

DOI: 10.20098/j.cnki.1001-5132.2025.0129

基于电机电流信号的多机床运行状态监测

金 汉^{1,2}, 李国富^{1,2*}

(1. 宁波大学 机械工程与力学学院, 浙江 宁波 315211; 2. 宁波大学 先进储能技术与装备研究院, 浙江 宁波 315211)

摘要: 针对离散制造车间中人工记录生产数据无法满足生产制造任务及时安排的问题, 通过分析机床电机电流信号实现机床运行状态监测, 以提高车间智能化水平。基于机床电机电流信号易采集、低成本的特性, 提出一种能够准确识别机床组中运行机床的监测新方法。新方法将灰狼优化算法 (Grey Wolf Optimization, GWO) 与变分模态分解 (Variational Mode Decomposition, VMD) 相结合, 对多机床复合电机电流信号进行频谱重构, 强化特征频段信息, 再搭建 CNN-GRU 神经网络模型完成运动状态分类。结果表明, 此频谱重构方法能够有效强化电流信号中的微弱特征频段, 显著提升模型识别效果, 不仅识别准确率达到 98% 以上, 且具有一定通用性。

关键词: 运行状态监测; 电机电流信号; 门控循环单元; 变分模态分解

中图分类号: TH164

文献标志码: A

文章编号: 1001-5132 (2026) 02-0028-08

Monitoring of multi-machine tool operation status based on motor current signals

JIN Han^{1,2}, LI Guofu^{1,2*}

(1. Faculty of Mechanical Engineering & Mechanics, Ningbo University, Ningbo 315211, China;

2. Laboratory of Advanced Energy Storage and Equipment, Ningbo University, Ningbo 315211, China)

Abstract: Aiming to address the problem that manual recording of production data in discrete manufacturing workshops cannot satisfy the timely scheduling of production tasks, this paper studied the current signal of the machine tool motor to monitor the running state of the machine tool, thereby improving the workshop intelligence. By exploiting the characteristics of easy collection and low cost of motor current signal, a monitoring method was proposed that can accurately identify the running machine tools within a machine tool group. In this method, both Grey Wolf Optimization (GWO) and Variational Mode Decomposition (VMD) were combined to reconstruct the frequency spectrum of the composite motor current signals from multiple machine tools and to enhance the characteristic frequency band information. A CNN-GRU neural network model was established for the classification of the operation status. The experimental results show that this method can effectively enhance the weak characteristic frequency band in the current signal and improve the model's recognition performance. The accuracy rate has shown to exceed 98%, demonstrating a certain level of universality.

Keywords: operation status monitoring; motor current signal; gated recurrent unit; variational mode decomposition

收稿日期: 2025-01-23

宁波大学学报(理工版)网址: <http://journal.nbu.edu.cn/>

基金项目: 国家自然科学基金 (22078164)

第一作者: 金 汉, 硕士研究生, 主要研究方向为机床监测与信号处理。E-mail: jhan54999@163.com

*通信作者: 李国富, 教授, 主要研究方向为制造系统、自动控制和计算机应用。E-mail: lgfdp@nbu.edu.cn

机床作为推动工业生产制造的关键设备,其运行状态和性能对生产效率和产品质量有着直接影响。随着互联网和深度学习的高速发展,一些离散制造企业面对市场个性化产品的快速交付压力(此类企业的产品通常是多品种小批量),致使生产制造计划排产难度较大^[1]。监测机床的运行负载、加工进度等实时信息,可为生产制造计划与制造任务分配提供科学依据,不仅能够帮助生产过程节省大量资源,还有助于提高生产效率,缩短产品交付周期^[2]。由于传统手工记录设备数据的方式存在统计困难、不易形成知识库等问题,设备的可用状态、维修情况和加工进度等信息无法及时传递给生产管理人员^[3]。因此,精确识别机床设备的运行状态,有助于提高企业的综合生产效率和优化生产制造排产,进一步降低企业成本。

目前,机床运行状态监测研究主要通过信号监测与人工记录相结合的方式。通过传感器获取设备信号来分析其具体工作状态,正逐步替代诸多需要人工记录的环节。众多学者也不断提出新方法用于处理不同传感器采集的信号数据。Seemuang 等^[4]对机床工作音频信号滤波与去噪后,使用短时傅里叶变换(Short-Time Fourier Transform, STFT)获取声音频谱,从中获取设备的状态信息,实现对设备进行状态监测,但其采集装置较大,安装位置易影响正常加工操作。此外,电流信号非侵入式的采集方式也受到更多的研究关注。Zou 等^[5]提出一种基于电流信号对车床加工状态进行监测的方法,结合双谱分析法(Modulation Signal Bispectrum, MSB)分析车床的负载转矩对电流幅值和相位调制的影响,证实车床的不同负载状态会在电流信号中产生对应的调制特征,为电流信号监测提供了理论依据,但未涉及具体机床状态的监测与识别。随着大量传感器进一步的应用,需要处理的数据量也在逐渐增大,若能实现一组传感器监测多台机床,不仅能够减少传感器数量,还能降低实时监测的数据运算压力。

为从复杂信号中提取出更多特征,众多学者尝试采用模态分解算法进行信号分析。经验模态分解(Empirical Mode Decomposition, EMD)算法虽具备良好自适应分解能力,但存在明显的模态混叠和端点效应等问题^[6]。集合经验模态分解(Ensemble

Empirical Mode Decomposition, EEMD)、自适应噪声完备集合经验模态分解(CEEMDAN)等改进经验模态分解算法通过加入高斯白噪声方式消除了模态混叠,但也大幅度增加了计算复杂度,不利于大量信号的处理^[7]。Arrieta 等^[8]引入变分模态分解(Variational Mode Decomposition, VMD)对电流信号进行处理,并通过希尔伯特变换提取瞬时特征,证明了使用 VMD 在电流信号特征提取中的可行性。Yan 等^[9]通过采集 5 种不同操作系统的铣床功率信号,使用 AlexCNN 网络模型对功率信号的时频谱进行识别,实现对铣床操作系统的高精度识别,研究结果表明不同型号的机床在功率信号上会表现出一些特别的响应。施莹等^[10]通过采集铣床运行的主轴振动信号,使用深度卷积神经网络(Deep Convolutional Neural Network, DCNN)模型对振动信号的时域特征和频域特征进行识别,实现对铣床空转与加工负载下状态的高精度区分。由于不同机床在结构特征上存在细微差别,并且不同加工状态对转矩的需求都不相同,在多种因素影响下的每台机床均具有自身的独特特征^[11]。

目前多数对机床状态监测的研究中,其监测范围通常多集中在单台机床,需要为每台机床安装一整套传感器设备,导致监测的复杂度和成本较高。本文通过对多机床复合电机电流信号进行分析,并基于灰狼优化算法(Grey Wolf Optimization, GWO)对 VMD 效果进行自适应优化,并提出一种对分解后的信号分量进行加权重构,提高频谱特征信噪比的方法;再结合 CNN-GRU 网络模型对多机床运行状态进行高精度识别,实现一组传感器同时监测多机床在不同组合下的运行状态。

1 电机电流信号监测模型构建

1.1 变分模态分解的参数优化

1.1.1 变分模态分解

VMD 是近年来提出的一种比较新颖的模态分解算法,与经验模态分解的自适应分解相比,VMD 能够将一个复杂信号分解为指定层数的固有模态函数(Intrinsic Mode Functions, IMF),可有效避免分解迭代过程中出现的端点效应和虚假分量等问题,对非平稳信号具有较好的效果^[12]。在 VMD 中,核心是将分解过程转为对变分方程的求解过

程,并且为了寻求变分问题的最优解,通常都会引入惩罚因子 α 、Lagrange算子 λ ,进一步将约束条件下的变分问题转化为非约束变分问题,具体模型如下:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_K u_k(t) \right\rangle \quad (1)$$

式中: u_k 表示每个IMF; ω_k 表示每个IMF中心频率; $f(t)$ 为原始信号; K 为指定分解的IMF个数; ∂_t 为求偏导; $\delta(t)$ 表示冲击函数; j 为虚数单位。

VMD过程使用交替方向算子法对 u_k 、 ω_k 和 λ 的公式进行循环迭代更新,给定一个精度参数 ε ,满足式(2)后则结束循环。

$$\sum_K^{K=1} \left(\frac{\|\hat{u}_K^{n+1} + \hat{u}_K^n\|_2^2}{\|\hat{u}_K^n\|_2^2} \right) < \varepsilon \quad (2)$$

式中: $\hat{u}$ 表示对 u 进行傅里叶变换; n 为迭代次数。

1.1.2 GWO 算法优化 VMD

在VMD的迭代分解过程中,惩罚因子 α 和模态数量 K 共同影响着分解性能。若 K 值设置过大或过小,都会造成分解结果出现模态混叠或者虚假分量;而惩罚因子 α 决定着每个IMF的频率带宽,当其值过大或者过小时,同样会造成不同IMF之间产生频带重叠或者特征信息丢失。在实际分析车床、铣床和钻床等不同类型机床的电流信号时,会发现不同类型的机床电流信号具有不同特点,因此需要在使用VMD时设置不同的参数组合,但是人工经验设置参数往往又不够准确,因此需要通过算法来实现最佳参数的自动设置。

GWO是一种基于种群的启发式算法,具有快速部署、快速求解等优点^[13]。在应用GWO算法优化分解VMD参数组合时,适应度函数的选取直接影响优化算法的性能和优化结果^[14],因此要求确保适应度函数能够反映分解结果是否满足要求。在VMD中,随着IMF数量的增加,越高频段中包含的有效信息会越少,且噪声频率越多。为评估GWO算法在优化过程中是否达到最优解,需引入包络熵

来衡量分解后信号分量中的有效信息量。包络熵能够有效反映信号的非平稳特性,有助于更好地提取机床运行状态的特征信息。机床运行状态的非平稳特性越明显,其包络熵值越大,因此最小化包络熵可以有效降低信号的非平稳特性,从而提高特征提取的准确性。当所有IMF的包络熵之和最小时,即为达到最优分解。因此本文使用最小包络熵作为GWO算法的适应度函数,定义如下:

$$\begin{cases} E_{pM} = \min_{K, \alpha} \left(\frac{1}{K} \sum_{i=1}^K E_p(i) \right) \\ E_p(i) = -\sum_{n=1}^N p_i(n) \log_2 p_i(n) \\ p_i(n) = \frac{a_i(n)}{\sum_{n=1}^N a_i(n)} \end{cases} \quad (3)$$

式中: E_{pM} 为最小包络熵; $E_p(i)$ 为第 i 个IMF的包络熵; $p_i(n)$ 为第 i 个IMF的包络序列; n 为采样点。

基于GWO优化VMD参数具体流程如下:

(1) 初始化GWO的种群数量,设置灰狼个数 N 为30,迭代次数为50;并设置待优化参数 $[K, \alpha]$ 的边界值。

(2) GWO在设置的边界条件内搜索最优值,并将每次迭代得到的 $[K, \alpha]$ 代入VMD中进行分解。

(3) 将GWO每次搜索得到的最优解 α 代入VMD,并对所有的IMF分量计算其包络熵,并更新GWO搜索参数。

(4) 通过迭代次数判断优化过程是否结束,若迭代完成,则返回包络熵最小的 $[K, \alpha]$ 组合。

1.2 VMD 频谱重构

VMD频谱重构(VMD Spectrum Reconstruction, VMDSR)是信号数据经GWO优化VMD参数分解后得到的 K 个IMF进行加权重构。由于每个IMF包含不同频带信息,能够反映不同机床运行状态信息分布在不同IMF中的状况。如果仅用提取特征值法或者部分IMF频谱对机床状态进行识别,效果并不理想,并且会导致计算量激增,造成计算资源浪费。因此还需要对 K 个IMF进行重构,同时还要保留分量中的特征响应。但信号经分解后,会造成较高频段IMF的幅频响应较弱,因此直接重构或归一化都无法更好地表现出较高频段IMF的幅频响应。

为此, 本文提出一种线性权值加权重构方法对 K 个信号分量进行重构。首先对所有 IMF 分量做标准化处理, 将各分量频谱的幅值都映射在 $[0,1]$ 范围内。经标准化后, 每个频谱分量的幅值被统一到同个量级, 但由于此时中高频段的噪声容易淹没相近分量中的幅频信息, 因此引入线性权重 τ (其为线性衰减函数, 定义如式 (4) 所示) 以削弱中高频段的影响。将 IMF 频谱矩阵与线性权重矩阵相乘后, 再将所有加权后 IMF 求和, 即可得到新的特征频谱 $\bar{x}$ 。这种加权重构频谱法在有效突出中高频频段特征信息的同时, 防止高频噪声频谱对其他 IMF 的干扰。其处理流程图如图 1 所示, 转换函数为式 (5) 和式 (6)。




图1 IMF加权重构流程图

$$\tau(i) = (K - i + 1)\eta \quad (4)$$

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

$$\bar{x} = \sum_{i=1}^K x'(i)\tau(i) \quad (6)$$

式中: x' 是对每个 IMF 频谱的归一化频谱; $\bar{x}$ 为加权重构后的信号频谱; τ 为线性权重; η 为衰减率, 文中为常数, $\eta = 0.1$ 。

1.3 CNN-GRU 模型

卷积神经网络 (Convolutional Neural Network, CNN) 及其改进模型在机床监测、刀具寿命预测等领域已取得了显著成果^[15]。作为深度学习中的典型网络, 卷积神经网络是在多层感知机 (Multilayer Perceptron, MLP) 的基础上增加了卷积网络层改进而来^[16]。卷积层通过调节卷积核的大小和数量, 可捕捉特征频谱的特征信息, 卷积过程中以局部连接和权值共享的模式自动提取数据中的局部特征, 并且卷积层计算可以在保留信号特征的同时减少后续计算量, 加快后续网络的计算速度, 提升网络性能, 此特性有助于从特征频谱中提取不同机床状态所对应的特征。

门控循环单元 (Gated Recurrent Unit, GRU) 由循环神经网络 (Recurrent Neural Network, RNN) 演化而来^[17]。由于 RNN 在训练中易出现梯度消失与梯度爆炸问题, 而长短期记忆 (Long Short-Term Memory, LSTM) 网络在 RNN 基础上进行了改进, 可捕捉序列数据的长期依赖关系^[18]。GRU 是 LSTM 改进模型, 将 LSTM 中的 3 个门函数进行优化^[19], 将遗忘门函数和输入门函数合并为一个更新门函数, 有效缓解了 RNN 中梯度消失或爆炸的问题, 相较于 LSTM 网络单元, 参数数量更少, 能有效缩短训练时间, 提高计算性能。GRU 网络基本结构如图 2 所示, 数学模型见式 (7)。




图2 GRU网络

$$\begin{cases} r_t = \sigma(W_r[h_{t-1}, x_t]) \\ z_t = \sigma(W_z[h_{t-1}, x_t]) \\ \tilde{h}_t = \phi(W_h[r_t h_{t-1}, x_t]) \\ h_t = (I - z_t)h_{t-1} + z_t \tilde{h}_t \\ y_t = \sigma(W_o h_t) \end{cases} \quad (7)$$

式中: r_t 为更新门状态; h_{t-1} 为上一时刻的记忆状态变量; x_t 为输入向量; z_t 为重置门状态; $\tilde{h}_t$ 为当前候选集状态; h_t 为当前时刻的记忆状态变量; I 为单位矩阵; y_t 为当前时刻的输出向量; W_r 、 W_z 、 W_h 、 W_o 分别为更新门、重置门、候选集和输出向量的权重矩阵; σ 表示 Sigmoid 激活函数; ϕ 表示 Tanh 激活函数。 σ 与 ϕ 数学表达式如下:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

$$\phi(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

在识别特征频谱序列时, CNN-GRU 模型可以充分利用 CNN 网络的数据特征提取能力以及 GRU 网络对序列数据强大的识别能力实现在多种不同运行组合下对机床的准确识别。在 CNN-GRU 模型

中,一维卷积层中卷积核数量分别设置为 16 和 32,步长 s 为 1,最大池化层步长 s 为 2,GRU 神经元数量设置为 50,全连接层神经元数量分别设置为 50 和 25。将通过 IMF 频谱重构得到的特征频谱作为 CNN-GRU 模型的输入序列,对卷积层进行局部特征的提取,再将卷积后的特征序列输入到 GRU 层中进行训练,最后经全连接层输出分类结果。模型结构如图 3 所示。




图 3 CNN-GRU 模型结构

2 实验验证

2.1 信号采集与预处理

为验证所提新方法的可行性,选择 3 台 CL6132 型车床和 3 台 X8130A 型号铣床进行实验,分别标记为车床 1、车床 2、车床 3 和铣床 1、铣床 2、铣床 3,通过电流信号实现对多机床不同运行组合的识别。在总电源箱处使用霍尔传感器采集每种机床类型的复合电机电流信号,采样频率设置为 50 kHz。采集工况为机床在随机转速下的加工状态,进给速度 0.088 mm/r,背吃刀量 1 mm。数据采集规则如下:单机床独立运行时,每台机床各采集 150 组;双机床组合运行时,每种运行组合数据采集 150 份;三机床组合运行时,每种运行组合数据采集 150 组。具体数据采集情况见表 1。

2.2 特征频谱重构

将采集的定子电流信号数据整理后切片成相同长度的样本,每个样本含 50 000 个采样点。对所

表 1 电流信号数据采集

组别	机床运行组合	样本/个
1	车床 1	150
2	车床 2	150
3	车床 3	150
4	车床 1+车床 2	150
5	车床 1+车床 3	150
6	车床 2+车床 3	150
7	车床 1+车床 2+车床 3	150
8	铣床 1	150
9	铣床 2	150
10	铣床 3	150
11	铣床 1+铣床 2	150
12	铣床 1+铣床 3	150
13	铣床 2+铣床 3	150
14	铣床 1+铣床 2+铣床 3	150

有数据采用 GWO 算法对 VMD 的分解层数 K 和惩罚因子 α 进行寻优,图 4 即为 GWO 对 VMD 寻优的迭代曲线,并最终确定当分解层数 $K=16$,惩罚参数 $\alpha=5973$ 时,GWO 的适应度函数达到最小值,即为车床信号 VMD 的最佳参数组合。




图 4 GWO 算法的迭代曲线

VMD 结果如图 5 所示,由图可见电流信号的主要频谱信息集中在中低频段。将前 8 层 IMF 分量做傅里叶变换得到频谱图后,先将每个频谱归一化,再分别乘以重构权值 τ ,最后通过线性组合得到一个特征频谱,并将其作为 CNN-GRU 网络的序列输入进行识别。

将 VMD 后的信号加权重构后,得到的新特征频谱能使中高频的特征频率更加明显,因此可将该频谱作为 CNN-GRU 网络的输入值,更利于网络学习机床不同状态间的差别。图 6 为车床原始电流信号经 VMD 重构后的频谱对比,可以看出重构前频




图5 VMD处理的IMF分量

谱中只有一个 50 Hz 的明显幅值, 而经分解重构后, 50 Hz 的倍频谐波幅值也更加明显, 并且 500 Hz 以上能够体现不同机床信号差异的频段幅值也得到了加强。为进一步对比该方法的性能, 分别将其与 EMD 及小波重构频谱进行对比, 如图 7 所示; 同时在相同 VMD 条件下, 对比自然指数函数与高斯函数作为权重函数时对频谱加权的影响效果, 如图 8 所示。从图 7 可见, EMD 对电流信号的分解重构难以突出频谱特征。原因是电流信号成分较为复杂, EMD 分解难以避免端点效应和模态混叠, 使重构效果欠佳; 小波分解虽然能够很好地根据频段




图7 不同频谱重构方法对比




图6 频谱重构前后对比




图8 VMD在不同权重函数下的对比

划分分量,但无法将电流信号中主要成分与高频噪声成分进行分离,并且使高频部分的微弱特征难以突出,进而影响分类效果。对图 8 两种非线性权重函数进行分析,显示指数函数在低频段特征响应微弱,高斯函数虽然能有效突出低频段特征,但也同样抑制了高频特征。由于同类型机床的频谱具有相似性,需要依靠多个频段特征进行区分,因此相比之下,线性权重更能兼顾多个频段的分量特征。

2.3 模型识别验证


在 CNN-GRU 模型中设置两层 CNN 网络和节点数量为 50 的 GRU 网络,激活函数采用 ReLU,全连接层为两层,且神经元数量分别为 50、25,输出函数为 SoftMax,学习率设置为 0.001。数据集按 60%作为训练集、40%作为测试集进行划分,每组数据随机重复训练 5 次并记录平均准确率。分别对表 1 中两类机床的 14 种运行组合进行识别,采用混淆矩阵图评估识别分类结果,分类混淆矩阵如图 9 所示。由图可见,基于 3 台机床的复合电流信号对不同运行组合进行识别时,车床和铣床平均准确率分别达到 98%和 97%以上,识别稳定性较好。实验结果证明,本文提出的识别模型能够有效从多机床的复合电流信号中识别出正在运行的对应机床,实现对多台机床的同时监测。

为进一步验证新方法的优越性,将未经重构的频谱和使用频谱重构法在不同模型中进行对比。其中 CNN 模型与图 3 的 CNN 部分采用相同的网络结构;LSTM 模型神经元数量设置为 50,保持与 GRU 神经元数量相同,全连接层设置均与图 3 相同,各模型对比结果见表 2。


表 2 各模型测试结果

分类模型	综合准确率/%	平均用时/s
CNN	80.46	8.5
VMDSR-CNN	90.55	9.3
VMDSR-CNN-LSTM	96.97	17.8
VMDSR-CNN-GRU	98.13	15.1

由表 2 可知,采用 VMD 频谱重构法可以有效突出复合信号中的频谱特征,提高识别准确率。与频谱重构数据集相比,CNN 模型平均准确率不到 81%。在使用 VMD 频谱重构数据集时,VMDSR-CNN 模型的平均准确率有明显提高,但是 CNN 网络计算速度快,平均识别时间最短。VMDSR-CNN-



(a) 车床不同运行组合识别结果



(b) 铣床不同运行组合识别结果

图 9 机床运行组合的识别结果

LSTM 与 VMDSR-CNN-GRU 模型相比,综合准确率差距较小,只差 1.16 百分点,但 VMDSR-CNN-GRU 模型识别效率比 VMDSR-CNN-LSTM 模型高,平均用时降低了 17.9%。

3 结论

针对离散制造车间中每台机床运行状态难以实时监测和数据统计的问题,本文提出一种基于复合电流信号的多机床运行状态快速监测模型,可在不影响车间生产活动前提下,实现对机床运行数据的监测。研究结合灰狼优化(GWO)算法优化变分模态分解(VMD)参数,通过频谱加权重构提取每种机床运行组合的特征频谱,结合 CNN-GRU 模型实现对运行中机床的准确识别。通过车床与铣

床实验验证, 得到以下结论:

(1) 采用 GWO 算法能够对 VMD 参数进行有效的自适应优化, 避免依靠经验设置不当引起的端点效应、模态混叠等问题。

(2) 提出一种将 VMD 处理后的多个 IMF 分量频谱进行重构。通过对不同 IMF 赋予差异化权重, 能有效突出电流信号中频谱特征表现较弱的频段, 提高分类效果, 且搭建的 CNN-GRU 模型更适合处理序列数据, 可进一步提高准确率。

(3) 通过搭建 CNN-GRU 网络模型对特征频谱进行分类识别, 能够更好地学习不同频段之间的特征关联, 更适合处理序列数据, 并进一步提高准确率, 在车床和铣床的多机床识别分类中综合准确率达到 98% 以上。

本文基于电流信号结合深度学习实现了多台机床运行组合状态的监测, 但尚未进一步识别单台机床的负荷状态; 且在更复杂的工业场景中, 干扰因素较多, 如何在多种因素影响下实现对机床运行状态的更精细监测, 仍有待深入研究与验证。

参考文献:

- [1] 李聪波, 曹宝, 吴畏, 等. 基于数字孪生的机械加工车间多级能效监测[J]. 计算机集成制造系统, 2023, 29(6): 2102-2117.
- [2] 刘华一, 鄢萍, 周强, 等. 基于语义网的机床故障诊断知识扩展方法[J]. 计算机集成制造系统, 2020, 26(3): 609-622.
- [3] 刘飞, 刘培基, 李聪波, 等. 制造系统能量效率研究的现状及难点问题[J]. 机械工程学报, 2017, 53(5): 1-11.
- [4] SEEMUANG N, MCLEAY T, SLATTER T. Using spindle noise to monitor tool wear in a turning process[J]. The international journal of advanced manufacturing technology, 2016, 86(9): 2781-2790.
- [5] ZOU Z X, LI C, SHEN G J, et al. Modulation signal bispectrum analysis of motor current signals for online monitoring of turning conditions[J]. Measurement and control, 2024, 57(5): 540-550.
- [6] KALEEM M, GUERGACHI A, KRISHNAN S. Hierarchical decomposition based on a variation of empirical mode decomposition[J]. Signal, image and video processing, 2017, 11(5): 793-800.
- [7] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing[J]. Biomedical signal processing and control, 2014, 14: 19-29.
- [8] ARRIETA PATERNINA M R, TRIPATHY R K, ZAMORA-MENDEZ A, et al. Identification of electro-mechanical oscillatory modes based on variational mode decomposition[J]. Electric power systems research, 2019, 167: 71-85.
- [9] YAN W, LU C X, LIU Y, et al. An energy data-driven approach for operating status recognition of machine tools based on deep learning[J]. Sensors, 2022, 22(17): 6628.
- [10] 施莹, 曾绍坤, 李泓, 等. 基于深度卷积神经网络的机床有效加工状态识别[J]. 军民两用技术与产品, 2020(11): 54-58.
- [11] WU S, LEI W, YU T, et al. Effect of the stiffness of the turntable bearing joint on the dynamic characteristics of the five-axis machine tool rotary system[J]. Machines, 2023, 11(3): 389.
- [12] WANG Q H, WANG L J, YU H T, et al. Utilizing SVD and VMD for denoising non-stationary signals of roller bearings[J]. Sensors, 2021, 22(1): 195.
- [13] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in engineering software, 2014, 69: 46-61.
- [14] 李玉珠, 金永. 基于 CCSO-VMD 的声发射脱粘信号特征提取[J]. 电子测量技术, 2024, 47(19): 96-103.
- [15] WANG H, LIU Z L, PENG D D, et al. Interpretable convolutional neural network with multilayer wavelet for Noise-Robust Machinery fault diagnosis[J]. Mechanical systems and signal processing, 2023, 195: 110314.
- [16] 邓志光, 李政希, 何亮, 等. 基于改进 CWT-CNN 的核电厂传感器故障诊断研究[J]. 核动力工程, 2024, 45(增刊 2): 156-162.
- [17] ZHOU Z X, WANG H, LI Z X, et al. Fault diagnosis of rolling bearing based on deep convolutional neural network and gated recurrent unit[J]. Journal of advanced mechanical design, systems, and manufacturing, 2023, 17(2): 17.
- [18] 李巧君, 郭彛. 基于改进 K 均值聚类的语音情感识别深度学习[J]. 计算机应用与软件, 2024, 41(9): 224-229.
- [19] 盛宇, 李维武, 杨昊奔, 等. 基于 VMD-GRU-Transformer 的电梯轴承故障诊断方法[J]. 机械设计, 2024, 41(11): 178-185.

(责任编辑 章践立)