<sup>[21]</sup>、ShuffleNet<sup>[22]</sup>等。但仅使用深度可分离卷积在减小参数量的同时会破坏输出通道数和卷积核之间的相互作用,导致模型性能下降。异构卷积(Hetconv)<sup>[23]</sup>能够在准确率和FLOPs之间进行权衡,且可以插入到任何现有的网络架构中,在保证较高准确率的同时,进一步减少模型的参数量。因此本文在深度可分离卷积的基础上引入异构卷积,构造了一种多卷积稠密块。构造方法如下:

1) 先将深度可分离卷积模块与异构卷积模块进行密集连接:深度可分离卷积模块中用 $1 \times 1$ 的卷积核代替 $3 \times 3$ 的卷积核,对输入的特征图进行降维处理,减少输入到 $3 \times 3$ 卷积的特征通道数,从而降低了网络模型的参数量。

2) 引入逆残差块连接思想,由于深度可分离卷积本身不能改变特征的通道数,而逆残差连接可以先对输入的特征图进行通道扩张,在特征转换之后再行通道压缩,这样可以在减少特征通道数时防止有效特征信息的丢失。

3) 异构卷积模块中,每个通道用 $1 \times 1$ 和 $3 \times 3$ 卷积核将标准卷积进行分组操作,这样可以去除多余的网络参数,缩减模型大小,同时建立了更多的非线性变换,使得网络的特征学习能力更强。

最终得到的改进多卷积稠密块结构如图1所示。

### 1.2 多卷积稠密块性能分析

深度可分离卷积是将深度卷积和逐点卷积相结合,对标准卷积的通道和空间的相关性进行解耦以降低模型的参数量和空间存储,但是直接使用会引起模型的性能下降。异构卷积可以弥补深度可分离卷积的不足,在模型的参数量和识别准确率之间取得折衷。采用深度可分

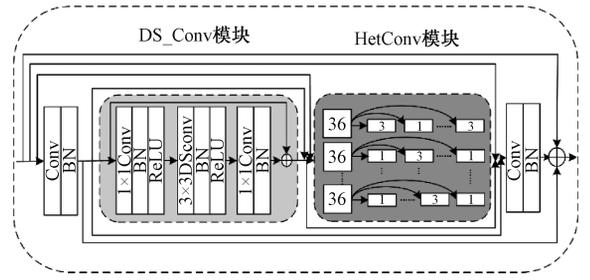


图1 多卷积稠密块结构

Fig. 1 Multi-convolution dense block structure

离卷积和异构卷积相结合进行特征提取可以在保证模型性能的情况下,减少卷积核的数量、减小输入特征的通道数、减小模型的参数量进而实现管道泄漏孔径的快速识别。

假设深度可分离卷积的卷积核为 $D_K \times D_K$ ,输入特征图为 $\{D_F, D_F, M\}$ , $M$ 为输入通道数,输出的特征图为 $\{D_F, D_F, N\}$ , $N$ 为输出通道数,其中 $D_F$ 为特征图的宽和高。深度分离卷积和标准卷积计算量对比如下:

$$\frac{\text{count}_{DS}}{\text{count}} = \frac{D_K D_K M D_F D_F + M N D_F D_F}{D_K D_K M N D_F D_F} = \frac{1}{N} + \frac{1}{D_K^2} \approx \frac{1}{D_K^2} \quad (1)$$

由式(1)可知,深度可分离卷积的参数量仅为标准卷积的 $\frac{1}{D_K^2}$ 。

对比深度可分离卷积直接代替标准卷积减少参数量时会引起模型性能下降,Hetconv中引入了参数 $P$ 来控制不同类型卷积核的个数, $P$ 值的大小可以在准确率和FLOPs之间进行权衡。假设Hetconv的输入特征图为 $\{D_0, D_0, M\}$ , $M$ 为输入通道数,输出的特征图为 $\{D_0, D_0, N\}$ , $N$ 为输出通道数。卷积核的 $1/P$ 控制 $K \times K$ 的内核,剩下的 $1-1/P$ 控制 $1 \times 1$ 的内核。异构卷积的参数量大小主要由参数 $P$ 和卷积核大小 $K$ 控制, $P$ 和 $K$ 越大,参数量越小。异构卷积和标准卷积的计算量对比如下:

$$\frac{\text{count}_H}{\text{count}} = \frac{(D_0 \times D_0 \times M \times N \times K \times K) / P + D_0 \times D_0 \times N \times (M - M/P)}{D_0 \times D_0 \times M \times N \times K \times K} = \frac{1}{P} + \frac{(1 - 1/P)}{K^2} \quad (2)$$

由式(2)可知,异构卷积的参数量为标准卷积的 $\frac{1}{P} + \frac{(1 - 1/P)}{K^2}$ 。异构卷积与标准卷积参数量对比如图2所示。

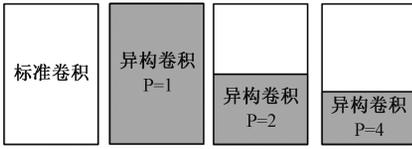


图 2 异构卷积参数量对比

Fig. 2 Comparison of hetconv parameter volume

从图 2 中可以看出当  $P=1$  时,异构卷积与标准卷积的参数量相等; $P=2$  时,参数量约为标准卷积的 50%; $P=4$  时,参数量约为标准卷积的 30%。异构卷积相比于其他卷积方式没有延迟,可以在保证准确率的同时,有效减少 FLOPs。

### 1.3 基于 CBAM 的特征重要性区分

本文构造的多卷积稠密结构中,深度可分离卷积模块和异构卷积模块减少了特征通道数,但每个特征通道所包含的特征信息不是均等的,其中存在大量的  $1 \times 1$  卷积核,占用大量内存的同时可能会传递一些无效的特征信息,因此本文引入卷积注意力机制对特征的权重进行重新分配,进而实现特征的重要性区分。

卷积注意力模块 (convolutional block attention module, CBAM)<sup>[24]</sup>通过对特征图中通道位置和空间位置分配不同的权重以供后续网络侧重学习。CBAM 可以直接插入到现有的网络中,实现特征重要性的区分。

通道注意力是利用特征间的通道关系生成通道注意力图,其关注的是全局特征,主要是建模各个特征通道的重要程度,然后针对不同的任务对各个特征通道进行增强或抑制。通道注意力的计算如式(3)所示:

$$M_c(F^c) = s( Conv_c( AvgPool(F^c) ) + Conv_c( MaxPool(F^c) ) ) = s( Conv_c(F^c_{avg}) + Conv_c(F^c_{max}) ) \quad (3)$$

其中,  $s$  为 sigmoid 函数,  $Conv_c$  为权重共享网络中的卷积层。

空间注意力是利用特征间的空间关系生成空间注意力图,其关注的是局部特征,是特征信息中最重要的一部分,与通道注意力相辅相成。空间注意力实现了对特征通道中信息的重要性区分。空间注意力计算为:

$$M_s(F^s) = s( Conv_s( AvgPool(F^s) ) + Conv_s( MaxPool(F^s) ) ) = s( Conv_s(F^s_{avg}) + Conv_s(F^s_{max}) ) \quad (4)$$

其中,  $F^s = M(F^c) \times F^c$ ,  $s$  为 sigmoid 函数,  $Conv_s$  为权重共享网络中的卷积层。

## 2 本文提出的方法

目前故障诊断领域常用的深度神经网络普遍存在模型参数量较大,训练时间长,计算速度慢等问题,在实际应用中面临对硬件要求高、实时响应能力不足的问题。本文在天然气管道泄漏监测研究中,以前文构造的多卷积稠密块为基础,搭建管道泄漏孔径识别网络,不仅实现了泄漏孔径的快速准确识别,而且降低了深度模型的参数量及浮点数。

本文提出的故障诊断网络主体包括多卷积稠密块 (主体为深度可分离卷积模块级联异构卷积模块)、过渡块、特征重要性区分模块、平铺层、全连接层和 Softmax 层。泄漏信号首先经深度网络学习后得到大量的特征,进一步通过 CBAM 对特征进行权重划分,去除一些冗余特征;最后通过 Softmax 实现管道泄漏孔径的高准确度识别。诊断网络的整体结构如图 3 所示。

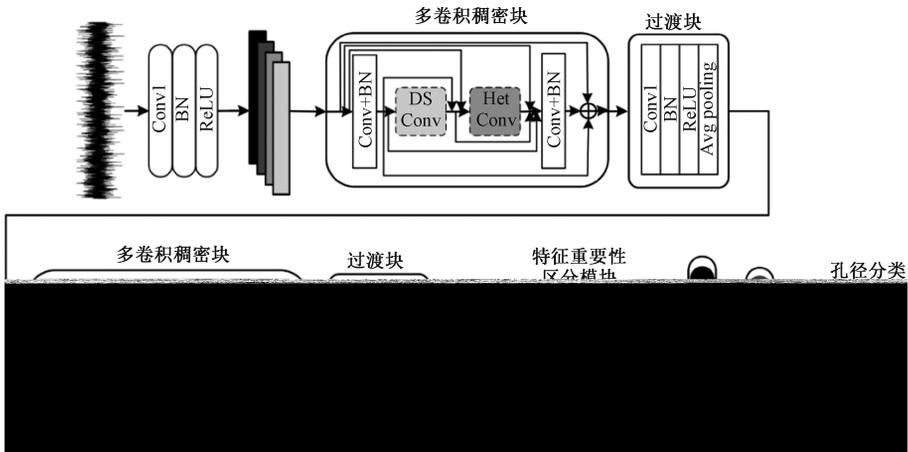


图 3 本文方法诊断处理过程图

Fig. 3 Flowchart of the proposed diagnosis method

## 2.1 基于多卷积稠密块的特征提取

管道泄漏信号是复杂非平稳信号,本文提出的改进的轻量级稠密网络进行不同孔径泄漏特征的提取,该网络在保证提取效果的同时,通过改进卷积方式极大地降低了模型的参数量。本文提出的多卷积稠密块是将深度可分离卷积与异构卷积进行密集连接,将单层特征重用扩展到多层,将前面层的特征映射到之后的每一层,这样操作不需要重新学习前面层的特征图,相比于其他模型具有更少参数,并且改进了整个网络的信息流和梯度,使得训练深层网络变得简单,因此构建的模块可以在维持模型的准确率的同时,减少了参数量和计算量,降低对运行系统的性能要求,提高了泄漏孔径识别的实时性。

## 2.2 管道泄漏孔径识别

通常层数较深的网络提取的特征更加全面,但同时会增加模型的参数量和计算复杂度,进而加大模型的训练难度。本文分析的管道泄漏信号为一维数据,样本维度低,为了避免增加模型的训练难度,本文选择堆叠2个多卷积稠密块和过渡块。

在网络训练过程中,首先采用交叉熵损失函数计算预测概率分布和目标概率分布之间的误差;其次使用Adam优化算法降低训练过程中的交叉熵损失函数的值,降低概率分布之间的误差;最后利用反向传播算法进行网络参数更新,逐步提高模型的准确率。

图4为本文管道泄漏孔径识别方法的处理过程。

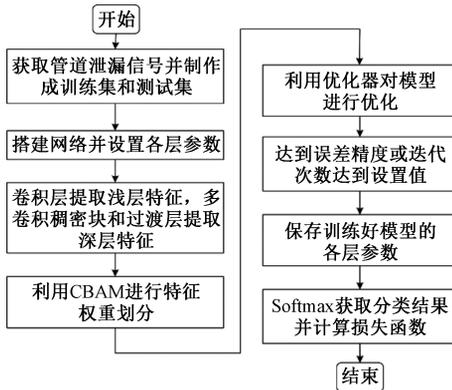


图4 本文方法处理过程

Fig. 4 Flowchart of the proposed method

诊断过程中,首先通过卷积池化层提取数据的浅层特征;其次堆叠多卷积稠密块和过渡块进一步提取深层的细节特征;然后用卷积注意力机制模块CBAM对输入特征进行通道注意和空间注意的权重划分,进一步提取有用特征,去除冗余特征,实现特征的重要性区分;最后通过Softmax分类器获取孔径分类结果,实现泄漏孔径的快速识别。

## 3 实验结果与分析

### 3.1 实验情况简介

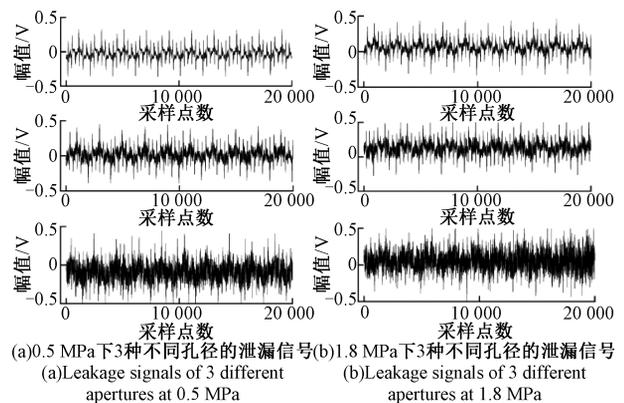
为了验证本文提出的方法,对实验采集的泄漏信号进行处理及结果分析。考虑到安全问题,实验中采用空气代替天然气,构建承压管道泄漏模拟实验装置。实验使用的泄漏数据来自承压管道模拟泄漏装置,模拟泄漏孔径为1、2和4 mm,泄漏信号采集的压力变化范围为0.5~2.0 MPa,泄漏信号的采样速率为100 kHz,信号由多个压电振动传感器模块采集,图5给出某泄漏孔附近安装的压电传感器。



图5 实验现场某压电传感器放置图

Fig. 5 Deployment of the piezoelectric sensor in field

在不同压强下采集大量管道泄漏信号,图6中给出了某传感器在不同压强下采集到的两组管道泄漏信号:图6(a)为压强0.5 MPa下3种不同孔径的泄漏信号,图6(b)为压强1.8 MPa下3种不同孔径的泄漏信号。



(a) 0.5 MPa下3种不同孔径的泄漏信号 (b) 1.8 MPa下3种不同孔径的泄漏信号  
(a) Leakage signals of 3 different apertures at 0.5 MPa (b) Leakage signals of 3 different apertures at 1.8 MPa

图6 3种不同孔径的管道泄漏信号

Fig. 6 Pipeline leakage signals with 3 different diameters

由图6中3种不同孔径泄漏信号的时域波形图可以看出,泄漏信号幅值受孔径大小影响较大,孔径越大,信号波动幅度更为剧烈,且谐振影响更为明显;管道内压强越大,泄漏信号波动更为复杂。

### 3.2 网络参数设置及识别结果

按本文方法构造孔径识别网络,参数如表1所示。

表1 本文网络参数表

Table 1 Parameters of the proposed network

层类型	值大小	输出尺寸
输入	-	36×1×784
Conv1	1 * 6 Conv, s = 1	36×24×781
多卷积稠密块1	1 * 1 Conv, s = 1	36×36×781
	3 * 3 DS_Conv, s = 1	
	1 * 1 Conv, s = 1	
	1 * 1/3 * 3 Hetconv, s = 1	
过渡块1	1 * 1 Conv, s = 1	36×18×390
	1 * 2 pool, s = 2	
多卷积稠密块2	1 * 1 Conv, s = 1	36×30×390
	3 * 3 DS_Conv, s = 1	
	1 * 1 Conv, s = 1	
	1 * 1/3 * 3 Hetconv, s = 1	
过渡块2	1 * 1 Conv, s = 1	36×15×195
	1 * 2 pool, s = 2	
Conv2	1 * 3 Conv, s = 1	36×15×97
平铺层	-	1 455
FC1	-	500
FC2	-	100
Softmax	-	3

采用本文深度网络进行不同泄漏孔径分类,取每类样本400个,其中75%用于训练,25%用于测试,为避免随机因素影响,进行10次实验后,统计泄漏孔径的平均识别准确率及标准差。以某传感器为例,统计压强0.5~2.0 MPa范围3种孔径的管道泄漏信号识别准确率如图,统计结果如图7所示。

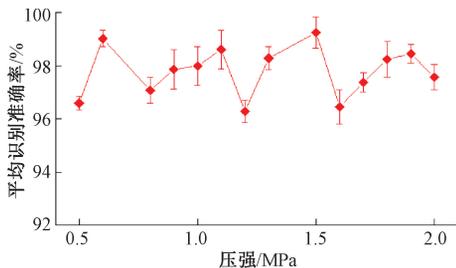


图7 不同压强下多次实验平均识别准确率及波动

Fig. 7 Average accuracy and fluctuation under different pressures

从图7中多次实验的波动情况可以看出不同压强下的平均识别准确率结果相差不大,都实现了较高的识别准确率。

不同压强下的平均识别准确率、多次诊断结果的标准差及训练网络所需时间的统计结果如表2所示。

表2 不同压强下的实验结果

Table 2 Experimental results under different pressures

压强/MPa	平均准确率/%	标准差/%	训练时间/s
0.5	96.59	0.25	278
0.6	99.02	0.31	282
0.8	97.07	0.49	285
0.9	97.86	0.74	286
1.0	97.99	0.73	282
1.1	98.61	0.73	284
1.2	96.28	0.42	279
1.3	98.28	0.43	276
1.5	99.25	0.58	280
1.6	96.45	0.65	281
1.7	97.37	0.36	277
1.8	98.24	0.66	277
1.9	98.45	0.34	277
2.0	97.57	0.47	275

从表2的统计结果分析可以得到,不同压强下的平均识别准确率为97.51%,本文方法整体上实现了较好的识别结果;其中压强为1.5 MPa时的平均识别准确率最高,达到了99.25%,实现了较好的识别效果。图8为某次实验的识别准确率曲线和训练损失曲线。

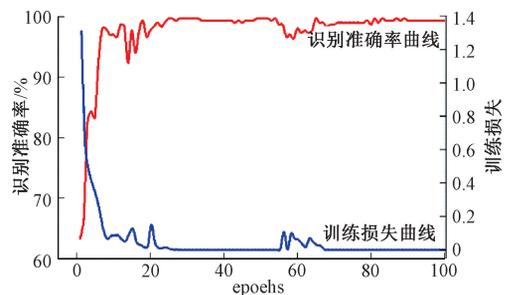


图8 某次实验的识别准确率曲线和训练损失曲线

Fig. 8 Recognition accuracy and training loss curves in an experiment

从图8的识别准确率变化曲线中可以看出本文方法的识别效果较好,具有较好的稳定性;从训练损失变化曲线中可以看出,本文方法收敛较快,损失较小。

### 3.3 网络主要参数的影响

本文构建的诊断网络中,深度卷积结构及注意力机制对诊断结果有较大的影响,选择合适的卷积结构既可

以保证诊断准确率,又可以有效缩减参数量和训练时间从而提高诊断效率,降低对运行设备的性能要求,改善泄漏识别的响应速度。下文将探讨不同的卷积结构和不同策略的注意力机制对本文所提方法诊断结果的影响。

### 1) 不同卷积结构的影响

在基于卷积叠加结构的网络中,不同的卷积操作方式对网络的特征提取效果有较大影响。本文诊断网络构建过程中采用了前文构建的多卷积密集网络结构,为了验证本文网络的效果,文中对几种常用的卷积结构进行了对比,对比网络的主要结构如下:

(1) 标准的稠密网络结构(标准卷积)+CBAM

(2) 稠密块中采用深度可分离卷积(DS\_Conv)代替标准卷积+CBAM

(3) 稠密块中采用异构卷积代替标准卷积+CBAM

(4) 本文方法(多卷积稠密块+CBAM,即(2)+(3))

基于以上4种卷积结构的诊断网络进行了实验对比。以某传感器、压强为0.5 MPa的泄漏数据处理结果为例,表3统计了10次重复诊断实验的平均准确率、标准差、参数量、浮点数和训练时间。

表3 不同卷积结构的实验对比结果

Table 3 Experimental results comparison of different convolution structures

方法	平均准确率/%	训练时间/s	参数量/K	FLOPs/M
(1)	95.05±0.61	716	1 412	454
(2)	94.46±1.04	650	1 405	324
(3)	95.37±0.33	387	929	151
(4)	<b>96.59±0.25</b>	<b>278</b>	<b>781</b>	<b>95</b>

从表3的统计结果可以看出,本文提出的基于改进稠密块的方法平均识别准确率最高、多次诊断结果的标准差最小,具有较好的鲁棒性;参数量为原来网络的50%,FLOPs为原来网络的21%,训练时间为原来网络的39%,均优于标准的稠密网络结构。

图9为4种不同卷积结构的平均准确率、标准差、参数量、FLOPs和训练所需时间的对比。

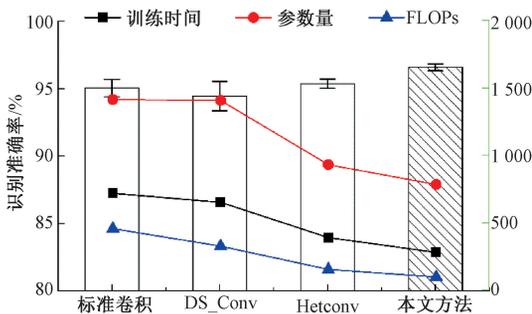


图9 4种不同卷积结构的对比

Fig. 9 Comparison of four different convolution structures

从图9中可以看出采用不同卷积结构对泄漏孔径的识别结果有一定影响,本文方法识别准确率最高;优化卷积操作的单独深度可分离卷积及单独异构卷积构成的诊断网络,在参数量、FLOPs参数及训练时间也都比标准卷积有所减少,但同时也造成识别准确率低于标准卷积;而本文提出的改进网络在保证较高识别准确率的情况下,网络模型的参数量和FLOPs降幅明显,训练时间也大幅度减少,总体性能较好。

管道运行环境较为复杂,且不同孔径泄漏时压强也会发生变化,导致采集的泄漏信号会受到异常因素影响,因此识别方法对于复杂信号处理时的偏差统计也十分重要。图10为4种不同卷积结构的管道泄漏孔径识别准确率的对比结果图。

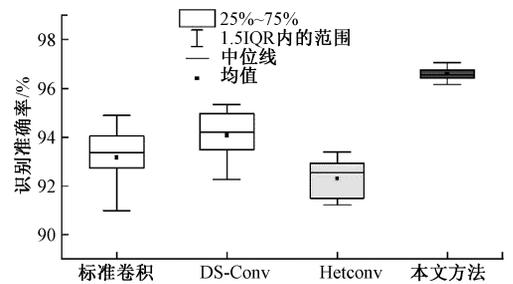


图10 不同卷积结构的识别准确率对比

Fig. 10 Accuracy comparison of different convolution structures

从图10中可以看出,采用不同卷积结构,识别准确率和稳定性有较大的差别,本文方法实现了较高的识别准确率,分布比较集中,稳定性较好,并且参数量、浮点数和训练时间都是最少的,实现了快速识别。

### 2) 不同注意力机制的影响

本文诊断网络模型中为了避免传递无效的特征信息影响模型的参数量和存储空间,提出采用卷积注意力机制对特征的权重进行重新分配,实现特征的重要性区分,改善泄漏的识别准确率。本文对比了常用的注意力机制模块的影响,主要对比方法为:无注意力机制(none)、通道注意力机制(squeeze and excitation, SE)<sup>[25]</sup>、瓶颈注意力机制(bottleneck attention module, BAM)<sup>[26]</sup>、本文方法采用的卷积注意力机制(CBAM)<sup>[24]</sup>以及有效通道注意力机制(efficient channel attention, ECA)<sup>[27]</sup>。在本文诊断网络基础上,采用不同注意力机制进行多次泄漏孔径分类,平均诊断准确率、标准差和训练时间的对比结果如图11所示。

通过图11可以看出,添加注意力机制处理实现特征的重要性区分可以帮助提升网络模型的性能。在采用注意力机制的网络中,本文采用的卷积注意力机制模块识别准确率最高,且多次诊断结果波动较小,所需的训练时间也最少。表4统计了本文网络模型应用不同注意力机

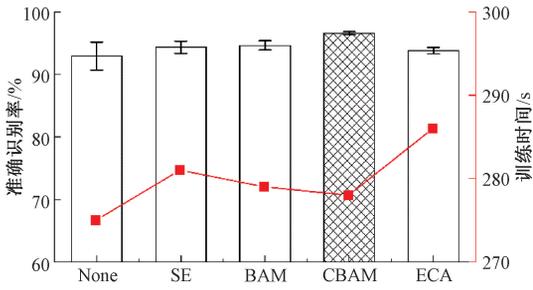


图 11 不同注意力机制的对比

Fig. 11 Comparison of different attention mechanisms

制模块的平均准确率、标准差、参数量、浮点数、训练时间的结果。

由表 4 的统计结果可以看出,应用不同的注意力机制模块对网络模型的性能有不同的影响。经过实验对比发现,应用注意力机制在一定程度上可以提升网络模型的性能,并且不会增加模型的参数量和 FLOPs,且本文采用的卷积注意力机制训练时间增幅小,且具有较好的稳定性。综合分析本文采用的卷积注意力机制模块 CBAM 优于其他注意力机制模块。

表 4 不同注意力机制的对比结果

Table 4 Comparison of different attention mechanisms

方法	平均准确率/%	训练时间/s	参数量/K	FLOPs/M
None	92.96±2.27	275	781	95
SE	94.35±0.99	281	781	95
BAM	94.67±0.74	279	781	95
CBAM	<b>96.59±0.25</b>	<b>278</b>	<b>781</b>	<b>95</b>
ECA	93.82±0.51	286	781	95

## 4 对比实验与分析

### 4.1 与其他轻量级网络的对比

轻量级网络引入的目的是减少网络模型参数量及 FLOPs 等,使得基于深度神经网络的泄漏孔径识别模型能够降低对监测系统的要求,并改善快速响应能力。此处将本文提出的基于多卷积稠密块轻量化神经网络的方法与其他轻量级网络,如 MobileNetV1<sup>[20]</sup>、MobileNetV2<sup>[21]</sup>、ShuffleNet<sup>[22]</sup> 构成的诊断网络进行对比,从识别准确率、多次诊断结果的标准差、参数量、FLOPs 和训练时间进行比较,对比结果如图 12 所示。

从图 12 中可以看出本文诊断方法不仅有较高的识别准确率,且网络模型的参数量和浮点数最少,多次诊断准确率的标准差最小,具有较好的鲁棒性,同时训练时间也是最少的,实现了快速准确识别,且降低了对运行设备的要求。

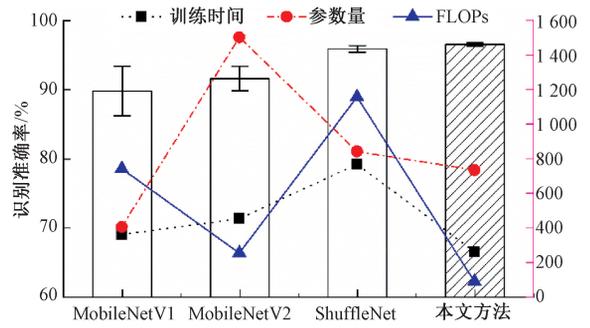


图 12 与其他轻量级网络的对比

Fig. 12 Comparison with other lightweight networks

表 5 统计了采用不同轻量级网络 MobileNetV1、MobileNetV2、ShuffleNet 和本文方法的平均准确率、标准差、参数量、FLOPs 和训练时间的结果。

表 5 与其他轻量级网络的对比结果

Table 5 Comparison with other lightweight networks

方法	平均准确率/%	训练时间/s	参数量/K	FLOPs/M
MobileNetV1	89.83±3.60	384	431	788
MobileNetV2	91.70±1.73	482	1597	270
ShuffleNet	95.90±0.49	817	895	1229
本文方法	<b>96.59±0.25</b>	<b>278</b>	<b>781</b>	<b>95</b>

从表 5 的统计结果可以看出,本文方法的识别准确率比 MobileNetV1 高出 6.76%、比 MobileNetV2 高出 4.89%、比 ShuffleNet 高出 0.69%;本文方法的参数量比 MobileNetV2 少 816 KB、比 ShuffleNet 少 114 KB;本文方法的浮点数比 MobileNetV1 少 693 MB、比 MobileNetV2 少 175 MB、比 ShuffleNet 少 1134 MB。总体上,本文方法在识别准确率、参数量、FLOPs 和训练时间上均优于其他轻量级网络。

### 4.2 与经典方法的对比

为了验证本文方法在参数量较小、占用内存小、能够快速识别的基础上具有较好的识别准确率,此处与常用的经典网络模型诊断效果进行对比。目前常用的经典方法主要为卷积神经网络 CNN<sup>[28]</sup>、残差网络 ResNet<sup>[29]</sup> 和卷积自编码 SAE<sup>[30]</sup>,因此本文采用这 3 种经典方法与本文方法进行比较。3 种经典方法的网络结构如表 6 所示。

表 7 统计了本文方法与常用经典方法的参数量、FLOPs 和训练时间的对比结果。从中可以看出本文方法在较高识别准确率的同时,实现了参数量、FLOPs 和训练时间的大幅减少,实现了快速识别,进一步验证了本文方法的优越性。

表6 经典方法的网络结构表

Table 6 Network structures of classical methods

方法	输入	网络结构	输出
CNN		(卷积+池化)×4	
ResNet	一维泄漏数据	残差块×4	Softmax
SAE		(卷积+池化)×4+(卷积+池化)×4	
本文方法		(多卷积稠密块+过渡层)×2+CBAM	

表7 与经典方法的对比结果

Table 7 Comparison with classical methods

方法	平均准确率/%	训练时间/s	参数量/K	FLOPs/M
CNN	93.16±1.15	462	3 236	717
ResNet	94.07±1.03	768	4 188	2 611
SAE	92.30±0.72	527	1772	1 966
本文方法	<b>96.59±0.25</b>	<b>278</b>	<b>781</b>	<b>95</b>

## 5 结 论

针对深度神经网络的管道泄漏孔径识别方法参数量大、占用内存大、对运行设备配置要求高、泄漏响应时间较长等问题,提出了一种基于多卷积稠密块轻量级神经网络的管道泄漏孔径识别方法。泄漏信号首先通过卷积池化层提取浅层特征;其次通过堆叠多卷积稠密块和过渡块进一步提取深层的有用特征来减小卷积操作的参数量和浮点数;然后再用卷积注意力机制模块对特征进行权重划分,实现特征的重要性区分;最后通过 Softmax 获取分类结果。使用参数量、浮点数、识别准确率和训练时间作为评价指标对模型进行评估。通过对实验采集的管道泄漏数据处理结果的分析及对比,表明本文方法在保证较高识别准确率的情况下可以有效地减轻网络模型的计算负担并提高了诊断效率,降低了对硬件系统的要求,提高了实时响应能力,为深度神经网络类诊断方法的实际应用提出一种解决办法。

## 参考文献

- [1] SUN J D, XIAO Q Y, WEN J T, et al. Natural gas pipeline leak aperture identification and location based on local mean decomposition analysis [J]. Measurement, 2016, 79: 147-157.
- [2] 焦敬品, 李勇强, 吴斌, 等. 基于 BP 神经网络的管道泄漏声信号识别方法研究[J]. 仪器仪表学报, 2016,

37(11): 2588-2596.

JIAO J P, LI Y Q, WU B, et al. Research on acoustic signal recognition method for pipeline leakage with BP neural network [J]. Chinese Journal of Scientific Instrument, 2016, 37(11): 2588-2596.

- [3] SUN J D, XIAO Q Y, WEN J T, et al. Natural gas pipeline small leakage feature extraction and recognition based on LMD envelope spectrum entropy and SVM [J]. Measurement, 2014, 55(9): 434-443.

- [4] 张勇, 段运达, 王臣. 基于小波阈值去噪的管道泄漏检测研究[J]. 化工自动化及仪表, 2021, 48(2): 128-133.

ZHANG Y, DUAN Y D, WANG CH. Research on pipeline leakage detection based on wavelet threshold denoising [J]. Chemical Automation and Instrumentation, 2021, 48(2): 128-133.

- [5] WEN L, LI X Y, 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.

- [6] BAI R X, XU Q SH, MENG Z, et al. Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation [J]. Measurement, 2021, 184: 109885.

- [7] DENG F Y, DING H, YANG S P, et al. An improved deep residual network with multiscale feature fusion for rotating machinery fault diagnosis [J]. Measurement Science and Technology, 2021, 32(2): 1-13.

- [8] 孙洁娣, 乔艳雷, 温江涛, 等. 压缩感知域智能天然气管道泄漏孔径识别[J]. 仪器仪表学报, 2017, 38(12): 3071-3078.

SUN J D, QIAO Y L, WEN J T, et al. Pipeline leak aperture identification based on compressed sensing [J]. Chinese Journal of Scientific Instrument, 2017, 38(12):

- 3071-3078.
- [9] 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. Gas pipeline leakage aperture identification based on compressed sensing combined with convolutional network [J]. *Vibration and Shock*, 2020, 39(21): 17-23.
- [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. Identification of oil and gas pipeline perimeter intrusion events in complex environment based on deep transfer learning [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(8): 12-19.
- [11] 李江昀, 赵义凯, 薛卓尔, 等. 深度神经网络模型压缩综述[J]. 工程科学学报, 2019, 41(10): 1229-1239.
- LI J Y, ZHAO Y K, XUE ZH ER, et al. A survey of model compression for deep neural networks [J]. *Journal of Engineering Science*, 2019, 41(10): 1229-1239.
- [12] 高晗, 田育龙, 许封元, 等. 深度学习模型压缩与加速综述[J]. 软件学报, 2021, 32(1): 68-92.
- GAO H, TIAN Y L, XU F Y, et al. Survey of deep learning model compression and acceleration[J]. *Journal of Software*, 2021, 32(1): 68-92.
- [13] WANG P, HU Q, ZHANG Y, et al. Two-step quantization for low-bit neural networks[C]. *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 4376-4384.
- [14] YANG Y Z, YU J H, JOJIC N, et al. FSNet: Compression of deep convolutional neural networks by filter summary [J]. *ArXiv Preprint*, 2020, arXiv: 1902.03264.
- [15] JIANG X, WANG N, XIN J, et al. Learning lightweight super-resolution networks with weight pruning [J]. *Neural Networks*, 2021, 144: 21-32.
- [16] CUI B Y, LI Y M, ZHANG ZH F. Joint structured pruning and dense knowledge distillation for efficient transformer model compression [J]. *Neurocomputing*, 2021, 458: 56-69.
- [17] JIAO J Y, ZHAO M, LIN J, et al. Deep coupled dense convolutional network with complementary data for intelligent fault diagnosis [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(12): 9858-9867.
- [18] 葛道辉, 李洪升, 张亮, 等. 轻量级神经网络架构综述[J]. 软件学报, 2020, 31(9): 2627-2653.
- GE D H, LI H SH, ZHANG L, et al. Survey of lightweight neural network [J]. *Journal of Software*, 2020, 31(9): 2627-2653.
- [19] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 1800-1807.
- [20] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[C]. *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 432-445.
- [21] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]. *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 4510-4520.
- [22] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices [C]. *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 6848-6856.
- [23] SINGH P, VERMA V K, RAI P, et al. HetConv: Heterogeneous kernel-based convolutions for deep CNNs [J]. *ArXiv Preprint*, 2019, arXiv: 1903.04120.
- [24] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. *European Conference on Computer Vision, Munich, Germany*, 2018: 3-19.
- [25] HU J, LI SH, SUN G. Squeeze-and-excitation networks [C]. *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7132-7141.
- [26] PARK J, WOO S, LEE J Y, et al. BAM: Bottleneck attention module [J]. *ArXiv Preprint*, 2018, arXiv: 07.06514.

- [27] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition, 2020: 11531-11538.
- [28] WU H J, CHEN J P, LIU X R, et al. One-dimensional CNN-based intelligent recognition of vibrations in pipeline monitoring with DAS [J]. IEEE Journal of Lightwave Technology, 2019, 37(17): 4359-4366.
- [29] ZHANG W, LI X, DING Q. Deep residual learning-based fault diagnosis method for rotating machinery [J]. ISA Transactions, 2019, 95: 295-305.
- [30] CHEN ZH Y, LI W H. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network [J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(7): 1693-1702.

## 作者简介



**孙洁娣**, 1998 年于河北师范大学获得学士学位, 2001 年于燕山大学获得硕士学位, 2008 年于天津大学获得博士学位, 现为燕山大学信息学院教授, 主要研究方向为智能故障诊断、深度学习理论及应用; 管道泄漏监测及预警。

E-mail: wjtsjd@163.com

**Sun Jiedi** received her B.Sc. degree from Hebei Normal University in 1998, received her M.Sc. degree from Yanshan University in 2001, and received her Ph.D. degree from Tianjin University in 2008. She is currently a professor with the School of Information Science and Engineering at Yanshan University. Her current research interests include intelligent diagnosis, deep learning and various applications and pipeline leak detection and pre-warning.



**温江涛**(通信作者), 1998 年、2003 年于燕山大学分别获得学士学位及硕士学位, 2009 年于清华大学获得博士学位, 现为燕山大学电气工程学院副教授, 主要研究方向为故障诊断、复杂振动信号处理及模式识别。

E-mail: wens2002@163.com

**Wen Jiangtao** (Corresponding author) received his B.Sc. and M.Sc. degrees both from Yanshan University in 1998 and 2003, and received his Ph.D. degree from Tsinghua University in 2009. He is currently an associate professor with the School of Electrical Engineering at Yanshan University. His main research interests include intelligent diagnosis, complex vibration signals processing and pattern recognition.