

控制与决策

Control and Decision

一种用于机械故障特征提取的多尺度稀疏滤波网络

张志强, 杨清宇

引用本文:

张志强, 杨清宇. 一种用于机械故障特征提取的多尺度稀疏滤波网络[J]. *控制与决策*, 2022, 37(5): 1267–1278.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1418>

您可能感兴趣的其他文章

Articles you may be interested in

[基于改进DenseNet网络的人体姿态估计](#)

Improved DenseNet network for human pose estimation

控制与决策. 2021, 36(5): 1206–1212 <https://doi.org/10.13195/j.kzyjc.2019.1218>

[改进集成深层自编码器在轴承故障诊断中的应用](#)

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

[融合稀疏编码与深度学习的草图特征表示](#)

A feature representation of sketch based on fusion of sparse coding and deep learning

控制与决策. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

[多目标小尺度车辆目标检测方法](#)

Multi-target and small-scale vehicle target detection method

控制与决策. 2021, 36(11): 2707–2712 <https://doi.org/10.13195/j.kzyjc.2020.0635>

[基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

一种用于机械故障特征提取的多尺度稀疏滤波网络

张志强, 杨清宇[†]

(西安交通大学 自动化科学与工程学院, 西安 710049)

摘要: 针对传统稀疏滤波网络缺乏多尺度特征提取能力, 难以充分挖掘故障信息的问题, 提出一种多尺度稀疏滤波网络. 该网络包括 5 层: 多尺度粗粒度层, 以获取多尺度信号; 样本分段层, 对每个尺度的信号分段; 局部特征提取层, 计算每个片段的特征向量; 特征平均化层, 将单个尺度下所有片段的特征向量池化以得到输入信号在该尺度下的表征; 特征堆叠层, 将所有尺度下的表征堆叠成一个长向量, 作为输入信号最终的特征向量. 采集 3 个齿轮数据集进行实验验证, 可视化和聚类结果表明, 多尺度网络从齿轮振动信号中提取的特征比原始网络提取的特征更具区分性和判别性. 用 Softmax 对这两种网络及 3 种传统多尺度方法提取的特征进行分类, 结果显示, 多尺度稀疏滤波网络对每种故障的识别精度均最高. 同时, 所提出的多尺度稀疏滤波网络的性能与两种其他框架下的多尺度网络相比非常具有竞争力. 所提出的多尺度稀疏滤波网络可广泛用于机械故障诊断的特征提取阶段, 能自动从大量无标注样本中挖掘有用的故障信息.

关键词: 故障诊断; 特征提取; 稀疏滤波网络; 多尺度学习; 样本分段; 特征堆叠

中图分类号: TP206

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1418

开放科学(资源服务)标识码(OSID):



引用格式: 张志强, 杨清宇. 一种用于机械故障特征提取的多尺度稀疏滤波网络[J]. 控制与决策, 2022, 37(5): 1267-1278.

A multi-scale sparse filtering network for fault feature extraction of machinery

ZHANG Zhi-qiang, YANG Qing-yu[†]

(School of Automation Science and Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: The traditional sparse filtering network (SFN) lacks multi-scale feature extraction ability, which makes it fail to dig adequate fault information. To deal with this problem, we propose a multi-scale sparse filtering network (MSSFN) which includes five layers. In particular, the multi-scale coarse-grained layer aims at obtaining multi-scale signals. The sample segmentation layer plays the role of dividing each sample at each scale into several segments. The local feature extraction layer aims to calculate feature vector of each segment. The feature averaging layer targets at averaging all segments as the feature representation of the input signal under this scale. The feature stacking layer plays the role of stacking all feature representations at different scales into a long vector as the final feature vector of the input signal. Three gear datasets are collected to validate the effectiveness. The results about visualization and clustering show that the MSSFN is able to learn more discriminative features from the gear vibration signals than those learned by the SFN. Softmax is used to classify features extracted by these two types of networks as well as three traditional multi-scale approaches, and it presents that the MSSFN achieves the highest recognition accuracy for each type of the gear fault. At the same time, the proposed MSSFN achieves the very competitive diagnosis results, in comparison with two other types of multi-scale networks under different architectures. The proposed MSSFN can be widely applied to the stage of feature extraction for machinery fault diagnosis, where it can discover useful fault information from massive unlabelled samples automatically.

Keywords: fault diagnosis; feature extraction; sparse filtering network; multi-scale learning; sample segmentation; feature stacking

收稿日期: 2020-10-14; 录用日期: 2021-03-16.

基金项目: 国家自然科学基金重点项目(61633001).

[†]通讯作者. E-mail: yangqingyu@mail.xjtu.edu.cn.

0 引言

科技和工业的迅速发展使得机械设备变得越来越精密化和复杂化,长时间运行在复杂多变的工况下,一些关键零部件容易出现异常,进而引发机械设备的故障. 机械设备一旦出现事故,将带来不可估量的经济损失和人员伤亡^[1]. 故障诊断是保障机械设备安全稳定运行的一把利器,该技术旨在借助机械、电子、计算机、信号处理和人工智能等知识,对连续运行的设备状态进行监测,定位故障位置并识别故障严重程度.

智能故障诊断是目前广泛研究的一种诊断框架,其基本思想是将机器学习理论应用于机械故障诊断中^[2]. 该框架一般包括3个步骤:信号获取、特征提取和故障识别^[3-4]. 首先,获取反映设备状态的监测信号;然后分析采集的信号,从中提取特征以揭示故障信息;最后用所提取的特征训练分类器以识别故障类型. 其中,特征提取是一个关键步骤,因为提取的特征好坏直接决定了故障识别效果^[5]. 传统的特征提取方法主要依靠诊断专家对特定工况下运行的特定部件深入分析后,运用各种信号处理技术,如时域/频域分析、经验模式分解^[6]和小波包分解^[7]等设计算法提取特征来表征设备的健康状态. 这类方法需要熟练掌握各种信号处理技术,具有丰富的诊断经验,并且投入大量的时间和精力^[8].

近年来,无监督特征学习^[9]作为一类新的特征提取方法被逐渐运用到机械智能故障诊断中^[10-11]. 这类方法最大的优势是可以从原始信号中自动学习特征,克服了传统基于信号处理的特征提取方法的不足. 在众多无监督特征学习方法中,稀疏滤波网络(sparse filtering network, SFN)^[12]因其网络结构简单、可调参数少、训练速度快而备受青睐. 一些学者尝试使用SFN从不同类型的信号中学习特征用于故障分类. Lei等^[13]提出一种两阶段故障诊断方法. 在第1阶段,用大量无标签的振动信号片段训练SFN的网络参数,然后基于训练的SFN提取每个样本的特征向量;在第2阶段,用所提取的特征向量训练Softmax分类器以实现故障识别. 该方法在电机轴承和机车轴承诊断案例中分别取得了99.66%和99.0%的识别精度. 何群等^[14]设计了一个基于SFN的局部特征学习网络,从原始电流信号和包络信号中分别学习不同的故障特征,然后进行特征融合并送入支持向量机中实现不同故障的分类. 该方法在风电齿轮箱诊断案例中取得了92.2%的诊断精度. 此外,部分学者尝试从引入正则项的角度改进标准SFN模型来进一

步增强其泛化能力. Qian等^[15]和Wang等^[16]分别提出了 l_1 范数正则化的SFN(l_1 -SFN)和 $l_{1/2}$ 范数正则化的SFN($l_{1/2}$ -SFN),他们分别使用 l_1 范数最小化和 $l_{1/2}$ 范数最小化约束网络的权重. 实验结果表明, l_1 -SFN和 $l_{1/2}$ -SFN均比标准SFN的泛化能力更强,诊断性能更好.

以上文献中标准SFN及其变体 l_1 -SFN和 $l_{1/2}$ -SFN的共同点在于,它们仅从单一尺度信号(原始信号)中学习特征而忽略了机械信号固有的多尺度特性^[17]. 多尺度特性体现在,实际工程中设备的运行工况复杂多变,辐射出的信号通常具有高度非线性、强耦合和不确定性,这些信号携带的故障信息往往分布在多个时间尺度上^[5]. 然而,仅从单尺度信号中提取的特征难以充分揭示信号中的故障信息,导致特征学习能力弱,诊断能力不足. 多尺度学习可以很好地解决上述问题,因为多尺度学习有助于充分挖掘不同尺度上的故障信息,从而显著提升诊断精度^[17-20].

基于以上分析,本文提出一种多尺度稀疏滤波网络(multi-scale sparse filtering network, MSSFN). 该方法将多尺度学习思想运用到SFN中. 与原始SFN相比,MSSFN的优点在于,它从多个尺度的信号中提取特征,然后进行特征融合,因而所提取的特征可以全面捕获信号中的故障信息,进而为后续的故障识别任务提供充足的决策力. 在3个从传动系统动态模拟器中采集的齿轮故障数据集上,通过大量对比实验验证了MSSFN的有效性.

1 稀疏滤波网络(SFN)

SFN是近年来故障诊断领域新兴的一种无监督特征学习方法. 与稀疏自编码器、稀疏编码、重构独立成分分析等传统方法相比,SFN的优点在于其网络结构简单,可调参数少且能有效处理高维输入,因此,SFN能很好地适应不同学习任务. 此外,不像传统方法那样对原始数据分布进行显示建模,SFN直接优化特征矩阵的稀疏性. 其核心思想是学习满足3个准则的特征:1)种群稀疏:每个样本只用很少的非零特征表示,即每个样本是稀疏的;2)存在稀疏:每个特征只在少数的样本中被激活,以保证所学的特征具有判别性;3)高分散性:每个特征具有相似的统计特性,以提高特征的泛化性.

如图1所示,SFN的基本结构是由输入层和特征层组成的两层神经网络. 给定一个无标签样本集 $\mathbf{X} = \{\mathbf{x}^i\}_{i=1}^M \in \mathbf{R}^{D \times M}$. 其中: $\mathbf{x}^i \in \mathbf{B}^D$ 是第*i*个输入样本,*M*为总样本数. $\mathbf{f}^i \in \mathbf{R}^d$ 是 \mathbf{x}^i 的特征向量,它




图1 SFN的网络结构

是 \mathbf{x}^i 经权重矩阵 $\mathbf{W} \in \mathbf{R}^{d \times D}$ 变换而来,即

$$\mathbf{f}^i = \sigma(\mathbf{W}\mathbf{x}^i), \quad (1)$$

其中 $\sigma(\cdot)$ 是一个非线性激活函数. 为了让所学特征能从复杂的输入信号中充分挖掘故障信息以及优化上的方便,通常采用简单的软绝对值函数^[12],即 $\sigma(t) = \sqrt{t^2 + \varepsilon} \approx |t|, \varepsilon = 10^{-8}$. 为了更具体说明式(1),令 \mathbf{w}_j 为权重矩阵 \mathbf{W} 的第 j 行 ($j = 1, 2, \dots, d$), 则 \mathbf{f}^i 中的第 j 个元素值 $f_j^i = \sigma(\langle \mathbf{w}_j, \mathbf{x}^i \rangle)$, 其中 $\langle \mathbf{w}_j, \mathbf{x}^i \rangle$ 表示向量 \mathbf{w}_j 和 \mathbf{x}^i 的内积.

假设 $\mathbf{F} = (f_j^i)_{d \times M}$ 是输入矩阵 \mathbf{X} 所对应的特征矩阵, $\mathbf{f}^i \in \mathbf{R}^{d \times 1}$ 和 $\mathbf{f}_j \in \mathbf{R}^{1 \times M}$ 分别表示矩阵 \mathbf{F} 的第 i 列和第 j 行. 其中: $i = 1, 2, \dots, M; j = 1, 2, \dots, d$. SFN 的损失函数通过以下3个步骤建立:

1) 行规范化:对矩阵 \mathbf{F} 的每一行进行 l_2 范数规范化处理得到 $\tilde{\mathbf{F}}$, 其中 $\tilde{\mathbf{F}}$ 的第 j 行为 $\tilde{\mathbf{f}}_j = \mathbf{f}_j / \|\mathbf{f}_j\|_2$.

2) 列规范化:再对矩阵 $\tilde{\mathbf{F}}$ 的每一列进行 l_2 范数规范化处理得到 $\hat{\mathbf{F}}$, 其中 $\hat{\mathbf{F}}$ 的第 i 列为 $\hat{\mathbf{f}}^i = \tilde{\mathbf{f}}^i / \|\tilde{\mathbf{f}}^i\|_2$.

3) 稀疏约束:对每一个规范化处理后的特征向量施加 l_1 范数稀疏性约束,得到SFN的损失函数如下:

$$\min_{\mathbf{W}} \sum_{i=1}^M \|\hat{\mathbf{f}}^i\|_1 = \sum_{i=1}^M \frac{\|\tilde{\mathbf{f}}^i\|_1}{\|\tilde{\mathbf{f}}^i\|_2}. \quad (2)$$

需要注意,一任意向量 $\mathbf{r} = [r_1, r_2, \dots, r_m]$ 的 l_p 范数定义为 $\|\mathbf{r}\|_p = (|r_1|^p + \dots + |r_m|^p)^{1/p}$.

为了更清楚地描述上述步骤,以 $d = M = 2$ 为例说明 \mathbf{F} 的行规范化(rn)和列规范化(cn),如下式所示:

$$\mathbf{F} = \begin{pmatrix} f_1^1 & f_1^2 \\ f_2^1 & f_2^2 \end{pmatrix} \xrightarrow{rn} \tilde{\mathbf{F}} = \begin{pmatrix} \tilde{f}_1^1 & \tilde{f}_1^2 \\ \tilde{f}_2^1 & \tilde{f}_2^2 \end{pmatrix} \xrightarrow{cn} \hat{\mathbf{F}} = \begin{pmatrix} \hat{f}_1^1 & \hat{f}_1^2 \\ \hat{f}_2^1 & \hat{f}_2^2 \end{pmatrix}. \quad (3)$$

其中

$$\begin{cases} \tilde{f}_1^1 = f_1^1 / \sqrt{(f_1^1)^2 + (f_1^2)^2}, \\ \tilde{f}_1^2 = f_1^2 / \sqrt{(f_1^1)^2 + (f_1^2)^2}, \\ \tilde{f}_2^1 = f_2^1 / \sqrt{(f_2^1)^2 + (f_2^2)^2}, \\ \tilde{f}_2^2 = f_2^2 / \sqrt{(f_2^1)^2 + (f_2^2)^2}; \end{cases}$$

$$\begin{cases} \hat{f}_1^1 = \tilde{f}_1^1 / \sqrt{(\tilde{f}_1^1)^2 + (\tilde{f}_1^2)^2}, \\ \hat{f}_1^2 = \tilde{f}_1^2 / \sqrt{(\tilde{f}_1^1)^2 + (\tilde{f}_1^2)^2}, \\ \hat{f}_2^1 = \tilde{f}_2^1 / \sqrt{(\tilde{f}_2^1)^2 + (\tilde{f}_2^2)^2}, \\ \hat{f}_2^2 = \tilde{f}_2^2 / \sqrt{(\tilde{f}_2^1)^2 + (\tilde{f}_2^2)^2}. \end{cases} \quad (4)$$

需要注意的是, $f_1^1, f_1^2, f_2^1, f_2^2$ 中含有待优化的参数矩阵 \mathbf{W} . 此时SFN的损失函数为

$$\min_{\mathbf{W}} (|\hat{f}_1^1(\mathbf{W})| + |\hat{f}_1^2(\mathbf{W})| + |\hat{f}_2^1(\mathbf{W})| + |\hat{f}_2^2(\mathbf{W})|). \quad (5)$$

在用SFN进行特征提取前,需要对SFN的网络权重进行训练. 训练过程等价于寻找一个最优的权重矩阵 \mathbf{W}^* 使得式(2)中的损失函数最小化. 与传统神经网络相似, SFN也是通过梯度法进行训练. 为了计算损失函数的梯度,将式(2)重新写为

$$\min_{\mathbf{W}} \psi(\mathbf{W}) = \sum_{i=1}^M \left(\left(\sum_{j=1}^d \tilde{f}_j^i \right) / \left(\sum_{j=1}^d (\tilde{f}_j^i)^2 \right)^{\frac{1}{2}} \right). \quad (6)$$

其中: $\tilde{f}_j^i = f_j^i / \|\mathbf{f}_j\|_2$, 且 f_j^i 是 \mathbf{f}_j 中第 i 个元素. 损失函数 $\psi(\mathbf{W})$ 对权重矩阵 \mathbf{W} 的梯度为

$$\frac{\partial \psi(\mathbf{W})}{\partial \mathbf{W}} = \left(\frac{\partial \psi(\mathbf{W})}{\partial \mathbf{F}} \odot \sigma'(\mathbf{W}\mathbf{X}) \right) \mathbf{X}^T. \quad (7)$$

其中: $\sigma'(t) = t / \sqrt{t^2 + \varepsilon}$ 是 $\sigma(t)$ 的导数, 符号“ \odot ”表示两矩阵的点乘. $\partial \psi(\mathbf{W}) / \partial \mathbf{F} = (\partial \psi / \partial f_j^i)_{d \times M}$. 其中

$$\frac{\partial \psi}{\partial f_j^i} = \frac{\partial \psi}{\partial \tilde{f}_j^i} \frac{\partial \tilde{f}_j^i}{\partial f_j^i} = \frac{\partial \tilde{f}_j^i}{\partial f_j^i} \frac{\partial \tilde{f}_j^i}{\partial f_j^i}, \quad (8)$$

$$\frac{\partial \tilde{f}_j^i}{\partial f_j^i} = (\|\tilde{\mathbf{f}}^i\|_2)^{-1} - \tilde{f}_j^i \left(\sum_{j=1}^d \tilde{f}_j^i \right) (\|\tilde{\mathbf{f}}^i\|_2)^{-3}, \quad (9)$$

$$\frac{\partial \tilde{f}_j^i}{\partial f_j^i} = (\|\mathbf{f}_j\|_2)^{-1} - f_j^i \left(\sum_{i=1}^M f_j^i \right) (\|\mathbf{f}_j\|_2)^{-3}. \quad (10)$$

有限拟牛顿法(L-BFGS)是一种有效的梯度法,在每步迭代时只需计算 $\psi(\mathbf{W})$ 和 $\partial \psi(\mathbf{W}) / \partial \mathbf{W}$. L-BFGS可自适应搜索步长,计算效率高,因此,通常采用L-BFGS算法优化SFN的损失函数^[12].

2 多尺度稀疏滤波网络(MSSFN)

2.1 基于MSSFN的特征提取流程

传统SFN缺乏多尺度特征提取能力,导致所提取的特征难以全面反映机械设备的健康状况. 为此,本文提出一种多尺度稀疏滤波网络(MSSFN)用于故障特征提取,其网络结构如图2所示,包括多尺度粗粒度层、样本分段层、局部特征提取层、特征平均化层和特征堆叠层. 该网络的输入是一个原始振动信号,不妨设为 $\mathbf{x} = \{x_1, x_2, \dots, x_N\}^T$, 其中 x_n 是 \mathbf{x} 的第 n 个数据点 ($n = 1, 2, \dots, N$), 经过层层处理后输出 \mathbf{x} 的多尺度特征向量 \mathbf{y} , 具体步骤如下.

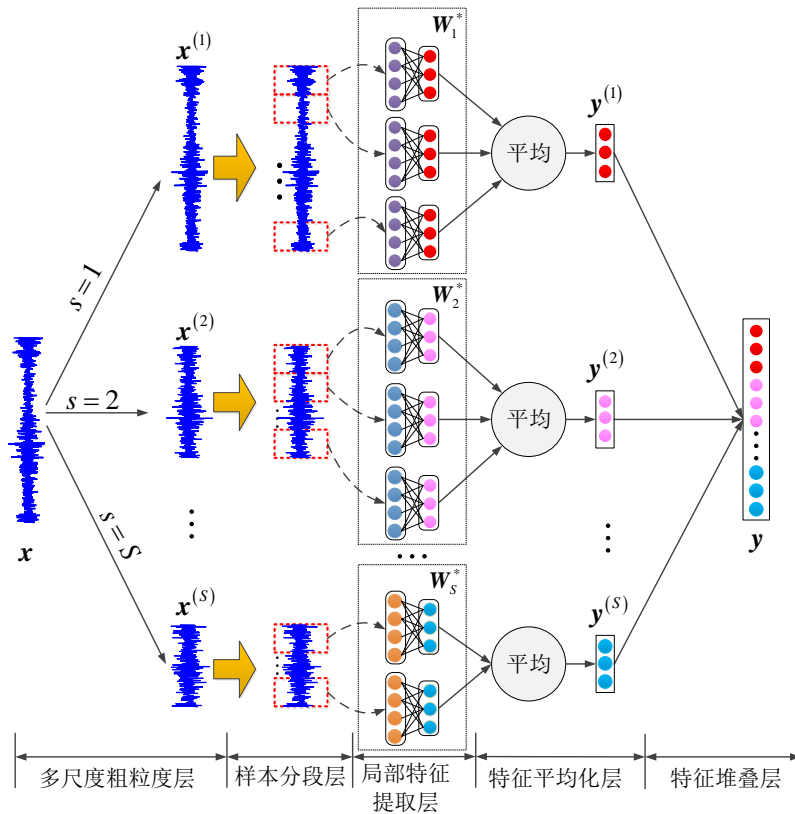


图2 MSSFN的网络结构

2.1.1 多尺度粗粒度层

多尺度粗粒度层的作用是获取多尺度信号,这些多尺度信号蕴含不同且互补的故障信息,可以全面反映设备的健康状态.该层利用与尺度深度等长的滑动窗对一个振动信号样本进行无重叠移动,求取每个滑动窗内数据点的平均值.多尺度粗粒度层操作简单,计算效率高,且一定程度上可以消除高频干扰和随机噪声的影响^[20].

在MSSFN中考虑S个尺度,设 $\mathbf{x}^{(s)} \in \mathbf{R}^{N/s}$ 为 \mathbf{x} 在第s个尺度下的表示($s = 1, 2, \dots, S$), $x_j^{(s)}$ 为 $\mathbf{x}^{(s)}$

的第j个数据点($1 \leq j \leq N/s$),其计算公式如下:

$$x_j^{(s)} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x_i. \quad (11)$$

其中: N/s 表示 $\mathbf{x}^{(s)}$ 的长度, $s = 1$ 表示原始振动信号 \mathbf{x} .图3展示了 \mathbf{x} 经多尺度粗粒度层处理后得到的前3种尺度下的表示.假设 \mathbf{x} 是一个含有2400个数据点的振动信号,即 $N = 2400$,则 \mathbf{x} 的前3种尺度表示分别为 $\mathbf{x}^{(1)} = \mathbf{x} \in \mathbf{R}^{2400}$, $\mathbf{x}^{(2)} \in \mathbf{R}^{1200}$, $\mathbf{x}^{(3)} \in \mathbf{R}^{800}$.

2.1.2 样本分段层

样本分段层的目的是将 $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(S)}$ 交替无重叠地划分成若干个片段,这样做一方面可以避免高维输入带来的高计算量,另一方面有助于捕捉信号中细致的局部特征^[14].

具体地, $\mathbf{x}^{(s)}$ 经样本分段层处理后得到 K_s 个无重叠长度为 D_s 的片段 $\{\mathbf{h}_k^{(s)}\}_{k=1}^{K_s}$.其中: $\mathbf{h}_k^{(s)} \in \mathbf{R}^{D_s}$, $K_s = N/(sD_s)$ 为整数.为了方便,本文中不同尺度信号划分的片段长度均设为 D ,即 $D_s = D$.例如 $D = 50$ 时,一个含有2400个数据点的振动信号的前3种尺度经样本分段层处理后分别得到48、24和16个长度为50的片段.

2.1.3 局部特征提取层

局部特征提取层的作用是利用训练好的MSSFN计算不同尺度下每个片段所对应的特征向

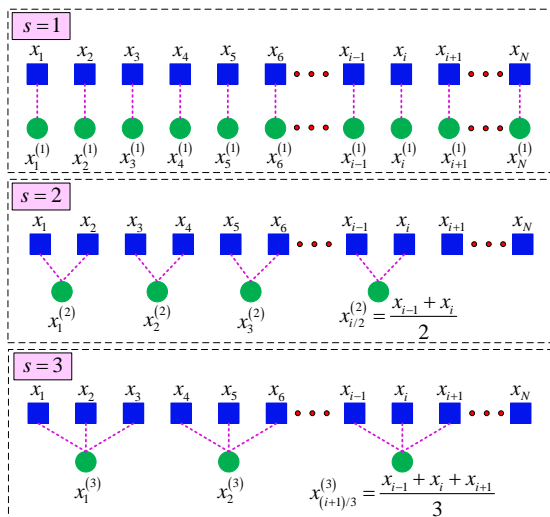


图3 多尺度粗粒度层的处理过程

量. 其中, 训练MSSFN等价于最小化式(2)中的损失函数以学习 S 个权重矩阵 $\mathbf{W}_1^*, \mathbf{W}_2^*, \dots, \mathbf{W}_S^*$, 具体训练步骤将在第2.2节中给出.

利用 \mathbf{W}_s^* 计算 $\{\mathbf{h}_k^{(s)}\}_{k=1}^{K_s}$ 所对应的特征向量 $\{\mathbf{f}_k^{(s)}\}_{k=1}^{K_s}$, 即

$$\begin{cases} \mathbf{f}_k^{(s)} = \sigma(\mathbf{W}_s^* \mathbf{h}_k^{(s)}), \\ \mathbf{f}_k^{(s)} = \mathbf{f}_k^{(s)} / \|\mathbf{f}_k^{(s)}\|_2. \end{cases} \quad (12)$$

其中: \mathbf{W}_s^* 表示第 s 个尺度下的信号训练得到的 SFN 权重矩阵; $\mathbf{f}_k^{(s)} \in \mathbf{R}^{d_s}$ 为 $\mathbf{h}_k^{(s)}$ 所对应的特征向量, d_s 表示 $\mathbf{f}_k^{(s)}$ 的维度, 实际上也是MSSFN在第 s 个尺度下所学特征的个数. 为了方便起见, 设定MSSFN在每个尺度下学习的特征数相同, 均为 d , 即 $d_s = d$.

2.1.4 特征平均化层

特征平均化层的目的是将第 s 尺度下获得的 K_s 个特征向量 $\{\mathbf{f}_k^{(s)}\}_{k=1}^{K_s}$ 进行平均池化处理, 以获得 \mathbf{x} 在第 s 尺度下的表征, 记为 $\mathbf{y}^{(s)} \in \mathbf{R}^d$, 有

$$\mathbf{y}^{(s)} = \frac{1}{K_s} \sum_{k=1}^{K_s} (\mathbf{f}_k^{(s)}). \quad (13)$$

特征平均化的作用是消除振动信号中存在的移位不变性, 抑制随机噪声的影响, 同时捕捉更多的判别性特征, 这有利于后续的有监督故障分类任务.

2.1.5 特征堆叠层

获得 \mathbf{x} 在不同尺度下的表征 $\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(S)}$ 后, 经特征堆叠层进行简单的首尾堆叠, 得到 \mathbf{x} 最终的多尺度特征向量 $\mathbf{y} \in \mathbf{R}^{dS}$, 即

$$\mathbf{y} = [\mathbf{y}^{(1)}, \dots, \mathbf{y}^{(s)}, \dots, \mathbf{y}^{(S)}]. \quad (14)$$

传统 SFN 从原始振动信号中提取特征, 因此, 所提取的特征向量仅仅为 $\mathbf{y}^{(1)}$; 而 MSSFN 提取的特征不仅包括 $\mathbf{y}^{(1)}$, 还包括其他尺度下的表征 $\mathbf{y}^{(2)}, \mathbf{y}^{(3)}, \dots, \mathbf{y}^{(S)}$. 因此, 与 SFN 提取的特征相比, MSSFN 提取的多尺度特征能够提供丰富且互补的故障信息, 有利于提高故障识别精度.

2.2 MSSFN 训练

收集设备正常和各种故障状态下的原始振动信号样本, 组成训练集 $\mathbf{T} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_U\}$, 每个样本含有 N 个采样点, U 为训练样本数. 利用第2.1.1节中的多尺度粗粒度划分方式, 对 \mathbf{T} 中每个信号样本进行尺度深度为 S 的多尺度划分, 得到训练集前 S 个尺度下的表示 $\{\mathbf{T}^{(1)}, \mathbf{T}^{(2)}, \dots, \mathbf{T}^{(S)}\}$, 其中 $\mathbf{T}^{(1)} = \mathbf{T}$.

MSSFN 的训练是利用 $\{\mathbf{T}^{(s)}\}_{s=1}^S$ 学习 S 个最优的权重矩阵 $\{\mathbf{W}_s^*\}_{s=1}^S$, 其中 $\mathbf{W}_s^* \in \mathbf{R}^{d \times D}$ 是由所对应数据矩阵 $\mathbf{T}^{(s)} \in \mathbf{R}^{(N/s) \times U}$ 训练而得. 不失一般性, 下面详述如何利用 $\mathbf{T}^{(s)}$ 得到最优的权重矩阵 \mathbf{W}_s^* , 步骤

如下.

step 1: 利用长度为 D 的滑动窗对 $\mathbf{T}^{(s)}$ 中每个长度为 N/s 的信号样本进行滑动分段, 如图4所示. 滑动窗每间隔一个数据点移动一次, 即相邻片段之间重叠的数据点数为 $D-1$. 这样一来, U 个样本共计可以得到 $J_s = U(N/s - D + 1)$ 个片段.




图4 每个信号样本的分段示意图

step 2: 从上述 J_s 个片段中任选 L 个组成数据矩阵 $\mathbf{H}_s \in \mathbf{R}^{D \times L}$, 每个片段是一个长度为 D 的样本.

step 3: \mathbf{H}_s 不做任何预处理, 直接用来训练 MSSFN 第 s 个尺度下的网络权重. 训练过程等价于最小化式(2)中的损失函数, 其中损失函数对权重矩阵的梯度由式(6)~(10)计算, L-BFGS 为优化器. 优化完毕后可以获得相应的权重矩阵, 记为 \mathbf{W}_s^* .

重复 step 1 ~ step 3 的步骤 S 次, 获得 S 个最优权重矩阵 $\{\mathbf{W}_1^*, \mathbf{W}_2^*, \dots, \mathbf{W}_S^*\}$, 从而完成 MSSFN 的训练. 之后, 对一个新输入的振动信号样本 $\mathbf{x}_{\text{new}} \in \mathbf{R}^N$, 根据图2描述的步骤计算其对应的特征向量 $\mathbf{y}_{\text{new}} \in \mathbf{R}^{dS}$, 然后利用 \mathbf{y}_{new} 训练一个分类器, 从而实现设备的故障诊断.

MSSFN 可广泛用于机械故障诊断的特征提取阶段, 具体过程如算法1所述. 首先, 收集历史数据训练 MSSFN 的网络权重; 然后, 将每个实时信号样本输入训练好的 MSSFN 中, 得到其多尺度特征向量.

算法1 用于机械故障特征提取的 MSSFN.

输入: 训练集 T , 新采集的振动信号样本 \mathbf{x}_{new} ;

输出: \mathbf{x}_{new} 的多尺度特征向量 \mathbf{y}_{new} .

训练 MSSFN

1) for $s = 1: S$

2) 对 \mathbf{T} 中的每个样本进行 s 尺度划分, 得到 $\mathbf{T}^{(s)}$;

3) 对 $\mathbf{T}^{(s)}$ 中的每个样本分段, 得到 J_s 个长度的 D 的片段;

4) 从 J_s 个片段中任选 L 个片段组成数据矩阵 \mathbf{H} ;

5) 随机初始化 \mathbf{W}_s ;

6) while iter \leq maxiter do

- 7) H_s 为输入, 式(2)为优化函数, 由式(6)~(10)计算优化函数对 W_s 的梯度;
- 8) 根据L-BFGS算法更新 W_s ;
- 9) end
- 10) 优化完毕, 获得最优权重矩阵, 记为 W_s^* ;
- 11) end
- 12) 保存 S 个最优权重矩阵 $\{W_1^*, W_2^*, \dots, W_s^*\}$, 训练完毕.

特征提取

13) 根据图2描述的步骤对 x_{new} 依次进行多尺度划分、样本分段、局部特征提取、平均池化和特征堆叠处理, 得到 x_{new} 的多尺度特征向量 y_{new} .

3 实验验证

3.1 实验数据集描述

利用传动系统动态模拟器^[21]采集的齿轮数据集对本文方法进行实验验证. 如图5所示, 动态模拟器由电机、电机控制器、行星齿轮箱、并联齿轮箱、制动器和制动控制器组成. 在两种运行工况下模拟5种齿轮状态, 分别为: 正常(F_1), 齿缺损(F_2), 齿根磨损(F_3), 齿面磨损(F_4)和断齿(F_5). 两种工况为转频20 Hz无负载和转频30 Hz有负载, 分别记为 C_1 和 C_2 . 试验台上安装7个608A11型振动传感器, 其中3个传感器测量行星齿轮箱 x 、 y 、 z 三个方向上的振动数据, 3个传感器测量并联齿轮箱 x 、 y 、 z 三个方向上的振动数据, 1个传感器测量电机驱动端的振动数据. 传感器的频率范围、测量范围和精度分别为0.5 Hz~10 kHz、

± 50 g 和 100 mV/g. 在电机与行星齿轮箱之间安装有PAD采集仪用于数据采集, 采样频率为1 024 Hz. 基于行星齿轮箱 x 方向上的振动数据进行实验分析.

为了验证MSSFN模型的有效性, 创建 A 、 B 、 C 三个数据集, 如表1所示. 数据集 A 和 B 分别包含 C_1 和 C_2 工况下5种齿轮状态的振动数据, 每种状态有300个样本, 每个样本含有2 400个数据点. 数据集 C 含有 C_1 和 C_2 两种工况下5种齿轮状态的振动数据, 每种状态有600个样本, 同种齿轮状态在不同运行工况下的样本视为同一类. 因此数据集 A 、 B 、 C 分别含有1 500、1 500、3 000个样本.

表1 三个齿轮数据集描述


数据集	运行工况	齿轮状态	样本数
A/B/C	$C_1/C_2/(C_1 + C_2)$	F_1	300 / 300 / 600
		F_2	300 / 300 / 600
		F_3	300 / 300 / 600
		F_4	300 / 300 / 600
		F_5	300 / 300 / 600

图6展示了5种齿轮状态所对应的时域振动信号, 其中每行的两个子图对应于同种齿轮状态的两种不同运行工况. 可以看出, 这些振动信号比较复杂, 高度非线性, 故障特征不明显, 仅仅通过观察曲线变化难以区分不同齿轮状态, 因此, 接下来利用所提出的MSSFN分析这些振动信号.


3.2 实验结果

本文所提出的MSSFN共涉及4个超参数: 每个片段的长度 D 、每个片段所对应的特征向量维度 d 、每个尺度下学习相应权重矩阵所需要的片段数 L 以及MSSFN的尺度深度 S . 根据文献[13]对参数 D 、 d 和 L 的分析, 本文设置 $D = d = 50, L = 20\,000$. 此外, MSSFN的尺度深度 S 暂定为3. 因此, 标准SFN和所提出的MSSFN分别提取了50和150个特征.

从数据集 A 、 B 、 C 的每一类中任选一半的样本组成训练集分别训练SFN和MSSFN, 利用t-分布邻域嵌入(t-distribution stochastic neighbor embedding, t-SNE)技术^[22]将得到的特征降维至二维空间进行可视化, 结果如图7所示. 在图7(a)中, MSSFN提取的特征能将不同类的样本完全分开, 而SFN提取的特征无法将齿缺损和齿根磨损样本完全分开. 在图7(b)中, 尽管MSSFN提取的特征无法将不同类的样本完全分开, 但是相比较SFN而言, MSSFN的各类样本之间的重叠程度明显较低. 在图7(c)中, 每类样本聚成的两个簇分别对应于两种运行工况 C_1 和 C_2 , 从该



(a) 系统实物



(b) 系统结构

图5 动力传动系统模拟测试平台

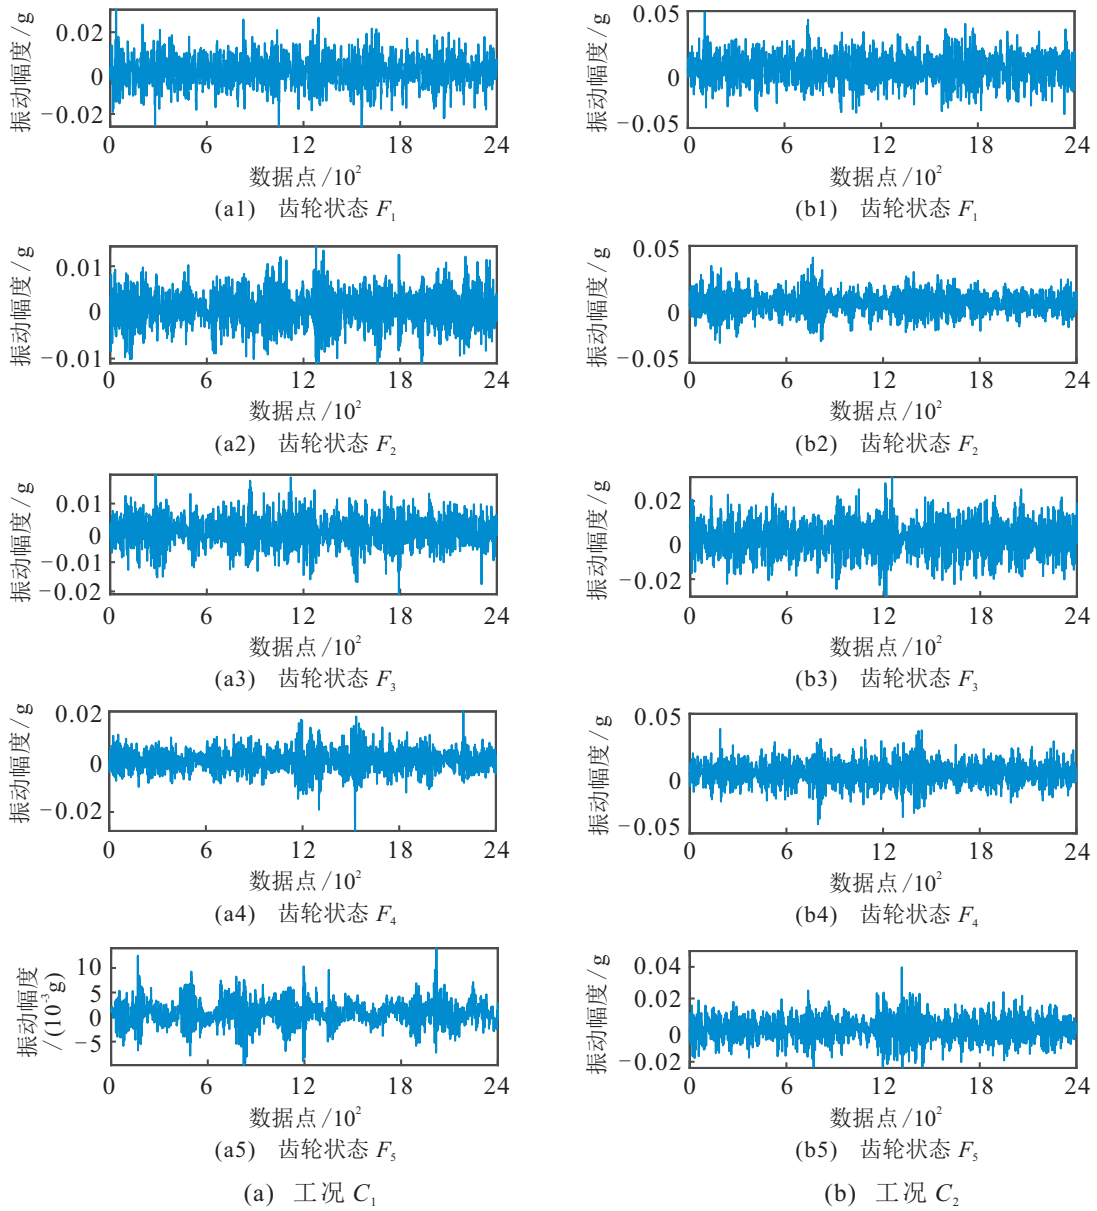


图6 两种工况下5种齿轮状态所对应的时域振动信号

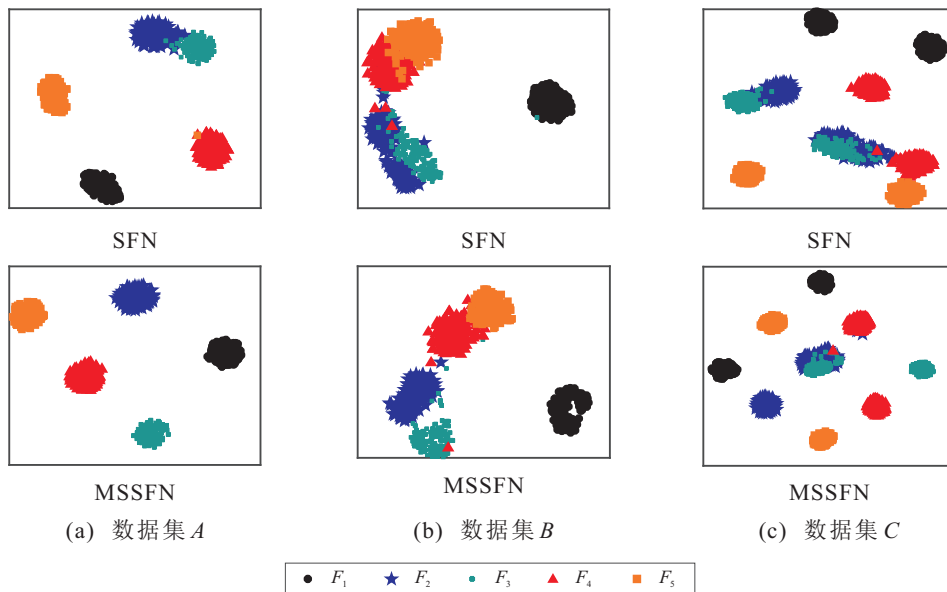


图7 SFN和MSSFN的可视化效果对比

图中可以看出, MSSFN的各簇之间的分离程度优于SFN的各个簇. 图7表明, MSSFN的可视化效果明显好于SFN.

为了定量评估MSSFN的特征提取效果, 将训练集分别投影至MSSFN和SFN特征提取后所对应的特征空间中, 得到训练集的特征表示矩阵, 利用常用的 K 均值聚类算法对两种网络的特征表示矩阵进行聚类分析. 评价指标采用常用的聚类精度 (clustering accuracy, CA)^[23] 和标准化互信息 (normalized mutual information, NMI)^[23]. 假设待聚类的数据集含有 n 个样本, 这些样本的真实标签和聚类标签分别为 $P = \{p_i\}_{i=1}^n$ 和 $Q = \{q_i\}_{i=1}^n$, 且这些样本来自 W 个类别, 即 $p_i, q_i \in \{1, 2, \dots, W\}$. 则CA和NMI定义如下:

$$CA = \left(\frac{1}{n} \sum_{i=1}^n \delta(p_i, \text{map}(q_i)) \right) \times 100\%. \quad (15)$$

其中: $x = y$ 时, $\delta(x, y)$ 值为1, 否则为0; $\text{map}(\cdot)$ 通过匈牙利算法^[23] 将聚类标签与真实标签进行最佳匹配.

$$NMI = \frac{2MI(P, Q)}{H(P) + H(Q)} \times 100\%. \quad (16)$$

其中: $MI(P, Q)$ 表示 P 与 Q 之间的互信息^[23], $H(P)$ 和 $H(Q)$ 分别表示 P 和 Q 的熵. 以真实标签集 P 为例, 设子集 P_w 为 P 中标签为 w 的所有样本集合, $w = 1, 2, \dots, W$, 则集合 P 的熵为

$$H(P) = - \sum_{w=1}^W \frac{|P_w|}{n} \log \frac{|P_w|}{n}, \quad (17)$$

其中 $|P_w|$ 表示子集 P_w 中的样本个数.

CA和NMI均位于0~100%之间, 值越大说明聚类效果越好. K 均值算法对初始类中心比较敏感, 且初始类中心通常随机选取, 为此, 重复运行 K 均值50次并计算平均值, 结果如表2所示. 可以看出, MSSFN在每个数据集上的每个性能指标均高于SFN, 说明前者的聚类效果优于后者. 同时表明MSSFN提取的特征更能区分不同的齿轮状态, 判别性更好.

表2 SFN和MSSFN的特征聚类效果对比 %

方法	数据集 A		数据集 B		数据集 C	
	CA	NMI	CA	NMI	CA	NMI
SFN	90.33	89.23	76.87	71.33	83.15	87.78
MSSFN	93.11	94.17	84.62	80.16	83.39	88.87

为了进一步说明MSSFN提取的特征能够适用于故障诊断, 利用Softmax回归分类器^[13]对MSSFN和SFN提取的特征进行故障分类. 两种最新的多尺度网络用作对比, 分别是多尺度卷积神经网络 (multi-scale convolutional neural network, MSCNN)^[17] 和多

尺度表征融合网络 (multi-scale representations fusion network, MSRFN)^[18]. 其中, MSCNN和MSRFN分别以卷积神经网络和自编码网络为基本框架. 为了公平比较, 这两种多尺度网络的尺度深度均设为3. 此外, 采用3种传统的基于信号处理技术的多尺度特征提取方法与本文的MSSFN做对比, 分别是多尺度熵^[24]、经验模式分解^[6]和小波包分解^[7]. 其中: 多尺度熵法将一个原始振动信号划分成多个不同粗粒度的信号, 取前20个尺度, 计算每个尺度的样本熵作为特征, 得到一个20维的特征向量; 经验模式分解法将一个原始振动信号分解成一组几乎正交的本征模态函数 (intrinsic mode function, IMF), 计算前8个IMF的能量作为特征, 得到一个8维的特征向量; 小波包分解法将一个原始振动信号分解为几个包含不同频带信息的分量. 采用“db4”作为小波基函数进行4层分解, 得到16个不同频带的分量. 计算每个分量的能量作为特征, 得到一个16维的特征向量. 采用常用的Fscore^[17]作为分类性能评价指标, 其定义如下:

$$Fscore = \frac{2TP}{2TP + FP + FN} \times 100\%. \quad (18)$$

其中: TP表示将正类预测为正类数, FN表示将正类预测为负类数, FP表示将负类预测为正类数. 这里, 正类指所关注的那一类, 其余类都是负类. 例如, 研究所提出方法对 F_1 的诊断效果, 则 F_1 为正类, $F_2 \sim F_5$ 均视为负类. 在实验中, 从每类中任选一半的样本组成训练集, 剩余的样本作为测试. 为消除随机性的影响, 重复进行实验20次取平均测试结果, 如表3所示.

从表3中可以看出, 基于MSSFN的诊断方法在每个数据集上均能准确识别每种齿轮故障, 诊断效果明显优于SFN和3种传统多尺度方法. 原因在于: 1) 对比MSSFN和SFN, 前者从原始振动信号的多个尺度中学习特征, 而后者仅从原始振动信号(单一尺度)中学习特征, 故MSSFN提取的特征比SFN提取的特征更加丰富, 能够更充分捕捉信号中的故障信息, 因而具有更好的诊断性能. 2) 3种传统方法提取的特征如熵和能量很可能没有充分捕捉故障信息, 导致对设备状态的表征能力不足. 要想充分表征设备状态, 还需设计新特征, 然而这需要工程人员熟练掌握信号处理知识, 具有丰富的工程经验, 同时针对不同的设备进行特定分析, 这对人力物力的依赖都很大. 相反, MSSFN能够从原始信号的不同尺度中自动学习有用的特征, 使工程人员摆脱了繁琐的特征设计. 在3个齿轮数据集上, MSSFN与MSCNN和MSRFN这两种多尺度网络的性能几乎相当, 甚至略优于它们. 这说明所提出的以SFN为框架的MSSFN

表3 使用不同特征提取方法得到的平均Fscore对比 %

数据集	特征提取方法	齿轮状态				
		F_1	F_2	F_3	F_4	F_5
A	多尺度熵	99.93	78.34	80.76	90.85	97.85
	经验模式分解	99.85	81.74	88.98	82.44	99.71
	小波包分解	99.93	91.71	97.48	92.64	99.65
	SFN	100	97.76	98.36	99.20	99.58
	MSCNN	100	99.33	99.33	99.98	100
	MSRFN	100	98.86	98.87	99.97	100
	MSSFN	100	99.97	99.98	99.98	100
B	多尺度熵	99.55	69.02	85.88	79.89	82.50
	经验模式分解	99.79	76.97	88.04	77.36	81.95
	小波包分解	99.90	83.67	90.01	92.46	94.97
	SFN	99.88	94.10	94.29	94.91	96.78
	MSCNN	100	97.20	99.40	97.34	98.36
	MSRFN	100	94.94	97.40	95.37	98.07
	MSSFN	100	98.95	98.52	97.43	98.55
C	多尺度熵	99.17	64.86	76.02	83.71	82.55
	经验模式分解	99.63	52.13	83.11	69.73	80.87
	小波包分解	99.50	75.41	85.94	91.84	93.49
	SFN	99.92	92.25	92.37	97.60	97.49
	MSCNN	99.85	97.35	97.48	100	99.77
	MSRFN	99.75	97.22	97.12	100	99.88
	MSSFN	99.98	98.11	97.95	99.50	99.68

与其他框架下的多尺度网络相比,非常具有竞争力。

此外,从表3中还有两个发现:1)以上7种方法在数据集B上的性能明显不如在数据集A上,原因在于数据集B所对应的运行工况是高转频有负载,比数据集A所对应的运行工况更复杂,因而诊断难度更大;2)在多工况混合的数据集C中,MSSFN对 F_2 和 F_3 的识别精度相比其他故障偏低,原因可能在于这两类故障信号比较相似,彼此之间有一定的重叠导致难以区分,这一点从图7(c)的右子图中也可以看出。

3.3 不平衡故障诊断能力研究

以上所有实验中用来训练MSSFN的训练集都是平衡集,即每一类含有相同的样本数。然而实际工程应用中,设备大部分时间处于正常运行状态,这意味着正常状态的样本数要远多于每一种故障状态的样本数。因此,本节尝试探究MSSFN对不平衡数据集的处理能力,同时SFN用作对比。根据文献[25]提供的规则,基于数据集A和B构造6个不平衡数据集 $U_1 \sim U_6$,如表4所示。构造规则如下:在这6个数据集中,除了训练集中的故障样本数不同外,其余的样本数都一样,其中一半来自A,另一半来自B。以 U_1 为例,从A和B的正常样本中任选150个作为训练,剩下的150作为测试;从A和B的每一类故障样本中任选

120个作为训练,余下的180个样本中任选150个作为测试。 $U_1 \sim U_6$ 训练集中的故障样本数不断减少,表明不平衡程度不断加剧。20次重复实验的平均Fscore如图8所示。

表4 不平衡数据集描述

不平衡集	训练集		测试集	
	正常样本	故障样本/类	正常样本	故障样本/类
U_1	300	240	300	300
U_2	300	180	300	300
U_3	300	120	300	300
U_4	300	60	300	300
U_5	300	30	300	300
U_6	300	20	300	300

从图8可以看出,在每个不平衡集上,MSSFN对每类故障的诊断精度均高于SFN。在数据集 $U_1 \sim U_4$ 上,MSSFN对每类故障的诊断精度始终保持在97%以上。而SFN的诊断精度恶化程度较大,尤其在 U_4 上对 F_2 的识别精度比MSSFN低将近10%。在两个严重不平衡的数据集 U_5 和 U_6 上,MSSFN的诊断精度虽有一定恶化,但始终保持在75%以上。而SFN的诊断性能严重恶化,尤其在 U_6 上对 F_2 、 F_3 和 F_5 的识别精度不足65%,说明此时SFN无法再进行有效的故障诊断。实验结果表明,所提出的MSSFN比SFN具有更好的不平衡数据集处理能力。

3.4 尺度深度对诊断性能的影响

在以上所有实验中,MSSFN的尺度深度均设定为3。本节将研究不同尺度深度对诊断性能的影响,实验在数据集C上进行。从图9(a)中可以看出,随着尺度的加深,对 F_1 、 F_4 和 F_5 的识别精度不断增加然后趋于稳定,对 F_2 和 F_3 的识别精度先逐渐升高而后略有下降。原因在于,当尺度增加时,MSSFN从多个尺度上提取特征使得更多的故障信息被挖掘,诊断性能越来越好。当尺度深度继续增加时,故障信息已经被充分挖掘,诊断性能趋于稳定。至于 F_2 和 F_3 ,表3结果已表明,这两类故障是相对最难区分的。当尺度深度更大时,对这两类故障的识别精度逐渐降低,可能是因为更多的冗余或无关特征被提取,加大了Softmax回归分类器对这两种故障的区分难度。

为了探索本文方法的计算复杂度,图9(b)展示了不同尺度深度下的训练时间和测试时间。其中:训练时间包括训练集的多尺度划分、MSSFN的网络训练以及Softmax分类器的训练这3个过程所消耗的总时间;测试时间指一个新采集的振动信号依次输入训练好的MSSFN和Softmax直至得到其预测标签所消

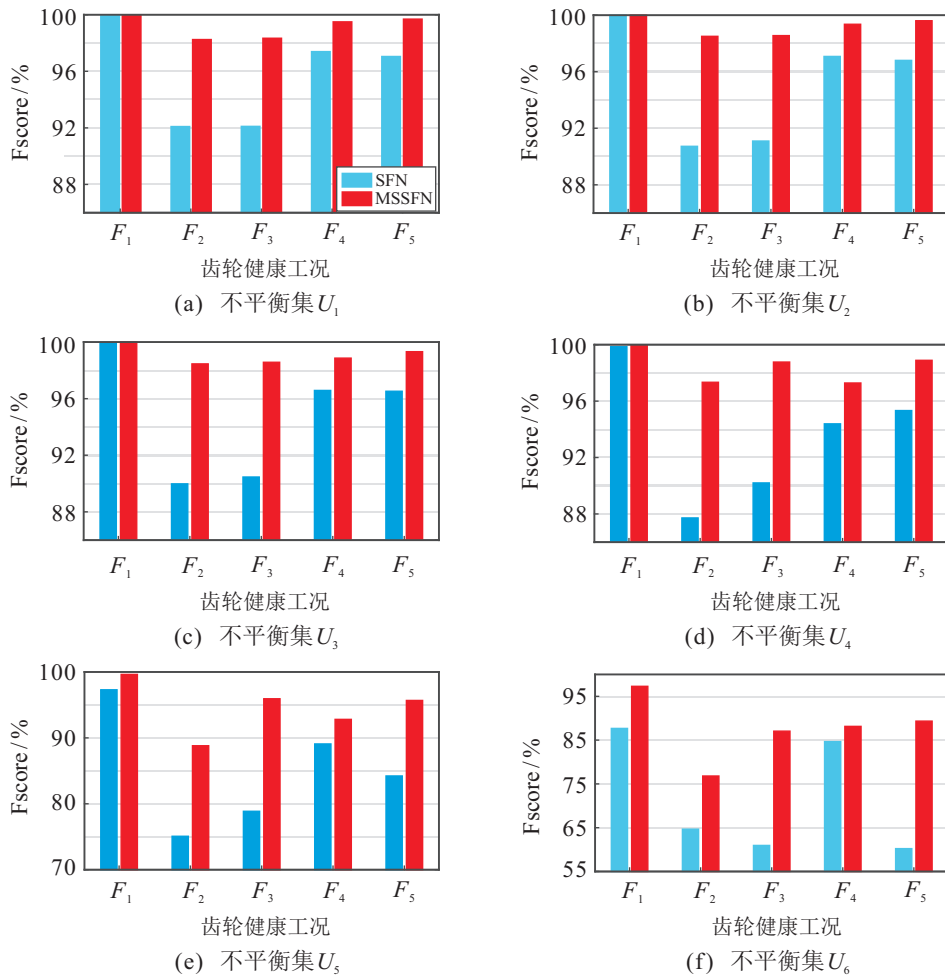


图8 不平衡数据集上SFN和MSSFN的平均Fscore对比

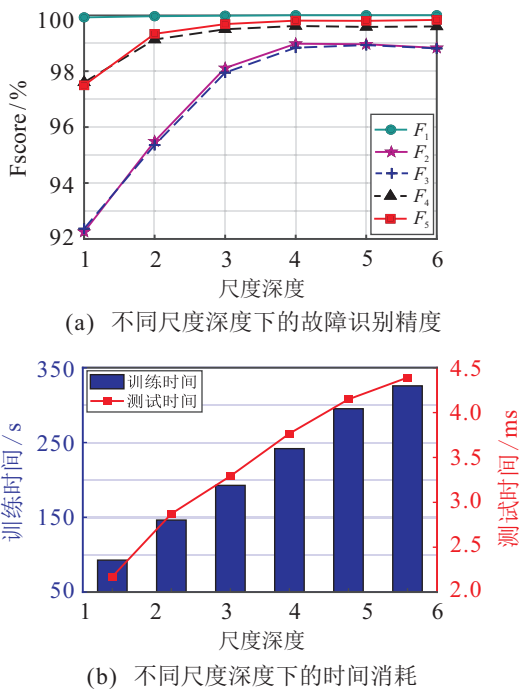


图9 尺度深度对诊断性能的影响

耗的总时间.可以看出,随着尺度的加深,训练时间和测试时间均几乎呈线性增加.原因在于,尺度的加深

意味着MSSFN的网络复杂度及Softmax输入维度的增加,因而导致更多的时间消耗.然而实际工程中,训练过程通常离线进行而测试过程在线进行^[17].这意味着训练时间并不直接影响到故障诊断系统的性能,而测试时间才是诊断系统关注的一个重要指标.从图9(b)的折线图可以看出,尽管测试时间随着尺度深度的增加而不断增加,但尺度深度为6时的测试时间不到4.5 ms,可以满足实时诊断需求.

3.5 MSSFN中使用的堆叠策略研究

MSSFN采用的融合方式是将不同尺度下的特征表示堆叠成一个长向量作为信号最终的特征向量用于故障分类.这种方法简单,但长向量中可能存在一定的无关或冗余特征.为了验证这一猜想,利用常用的距离评估技术^[7]对每个特征的重要性进行评估并排序,选择排名靠前的特征用于后续的故障分类,而剩余的特征直接丢弃.实验在数据集C上进行,尺度深度分别设定为3和4,重复实验20次记录不同特征选择比下的平均Fscore,如图10所示.可以看出,随着特征选择比的增加,识别精度逐渐升高,诊断性能越来越好.然而,对于含有3个尺度的MSSFN,当特征

选择比超过85%以后,对所有齿轮故障的识别精度已达到稳定;对于含有4个尺度的MSSFN,当特征选择比超过80%以后,对所有齿轮故障的识别精度已基本趋于稳定.图10的结果说明两点:1)堆叠法得到的长向量中并非每个特征对后续故障分类都有用,存在一定的冗余或无关特征;2)尺度越深,冗余或无关的特征越多.因此,如何消除无关冗余特征将是未来的研究工作之一.




图10 不同特征选择比下的平均Fscore

4 结论

为了解决传统SFN缺乏多尺度特征提取能力这一问题,本文提出了MSSFN.与SFN相比,MSSFN从多个尺度的振动信号中提取特征,可以充分挖掘原始信号中的故障信息.在3个齿轮数据集上测试MSSFN的性能,得出如下结论.

1)对MSSFN和SFN提取的特征进行定性分析(可视化)和定量分析(聚类),结果表明,前者具有更好的区分性和判别性.

2)用Softmax回归分类器对MSSFN、SFN及3种传统的多尺度方法提取的特征进行故障分类,结果表明,MSSFN对每类故障的诊断精度均最高.同时,将本文的MSSFN与两种其他框架下的多尺度网络进行对比,发现MSSFN的诊断性能与这两种多尺度网络的诊断性能几乎相当,甚至略优.

3)在6个不平衡数据集上对比MSSFN和SFN,结果显示,前者的性能远远优于后者,表明MSSFN具有更好的不平衡故障诊断能力.

4)研究不同尺度深度对MSSFN性能的影响,从总体上看,尺度的加深使得模型的性能逐渐变好并趋于稳定.然而,对某些难以区分的故障而言,更深的尺度则可能导致识别精度的略微下降.尽管更深的尺度会带来更多的训练和测试时间,但一个故障诊断系统通常离线训练,而尺度深度为6的测试时间也不到4.5 ms,因此,本文所提出的MSSFN可用于设计故障诊断系统以进行实时特征提取和故障识别.

未来工作将着重于两个方面:

1)进一步探究多尺度特征学习在卷积神经网络、深度置信网络和自编码网络等其他神经网络框架下的应用;

2)设计有效的特征评估机制以评估堆叠后每个特征的质量,选择最有用的特征进行后续的故障分类以消除无关和冗余特征的影响.

参考文献(References)

- [1] 王国彪,何正嘉,陈雪峰,等.机械故障诊断基础研究“何去何从”[J].机械工程学报,2013,49(1):63-72.
(Wang G B, He Z J, Chen X F, et al. Basic research on machinery fault diagnosis — what is the prescription[J]. Journal of Mechanical Engineering, 2013, 49(1): 63-72.)
- [2] Lei Y G, Yang B, Jiang X W, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [3] 曲建岭,余路,袁涛,等.基于卷积神经网络的层级化智能故障诊断算法[J].控制与决策,2019,34(12):2619-2626.
(Qu J L, Yu L, Yuan T, et al. A hierarchical intelligent fault diagnosis algorithm based on convolutional neural network[J]. Control and Decision, 2019, 34(12): 2619-2626.)
- [4] 雷亚国,贾峰,孔德同,等.大数据下机械智能故障诊断的机遇与挑战[J].机械工程学报,2018,54(5):94-104.
(Lei Y G, Jia F, Kong D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.)
- [5] Peng D D, Wang H, Liu Z L, et al. Multibranch and multiscale CNN for fault diagnosis of wheelset bearings under strong noise and variable load condition[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4949-4960.
- [6] Lei Y G, Lin J, He Z J, et al. A review on empirical mode decomposition in fault diagnosis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2013, 35(1/2): 108-126.
- [7] Lei Y G, He Z J, Zi Y Y. Application of an intelligent classification method to mechanical fault

- diagnosis[J]. *Expert Systems With Applications*, 2009, 36(6): 9941-9948.
- [8] 向宙, 张西宁, 张雯雯, 等. 区分自编码网络及其在滚动轴承故障特征提取中的应用[J]. *西安交通大学学报*, 2019, 53(8): 47-55.
(Xiang Z, Zhang X N, Zhang W W, et al. Discriminative auto-encoding network with applications in fault feature extraction of rolling bearing[J]. *Journal of Xi'an Jiaotong University*, 2019, 53(8): 47-55.)
- [9] Adam Coates, Honglak Lee, Andrew Y Ng. An analysis of single-layer networks in unsupervised feature learning[C]. *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*. Fort Lauderdale, 2011: 215-223.
- [10] 李东东, 王浩, 杨帆, 等. 基于无监督特征学习的行星齿轮箱故障特征提取和检测[J]. *电网技术*, 2018, 42(11): 3805-3811.
(Li D D, Wang H, Yang F, et al. Feature extraction and detection of planetary gear box fault using unsupervised feature learning[J]. *Power System Technology*, 2018, 42(11): 3805-3811.)
- [11] He Q, Zhao J Y, Jiang G Q, et al. An unsupervised multiview sparse filtering approach for current-based wind turbine gearbox fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(8): 5569-5578.
- [12] Ngiam J, Chen Z H, Bhaskar S A, et al. Sparse filtering[C]. *Advances in Neural Information Processing Systems*. Granada, 2011: 1125-1133.
- [13] Lei Y G, Jia F, Lin J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data[J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(5): 3137-3147.
- [14] 何群, 赵婧怡, 江国乾, 等. 基于电流信号稀疏滤波特征融合的齿轮箱故障诊断方法[J]. *电网技术*, 2020, 44(5): 1964-1971.
(He Q, Zhao J Y, Jiang G Q, et al. Current-based gearbox fault diagnosis based on sparse filtering feature fusion[J]. *Power System Technology*, 2020, 44(5): 1964-1971.)
- [15] Qian W W, Li S M, Wang J R, et al. An intelligent fault diagnosis method of rotating machinery using L_1 -regularized sparse filtering[J]. *Journal of Vibroengineering*, 2018, 20(8): 2839-2854.
- [16] Wang J R, Ji S S, Han B K, et al. Intelligent fault diagnosis for rotating machinery using $L_{1/2}$ -SF under variable rotational speed[J]. *Proceedings of the Institution of Mechanical Engineers — Part D: Journal of Automobile Engineering*, 2021, 235(5): 1409-1422.
- [17] Jiang G Q, He H B, Yan J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3196-3207.
- [18] Yu H, Wang K, Li Y. Multiscale representations fusion with joint multiple reconstructions autoencoder for intelligent fault diagnosis[J]. *IEEE Signal Processing Letters*, 2018, 25(12): 1880-1884.
- [19] Gao X R, Yang F, Feng E B. A process fault diagnosis method using multi-time scale dynamic feature extraction based on convolutional neural network[J]. *The Canadian Journal of Chemical Engineering*, 2020, 98(6): 1280-1292.
- [20] 吴静然, 丁恩杰, 崔冉, 等. 采用多尺度注意力机制的旋转机械故障诊断方法[J]. *西安交通大学学报*, 2020, 54(2): 51-58.
(Wu J R, Ding E J, Cui R, et al. A diagnostic approach for rotating machinery using multi-scale feature attention mechanism[J]. *Journal of Xi'an Jiaotong University*, 2020, 54(2): 51-58.)
- [21] Zhao R, Wang D Z, Yan R Q, et al. Machine health monitoring using local feature-based gated recurrent unit networks[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(2): 1539-1548.
- [22] Der Maaten L V, Hinton G E. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(11): 2579-2605.
- [23] Kong D G, Ding C, Huang H. Robust nonnegative matrix factorization using L_{21} -norm[C]. *Proceedings of the 20th ACM International Conference on Information and Knowledge Management*. Glasgow, 2011: 673-682.
- [24] Zhang L, Xiong G L, Liu H S, et al. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference[J]. *Expert Systems With Applications*, 2010, 37(8): 6077-6085.
- [25] Shao H D, Jiang H K, Lin Y, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders[J]. *Mechanical Systems and Signal Processing*, 2018, 102: 278-297.

作者简介

张志强(1993—), 男, 博士生, 从事智能故障诊断的研究, E-mail: zzq2012217637@stu.xjtu.edu.cn;

杨清宇(1974—), 男, 教授, 博士生导师, 从事故障诊断与智能运维等研究, E-mail: yangqingyu@mail.xjtu.edu.cn.

(责任编辑: 李君玲)