

DOI:10.3969/j.issn.1001-4551.2022.10.017

基于多过程信号的轧辊磨削表面粗糙度智能预测*

蔡恩磊¹, 王立平^{1,2}, 孙丽荣^{3,4}, 杨金光⁴, 王冬^{2*}, 李学崑²

(1. 电子科技大学机械与电气工程学院, 四川 成都 611731; 2. 清华大学机械工程系, 北京 100084;

3. 轧制技术及连轧自动化国家重点实验室, 辽宁 沈阳 110819; 4. 山东钢铁集团日照有限公司, 山东 日照 276806)

摘要: 由于轧辊磨削表面粗糙度预测困难, 且其预测精度不足, 为此, 笔者提出了一种基于多过程信号的轧辊磨削表面粗糙度智能预测方法。首先, 以砂轮转速、磨削深度、拖板速度和头架转速为变量, 对轧辊进行了全因素磨削实验, 采集了磨削过程中的多过程信号, 即声发射信号、振动信号和主轴电流信号, 测量了磨后轧辊的表面粗糙度; 对信号进行了分段处理, 强化了信号与粗糙度的关联, 并对粗糙度进行了离散化处理, 将回归问题转化为分类问题; 然后, 提取了各类信号在时域和频域上的众多特征值, 并利用主成分分析法 (PCA) 对其进行了特征降维融合, 构建了多种类型的特征输入; 最后, 利用网格搜索法优化了多层感知机 (MLP) 网络, 得到了粗糙度的预测模型, 实现了对轧辊磨削表面粗糙度的智能预测。研究表明: 相较于单信号方案, 多信号方案能够提供更全面、准确的信息; 基于 PCA 的降维融合特征能进一步提高 MLP 网络的预测效果, 其准确率为 78.16%, F1 值为 0.777 6, 平均偏离距离为 0.29。

关键词: 全因素磨削实验; 声发射信号; 网格搜索法; 多过程信号; 降维融合特征; 主成分分析法; 多层感知机网络; 粗糙度预测模型

中图分类号: TH161.14; TG580

文献标识码: A

文章编号: 1001-4551(2022)10-1462-08

Intelligent prediction of surface roughness in roller grinding based on multi-process signals

CAI En-lei¹, WANG Li-ping^{1,2}, SUN Li-rong^{3,4}, YANG Jin-guang⁴, WANG Dong², LI Xue-kun²

(1. School of Mechanical and Electrical Engineering, UESTC, Chengdu 611731, China; 2. Department of Mechanical Engineering, Tsinghua University, Beijing 100084, China; 3. State Key Laboratory of Rolling and Automation, Shenyang 110819, China; 4. Shandong Iron and Steel Group Rizhao Co., Ltd., Rizhao 276806, China)

Abstract: Due to the difficulty in predicting the surface roughness of roll grinding and its insufficient prediction accuracy, an intelligent prediction method of rolling surface roughness based on multi-process signals was proposed. Firstly, with the wheel speed, grinding depth, carriage speed and headstock speed as variables, a full-factor grinding experiment was carried out on the roll, and multi-process signals during the grinding process were collected, namely acoustic emission, vibration and spindle current signals, the surface roughness of the roll after grinding was measured. Then, many eigenvalues of various signals in the time domain and frequency domain were extracted, and feature dimension reduction and fusion were carried out by using principal component analysis (PCA), and various types of feature inputs were constructed. Finally, the multi-layer perceptron (MLP) network was optimized by grid search method, and the prediction model of roughness was obtained, which realizes the intelligent prediction of the surface roughness of roll grinding. The results show that the multi-signal scheme can provide more comprehensive and accurate information than single-signal scheme; the reduced dimensional fusion feature based on PCA can further improve the prediction effect of MLP networks, and the accuracy, F1-score and mean deviation distance are 78.16%, 0.777 6 and 0.29 respectively.

Key words: full-factor grinding experiment; acoustic emission signals; grid search method; multi-process signals; reduced dimensional fusion feature; principal component analysis (PCA); multi-layer perception (MLP) networks; prediction model of roughness

收稿日期: 2022-04-18

基金项目: 国家自然科学基金资助项目 (52105520, 51975319); 北京市自然科学基金资助项目 (3214043)

作者简介: 蔡恩磊 (1996-), 男, 河南信阳人, 硕士研究生, 主要从事机械设计、智能制造方面的研究。E-mail: 1209399337@qq.com

通信联系人: 王冬, 男, 助理研究员, 硕士生导师。E-mail: d-wang@mail.tsinghua.edu.cn

0 引言

轧辊是使金属产生连续塑性变形的直接作用部件。由于轧制中的高温高压作用,轧辊表面磨损严重,需要进行磨削修复。而粗糙度是衡量轧辊表面质量的核心指标,其与轧辊的轧制质量密切相关。

轧辊在磨削后,要对其表面粗糙度进行测量。由于轧辊是大型长轴类零件,测量工作量大,效率不足。针对该问题,笔者开展基于多过程信号的轧辊磨削表面粗糙度智能预测研究,以实现粗糙度的高效准确预测,相关工作对轧辊磨削质量在线监控和磨削效率提升具有重要意义。

轧辊表面粗糙度受众多因素影响,如工艺参数、零部件缺陷、尺寸匹配等,这些因素以非线性且相互耦合的形式影响表面粗糙度,这也使得基于物理模型的表面粗糙度预测方法在实际生产应用中往往效果较差。

随着传感器技术及信号处理方法的快速发展,基于加工过程信号的表面粗糙度预测方法成为了研究热点,其主要包括实验设计、信号采集、模型训练 3 个步骤。

胡仲翔等人^[1]研究了声发射信号下反向传播(back propagation, BP)神经网络的粗糙度预测问题,并以声发射信号的均方根、傅里叶峰值、标准差、方差和斜度作为输入,建立了 BP 神经网络预测磨削表面粗糙度。谭芳芳等人^[2]研究了振动信号下极限学习机(extreme learning machine, ELM)的粗糙度预测,对振动信号进行了特征提取,并利用遗传算法对特征向量及 ELM 神经元个数进行了优化,获得了较高的预测精度。裴宏杰等人^[3]研究了切削力下的粗糙度预测,将肯德尔(Kendall)秩相关系数最大的主切削力均值作为 BP 神经网络的输入,利用科普拉(Copula)分布估计算法对网络进行了优化,以对其表面粗糙度进行预测。龙华等人^[4]研究了声发射信号下支持向量回归(support vector regression, SVR)模型的粗糙度预测,对球墨铸铁磨削中的声发射信号提取了 13 个特征值,利用遗传算法和粒子群算法优化 SVR,以实现磨削表面粗糙度的预测。PAN Y N 等人^[5]研究了振动信号下卷积神经网络(convolutional neural networks, CNN)的粗糙度预测,将粗糙度离散化使得粗糙度预测从回归问题转化为分类问题,通过引入批标准化与神经元失活,提高了其模型的泛化能力。

基于单一信号的粗糙度预测研究虽然在特定场景上取得了一定的效果,但是由于单一信号更易受外界噪声影响,且包含加工信息有限,这就导致了单一信号方案在实际应用中的鲁棒性较弱。

多信号融合方案考虑到不同信号具有不同表征特

性,通过将多种信号进行联合利用,能够获取更加全面、准确的信息,与表面粗糙度的关联会更强,预测稳定性会更优。

潘宇航^[6]研究了磨削力与振动信号作为表征信号的碳化硅表面粗糙度预测问题,利用 PCA 法进行了信号融合,进而使用长短期记忆网络(long short-term memory, LSTM),以实现表面粗糙度的预测。GUO J L 等人^[7]研究了磨削参数、振动信号下,相关向量机(relevance vector machine, RVM)的粗糙度预测,将磨削参数视为静态特征,振动信号的某些特征视为动态特征,使用 RVM 以实现粗糙度的预测。章本毅^[8]研究了排屑钻削表面粗糙度预测问题,以工艺参数及振动信号均方根特征作为输入,利用 BP 神经网络以实现粗糙度的预测。谢楠等人^[9]研究了以振动信号、能耗特征以及工艺参数作为表征的粗糙度预测,利用支持向量机(support vector machine, SVM)以实现表面粗糙度预测,结果发现,特征融合可进一步提升预测精度。PIMENOV D Y 等人^[10]研究了主驱动功率和刀具磨损信息作为模型输入的粗糙度预测,对比了随机森林、MLP 网络以及回归树的预测效果,结果发现,随机森林法的效果最优。GUO W 等人^[11]研究了磨削力、振动和声发射信号作为表征信号的粗糙度预测,并对特征进行了筛选,采用 LSTM 网络对表面粗糙度进行了预测。SEGRETO T 等人^[12]研究了抛光加工的粗糙度预测问题,利用传统统计特征提取方法,以及基于小波包变换的改进特征提取方法,对应变值、声发射以及电流信号进行了特征提取,并对多信号融合特征优于单一信号特征进行了验证。

得益于多种信号对粗糙度进行表征,基于多信号的粗糙度预测方法取得了更好的预测精度,但是现有的研究场景多限于铣削和平面磨削,而对于应用广泛的外圆类磨削粗糙度预测研究较少。外圆磨削加工中磨具与工件同时回转,运动的复杂性使外圆磨削表面粗糙度预测更具难度。

针对上述问题,笔者以轧辊为研究对象进行表面粗糙度预测研究,提出一种基于多过程信号融合的智能预测方法。首先,开展全因素实验采集磨削过程中的振动信号、声发射信号与主轴电流信号,并使用 PCA 法获得降维融合特征,构建 5 种不同的输入,进而利用网格搜索法优化训练 MLP 网络,完成对粗糙度的智能预测。

1 轧辊磨削实验

1.1 实验设计

在轧辊表面粗糙度形成过程中,受到众多因素影

响,其中可控因素主要为磨削工艺参数。针对实际磨削中,常通过改变磨削工艺参数来获取理想表面质量的情况,在综合考虑实验成本和数据区分度后,笔者设计了混合全因素实验。

实验方案如表 1 所示(共计 144 组实验)。

表 1 实验方案

砂轮转速 /(r · min ⁻¹)	磨削深度 /μm	头架转速 /(r · min ⁻¹)	拖板速度 /(mm · min ⁻¹)
550	0	60	900
700	2	70	1 050
850	3.5	80	1 200
1 000	5	—	—

1.2 实验平台及测量设备

磨削平台 MKT8445 型轧辊磨床如图 1 所示。



图 1 MKT8445 型轧辊磨床

MKT8445 主要参数如表 2 所示。

表 2 MKT8445 参数

参数名称/单位	参数范围	参数名称/单位	参数范围
加工直径 /mm	50 ~ 450	头架转速 /(r · min ⁻¹)	< 150
拖板速度 /(mm · min ⁻¹)	< 2 000	砂轮转速 /(r · min ⁻¹)	< 1 200
磨削长度 /m	< 4	加工质量 /t	< 3

砂轮选用白刚玉砂轮,砂轮主要参数如表 3 所示。

表 3 砂轮主要参数

外径/mm	磨粒	粒度	硬度	结合剂	宽度/mm
404	白刚玉	150#	E	树脂	60

轧辊为箔轧工作辊,轧辊材料为 92CrMo,其表面硬度达 70 HSD,加工长度为 1 480 mm,初始直径为 244 mm。

笔者选定声发射信号、振动信号和主轴电流信号作为粗糙度的表征信号。

其中,声发射传感器采用 WG-50 谐振传感器,声发射传感器通过磁吸式夹具固定在砂轮端盖位置,用以采集砂轮与轧辊接触产生的声发射信号。

WG-50 谐振传感器主要参数如表 4 所示。

表 4 WG-50 主要参数

频率范围/kHz	谐振范围/kHz	使用温度/℃	防护等级
100 ~ 1 000	150	- 20 ~ 120	IP66

振动传感器为 356A14 型三轴加速度传感器,其具有磁吸底座,使用便捷。加速度传感器吸附在左右托瓦侧面,共计 2 个,用以采集加工过程中支撑部件的振动信号。

356A14 振动传感器主要参数如表 5 所示。

表 5 356A14 主要参数

频率范围 /Hz	测量范围 /g	灵敏度 /(mV · g ⁻¹)	谐振频率 /kHz
0.5 ~ 5 000	± 50	100	≥ 25

实验磨床采用自主研发的数控系统,配备有砂轮主轴电流采集功能。实验电流信号由机床系统自动读取保存。磨削结束后采用 SurfTest-SJ210 型便携式粗糙度仪进行粗糙度测量。

SurfTest-SJ210 粗糙度仪主要参数如表 6 所示。

表 6 SurfTest-SJ210 主要参数

分辨率 /μm	测量范围 /μm	平移范围 /mm	测针半径 /μm	针尖角度 /(°)
0.002	360	12.5	2	60

由于所磨削轧辊属于大型长轴类零件,因此,笔者在进行粗糙度测量时,以 200 mm 为间隔,在轧辊轴向 6 个点位进行测量,且每个点位在测量时,以 90° 为间隔旋转轧辊,采用 4 个相位的粗糙度均值作为该点位最终粗糙度。

1.3 实验数据预处理

基于全因素实验结果,即使在同一组工艺参数下,轧辊不同位置的粗糙度值也存在较明显差异,最大值超过了 0.6 μm,因此,将单一位置的粗糙度值或多位置均值作为轧辊表面粗糙度是不合理的。

针对上述问题,笔者将采集的信号与粗糙度测量位置进行对应划分,即保留每个测量位置前后共计 2 s 的信号长度,作为与该位置表面粗糙度对应的信号,强化信号与粗糙度的关联性;144 组全因素实验信号分割后,共可得到 144 × 6 = 864 组数据,为后续预测模型训练提供数据支撑。

笔者对采集到的 864 组数据进行了初步分析。粗糙度累计占比如图 2 所示。

由图 2 可知:粗糙度在 0.3 μm 以内的样本占比超过 89.5%,占绝大多数,而粗糙度大于 0.4 μm 的情况极少出现,因此,粗糙度分布不平衡。




图2 粗糙度累计占比

针对上述分布情况,笔者以 $0.1 \mu\text{m}$ 为区间长度对粗糙度进行离散化处理,将粗糙度预测由回归问题转化为分类问题;同时,考虑到大于 $0.4 \mu\text{m}$ 的粗糙度数量较少,且在实际磨削中当轧辊表面粗糙度大于 $0.4 \mu\text{m}$ 时属于明显不合格,故将大于 $0.4 \mu\text{m}$ 的粗糙度视作一个类别。

粗糙度离散类别数量如图3所示。




图3 粗糙度离散类别数量

2 粗糙度关联特征提取

2.1 小波包降噪

在数据采集过程中,由于传感器易受到各类环境因素的干扰,采集信号中不可避免地混合了不易区分的噪声成分,而噪声信号通常具有高频特性。

小波包分析是一种信号时频域分析方法,通过将时频平面进行更为细致的划分,解决了小波分析在高频信号区域分辨率较低的问题。此外,小波包分析还引入了最优基函数选择的概念,可以根据不同频带信号的具体特征,自适应地选取最佳基函数,进而提高信号的分析能力。因此,基于小波包的阈值降噪方法适合于信号的噪声去除。

笔者利用软硬折中法进行降噪,其表达式为:

$$w_{\text{new}} = \begin{cases} \text{sgn}(w)(|w| - \alpha\lambda), & |w| \geq \lambda \\ 0, & |w| < \lambda \end{cases} \quad (1)$$

式中: w —原始信号幅值, g ; w_{new} —转换后的幅值, g ; $\text{sgn}(\cdot)$ —符号函数; α —调整系数, $0 < \alpha \leq 1$; λ —阈值, g 。

其中:

$$\lambda = \frac{\text{mid}(w)}{0.6745} \sqrt{2 \log(n)} \quad (2)$$

式中: n —信号长度; $\text{mid}(\cdot)$ —计算中位数函数。

笔者以左侧托瓦 x 方向振动信号为例,对其进行傅里叶变换,其频谱图如图4所示。




图4 频谱图

从图4可以观察到:在高频部分存在较明显的分量,这表明信号中存在相应的高频噪声。

针对上述信号,笔者进行小波包降噪处理,具体参数设置为“db5”小波基与5层分解。

基于小波包降噪效果如图5所示。




图5 基于小波包降噪效果

由图5可知:高频噪声得到了有效去除,并保留了信号的主要变化趋势。

笔者进一步对其他磨削过程中采集的振动信号和声发射信号,均采用该方法进行降噪;此外,由于主轴电流信号变化相对平缓,在高频部分的幅值较小,故无需对主轴电流信号进行降噪处理。

2.2 时频域特征提取

实验中的各类信号均在时域中保存,可以直接观察到信号幅值的瞬时及连续变化情况,具有直观的特点。但由于轧辊磨削是典型的多道次加工,时间较长,且传感器采样频率较高,造成时域数据的原始维度过大,不宜处理,且信息密度低。因此,需要利用统计学方法提取信号的时域特征。

设信号形式为 $\{x_i, i = 1, 2, 3, \dots, n\}$,笔者首先提取如下有量纲时域特征,其中:

(1) 最小值为:

$$x_{\min} = \min(x_i) \quad (3)$$

(2) 最大值为:

$$x_{\max} = \max(x_i) \quad (4)$$

(3) 平均值为:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (5)$$

(4) 峰峰值为:

$$x_p = x_{\max} - x_{\min} \quad (6)$$

(5) 绝对平均值为:

$$x_{\text{am}} = \frac{1}{n} \sum_{i=1}^n |x_i| \quad (7)$$

(6) 方差为:

$$x_{\text{var}} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (8)$$

(7) 标准差为:

$$x_{\text{std}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (9)$$

(8) 峭度为:

$$x_{\text{ku}} = \frac{1}{n-1} \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{x_{\text{std}}^4} \quad (10)$$

(9) 偏度为:

$$x_{\text{sk}} = \frac{1}{n-1} \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{x_{\text{std}}^3} \quad (11)$$

(10) 均方根为:

$$x_{\text{rms}} = \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} \quad (12)$$

同时,提取如下无量纲特征,其中:

(1) 波形因子为:

$$S = \frac{x_{\text{rms}}}{\frac{1}{n} \sum_{i=1}^n |x_i|} \quad (13)$$

(2) 峰值因子为:

$$C = \frac{x_p}{x_{\text{rms}}} \quad (14)$$

(3) 脉冲因子为:

$$S = \frac{x_p}{\frac{1}{n} \sum_{i=1}^n |x_i|} \quad (15)$$

(4) 裕度因子为:

$$L = \frac{x_p}{\left(\frac{1}{n} \sum_{i=1}^n |x_i|^{\frac{1}{2}} \right)^2} \quad (16)$$

在轧辊磨削过程中,各类信号不仅仅会在时域上产生变化,在频率分布上同样会产生变化,因此,除时

域特征外,还需要提取相应的频域特征。

假设时域信号经离散傅里叶变换后,其各谐波分量集合为 $\{(f_i, p_i), i = 1, 2, \dots, N\}$, 其中, (f_i, p_i) 表示第 i 组谐波分量的频率和幅值。

笔者进一步提取如下频域特征,其中:

(1) 平均频率为:

$$\bar{f} = \frac{1}{N} \sum_{i=1}^N f_i \quad (17)$$

(2) 重心频率为:

$$f_c = \frac{\sum_{i=1}^N f_i p_i}{\sum_{i=1}^N p_i} \quad (18)$$

(3) 频率均方根为:

$$f_{\text{rms}} = \left(\frac{\sum_{i=1}^N f_i^2 p_i}{\sum_{i=1}^N p_i} \right)^{\frac{1}{2}} \quad (19)$$

(4) 频率标准差为:

$$f_{\text{std}} = \left(\frac{\sum_{i=1}^N (f_i - f_c)^2 p_i}{\sum_{i=1}^N p_i} \right)^{\frac{1}{2}} \quad (20)$$

2.3 表面粗糙度特征降维融合

在对每个信号提取时域和频域特征后,各表面粗糙度值对应的信号具有 144 个特征。众多的特征能够帮助研究人员从多个角度对粗糙度进行建模,但是并非所有的特征都与表面粗糙度具有强关联性,且特征与特征之间也存在冗余关系。此外,过多的输入会增加模型的复杂度,进而导致模型训练困难甚至失败。

为了去除多特征向量中与表面粗糙度关联性较差或冗余的特征,笔者进一步采用主成分分析法^[13]对主轴电流、振动、声发射 3 类信号的特征进行降维融合。

主成分分析结果如图 6 所示。




图 6 主成分分析结果

下方浅灰色部分表示单个主成分的独立贡献率,上方黑色折线表示累计贡献率。

从图 6 中可以看到:虽然原始特征众多,共计 144

项,但大量特征贡献率极低;而前 13 项主成分的累计贡献率达 91.92%,超过 90%。

由此可见,若将过多的低贡献率特征作为模型的输入,会导致模型复杂度增加且训练困难。故笔者选取前 13 项主成分进行特征降维,降维后的特征矩阵大小为 864×13 。

3 基于 MLP 网络的粗糙度预测

3.1 MLP 网络

三层 MLP 网络^[14]如图 7 所示。




图 7 三层 MLP 网络

图 7 中,输入层有 d 个神经元,隐藏层有 q 个神经元,输出层有 l 个神经元。

MLP 网络的前向传播过程可表示为:

$$h_i = f_h \left(\sum_{i=1}^d w_i x_i \right) \quad (21)$$

$$y_i = f_o \left(\sum_{i=1}^q v_i y_i \right) \quad (22)$$

式中: $x_i (i = 1, 2, \dots, d)$ —MLP 输入; $h_i (i = 1, 2, \dots, q)$ —隐藏层输出; $y_i (i = 1, 2, \dots, l)$ —输出层输出; v —输入层与隐藏层的权重参数; w —隐藏层与输出层的权重参数; f_h —隐藏层激活函数; f_o —输出层激活函数。

损失函数计算式为:

$$\text{loss} = - \sum_{i=1}^l y_i \log(\hat{y}_i) \quad (23)$$

式中: $\hat{y}_i (i = 1, 2, \dots, l)$ —样本对应的实际标签; loss —网络的损失。

为达到损失最小的目标,此处的反向传播算法采用梯度下降策略,以损失的负梯度方向对网络的训练参数进行更新,其表达式如下:

$$\Delta w = -\eta \frac{\partial \text{loss}}{\partial w} \quad (24)$$

$$\Delta v = -\eta \frac{\partial \text{loss}}{\partial v} \quad (25)$$

式中: η —学习率; Δw —参数 w 调整量; Δv —参数 v 调整量。

在得到可训练参数的更新量后,即可利用优化器对其更新,待模型的损失稳定或达到预设终止条件,便可停止训练并保存模型,之后利用训练好的模型,在测试集上进行预测评价。

3.2 模型调优

MLP 网络具有结构简洁,可调节参数较少的优点,在本数据集下一个轮次训练仅耗时几秒。为取得最好的预测效果,笔者在 MLP 网络的训练中,采用网格搜索法^[15]进行最优参数搜索。网格搜索法会穷举在设定区间内参数的所有可能,从而找到所有参数中效果最好的参数。

网格搜索方法下的 MLP 网络训练流程为:

- (1) 将数据集划分为训练集和测试集;
- (2) 设定训练参数取值范围;
- (3) 利用训练集和参数范围内的某一参数对 MLP 网络进行训练得到预测模型;
- (4) 计算预测模型的误差;
- (5) 重复 Step3、Step4 完成所有参数组合训练得到最优模型;
- (6) 利用最优模型得到测试集评价结果。

该研究中 MLP 网络采用三层结构,网络训练中的可调节选项包括:隐藏层神经元个数、批大小、训练轮次、隐藏层激活函数以及优化器。

MLP 网络的网格搜索参数设置如表 7 所示。

表 7 MLP 网络的网格搜索参数设置

参数	取值范围	步距
隐藏层神经元个数	[2, 32]	1
批大小	[1, 32]	2
训练轮次	[1, 100]	1
隐藏层激活函数	[Sigmoid, Tanh, Relu]	—
优化器	[sgd, adam]	—

3.3 评价指标

在预测模型输出粗糙度结果后,需要对模型性能进行评价。该实验中采用准确率 (Accuracy) 与 F1 值 (F1-score) 作为模型的评价指标。

此外,针对该分类问题中类别与类别之间的距离具有实际物理意义,笔者提出考虑类间偏离距离的评价指标—平均偏离距离 (mean deviation distance, MDD),该指标用于衡量模型的预测类别与样本实际类别的平均偏离程度,其计算式为:

$$\text{MDD} = \frac{1}{n} \sum_{i=1}^n |l_{i,p} - l_{i,r}| \quad (26)$$

式中: $l_{i,p}$ —第 i 样本对应的实际标签; $l_{i,r}$ —第 i 个样本对应的预测标签; n —样本总数。

3.4 实验结果分析

为了验证 PCA 方案的有效性,并与单一信号输入结果进行对比,笔者构建了 5 种输入,即:单一信号特征输入(3 种)、多信号特征直接拼接输入以及 PCA 降维融合输

入。864 组样本按照 9 : 1 划分得到训练集和测试集。

笔者在训练集上使用网格搜索法,得到各模型的最优参数,并利用测试集对各模型进行验证,预测结果如图 8 所示。

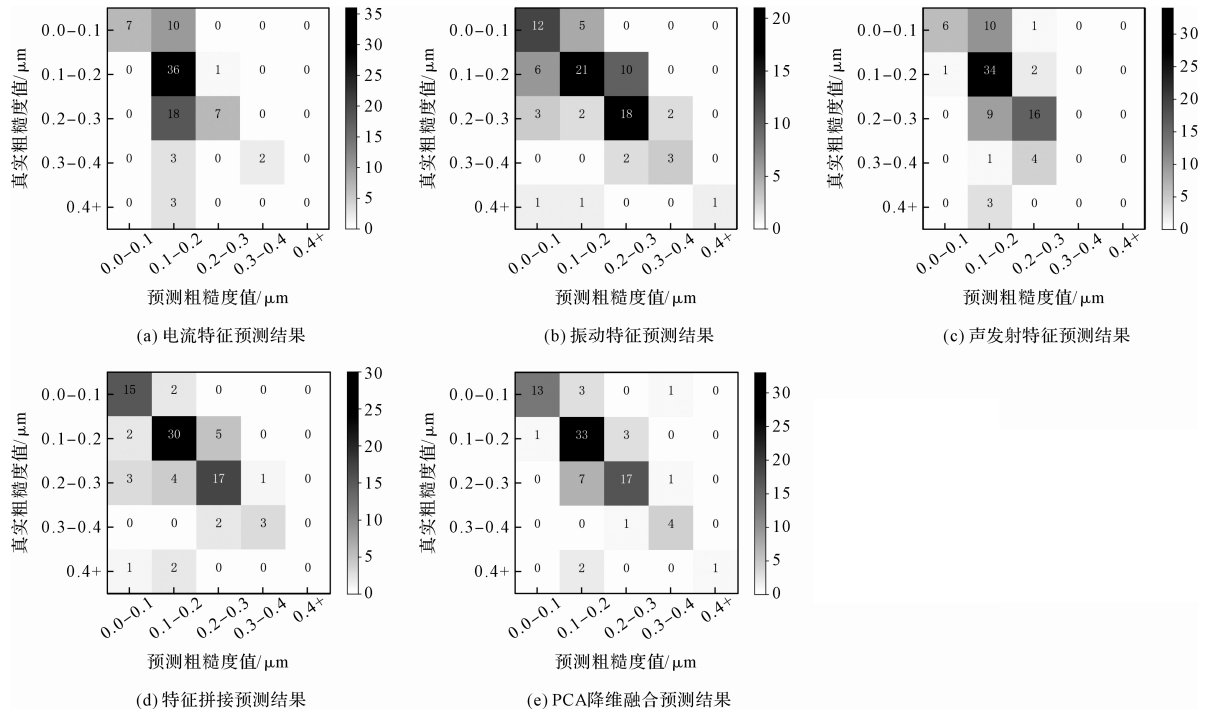


图 8 预测结果

评价指标对比结果如表 8 所示。

表 8 评价指标对比结果

输入类型	准确率/%	F1-score	平均偏离距离
主轴电流信号	59.77	0.554 9	0.51
振动信号	63.22	0.630 7	0.46
声发射信号	64.37	0.596 9	0.45
特征拼接	74.71	0.732 2	0.37
PCA 降维融合	78.16	0.777 6	0.29

对比 3 种单一信号实验结果可知:在准确率和平均偏离距离指标上,声发射信号最优,其次为振动信号,主轴电流信号最差。

通过对比直接拼接特征、PCA 降维融合特征与单一信号特征的实验结果,说明了特征融合的有效性。同时,利用 PCA 降维融合特征训练得到的 MLP 模型在各项指标下均为最优。

在 PCA 降维融合特征下,某样本的实测粗糙度值为 $[0.1, 0.2] \mu\text{m}$, 其预测概率分布为 $[0.014 21, 0.918 37, 0.059 16, 0.008 13, 0.000 12]$, 概率向量第二位最大表示预测粗糙度为 $[0.1, 0.2] \mu\text{m}$, 同时概率值超过 0.9。

4 结束语

由于轧辊磨削表面粗糙度预测困难,且预测精度

不足,为此,笔者提出了一种基于多过程信号的轧辊磨削表面粗糙度智能预测方法。

首先,笔者通过全因素实验采集到了多过程信号数据,提取出了原始信号大量时域、频域特征,然后利用主成分分析法(PCA)对其进行了特征降维融合,构建了多种类型的特征输入,利用网格搜索法优化了多层感知机(MLP)网络,最后实现了对轧辊磨削表面粗糙度的智能预测。

研究结论如下:

(1) 单信号特征中,声发射信号取得最优结果,其次为振动信号特征,主轴电流信号特征最后。单一信号的效果排序为有限条件下选取最优表征信号提供了支撑;

(2) 直接拼接特征与 PCA 降维融合特征实验结果均优于单一信号特征,并且 PCA 降维融合特征结果最优,证明了 PCA 降维融合方法联合 MLP 神经网络的有效性;

(3) 某样本粗糙度预测概率中真实类别概率超过 0.9,说明该模型对于预测结果具有较高的确信度和适用性。

在后续的研究中,笔者将采用深度学习技术,实现对多信号表征下轧辊磨削表面粗糙度进行预测。

参考文献 (References):

- [1] 胡仲翔,滕家绪,钱耀川,等. 用声发射信号和改进的 BP 神经网络预测磨削表面粗糙度[J]. 装甲兵工程学院学报,2009,23(6):76-79.
- [2] 谭芳芳,朱俊江,严天宏,等. 基于 GA-WPT-ELM 的 6061 铝合金表面粗糙度预测[J]. 浙江大学学报:工学版,2020,54(1):40-47.
- [3] 裴宏杰,陈钰莹,李公安,等. 基于 Copula EDA 优化 BP 神经网络的表面粗糙度预测[J]. 江苏大学学报:自然科学版,2020,41(3):366-372.
- [4] 龙华,朱奇,郭力,等. 球墨铸铁磨削表面粗糙度的声发射智能预测研究[J]. 机电工程,2021,38(8):1076-1080.
- [5] PAN Y N, KANG R K, DONG Z G, et al. On-line prediction of ultrasonic elliptical vibration cutting surface roughness of tungsten heavy alloy based on deep learning[J]. **Journal of Intelligent Manufacturing**,2020,33(3):675-685.
- [6] 潘宇航. 考虑时变特性的磨削表面粗糙度预测方法研究[D]. 大连:大连理工大学机械工程学院,2021.
- [7] GUO J L. Surface roughness prediction by combining static and dynamic features in cylindrical traverse grinding[J]. **International Journal of Advanced Manufacturing Technology**,2014,75(5-8):1245-1252.
- [8] 章本毅. 基于工艺参数和监测信号特征的排屑钻削表面粗糙度预测[D]. 湘潭:湘潭大学机械工程学院,2017.
- [9] 谢楠,周俊峰,郑蓓蓉. 考虑能耗的多传感器融合加工表面粗糙度预测方法[J]. 表面技术,2018,47(9):240-249.
- [10] PIMENOV D Y, BUSTILLO A, MIKOLAJCZYK T. Artificial intelligence for automatic prediction of required surface roughness by monitoring wear on face mill teeth[J]. **Journal of Intelligent Manufacturing**,2018,29(5):1045-1061.
- [11] GUO W, WU C, DING Z, et al. Prediction of surface roughness based on a hybrid feature selection method and long short-term memory network in grinding[J]. **The International Journal of Advanced Manufacturing Technology**,2021,112(9):2853-2871.
- [12] SEGRETO T, KARAM S, TETI R. Signal processing and pattern recognition for surface roughness assessment in multiple sensor monitoring of robot-assisted polishing[J]. **International Journal of Advanced Manufacturing Technology**,2016,90(1-4):1023-1033.
- [13] 唐向红,刘国凯,陆见光,等. 铣削表面粗糙度在线智能预测方法研究[J]. 组合机床与自动化加工技术,2017(8):68-72.
- [14] McCulloch W S, PITTS W. A logical calculus of the ideas immanent in nervous activity[J]. *Bulletin of Mathematical Biophysics*,1943,5(4):115-113.
- [15] 马良玉,赵尚羽,孙佳明,等. 基于网格搜索优化 ERF 模型的风电机组异常状态预警[J]. 热能动力工程,2022,37(2):160-166.

[编辑:李辉]

本文引用格式:

蔡恩磊,王立平,孙丽荣,等. 基于多过程信号的轧辊磨削表面粗糙度智能预测[J]. 机电工程,2022,39(10):1462-1469.

CAI En-lei, WANG Li-ping, SUN Li-rong, et al. Intelligent prediction of surface roughness in roller grinding based on multi-process signals[J]. *Journal of Mechanical & Electrical Engineering*, 2022,39(10):1462-1469. 《机电工程》杂志:<http://www.meem.com.cn>

(上接第 1439 页)

- [8] 王观石,郭媛,胡世丽,等. 岩石粘性系数的测试方法[J]. 地球物理学进展,2014,29(5):2411-2415.
- [9] XU Cheng, CHEN Wen-su, HAO Hong, et al. Experimental and numerical assessment of stress wave attenuation of metaconcrete rods subjected to impulsive loads[J]. **International Journal of Impact Engineering**,2021,159:743-748.
- [10] 李足. 振动加载辅助成形机理及其用于非晶基复合材料的制备[D]. 武汉:华中科技大学材料学院,2020.
- [11] 王礼立. 应力波基础教程[M]. 北京:国防工业出版社,2005.
- [12] 郑翔,高建和,杨福俊,等. DICM 在发动机模态参数识别中的试验研究[J]. 振动. 测试与诊断,2010,30(3):280-285,339-340.
- [13] 谭登洪,余虎. 粘弹性阻尼材料在减振降噪中的应用研究[J]. 船电技术,2015,35(2):63-66.
- [14] ZHAN GJu-sheng. Study on polyurethane/(viny ester resin) IPN damping materials[J]. **Materials Science and Technology: English Edition**,2003(z1):56-58.
- [15] HAN Zhen-yu, LI Di-yuan, ZHOU Tao, et al. Experimental study of stress wave propagation and energy characteristics across rock specimens containing cemented mortar joint with various thicknesses[J]. **International Journal of Rock Mechanics and Mining Sciences**,2020,131(C):1365-1609.
- [16] 尹航,杨国标,池瑛斌,等. 界面上应力波传播规律的动态光弹性试验研究[J]. 力学季刊,2015,36(1):55-61.
- [17] ZHANG Hou-jiang, WANG Xi-ping, SU Juan. Experimental investigation of stress wave propagation in standing trees[J]. **Holzforschung**,2011,65(5):54-65.

[编辑:李辉]