

基于深度 SSDAE 网络的刀具磨损状态识别*

郭润兰, 尉卫卫, 王广书, 黄 华

(兰州理工大学机电工程学院 兰州, 730050)

摘要 针对刀具磨损状态识别过程中采集数据量大、干扰信号复杂且需人为选择特征参数的问题,为提高刀具磨损状态识别模型的鲁棒性与泛化性,提出了一种数据驱动下深度堆叠稀疏降噪自编码(stacking sparse denoising auto-encoder,简称 SSDAE)网络的刀具磨损状态识别方法,实现隐藏在数据中深层次的数据特征自动挖掘。首先,将原始振动信号分解为一系列固有模态分量(intrinsic mode function,简称 IMF),并采用皮尔逊相关系数法选取了最优固有模态来组合一个新的信号;其次,采用 SSDAE 网络自适应提取特征后对刀具磨损阶段进行了状态识别,识别精度达到 98%;最后,对网络模型进行实验验证,并与最常用的刀具磨损状态识别方法进行了对比。实验结果表明,所提出的方法能够很好地处理非平稳振动信号,对不同刀具磨损阶段状态的识别效果良好,并具有较好的泛化性能和可靠性。

关键词 深度堆叠稀疏自编码网络;变分模态分解;K-最近邻分类器;自适应特征提取;状态识别
中图分类号 TH164;V262.3⁺³

引 言

作为数控机床的“牙齿”,刀具对加工件的加工质量和加工精度起着至关重要的作用。据统计,机床总停机时间的 20% 源于刀具失效引起的故障停机^[1]。因此,需要一种可靠的刀具磨损状态识别方法,提高刀具加工效率和利用率,减少加工过程中的故障率。

刀具磨损监测依据测量原理可分为直接法和间接法^[2]。间接法具有安装方便、不需要停机检测等优点,成为刀具磨损状态监测的主流。近年来,深度学习因具有“端到端”学习特性,在刀具磨损监测领域深受青睐。Xu 等^[3]利用并行卷积神经网络实现了多尺度特征融合,提出了一种基于深度学习的新方法,提高了刀具磨损的预测精度。Chen 等^[4]将卷积神经网络与双向长短期记忆网络相结合,建立了一种基于整体和局部特征的深度学习方法,提高了刀具磨损预测的准确性。Sun 等^[5]利用加工过程中获得的原始信号,建立了残差卷积神经网络,实现了加工过程中刀具状态监测。郭宏等^[6]在深度卷积神经网络中加入注意力机制,构建了刀具寿命预测模型。吴雪峰等^[7]利用卷积自动编码器对网络模型进行识别,通过 BP 算法结合 Adam 算法对模型参数进行微调,建立了卷积神经网络刀具磨损类型智能识别方法,提高了模型识别率。Li 等^[8]提取振动信号和切削力信号的多域特

征,建立了一种多域特征融合的深度可分离卷积神经网络刀具磨损自动预测方法。上述方法在一定程度上能够有效解决刀具磨损预测问题,但仍然存在以下不足:①实际生产环境中存在各种各样的噪声,上述建模方法均在比较理想的环境中采集刀具磨损信号,采集的信号具有针对性和特殊性,在强噪声的环境中将会失效;②在采用时频分析方法进行特征提取时,因需要人为进行参数的选择,大量参数使得训练过程复杂并产生冗余的信息,使刀具实际磨损状态与网络训练磨损状态产生了偏差。

针对以上问题,笔者提出了一种数据驱动下 SSDAE 的刀具磨损状态识别方法,并加入了正则化作为优化阶段中损失函数的惩罚项,使输出的低维信号在包含原数据本质特征的同时去除高维信号中的干扰部分,最终将训练得到的特征用于分类识别,可自适应提取数据信息,挖掘深层次的数据特征。首先,利用变分模态(variational modal decomposition,简称 VMD)对原始振动信号进行降噪,采用皮尔逊相关系数选取最优 IMF,进一步对选取的 IMF 进行特征提取;其次,应用 SSAEN 对数据集分别进行自适应特征提取,并将提取后的特征应用 K-最近邻分类器进行训练与测试;最后,将模型分类精度与 BP 神经网络(back propagation neural networks,简称 BPNN)、支

* 国家自然科学基金资助项目(52365057, 51965037)

收稿日期:2022-08-05;修回日期:2022-12-20

持向量机(support vector machines,简称SVM)、随机森林(random forest,简称RF)这3种模型精度进行对比,证明该建模方法的有效性和鲁棒性。

1 刀具磨损状态识别模型及理论

刀具磨损状态识别建模分析方式有基于模型的建模方法和基于数据驱动的建模方法^[9],其中基于数据驱动的建模方法是一种高效的分析方法^[10]。笔者提出了一种数据驱动下深度堆叠稀疏降噪自编码网络的刀具磨损状态识别方法,模型框架如图1所示。

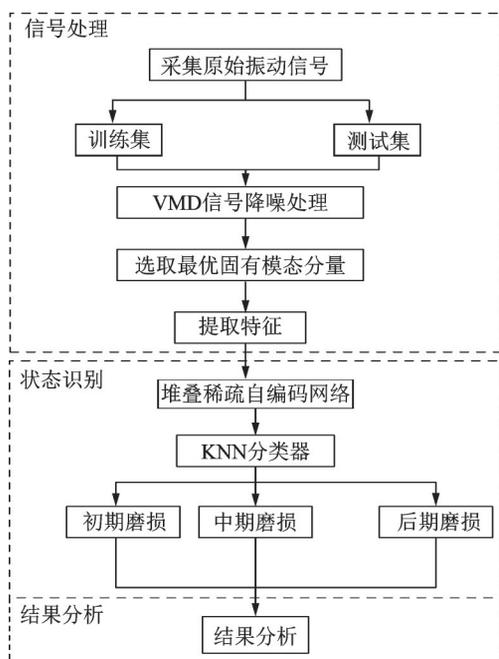


图1 模型框架

Fig.1 Model framework

1) 信号处理阶段:采集铣刀3个方向振动信号,并利用VMD进行降噪处理,采用皮尔逊相关系数法选取最优固有模态,然后提取时域、频域特征。

2) 状态识别阶段:将提取的特征输入网络,训练堆叠稀疏自编码网络;进一步丢弃解码器层,使得隐藏层单元(第1层特征)的激活成为用于训练第2层编码器的输入,从而产生另一个表示(第1层特征);将训练得到的特征输入k-最近邻分类器,对刀具磨损状态进行精确识别。

3) 结果分析阶段:将SSDAE网络自适应特征提取后采用t-SNE降维技术可视化,并将K-最近邻分类器分类识别精度与BP神经网络、支持向量机及随机森林分类识别精度作对比,证明所提方法的可靠性。

1.1 变分模态分解

由于铣削加工过程中利用传感器采集的铣削信号存在大量的噪声,会对刀具磨损状态分析产生影响。VMD是一种新的自适应信号处理方法,对非线性、非平稳信号的处理具有明显的优势。该方法运算效率高,可克服经验模态分解(empirical mode decomposition,简称EMD)中的模态混叠问题,实现信号的准确分离,利用其自身具有的维纳滤波特性可获得更优的噪声滤除效果,所以采用变分模态对采集的原始振动信号进行降噪。

VMD可以将非平稳输入信号 f 分解为 k 个离散的模态 $u_k(k=1,2,\dots,K)$, u_k 在频率中的带宽都具有特定的稀疏属性,是一种具有经典维纳滤波、希尔伯特变换和频率混合这3个概念为基础的变分问题求解方法。其中:维纳滤波用于信号去噪;希尔伯特变换用于构造分析信号以获得单边带频谱;频率混合用来将频谱移到基带。为了获得具有紧凑带宽的模态,并要求所有模态总和能够重构输入信号 f ,构造了以下约束变分问题^[11]

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial(t) \left[\partial(t) + \frac{j}{\pi t} \right] u_k(t) e^{j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$\sum_{k=1}^K u_k(t) = f \quad (2)$$

其中: f 为原始信号; $u_k(t)$ 为模态函数; ω_k 为各个模态中心频率。

为了在高斯白噪声存在的情况下将输入的信号完全分解为 $u_k(t)$ 模态,引入二次惩罚因子 ∂ 和拉格朗日因子 λ ,将约束问题转化为无约束优化问题,用交替方向乘子法进行优化求解。二次惩罚项保证信号的重构精度,而拉格朗日乘子保持约束条件的严格性。

1.2 堆叠稀疏自编码网络

堆叠自编码的基本思想是训练SSDAE网络,使输出的低维信号在包含原数据本质特征的同时去除高维信号中的干扰部分,最终将得到的特征进行分类识别。

1.2.1 3层稀疏自编码网络

自编码网络是一种用于数据降维和特征提取的无监督深度学习网络。图2所示为3层稀疏自编码网络,包含1个输入层、1个隐藏层和1个输出层。

数据集 $X = \{x_1, x_2, \dots, x_n\}$ 由 n 个 x 数据样本组成,隐藏层节点的激活函数 h 可以表示为

$$h = f(W^{(1)}x + b^{(1)}) \quad (3)$$

其中: $W^{(1)}$ 为连接输入层和隐含层的权重; $b^{(1)}$ 为偏

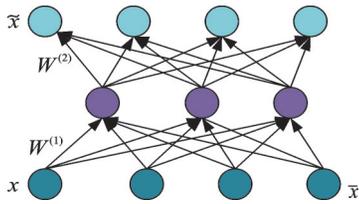


图 2 3 层稀疏自编码网络

Fig.2 Three layer sparse auto-encoder network

差; f 为一个激活函数,笔者采用 sigmoid 函数。

利用隐含层与输出层之间的连接权值,通过隐含层对原始数据进行重构

$$\tilde{x} = f(W^{(2)}h + b^{(2)}) \quad (4)$$

其中: \tilde{x} 为重构数据; $W^{(2)}$ 为隐含层与输出层之间的权值; $b^{(2)}$ 为偏置。

在 SAE 训练中,分别给权重 $W^{(1)}$, $W^{(2)}$ 和偏置 $b^{(1)}$, $b^{(2)}$ 一个初值。在初始设置的情况下,执行前向传递过程计算隐含层的激活,然后在输出层重构数据。对于数据集中的所有数据 $x_i (i=1, 2, \dots, n)$ 计算重构误差,以设计 SAE 网络的总体成本函数,即

$$J(W, b) = \frac{1}{n} \sum_{i=1}^n \left(\frac{1}{2} \|x_i - \tilde{x}_i\|^2 \right) + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)})^2 \quad (5)$$

其中: $J(W, b)$ 为优化变量 W 和 b 的成本函数; n_l 为网络的层数; l 为层序数; s_l 为网络第 l 层节点数; $W_{ji}^{(l)}$ 为连接第 l 层和第 $(l+1)$ 层的所有权值向量。

对于 $n_l=3$ 的情况,图 2 所示的网络中使用 1 个隐藏层,如果 $n>3$ 则包含多个隐藏层。在式(5)中,第 1 项是数据重构的误差,最小化该项可以生成准确的数据表示;第 2 项是正则化,限制权值的幅度并防止网络过拟合。参数 λ 用于调整重构误差和网络权值。

在隐藏层中,数据集上第 j 个节点的平均激活函数表示为

$$\rho_j = \frac{1}{n} \sum h_j(x_i) \quad (j=1, 2, \dots, s_l) \quad (6)$$

其中: s_l 为网络第 l 层隐含层的节点数。

稀疏参数 ρ 用来限制隐含层的激活,第 l 层隐含层中所有节点的总体约束表示为

$$\sum_{j=1}^{s_l} \text{KL}(\rho \| \rho_j) = \sum_{j=1}^{s_l} \rho \log \frac{\rho}{\rho_j} + (1 - \rho) \log \frac{(1 - \rho)}{(1 - \rho_j)} \quad (7)$$

其中: $\text{KL}(\rho \| \rho_j)$ 为 Kullback-Leibler (KL) 散度,通过激活节点来逼近具有该约束的给定稀疏参数。

考虑稀疏约束,将 SAE 的成本函数重写为

$$J_{\text{sparse}}(W, b) = J(W, b) + \beta \sum_{j=1}^{s_l} \text{KL}(\rho \| \rho_j) \quad (8)$$

其中: β 为调整稀疏惩罚和 $J(W, b)$ 的参数。

前向传递处理后,按照式(8)计算 SAE 网络的成本函数。为了最小化成本函数,通过反向传播算法求解 J_{sparse} 对 W 和 b 的偏导数来更新初始权值和偏差。参数更新后,得到一个训练好的 SAE 网络。训练后的 SAE 进行第二轮前向传递,并将隐含层的激活值作为数据降维后提取的特征。

1.2.2 深层稀疏自编码网络

按照对 3 层架构稀疏自编码所述的训练方法,将原始数据集 x 输入到第 1 个 SAE 网络中,即可训练第 1 个 SAE 网络,得到网络权值 $W_1^{(1)}$ 和隐含层输出 h_1 , 下标 1 表示第 1 层 SAE 隐含层,即 SAE₁。以 h_1 为输入,训练第 2 个 SAE₂, 得到其权值 $W_2^{(1)}$ 和隐含层。

生成一系列的 SAE 网络后,通过叠加这些 SAE 网络的隐藏层,构建一个更深层次的 SAE 网络。图 3 所示为深层稀疏自编码网络,由 1 个输入层和 3 个隐含层组成。第 k 层和第 $(k+1)$ 层来自第 k 个 SAE 网络,其中 $k=1, 2, 3$ 。第 k 个 SAE 的隐含层作为第 $(k+1)$ 个 SAE 的输入^[12]。

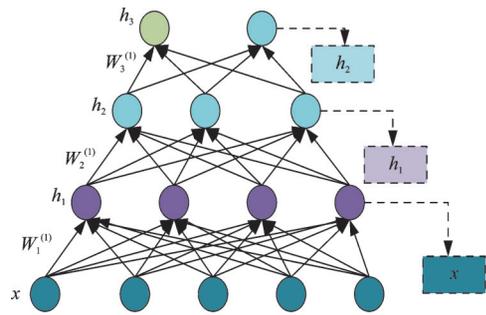


图 3 深层稀疏自编码网络

Fig.3 Deep sparse auto-encoder network

1.3 皮尔逊相关系数

皮尔逊相关系数是用于度量 2 个大小为 N 的变量 A 与 B 之间的相关程度,其值 ρ 介于 -1 与 1 之间。皮尔逊相关系数的计算如下

$$\rho(A, B) = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{A_i - \mu_A}{\sigma_A} \right) \left(\frac{B_i - \mu_B}{\sigma_B} \right) \quad (9)$$

其中: μ_A, σ_A 和 μ_B, σ_B 分别为 A 和 B 的平均值和标准差。

2 实验验证

为了验证笔者所提刀具磨损状态辨识建模方法

的有效性,利用2010年故障预测与健康管理(prognostics health management,简称PHM)数据竞赛上公开的高速铣削刀具磨损数据集进行验证^[13],铣削过程是用一把球头铣刀在长度为108 mm的端面重复铣削315次完成的。图4为信号采集系统示意图。

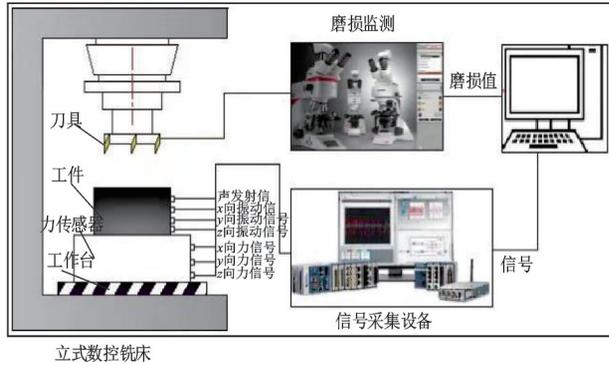


图4 信号采集系统示意图

Fig.4 Schematic diagram of signal acquisition system

铣削实验在Rodgers Tech RFM760立式数控铣床上进行,铣削工件材料为不锈钢HRC52,铣削刀具为三刃球头硬质合金铣刀。实验加工时,每次走刀进给量为0.001 mm,采样频率为50 kHz。实验设备和实验加工参数分别如表1,2所示。

利用Kistler三分量测力计分别采集 x, y, z 方向的铣削力信号,利用Kistler三轴加速度传感器分别

表1 实验设备

Tab.1 Experimental equipment

| 设备 | 型号 |
|--------|---------------------|
| 立式数控机床 | Rodgers Tech RFM760 |
| 力传感器 | Kistler三分量测力计 |
| 振动传感器 | Kistler三轴加速度传感器 |
| 声发射传感器 | Kistler声发射传感器 |
| 放大器 | Kistler电荷放大器 |
| 数采设备 | NI DAQ PCI 1200 |
| 磨损测量设备 | LEICA MZ12 |
| 铣削刀具 | 球头硬质合金铣刀 |

表2 实验加工参数

Tab.2 Experimental processing parameters

| 参数 | 数值 |
|--------------------------------------|----------|
| 主轴转速/($r \cdot \min^{-1}$) | 10 400 |
| 进给速度/($\text{mm} \cdot \min^{-1}$) | 1 555 |
| y 向切削深度/mm | 0.125 |
| z 向切削深度/mm | 0.2 |
| 铣削方式 | 顺铣 |
| 冷却方式 | 干切 |
| 工件材料 | 不锈钢HRC52 |

采集 x, y, z 方向的振动信号,利用Kistler声发射传感器采集铣削过程的高频应力波,总共得到7维传感器信号(x, y, z 铣削力信号; x, y, z 振动信号;声发射信号)。公开数据给出了 C_1, C_4 和 C_6 这3把刀具的全寿命周期的磨损,每把刀具走刀315次,利用显微镜测量刀具3个刃后刀面磨损值,并以三齿刃平均磨损量作为测量铣刀的实际磨损量。

为了尽可能提取到刀具磨损过程中隐含的信号特征,对每次走刀 x, y, z 方向的前16 000个采样点数据进行特征提取。每次走刀振动信号可提取时域特征14个、频域特征6个,总共提取到时域特征和频域特征20个,3个方向共可获得60个特征,并将其作为特征数据集,具体特征指标如表3所示。

表3 特征指标

Tab.3 Characteristic index

| 序号 | 特征名称 | 序号 | 特征名称 |
|----|------|----|-------|
| 1 | 峰峰值 | 11 | 峰值指标 |
| 2 | 方差 | 12 | 脉冲指标 |
| 3 | 均值 | 13 | 裕度指标 |
| 4 | 歪度 | 14 | 峭度指标 |
| 5 | 峭度 | 15 | 均值频率 |
| 6 | 均方值 | 16 | 频谱二阶距 |
| 7 | 方根幅值 | 17 | 标准偏差频 |
| 8 | 均方根值 | 18 | 峭度频率 |
| 9 | 绝对均值 | 19 | 均方根频率 |
| 10 | 波形指标 | 20 | 中心频率 |

3 状态识别

根据刀具磨损的特征,将刀具全寿命周期磨损的过程划分为3个阶段:初期磨损、中期磨损、后期磨损。不同磨损阶段的磨损趋势有较大差异:初期磨损阶段刀具磨损量先急剧后平缓;中期磨损阶段刀具磨损量一直缓慢增加;后期磨损阶段刀具磨损缓慢增加后急剧加快。实际磨损量下的刀具磨损曲线如图5所示。

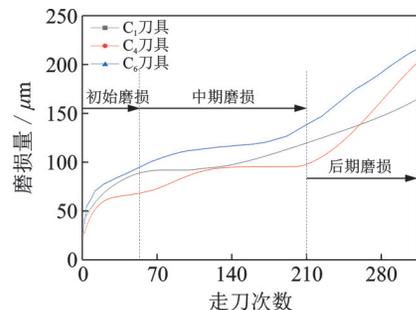


图5 刀具磨损曲线

Fig.5 Tool wear curve

3 个磨损阶段分别用标签 1,2,3 表示。在实验过程中,刀具总走刀次数为 315 次。在本研究中根据刀具全寿命实际磨损曲线将第 1~50 次走刀划分为初期磨损阶段,第 51~200 次走刀划分为中期磨损阶段,第 201~315 次走刀划分为后期磨损阶段,最终每把刀具的磨损阶段划分如表 4 所示。

表 4 磨损阶段划分
Tab.4 Division of wear stages

| 磨损阶段 | 走刀次数 | 磨损标签 | 特征大小 |
|------|---------|------|--------|
| 初期磨损 | 1~50 | 1 | 50×60 |
| 中期磨损 | 51~200 | 2 | 150×60 |
| 后期磨损 | 201~315 | 3 | 115×60 |

3.1 信号处理

在实验过程中,利用传感器采集的信号多为不均匀的非平稳信号,以 C_4 刀具 x 方向振动信号为例,3 个阶段原始信号中含有大量的噪声,对刀具磨损状态识别产生了较大的干扰。VMD 能够自适应处理信号,利用重构信号获得更加优质的降噪信号,因此采用 VMD 将原始振动信号进行降噪处理。

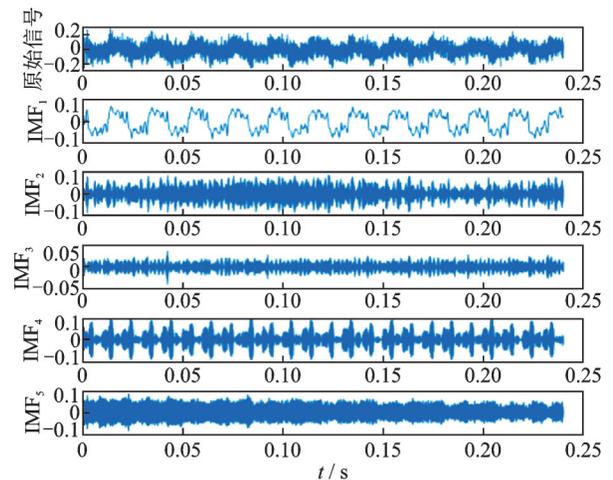
笔者采用中心频率法确定模态分解层数,首先通过选择模态数 $K=2\sim 10$ 进行预分解,当相邻模态的中心频率接近时,被认为过度分解。在这种情况下,最佳分解层数是中心频率接近时前 1 项的 K 值。表 5 为不同 K 值下的中心频率。

表 5 不同 K 值下的中心频率
Tab.5 Center frequency under different K values

| K 值 | 中心频率/Hz | | | | | |
|-------|---------|---------|---------|---------|---------|---------|
| 1 | 25.11 | — | — | — | — | — |
| 2 | 27.2 | 2 970.3 | — | — | — | — |
| 3 | 25.3 | 1 013.4 | 3 224.4 | — | — | — |
| 4 | 24.0 | 861.5 | 2 988.3 | 3 950.8 | — | — |
| 5 | 23.6 | 797.7 | 2 281.7 | 3 190.4 | 3 991.2 | — |
| 6 | 24.2 | 769.6 | 1 304.5 | 2 363.7 | 3 813.4 | 3 996.5 |

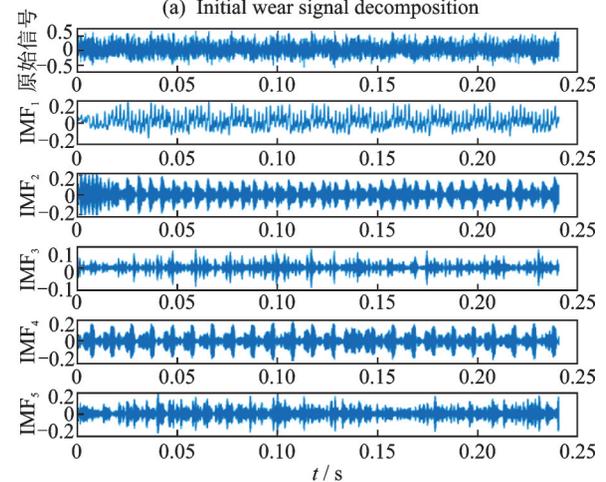
由表 5 可知, $K=6$ 时存在 2 个模态的中心频率 3 813.7 和 3 996.5 Hz,两者十分接近,因此将 $K=5$ 作为 VMD 分解时的预设数。原始振动信号分解如图 6 所示。

因为 C_1, C_4 和 C_6 这 3 把刀具是在相同的条件下进行实验,采集的振动信号具有相似的特征,所以利用 VMD 信号处理时,设置相同的采样点数和分解层数。采样点数为 12 000,原始信号分解为 5 个子序列,每个子序列对应的频率随着频率的增加从 IMF_1 到 IMF_5 。 IMF_1 序列的最低频率反映了原始信



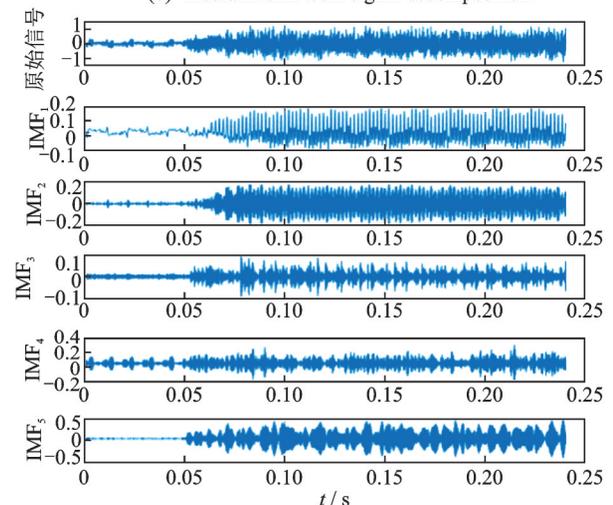
(a) 初期磨损信号分解

(a) Initial wear signal decomposition



(b) 中期磨损信号分解

(b) Medium term wear signal decomposition



(c) 后期磨损信号分解

(c) Later wear signal decomposition

图 6 信号分解

Fig.6 Signal decomposition

号的变化趋势,而 IMF_5 序列的最高频率反映了原始信号的变化趋势。

将初期磨损、中期磨损和后期磨损 3 个阶段振动信号经过 VMD 信号分解后,采用皮尔逊相关系数法选取

最优固有模态分量,经过处理后的信号过滤掉了干扰信号,较原始信号更加平稳均匀。与原始振动信号相比,初期磨损和中期磨损信号比较稳定,而后期磨损信号振幅较大。将选取的最优固有模态分量提取时、频域特征作为堆叠稀疏自编码网络的输入。

3.2 网络结构及参数的设置

将经过选取的最优固有模态分量提取时、频域特征作为SSDAE网络的输入,训练网络和进行状态辨识。在第1个SAE网络结构中,经过反复测试将SAE网络结构输入层的节点数设置为1024,即谱序列的长度。第1层的SAE网络有100个隐含层节点,输出层的节点数为1000,与输入层的节点数一致。在第2层SAE网络结构中,输入层的节点数为100,隐含层的节点数为20,输出层的节点数为100。将这2个网络结构堆叠在一起便可形成一个深层次的堆叠稀疏自编码网络,即此网络结构有2个隐含层,其系数 ρ 均设置为0.01,2个网络模块中设置调整网络权值的参数 λ 分别为0.07和0.01,稀疏度参数分别设置为20和15,堆叠稀疏自编码网络结构参数如表6所示。

表6 网络结构参数

Tab.6 Network structure parameters

| 类型 | 节点数 | ρ | λ | β |
|------|------|--------|-----------|---------|
| 输入层 | 1024 | — | — | — |
| 隐含层1 | 100 | 0.01 | 0.07 | 20 |
| 隐含层2 | 20 | 0.01 | 0.01 | 15 |

3.3 状态可视化

实验数据中,提取 C_1 、 C_4 和 C_6 在3个方向每次走刀160000个振动信号数据,前80000个振动信号为训练集数据,后80000个振动信号为测试集数据。将提取的2个原始信号数据集分别采用VMD降噪,再利用皮尔逊相关系数法选取最优IMF,然后将选取的最优IMF分量提取时域、频域特征,分别形成 60×315 数据特征训练集和数据特征测试集。将经过降噪的数据特征分为2组,一组直接采用t-SNE降维技术可视化,另一组经过堆叠稀疏自编码自适应特征提取后,再采用t-SNE降维技术可视化。未经过堆叠稀疏自编码网络自适应提取特征可视化结果如图7所示。

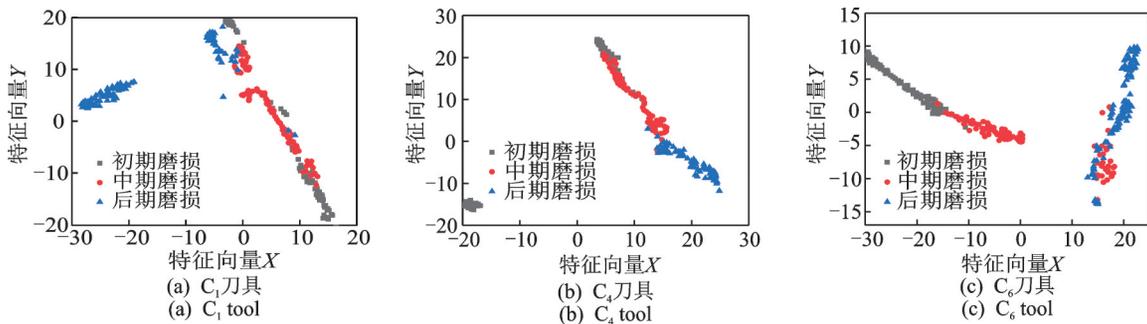


图7 特征提取可视化

Fig.7 Feature extraction visualization

由图7可以看到,未经过堆叠稀疏自编码网络自适应提取特征的可视化效果较差,3个磨损阶段状态混叠,未能将刀具磨损3个状态分离。经过堆叠稀疏自编码网络自适应提取特征的t-SNE降维技术可视化如图8所示。作为无监督学习的方法,堆叠稀疏自编码用于降低特征维数,k-最近邻分类器用于识别刀具磨损状态。堆叠稀疏自编码器包含1个编码器和1个解码器,是一种无监督的神经网络模型,其增加了一定的稀疏性限制,以避免因为大量隐藏层神经元引起的过度拟合,提高了分类任务的性能。

由图8可以看到,刀具初期磨损、中期磨损、后期磨损3个阶段状态均能被很好地分离出来,且3个磨损状态可以很好地聚类,聚类效果明显,这说明堆叠稀疏自

编码网络对刀具磨损状态具有很好的识别效果。用于表示模型识别结果的混淆矩阵如图9所示。

对 C_1 、 C_4 和 C_6 刀具利用笔者所提方法进行状态识别精度混淆矩阵可视化,图9中1~3对应刀具磨损3种不同的状态,纵坐标和横坐标分别表示实际的刀具磨损状态与网络预测的刀具磨损状态。由图9可以看到,振动信号经过降噪,再利用堆叠稀疏自编码网络提取特征,3把刀具的3个状态均能被很好地识别分类,且每个状态的识别精度均在97%以上。对于 C_1 、 C_4 和 C_6 刀具,其 x 、 y 和 z 方向状态识别平均精度分别达到了98%、97.7%和98.3%。整体来说,笔者所提方法对于任何一把刀具都具有较好的适应性能,能够得到良好的状态识别效果。

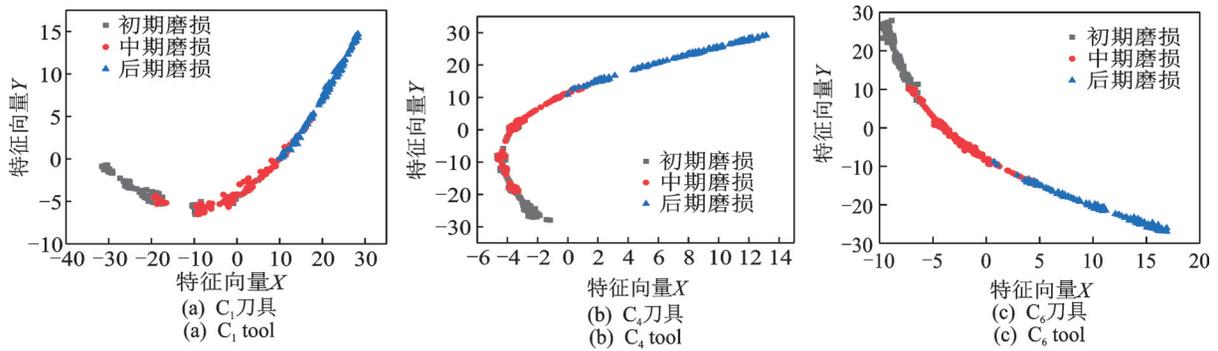


图 8 自适应特征提取信号可视化

Fig.8 Adaptive feature extraction signal visualization

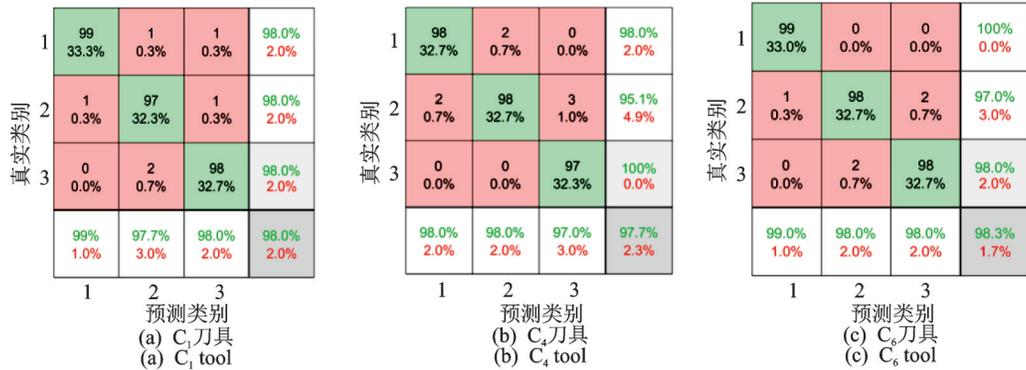


图 9 混淆矩阵

Fig.9 Confusion matrix

3.4 刀具磨损状态识别结果及分析

为了证明笔者所提方法的有效性和鲁棒性,选择常用的分类算法如BPNN,SVM,RF与本研究所提的建模方法作为对比进行实验^[14]。用同样的方法,将经过VMD降噪后的数据采用BPNN,SVM和RF进行状态识别。

分类精度计算公式为

$$A_{cc} = \frac{T_1 + T_2 + T_3}{N} \times 100\% \quad (10)$$

其中: T_1 为正确分类标签1的样本数量, T_2 为正确分类标签2的样本数量; T_3 为正确分类标签3的样本数量; N 为样本总数量。

实验结果表明,上述建模方法与本研究所提方法均能很好地识别刀具磨损状态,精度对比如表7所示。

表 7 精度对比

Tab.7 Accuracy comparison

| 建模方法 | C ₁ | C ₄ | C ₆ | 平均识别精度 |
|-------|----------------|----------------|----------------|---------|
| BPNN | 0.889 0 | 0.869 8 | 0.904 7 | 0.887 8 |
| SVM | 0.898 4 | 0.873 0 | 0.892 1 | 0.887 8 |
| RF | 0.927 0 | 0.854 0 | 0.930 2 | 0.903 7 |
| SSAEN | 0.980 0 | 0.977 0 | 0.983 0 | 0.980 0 |

相比于BP神经网络,C₁,C₄和C₆刀具状态识别精度分别提高了9.10%,10.72%和7.83%。相比于支持向量机,C₁,C₄和C₆刀具状态识别精度分别提高了8.16%,10.4%和9.09%。相比于模糊神经网络,C₁,C₄和C₆刀具状态识别精度分别提高了5.3%,12.3%和5.28%。总体而言,相比于BP神经网络、支持向量机和随机森林,本研究所提方法平均识别精度分别提高了9.22%,9.22%和7.63%。其中:BP神经网络与支持向量机平均识别精度均为88.78%;随机森林平均识别精度为90.37%;笔者所提堆叠稀疏自编码网络平均识别精度高达98%。综上所述,笔者所提方法在实际生产和加工过程中具有更好的实用性和可靠性。

4 结 论

1) 采用VMD对原始振动信号进行降噪,降低了非平稳振动信号的复杂度和非平稳性,产生了与刀具磨损具有强相关性的数据降噪样本,具有鲁棒性,对实际加工生产有指导意义。

2) 构建了SSDAE网络,不仅克服了因样本数据过少、训练网络不具有泛化性的缺点,还可以从大量的信号中挖掘更深层次的数据特征,避免了人为

提取特征过程中信号丢失的问题。实验证明,本研究所提方法刀具磨损状态识别精度高达98%,与常用刀具磨损状态识别方法相比,状态识别精度高出至少7.63%。

3) 所提方法仍然受限于单一工况下的状态识别,在今后的研究过程中,应当考虑在不同工况下的刀具磨损状态识别,提高模型的实际利用率和泛化性能。

参 考 文 献

- [1] 刘辉,张超勇,戴稳.基于堆叠稀疏去噪自动编码网络与多隐层反向传播神经网络的铣刀磨损预测模型[J].计算机集成制造系统,2021,27(10):2801-2812.
LIU Hui, ZHANG Chaoyong, DAI Wen. Milling tool wear prediction model based on stacked sparse denoising automatic coding network and multi-hidden layer back propagation neural network[J]. Computer Integrated Manufacturing Systems, 2021, 27(10): 2801-2812. (in Chinese)
- [2] 谢振龙,岳彩旭,刘献礼,等.基于EMD-SVM的钛合金铣削过程刀具磨损监测[J].振动、测试与诊断,2022,42(5):988-996.
XIE Zhenlong, YUE Caixu, LIU Xianli, et al. EMD-SVM based tool wear monitoring for titanium alloy milling process[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(5): 988-996. (in Chinese)
- [3] XU X W, WANG J W, ZHONG B F, et al. Deep learning-based tool wear prediction and its application for machining process using multi-scale feature fusion and channel attention mechanism[J]. Measurement, 2021, 177:109254.
- [4] CHEN Y W, ZENG Q G, ZHAO D Y, et al. Tool wear prediction using convolutional bidirectional LSTM networks[J]. The Journal of Supercomputing, 2022, 78(12):810-832.
- [5] SUN H B, ZHANG J D, MO R, et al. In-process tool condition forecasting based on a deep learning method[J]. Robotics and Computer-Integrated Manufacturing, 2020, 64:101924.
- [6] 郭宏,任必聪,闫献国,等.基于深度卷积神经网络的刀具寿命动态预测研究[J].控制与决策,2022,37(8):2119-2126.
GUO Hong, REN Bicong, YAN Xianguo, et al. Research on dynamic prediction of tool life based on deep convolutional neural networks[J]. Control and Decision, 2022, 37(8):2119-2126. (in Chinese)
- [7] 吴雪峰,刘亚辉,毕淞泽.基于卷积神经网络刀具磨损类型的智能识别[J].计算机集成制造系统,2020,26(10):2762-2771.
WU Xuefeng, LIU Yahui, BI Songze. Intelligent recognition of tool wear types based on convolutional neural networks[J]. Computer Integrated Manufacturing Systems, 2020, 26(10):2762-2771. (in Chinese)
- [8] LI G F, WANG Y B, WANG J L, et al. Tool wear prediction based on multidomain feature fusion by attention-based depth-wise separable convolutional neural network in manufacturing[J/OL]. [2022-08-03]. <https://doi.org/10.1007/s00170-021-08119-7>
- [9] TAO Z R, AN Q L, LIU G Y, et al. A novel method for tool condition monitoring based on long short-term memory and hidden Markov model hybrid framework in highspeed milling Ti-6Al-4V[J]. The International Journal of Advanced Manufacturing Technology, 2019, 105:3165-3182.
- [10] SUN C, MA M, ZHAO Z B, et al. Deep transfer learning based on sparse autoencoder for remaining useful life prediction of tool in manufacturing[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4):2416-2425.
- [11] CHANG H, GAO F, LI Y, et al. An optimized VMD method for predicting milling cutter wear using vibration signal[J]. Machines, 2022, 10(7):548-566.
- [12] 徐帆,常建华,刘秉刚,等.基于VMD的激光雷达回波信号去噪方法研究[J].激光与红外,2018,48(11):1443-1448.
XU Fan, CHANG Jianhua, LIU Binggang, et al. Research on VMD-based LIDAR echo signal denoising method[J]. Laser & Infrared, 2018, 48(11):1443-1448. (in Chinese)
- [13] QIN Y Y, LIU X L, YUE C X, et al. Tool wear identification and prediction method based on stack sparse self-coding network[J]. Journal of Manufacturing Systems, 2023, 68:72-84.
- [14] 黄华,姚嘉靖,薛文虎,等.基于多域特征联合分布适配的刀具磨损状态识别[J].计算机集成制造系统,2022,28(16):2419-2429.
HUANG Hua, YAO Jiajing, XUE Wenhui, et al. Tool wear status recognition based on multi-domain feature joint distribution[J]. Computer Integrated Manufacturing Systems, 2022, 28(16):2419-2429. (in Chinese)



第一作者简介:郭润兰,女,1963年6月生,教授、硕士生导师。主要研究方向为现代制造技术、故障诊断理论与应用。
E-mail:llggrl@126.com

通信作者简介:黄华,男,1978年8月生,博士、教授、博士生导师。主要研究方向为机械结构健康监测、数控技术与装备。
E-mail:hh318872@126.com