DOI: 10.3901/JME.2021.01.110

基于多通道加权卷积神经网络的齿轮箱振动信号特征提取*

叶 壮 余建波

(同济大学机械与能源工程学院 上海 201804)

摘要: 为了解决单通道振动信号输入不能全面表达故障特征信息及齿轮箱故障早期诊断问题,提出了一种新的深度神经网络(Deep neural network, DNN)模型—多通道加权卷积神经网络(Multi-channels weighted convolutional neural network, MCW-CNN),并应用于齿轮箱振动信号特征学习和故障诊断。首先,采用经验模态分解(Empirical mode decomposition, EMD)对振动信号进行处理,得到多通道一维信号突出振动信号的故障特征,并将其转化为多通道图像输入,从而充分发挥 CNN 在图像特征提取上的优良性能,将齿轮箱故障诊断问题进一步转化为 CNN 更为擅长的多通道图像识别问题;其次,针对各通道图像频率和带宽的不同,在卷积层采用动态感受野进行图像特征提取,全面提取多通道图像特征细节;针对各通道图像携带冲击特征的强弱不同,提出了基于峭度加权的多通道融合方法,增强了冲击特征强的通道故障特征。最后,通过故障诊断仿真试验和齿轮箱故障诊断试验验证所提方法的有效性。试验结果表明,MCW-CNN 可有效提取振动信号的故障特征,识别正确率明显高于典型的深度学习方法 and 传统的分类器。

关键词: 齿轮箱故障诊断;多通道信号;特征学习;卷积神经网络;信息融合

中图分类号: TH165

Feature Extraction of Gearbox Vibration Signals Based on Multi-Channels Weighted Convolutional Neural Network

YE Zhuang YU Jianbo

(School of Mechanical Engineering, Tongji University, Shanghai 201804)

Abstract: A new DNN model, called multi-channels weighted convolutional neural network (MCW-CNN) is proposed in order to solve the feature extraction problem of CNNs that use single-channel signal as input, which can not express the fault characteristics hidden in the vibration signals effectively. Firstly, empirical mode decomposition (EMD) is used to obtain multi-channel one-dimensional signals to highlight the fault characteristics, which is converted into multi-channel image as input of MCW-CNN. So that the image feature extraction of CNN can be fully utilized, and the gearbox diagnosis is further converted into an image recognition issue that CNN is good at dealing with. Secondly, due to the difference of frequency and bandwidth of each channel, a dynamic receptive field is proposed in MCW-CNN to extract the detailed features from these images. In addition, the intensity of the impact feature of each channel image is different, so the fusion weight is determined based on the kurtosis, which can highlight the channels that have strong impact characteristics. Finally, the effectiveness of the proposed method is verified on a gearbox fault diagnosis case. Experimental results show that the MCW-CNN can effectively extract the fault characteristics of the vibration signal. It has a significantly higher recognition accuracy rate than other typical deep learning methods and traditional classifiers.

Key words: gearbox fault diagnosis; multi-channels signal; feature learning; convolutional neural network; information fusion

0 前言

齿轮箱是一种被广泛应用于各种机械设备中的

传动装置,在交通、电力、航空航天等领域发挥了关键作用^[1]。然而由于其复杂的工作环境和长时间的负荷运转,齿轮箱常常会发生故障^[2],造成巨大的经济损失甚至人员伤亡。因此,对齿轮箱早期故障进行诊断具有重要的意义,以便及时发现问题、排除故障,进而降低损失。

近年来,众多学者对齿轮箱故障诊断进行了广

* 国家自然科学基金(71777173)、上海科委“科技创新行动计划”高新技术领域项目(19511106303)和中央高校基本业务经费资助项目。20191010 收到初稿,20200605 收到修改稿

泛且深入的研究。在众多研究方法中, 信号处理方法最为常见, 如傅里叶变换(Fourier transform, FT)、经验模态分解(Empirical mode decomposition, EMD)等。然而, 使用单一的信号处理方法很难达到理想的诊断效果^[3]。因此需要将处理过的信号进一步进行特征提取和识别。机器学习方法如支持向量机(Support vector machine, SVM)、人工神经网络(Artificial neural network, ANN)等得到了广泛的关注。刘畅等^[4]首先使用高斯随机投影对滚动轴承信号进行降维处理, 随后利用 SVM 对信号进行诊断。RAFIEE 等^[5]开发了一种基于 ANN 的故障诊断系统, 可以识别出故障齿轮, 该系统在齿轮箱故障诊断方面有着广泛的应用。虽然机器学习在机械故障诊断方面取得了不错的成就, 但是其浅层的网络结构很难学习到故障信号高维度、非线性的数据特征^[6], 并且上述分类器均需要有效的高质量训练数据和基于专家知识筛选出的特征进行故障诊断。

深度学习(Deep learning)方法, 如深度信念网络(Deep belief network, DBN)^[7]、堆叠降噪自编码器(Stacked denoised autoencoders, SDAE)^[8]、卷积神经网络(Convolutional neural network, CNN)^[9], 已经在计算机视觉、自然语言处理和机械故障诊断中, 发挥出优良性能。DNN 深层次的网络结构, 弥补了浅层学习器在处理高维数据方面的不足。CNN 作为深度学习的代表, 具有很强的特征提取和表达能力, 被广泛地应用于机械故障诊断中。由于齿轮箱振动信号一般是时域信号, 因此有学者对一维 CNN(One-dimensional CNN, 1-D CNN)进行了研究。WU 等^[10]使用 1-D CNN 解决了固定轴齿轮箱和行星齿轮箱的故障诊断问题。也有学者通过将一维时域信号转换为二维格式如时频谱等, 进行故障诊断。MONTEIRO 等^[11]使用 FT 对齿轮箱数据进行处理形成图谱, 随后输入到 CNN 中进行故障诊断, 很好地解决了齿牙断裂故障诊断问题。ZHU 等^[12]将振动信号转化为对称点图, 随后使用 CNN 对图像进行自适应提取特征信息, 通过转子试验台数据进行试验, 验证了所提方法的有效性。

为了更加有效地提取故障信号的隐含特征, 有学者将多通道 1-D CNN 引入到故障诊断中来。SHE 等^[13]将多传感器信号输入到提前构建好的多通道 1-D CNN 中, 进行滚动轴承的故障诊断。胡芑庆等^[14]提出采用多通道 1-D CNN 的齿轮箱故障诊断方法, 对比试验结果表明使用多通道信号的诊断效果显著优于单通道信号输入。可见, 多通道信号比单通道信号可以展示更多的信号细节, 可更加全面地提取信号隐含

特征。目前多通道信号基本上采用一维振动信号的融合, 并使用多通道 1-D CNN 进行特征提取。但是 CNN 主要用于图像特征提取, 多通道 1-D CNN 无法充分发挥其在图像的特征提取功能, 并且多通道振动信号的有效融合还未被深入研究。这都显著地影响多通道 1-D CNN 的特征提取性能。

基于以上分析, 本文提出了一种新的深度神经网络模型, 多通道加权卷积神经网络(Multi-channels weighted convolutional neural network, MCW-CNN), 应用于齿轮箱振动信号的故障特征提取, 从而显著地提升识别器的故障诊断性能。本文的主要贡献点总结如下。

(1) 采用 EMD 实施对振动信号的有效分解, 分解的 IMF 信号可进一步在不同尺度上凸显振动信号中的缺陷特征, 并转化为 MCW-CNN 的多通道图像输入, 有效地将一维振动信号转化为 CNN 更为擅长的图像识别问题。

(2) 多通道图像比单通道的信号表达特征更加有效全面, MCW-CNN 可以充分提取图像数据的隐含特征。

(3) MCW-CNN 采用动态感受野对多通道图像进行特征提取, 提取更多图像细节和信号的冲击特征, 依据各通道输入 IMF 分量峭度自适应地确定各通道融合权重进行加权融合, 进一步突出所提取特征图的冲击特征。

1 经验模态分解

EMD 是一种可以对收集到的时变非平稳信号进行自适应分解的时频分析方法, 可以将任意非线性信号分解为一系列 IMF 信号和一个余项^[15], 即

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (1)$$

式中, n 为分解得到的 IMF 分量的个数; $c_i(t)$ 为第 i 个 IMF 分量; $r_n(t)$ 为最终残余分量。

假设待分解信号为 $x(t)$, 具体的算法流程如下:

(1) 利用样条插值方法拟合得到上、下包络线。

(2) 用 $x(t)$ 减去上、下包络线的均值 $m_1(t)$ 得到一个分量 $h_1(t)$

$$h_1(t) = x(t) - m_1(t) \quad (2)$$

(3) 判断 $h_1(t)$ 是否满足 IMF 条件, 若满足, 则将 $h_1(t)$ 记为 c_1 , 作为第一个 IMF。否则重复上述步骤, 假设直至第 k 次满足条件, 得到

$$c_1 = h_{1k}(t) = h_{1(k-1)}(t) - m_{1k}(t) \quad (3)$$

(4) 从 $x(t)$ 中减去 c_1 , 得到残余分量 $r_1(t)$, 将 $r_1(t)$ 重复步骤(1)、(2), 并将得到的新残余分量判断是否

需要分解,若需要,则重复上述步骤,否则停止分解。

2 多通道加权卷积神经网络

本节提出了一种新的 DNN 模型 MCW-CNN,其显著特点在于:通过一个特殊的卷积层有效地处理多通道二维图像输入,全面提取振动信号的故障特征信息;提出多通道卷积层的动态感受野方法进

行图像特征提取,充分地提取图像信号中各种关键特征;各通道依据输入信号的峭度值自适应地确定融合权重,从而增强冲击特征强的通道,进而突出融合特征图振动信号的冲击特征。

MCW-CNN 的网络结构模型如图 1 所示,第一个卷积层采用多通道加权融合卷积层,随后接池化层和两组卷积池化层,最后接全连接层和分类器层,实现对齿轮箱振动信号的故障特征提取与故障诊断。

图 1 MCW-CNN 网络结构

2.1 数据增强

深度学习需要较大的数据样本,在数据量有限的情况下,通过数据增强的方式,可增加训练样本的多样性,提高鲁棒性,避免过拟合。对于一维信号而言,采用对原始数据进行重叠取样的方式进行数据增强。数据增强过程示意图如图 2 所示。

图 2 数据增强示意图

从图中可以看出,当信号总长度为 L , 截取目标信号长度为 l , 步长为 n , 则可得到的子信号数目

m 的计算公式如式(4), 式中 $\lfloor \cdot \rfloor$ 为向下取整运算符。

$$m = \left\lfloor \frac{L-l}{n} + 1 \right\rfloor \quad (4)$$

2.2 多通道振动图像

通过 EMD 方法分解一维的齿轮箱振动信号,得到的各种 IMF 信号在各个尺度细节上可更加有效地表达齿轮箱的缺陷特征。通过统计各通道 IMF 信号峭度值,筛选出峭度值较大的若干个 IMF 信号作为多通道信号。最后将选择的 IMF 信号绘制并保存为灰度图,得到多通道图像输入。具体操作过程如图 3 所示,可以看到,经 EMD 分解的信号包含了

图 3 多通道振动图像信号构造过程

原始信号中不同频率段的缺陷成分, 且振动频率从前至后依次降低, 因此针对不同通道振动图像的特点进行不同的卷积计算是非常必要的, 从而有效地提取各个通道中特殊的故障特征。

2.3 动态感受野

CNN 的卷积层中存在着许多大小相同的卷积核形成单组特征映射^[16]。经 EMD 处理后的多通道信号, 包含了振动信号从高至低不同频率段的成分, 而且不是等带宽的^[17]。因此, MCW-CNN 将结合各通道信号的特点在各通道采用不同的卷积核形成不同的感受野单独进行特征提取。

感受野的大小随卷积核的变化而变化, 可以通过改变卷积核的大小实现感受野的不同, 两者存在着以下关系

$$\begin{aligned} rf_{n-1} &= (rf_n - 1) \times s_{n-1} + k_{n-1} \\ rf_{last} &= k_{last} \end{aligned} \quad (5)$$

式中, n 为卷积池化层的层数; rf_{n-1} 为 $n-1$ 层感受野大小; rf_n 为 n 层感受野大小; s_{n-1} 为 $n-1$ 层步长; k_{n-1} 为 $n-1$ 层卷积大小; rf_{last} 为最后一层感受野大小, 其等于该层卷积核 k_{last} 大小。

通过不同的卷积核进行特征提取后, 各通道得到的输出为

$$X_j^l = \sum_{i=1}^k (x_{ij}^{l-1} \times w_{ij}^{l-1}) \quad (6)$$

式中, X_j^l 为通道 j 第 l 层卷积层的输出; x_{ij}^{l-1} 为通道 j 第 $l-1$ 层卷积层第 i 个特征输入, 共有 k 个特征输入; x_{ij}^{l-1} 为通道 j 第 $l-1$ 层的卷积核; 各通道卷积核不同, 从而获得动态感受野。

2.4 多通道加权融合

在基于动态感受野进行特征提取后, 各通道获取相同数量的特征图, 随后需要对其有效融合。对于振动信号图像, 由于各通道携带冲击特征不同, 各通道图像的相对重要性存在差异, 本文采用峭度值作为权重来衡量这种重要度的差异性, 从而实现了对强冲击特征的信号通道进行进一步增强。假设 k_j 表示通道 j 上振动信号的峭度值, m 表示通道数, 则该通道的权重为

$$a_j = \frac{k_j}{\sum_{j=1}^m k_j} \quad (7)$$

在得到各通道的权重后, 需要对其进行加权融合

$$X^l = f_{l-1} \left(\sum_{j=1}^m (a_j^{l-1} \times X_j^{l-1} + b_j^{l-1}) \right) \quad (8)$$

式中, X^l 为第 l 层卷积层的输出; X_j^{l-1} 为通道 j 第 $l-1$ 层卷积层特征输出; b_j^{l-1} 为通道 j 第 $l-1$ 层的偏移向

量; a_j^{l-1} 为通道 j 第 $l-1$ 层的权重; $f_{l-1}(x)$ 为第 $l-1$ 层卷积层的激活函数; m 为通道数。

2.5 网络结构

MCW-CNN 的第一个卷积层采用多通道加权融合卷积层, 后接池化层和两组卷积池化层, 最后接全连接层和分类器层。

多通道加权融合卷积层: 由于各通道图像信号携带冲击特征的强弱存在差异, 为了更加全面有效地提取冲击特征, 在各通道采用动态感受野单独进行扫描, 从而提取出更多图像的细节信息, 各通道的输出如式(6)所示; 随后依据峭度确定各通道的融合权重, 重点突出冲击特征强的通道, 融合方法如式(8)所示。

池化层: 在经过卷积层后, 池化层进行对特征进行降采样操作, 从而有效降低运算复杂度, 提高学习效率, 并且可以降低过拟合问题的发生概率。降采样操作为

$$y_n = \text{downsample}(x, g)[n] = g(x_{(n-1)m+1:nm}) \quad (9)$$

式中, m 为池化带宽; x 、 y 分别为输入、输出; $\text{downsample}(x, g)[n]$ 为 $\text{downsample}(x, g)$ 的第 n 个元素。在本文中采用最大池化, 所以 $g(x) = \max(x)$ 。

卷积层: 除第一个在卷积过程中, 前一层的输入特征图与后一层的卷积特征图通过卷积核相连, 根据局部连接和权值共享的原则, 逐一提取特征。

假设 X_i 表示第 i 层某一特征图的输出, 其卷积的计算公式为

$$X_i = f_i \left(\sum_{j=1}^k (X_{i-1} \times w_i) + b_i \right) \quad (10)$$

式中, X_{i-1} 为第 $i-1$ 层卷积层或者池化层的输出, 也是第 i 层卷积层的输入; w_i 为第 i 层的卷积核; b_i 为第 i 层的偏移向量; $f_i(x)$ 为第 i 层卷积层的激活函数。

全连接层: 在最后一层池化层后接全连接层, 将所提取特征平铺成一排, 随后使用全连接神经元进行操作

$$\delta_i = f(w_i p_i + b_i) \quad (11)$$

式中, $i=1, 2, \dots, k$; δ_i 为第 i 个输出, 共有 k 个输出; w_i 和 b_i 分别为第 i 个神经元的权值和阈值; p_i 为前一层的输出; $f(x)$ 为激活函数。

Softmax 分类器层: 在全连接层后, 接 Softmax 分类器完成分类操作。Softmax 函数为

$$p(i) = \frac{e^{\delta_i}}{\sum_{k=1}^K e^{\delta_k}} \quad (12)$$

式中, $i=1, 2, \dots, k$; δ_i 为上一层第 i 个输出, 共有 k 个输出; $p(i)$ 为每一个输出的概率, 所有的 $p(i)$ 之和为 1。

2.6 模型损失函数与训练算法

MCW-CNN 的分类器损失函数通过 Softmax 的输出向量与样本的实际标签做交叉熵计算得到的。其损失函数的计算公式为

$$Loss = -\sum_i y'_i \log(y_i) \quad (13)$$

式中, y'_i 为实际标签中第 i 个值, y_i 为 Softmax 输

出向量中第 i 个值。

在反向传播阶段, 使用 Adam 算法对参数进行优化, 利用参数的一阶矩估计和二阶矩估计动态调整每个参数的学习率, 从而更新权值得到最优解^[18]。

3 基于 MCW-CNN 的故障诊断方法

本文提出了一种基于 MCW-CNN 的故障诊断方法, 其故障诊断流程如图 4 所示, 具体步骤如下。

图 4 基于 MCW-CNN 的齿轮箱故障诊断模型

(1) 数据预处理。

步骤 1: 通过安装在齿轮箱试验设备上的传感器收集振动信号。

步骤 2: 使用数据增强技术获得更多的数据样本, EMD 方法处理振动信号, 筛选出具有显著冲击特征的 IMF 子信号。

步骤 3: 将振动信号转化成灰度图并构建训练集和测试集。

(2) 离线训练。

步骤 1: 构建 MCW-CNN, 对网络参数进行初始化。

步骤 2: 将训练集输入网络模型中, 对各层网络参数进行训练, 输出网络模型。

(3) 在线检验。

将测试集输入训练好的模型中, 以对齿轮箱故障类型进行识别。

4 仿真验证和分析

在实际工业生产中, 可供直接使用的大量带标签训练集往往难以获得。通过信号仿真可以以较小的成本获得理想数据集。滚动轴承是行星齿轮箱的关键部件, 可以根据故障模型较容易得到相应的仿真信号, 因此本节将基于仿真信号验证 MCW-CNN 的故障诊断有效性。

4.1 仿真数据生成

滚动轴承在故障初期表现为局部点蚀, 且产生的振动信号具有周期性。根据周期性变化的不同, 可以判断点蚀发生的位置。在运行过程中, 点蚀绝对位置的旋转周期比冲击的周期大, 会产生调制冲击现象。而轴承运行具有固定频率, 相比于该频率, 冲击具有短且衰减快的特点。轴承的点蚀故障模型可以表示为

$$x(t) = \sum_i A_i s(t - iT) + n(t) \quad (14)$$

式中, A_i 为第 i 次冲击的幅值, $s(t)$ 为局部点蚀的冲击振荡, T 为冲击振荡的周期, $n(t)$ 为噪声干扰。冲击振幅 A_i 与点蚀位置有关, 当点蚀发生在内圈和滚动体上时, A_i 为周期信号; 当点蚀发生在外圈时, A_i 为常数。冲击周期 T 也由故障位置决定, 当点蚀发生在滚动体时, T 为滚动体故障频率 f_{roller} 的 2 倍的倒数; 当点蚀发生在内圈或者外圈时, T 为对应故障频率(即 f_i 、 f_o)的倒数。冲击振荡 $s(t)$ 可用指数衰减函数表示, 因此 A_i 和 $s(t)$ 可以表示为

$$s(t) = e^{-kt} \sin(2\pi f_n t) \quad (15)$$

$$A_i = A(\cos(2\pi f_r t + \phi_A + C_A)) \quad (16)$$

通过式(15)和式(16)可以得到轴承的点蚀故障模型为

$$x(t) = \sum_i A_i e^{-k(t-iT)} \sin(2\pi f_n(t-iT) + \phi_i) + n(t) \quad (17)$$

式中, k 为衰减常数, f_n 为共振频率, f_r 为转频, ϕ_i 是初相位, C_A 是任意常数。

本文以 6205-2RS 深沟球轴承为基础进行信号仿真。该轴承节径 D 为 39.04 mm, 9 个滚动体($Z=9$), 滚动体直径 d 为 7.94 mm。假设轴承转速为 1797 r/min, 生成 4 种健康类型的仿真信号, 分别为健康(H)、内圈故障(IF)、外圈故障(OF)和滚动体故障(RF), 信号波形如图 5 所示。

图 5 各故障类型信号波形

本文首先将数据进行归一化, 以 2 048 作为样本长度截取仿真信号, 以 1 024 为步长, 达到数据增强的目的。最终每类故障类型共截取 200 个数据样本, 按照 8:2 的原则划分训练集和测试集, 得到数据集描述如表 1 所示。

表 1 仿真数据集描述

类别	健康状况	转速(r/min)	训练集	测试集
C1	正常	1 797	160	40
C2	外圈故障	1 797	160	40
C3	内圈故障	1 797	160	40
C4	滚动体故障	1 797	160	40

首先, 通过 EMD 方法对信号进行分解, 得到 7

个 IMF 子信号, 引入峭度用于筛选子信号, 统计各子信号峭度的平均值, 选择峭度值较大的前三个子信号, 形成 $800 \times 2 \ 048 \times 3$ 的多通道信号输入。随后, 将各个通道振动信号转化为二维图像。每条数据各通道均转化为 100×157 的图像, 为了存储方便, 将每一张图片平铺成长条数据, 得到 $800 \times 15 \ 700 \times 3$ 的多通道输入。

4.2 网络参数设计

MCW-CNN 各通道采用动态感受野进行特征提取和加权融合, 实现图片数据的有效降噪。该模型采用的网络结构和参数如表 2 所示。其中, CW 表示卷积核宽度; CH 表示卷积核高度; CC 表示输入特征图通道数; CN 表示输出特征图通道数; S 指池化层池化带宽度; Strides 表示卷积核的移动步长; Keep_prob 表示以一定的概率使某些神经元置为 0, 从而在一定程度上抑制过拟合; 另外, 所有的卷积层都使用了 SAME 函数进行边缘化处理; 前三个卷积层采用 Tanh 作为激活函数, 全连接层使用 Relu 作为激活函数。

表 2 MCW-CNN 网络参数

结构	变量名称	输出	训练参数
输入层	Image=3@100×157	3@100×157	
卷积层 1	Kernels=3×3, 5×5, 7×7; CC=3; CN=32; Strides=2	32@50×79	
池化层 1	S=2	32@25×40	Train size=150;
卷积层 2	Kernels=3×3; CC=32; CN=64; Strides=2	64@13×20	Learn
池化层 2	S=2	64@7×10	rate=0.001;
卷积层 3	Kernels=3×3; CC=64; CN=128; Strides=2	128@4×5	Validation rate=0.2
池化层 3	S=2	128@2×3	
全连接层	Keep_prob=0.85	1@768	
Softmax 层	—	1@11	

本仿真案例中, 通道 1 输入的峭度平均值为 1.94, 通道 2 的峭度平均值为 2.95, 通道 3 的峭度平均值为 3.00, 因此, 各通道权值 a_1 、 a_2 与 a_3 分别为 0.245 9、0.373 9 与 0.380 2。

4.3 诊断性能

将仿真信号输入到 MCW-CNN 中, 基于五折交叉验证进行故障诊断测试, 得到故障诊断正确率如表 3 所示。

表 3 各故障类型诊断正确率(%)

试验次数	C1	C2	C3	C4	AVG
1	100	97.50	100	97.50	98.75
2	100	97.56	100	100	99.39
3	100	100	100	100	100
4	100	97.50	100	97.50	98.75
5	100	100	100	97.50	99.38

可以看到, MCW-CNN 在仿真数据集上达到了 99.25% 的平均正确率, 展现了很好的诊断精度, 说明该模型可以出色的完成故障信息的学习和提取任务。然而, 由于仿真信号是在理想的条件下, 通过理论故障模型得到, 与齿轮、轴承在真实运转条件下的振动特性有很大差异。在齿轮箱运转过程中, 受载荷、温度、润滑和冲击等因素影响, 振动信号呈现高度非平稳、非线性的特点, 故障信息被噪声掩盖, 故障诊断的难度增大。因此, 本文进一步设计齿轮箱试验台, 基于齿轮箱在实际运转过程中的各类故障信号进行故障诊断, 以充分验证 MCW-CNN 的有效性。

5 试验验证和分析

本节通过齿轮箱故障诊断试验对所提出的 MCW-CNN 的有效性进一步验证, 将该方法与其他 DNN 及识别器进行了对比, 验证所提方法的优越性能。此外为更加深入了解 MCW-CNN 的特征降维和提取能力, 对该网络模型各层提取的特征进行了可视化呈现。

5.1 试验设计及数据预处理

采用自行设计的试验装置进行试验, 试验装置包括行星齿轮箱(含一个 75 齿太阳轮 25 齿行星轮)、驱动电动机、磁力制动器, 如图 6 所示。振动信号由安装在变速箱外壳上的加速度传感器收集, 采样频率为 30 kHz。齿轮箱的健康状况包括齿轮故障和轴承损伤, 共计 11 种, 分别为正常、四种不同程度的磨损、断齿、保持架缺陷、点蚀故障、内圈故障、滚动体故障、外圈故障, 带有不同缺陷的齿轮和轴承如图 7 所示。

图 6 行星齿轮箱试验台

图 7 不同缺陷的轴承和齿轮

每一类健康状况信号以 2 048 个点截取子信号长度, 以 1 948 为步长, 共截取得到 500 个样本, 按照 8:2 的原则, 划分训练集和测试集。各类健康状况数据规模如表 4 所示。

表 4 数据集描述

类别	齿轮箱状况	转速/(r/min)	训练集	测试集
C1	正常	294,588, 882	400	100
C2	齿牙磨损 1	294,588, 882	400	100
C3	齿牙磨损 2	294,588, 882	400	100
C4	齿牙磨损 3	294,588, 882	400	100
C5	齿牙磨损 4	294,588, 882	400	100
C6	齿牙磨损 5	294,588, 882	400	100
C7	齿牙点蚀	294,588, 882	400	100
C8	齿牙断裂	294,588, 882	400	100
C9	轴承内圈缺陷	294,588, 882	400	100
C10	轴承球缺陷	294,588, 882	400	100
C11	轴承保持架缺陷	294,588, 882	400	100

首先, 通过 EMD 方法对信号进行分解, 得到 7 个 IMF 子信号, 基于整个数据集的统计结果, 将各 IMF 子信号的峭度求均值, 选择出峭度值较大的前三个子信号, 形成 $500 \times 2\ 048 \times 3$ 的多通道信号输入。与仿真信号处理方式相同, 每条数据各通道均转化为 100×157 的图像, 现将前 3 种状态各通道图像特征展示如表 5 所示。

表 5 各通道图像

状态	通道 1	通道 2	通道 3
正常			
齿牙磨损 1			
齿牙磨损 2			

5.2 试验结果分析

MCW-CNN 模型参数与仿真试验设置相同, 该模型共进行了 2 000 次训练, 训练过程的正确率和损失变化如图 8 所示。

采用五折交叉验证的方法, 进行了五次试验, 试验结果如图 9 所示, 平均正确率为 97.61%, 混淆矩阵如图 10 所示。

图 8 训练过程识别正确率和损失函数变化

图 9 每一种健康状况的识别正确率(%)

C1	98.2	0	0	0	1.8	0	0	0	0	0	0
C2	0	96.3	0	3	0	0.7	0	0	0	0	0
C3	0	0	96.5	0	1.5	0	2	0	0	0	0
C4	0	0	0	99	0	0	1	0	0	0	0
C5	0	0.6	0	0	99.4	0	0	0	0	0	0
C6	0	0	0	0	0	99	0	0	1	0	0
C7	0	0	0	1.1	0	0	96.9	0	0	0	2
C8	0	0	1.8	0	0	0	1	95.2	2	0	0
C9	0	0	2	0	4	0	0	0	93.9	0	0
C10	0	0	0	0	0	0	0	0	0	100	0
C11	0	0	0	0	2.4	0	0	0	0	0	97.6
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11

图 10 MCW-CNN 识别正确率的混淆矩阵

5.3 多通道图像融合分析

为了分析 MCW-CNN 的多通道加权融合卷积层的振动图像融合效果, 将正常状态下的信号输入网络, 经该层融合后的图像以热力图的形式如图 11 所示。由于该层共有 32 个卷积核, 所以有 32 个特征图输出。从图中可以看出, 图像中的波形信号更加复杂抽象且保持了振动信号的冲击特征, 这说明多通道融合层可以全面提取到信号的冲击特征, 同

时各个通道卷积核的激活函数过滤了大部分振动噪音, 起到多通道冲击特征的深度融合的作用; 在波形信号外圈存在一些纹理特征, 这得益于动态感受野的使用, 采集到了更多图像细节; 在波形信号中存在红色区域, 这是由于融合权重的使用, 突出了冲击特征强的通道。因此, 多通道加权融合卷积层的使用, 起到了深层次融合、重点突出冲击特征的效果。

图 11 正常状态的多通道加权融合卷积层输出

5.4 可视化分析

深度神经网络是一个黑盒子, 这使得难以真正理解网络在深层结构中的工作原理。为了更加深刻地理解 MCW-CNN 提取特征的过程, 现选取齿轮箱齿牙磨损 1 的信号输入到 MCW-CNN 中, 并将各网络的输出逐层展示, 如图 12 所示。从图中可以看出, 该健康状态的输入在第一层卷积池化层表现出波形信号的形态, 随着网络层级的不断加深, 图像特征越来越抽象。总结为以下三点: ① 浅层神经网络提取的是纹理、细节特征, 如 Conv-Pool1 所突出显示的为信号的波形特征; ② 深层提取更具代表性的特征, 如全连接层只有少数特征被激活(为红色), 大部分未被激活(为深蓝色); ③ 图像的特征越来越抽象。另外 FC2 层是 MCW-CNN 最后一层, 后面接 Softmax 分类器进行分类, 从图中 FC2 层可以看出, 该健康类型被准确判断。

为了进一步探索 MCW-CNN 提取特征的过程。将数据输入到 MCW-CNN 中, 把各层提取特征通过 t-SNE^[19]进行降维可视化呈现, 图 13a~e 分别表示原始数据、第一层卷积池化层、第二层卷积池化层、第三层卷积池化层和全连接层提取的特征。从图中可以看出, 原始数据在经过各层网络结构后, 分类特征逐渐鲜明。在全连接层已表现出明显的分类特性。

图 12 健康状态为齿牙磨损 1 的网络节点可视化

图 13 T-SNE 对每层特征进行降维可视化

5.5 性能比较

为了进一步验证 MCW-CNN 的故障诊断能力, 将其与 SVM、BPN、DBN 和 SDAE 进行了对比,

其中, SVM 使用 RBF 函数作为核函数, BPN 网络使用三层隐含层, SDAE 和 DBN 采用的是三个中间隐含层的网络结构。通过五折交叉试验, 正确率对比结果如图 14 所示。MCW-CNN 的识别率远好于其他识别器。

MCW-CNN	97.67	98.02	97.01	97.98	97.36	97.61
SVM	71.78	70.53	71.09	68.51	70.32	70.45
BPN	71.17	61.25	62.92	50.87	58.00	60.84
DBN	57.66	84.60	71.60	80.63	80.57	75.01
SDAE	71.07	73.48	62.07	73.30	75.57	70.50

图 14 基于五折交叉验证的结果比较(%)

进一步将 MCW-CNN 与单通道 CNN(Single-channel CNN, SC-CNN)、稀疏 CNN(Sparse-CNN) 和 1-D CNN 进行了比较, 其中 SC-CNN 和 Sparse-CNN 采用二维图像输入, 三层卷积池化层交替连接、一个全连接层和一个输出层的网络结构; 1-D CNN 采用一维信号输入, 三层卷积池化层交替连接、一个全连接层和一个输出层的网络结构。各次试验的识别正确率对比结果如图 15 所示。

MCW-CNN	97.67	98.02	97.01	97.98	97.36	97.61
SC-2DCNN	96.64	95.49	95.43	94.30	95.50	95.47
Sparse-2DCNN	91.49	94.01	95.20	91.29	94.63	93.33
SC-1DCNN	93.30	93.26	93.82	95.08	93.91	93.87

图 15 基于五折交叉验证的典型 CNN 识别结果比较(%)

从图中可以看出, MCW-CNN 的识别正确率显著高于 SVM、BPN 等方法; CNN 在故障诊断分类中有着不错的表现, 均达到了 90% 以上的正确率。但相较于其他 CNN 方法, 本文提出的 MCW-CNN 方法表现出了更加优秀的性能。这些比较结果表明 MCW-CNN 的多通道振动图像输入、动态感受野及多通道加权融合显著地提升了其特征提取性能。

6 结论

本文提出的 MCW-CNN 采用动态感受野和加权融合策略,可以很好地提取振动信号的抽象特征,并重点突出冲击特征强的通道信息,在齿轮箱故障诊断中表现出了优良的性能,主要结论如下。

(1) 基于 EMD 对信号的有效分解,多通道信号可以在不同尺度上凸显信号的冲击特征;并且通过把一维振动信号转化为二维图像,将齿轮箱故障诊断问题进一步转化为 CNN 更为擅长的图像识别问题,显著提高了 MCW-CNN 的故障诊断的正确率和稳定性。

(2) 多通道图像的输入,可以充分地挖掘故障信息;多通道融合后的特征,增强了振动信号中的冲击特征。

(3) 多通道加权融合卷积层,显著提升了 MCW-CNN 特征提取的性能。采用动态感受野在各通道进行特征提取,可以提取到更多的关键特征;利用峭度确定各通道融合权重,重点突出了冲击特征强的通道信息。

参 考 文 献

- [1] LEI Y, HAN D, LIN J, et al. Planetary gearbox fault diagnosis using an adaptive stochastic resonance method[J]. *Mechanical Systems and Signal Processing*, 2013, 38: 113-124.
- [2] 雷亚国,何正嘉,林京,等. 行星齿轮箱故障诊断技术的研究进展[J]. *机械工程学报*, 2011, 47(19): 59-67.
LEI Yaguo, HE Zhengjia, LIN Jing, et al. Research advances of fault diagnosis technique for planetary gearboxes[J]. *Journal of Mechanical Engineering*, 2011, 47(19): 59-67.
- [3] LIANG P, DENG C, WU J, et al. A semi-supervised fault diagnosis framework for a gearbox based on generative adversarial nets[C]// 2018 IEEE 8th International Conference on Underwater System Technology: Theory and Applications (USYS), December 1-3, 2018, Wuhan, China, IEEE, 2019: 1-4.
- [4] 刘畅,伍星,刘韬,等. 基于近似等距投影和支持向量机的滚动轴承故障诊断[J]. *振动与冲击*, 2018, 37(5): 234-239.
LIU Chang, WU Xing, LIU Tao, et al. Fault diagnosis of rolling bearing based on near-isometric projection and support vector machine[J]. *Journal of Vibration and Shock*, 2018, 37(5): 234-239.
- [5] RAFIEE J, ARVANIA F, HARIFIB A, et al. Intelligent condition monitoring of a gearbox using artificial neural network[J]. *Mechanical Systems and Signal Processing*, 2007, 21: 1746-1754.
- [6] JIA F, LEI Y, LIN J, et al. Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. *Mechanical Systems and Signal Processing*, 2016, 72: 303-315.
- [7] 沈长青,汤盛浩,江星星,等. 独立自适应学习率优化深度信念网络在轴承故障诊断中的应用研究[J]. *机械工程学报*, 2019, 55(7): 81-88.
SHEN Changqing, TANG Shenghao, JIANG Xingxing, et al. Bearings fault diagnosis based on improved deep belief network by self-individual adaptive learning rate[J]. *Journal of Mechanical Engineering*, 2019, 55(7): 81-88.
- [8] YU J. A selective deep stacked denoising autoencoders ensemble with negative correlation learning for gearbox fault diagnosis[J]. *Computers in Industry*, 2019, 108: 62-72.
- [9] JING L, ZHAO M, LI P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. *Measurement*, 2017, 11: 1-10.
- [10] WU C, JIANG P, DING C, et al. Intelligent fault diagnosis of rotating machinery based on one-dimensional convolutional neural network[J]. *Computers in Industry*, 2019, 108: 53-61.
- [11] MONTEIRO R, BASTOS-FILHO C, CERRADA M, et al. Convolutional neural networks using fourier transform spectrogram to classify the severity of gear tooth breakage[C]// 2018 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC), August 15-17, 2018, Xi'an, China, IEEE, 2019: 490-496.
- [12] ZHU X, HOU D, ZHOU P, et al. Rotor fault diagnosis using a convolutional neural network with symmetrized dot pattern images[J]. *Measurement*, 2019, 138: 526-535.
- [13] SHE D, JIA M. Wear indicator construction of rolling bearings based on multi-channel deep convolutional neural network with exponentially decaying learning rate[J]. *Measurement*, 2019, 135: 368-375.
- [14] 胡芑庆,陈徽鹏,程哲,等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. *机械工程学报*, 2019, 55(7): 9-18.

- HU Niaoqing, CHEN Huipeng, CHENG Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks[J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18.
- [15] 汤宝平, 蒋永华, 张详春. 基于形态奇异值分解和经验模态分解的滚动轴承故障特征提取方法[J]. 机械工程学报, 2010, 46(5): 37-42.
- TANG Baoping, JIANG Yonghua, ZHANG Xiangchun. Feature extraction method of rolling bearing fault based on singular value decomposition-morphology filter and empirical mode decomposition[J]. Journal of Mechanical Engineering, 2010, 46(5): 37-42.
- [16] CHEN L, WU C, FAN W, et al. Adaptive local receptive field convolutional neural networks for handwritten Chinese character recognition[J]. Communications in Computer & Information Science, 2014, 484:455-463.
- [17] 聂永红, 程军圣, 杨宇, 等. 基于经验模态分解的多通道有源噪声控制[J]. 振动与冲击, 2013, 32(20): 189-195.
- NIE Yonghong, CHENG Junsheng, YANG Yu, et al. A multichannel active noise control system based on empirical mode decomposition[J]. Journal of Vibration and Shock, 2013, 32(20): 189-195.
- [18] 胡晓依, 荆云建, 宋志坤, 等. 基于 CNN-SVM 的深度卷积神经网络轴承故障识别研究[J]. 振动与冲击, 2019, 38(18): 173-178.
- HU Xiaoyi, JING Yunjian, SONG Zhikun, et al. Bearing fault identification by using deep convolutional neural network based on CNN-SVM[J]. Journal of Vibration and Shock, 2019, 38(18): 173-178.
- [19] BUNTE K, HAASE S, BIEHL M, et al. Stochastic neighbor embedding (SNE) for dimension reduction and visualization using arbitrary divergences[J]. Neurocomputing, 2012, 90: 23-45.

作者简介: 叶壮, 男, 1996 年出生, 博士研究生。主要研究方向为深度学习、机械故障诊断。

E-mail: yezhuang@tongji.edu.cn

余建波(通信作者), 男, 1978 年出生, 博士, 教授, 博士研究生导师。主要研究方向为机械故障诊断、设备智能维护。

E-mail: jbyu@tongji.edu.cn