

表面质量控制及检测

考虑能耗的多传感器融合加工
表面粗糙度预测方法谢楠^{1a}, 周俊锋^{1b}, 郑蓓蓉²(1. 同济大学 a. 中德工程学院 b. 机械与能源工程学院, 上海 201804;
2. 温州大学 机电工程学院, 浙江 温州 325000)

摘 要: **目的** 提出一种考虑能耗的多传感器融合加工表面粗糙度预测方法, 精确预测零件表面粗糙度。**方法** 首先采集车削过程中的功率和振动信号, 测量加工表面粗糙度值, 利用集成经验模态分解 (Ensemble empirical mode decomposition, EEMD) 和小波包分析提取振动信号的时域与频域特征, 联合功率信号的时域特征、能耗特征与切削参数, 构造联合多特征向量。然后采用核主成分分析 (Kernel principal component analysis, KPCA) 对联合多特征向量进行融合降维处理生成融合特征。最后将融合特征作为基于支持向量机 (Support vector machine, SVM) 的表面粗糙度预测模型的输入特征, 并使用遗传算法 (Genetic algorithm, GA) 对 SVM 模型相关核参数进行优化以提高预测精度。**结果** 预测得到的表面粗糙度平均相对误差为 4.91%, 最大误差为 0.111 μm , 预测时间为 9.24 s。与单传感器预测方法及多传感器联合特征预测方法相比, 多传感器融合预测方法具有最高的准确率且预测速度快。**结论** 多传感器采集的信息更全面、准确, 保证了预测的准确性, 对特征进行融合可进一步提高预测精度。

关键词: 能耗; 多传感器融合; 表面粗糙度; 预测方法; 核主成分分析; 支持向量机

中图分类号: TH161.1 **文献标识码:** A **文章编号:** 1001-3660(2018)09-0240-10

DOI: 10.16490/j.cnki.issn.1001-3660.2018.09.032

An Approach for Surface Roughness Prediction in Machining Based on
Multi-sensor Fusion Considering Energy ConsumptionXIE Nan^{1a}, ZHOU Jun-feng^{1b}, ZHENG Bei-rong²(1. a.Sino-German College of Applied Sciences, b.School of Mechanical Engineering, Tongji University, Shanghai 201804, China;
2. College of Mechanical and Electrical Engineering, Wenzhou University, Wenzhou 325000, China)

ABSTRACT: In order to predict surface roughness of the workpiece accurately, an approach for surface roughness prediction in machining based on multi-sensor fusion considering energy consumption is proposed. The power signal and the vibration signal of the turning process were collected firstly. Surface roughness was measured. The time domain and frequency domain characteristics of the vibration signal were extracted by using the EEMD and wavelet packet analysis. And the vibration features with the time domain feature of power signal, energy features and cutting parameters constructed the joint multi-eigenvectors. Then the KPCA was used to fuse the joint multi-eigenvectors to generate the fusion feature. Finally, the fusion feature was taken as

收稿日期: 2018-05-30; 修订日期: 2018-07-25

Received: 2018-05-30; Revised: 2018-07-25

基金项目: 国家自然科学基金项目 (71471139); 国家工信部智能制造标准化项目

Fund: Supported by the National Natural Science Foundation of China (71471139) and MITT Intelligent Manufacturing Project of China

作者简介: 谢楠 (1975—), 女, 博士, 副教授, 主要研究方向为制造工程。

Biography: XIE Nan (1975—), Female, Doctor, Professor, Research focus: manufacturing engineering.

the input characteristic of the SVM-based surface roughness prediction model. In addition, GA was used to optimize the relevant kernel parameters of SVM model to improve the prediction accuracy. For the prediction results obtained by multi-sensor fusion, the mean relative error was 4.91%, the maximum error was 0.111 μm and the prediction time was 9.24 seconds. The experimental results showed the proposed method had the highest prediction accuracy compared with the joint feature and single sensor. A comparative study with multi-sensor joint feature prediction method and signal-sensor feature prediction method shows the information collected by multi-sensor is more comprehensive and accurate, which ensures prediction accuracy and the prediction accuracy can be further improved by fusing the features.

KEY WORDS: energy consumption; multi-sensor fusion; surface roughness; prediction approach; KPCA; SVM

在工业 4.0 的背景下,随着加工自动化技术的发展,对产品的生产效率和生产质量提出了更高的要求。表面粗糙度是衡量机械产品质量的常用指标,也是一项技术要求。它影响零件的机械性能,如配合性质、耐腐蚀性、耐磨性和寿命等^[1]。因此,准确、有效的表面粗糙度预测对提高产品质量与加工效率、降低加工成本有重要意义。

表面粗糙度的影响因素有很多,如切削速度、进给速度、切削深度、工件材料、切屑、冷却润滑情况和振动等。这些不确定因素对表面粗糙度的影响是非线性的,难以精确计算。随着传感器技术的快速发展及其在加工过程中的广泛应用,基于传感器信号驱动的表面粗糙度预测方法已经成为研究热点。其基本思路是利用单个传感器采集加工信息,如声发射、功率、振动、切削力信号等,然后对信号进行处理,通过人工智能算法建立过程信号与表面粗糙度之间的关系,进而预测表面粗糙度^[2]。Kamathi 等^[3]采集车削中的声发射信号并建立人工神经网络模型,预测工件表面粗糙度。Upadhyay 等^[4]将振动信号的幅值与切削速度、进给速度、切削深度作为参数,构建表面粗糙度的预测回归方程。Aydin 等^[5]通过压电测力计收集切削力信号,利用基于粒子群优化算法的自适应模糊神经推理系统预测表面粗糙度。虽然以上研究都取得了一定的预测效果,但是单个传感器只能在一定范围内从单方面描述被测对象,而且单一传感器预测方法受传感器特性、外界干扰和信噪比等因素影响,不具备很强的鲁棒性。

多传感器融合技术可以充分利用多个传感器的特性,将多个传感器采集的数据进行联合分析,完整描述被测对象信息,有效提取被测对象特征。较单一传感器,它得到的信息更加全面和准确,因此能反映切削过程多方面的信息,因而可以取代单一昂贵传感器。Bhuiyan 等^[6]融合声发射信号和振动信号实现车削过程表面粗糙度的在线监测。Cruz 等^[7]利用多个传感器采集切削力、声发射、振动和功率信号,采用神经网络进行表面粗糙度的预测。Moralagüello 等^[8]融合切削力、刀具振动和加工条件来预测车削表面粗糙度,结果表明切削力与加工条件融合具有最好的预测效果。

基于多传感器融合的表面粗糙度预测的另一核心问题是,建立高精度的预测模型来学习加工信号与表面粗糙度之间复杂的非线性关系。常用的人工智能算法有神经网络、支持向量机等。神经网络预测算法可以实现加工过程表面粗糙度的准确预测^[9-10],但神经网络在粗糙度预测时会表现出过学习、泛化能力弱等缺点,而且需要大量实验样本^[11]。支持向量机可以较好地解决小样本表面粗糙度学习问题,且预测性能优于神经网络^[12]。Zhang 等^[13]提出了一种基于最小二乘支持向量机的车削表面粗糙度预测方法,并与神经网络进行对比,结果表明支持向量机的预测性能优于神经网络。Hashmi 等^[14]分别使用模型树和序列最小算法优化基于支持向量机的表面粗糙度预测模型,得到的最小表面粗糙度值均比实际值低。

本文提出一种考虑能耗的多传感器融合加工表面粗糙度预测方法。提取车削时振动信号的时域与频域特征、功率信号的时域特征、能耗特征与切削参数特征,利用核主成分分析(Kernel principal component analysis, KPCA)对联合特征向量进行融合降维,生成融合特征,建立基于支持向量机(Support vector machine, SVM)的表面粗糙度预测模型,采用遗传算法(Genetic algorithm, GA)优化 SVM 模型的关键参数,以提高模型预测精度。

1 考虑能耗的多传感器融合加工表面粗糙度预测方法

考虑能耗的多传感器融合表面粗糙度预测方法如图 1 所示,包括数据采集模块、特征提取模块、特征融合模块和预测模型及优化模块。

1.1 数据采集模块

在已经确定的切削工况下,包括切削参数在内的各影响因素相互作用,最终会以振动的形式呈现在加工工艺系统中。刀具偏离理想位置,在工件表面上形成微观凹凸不平的表面形貌^[15]。本文考虑加工过程中的刀具磨损,其变化反映在振动和功率信号中,刀具磨损会引起加工过程振动,从而影响表面粗糙度,振动信号可以利用振动传感器获得。同时刀具磨损会引

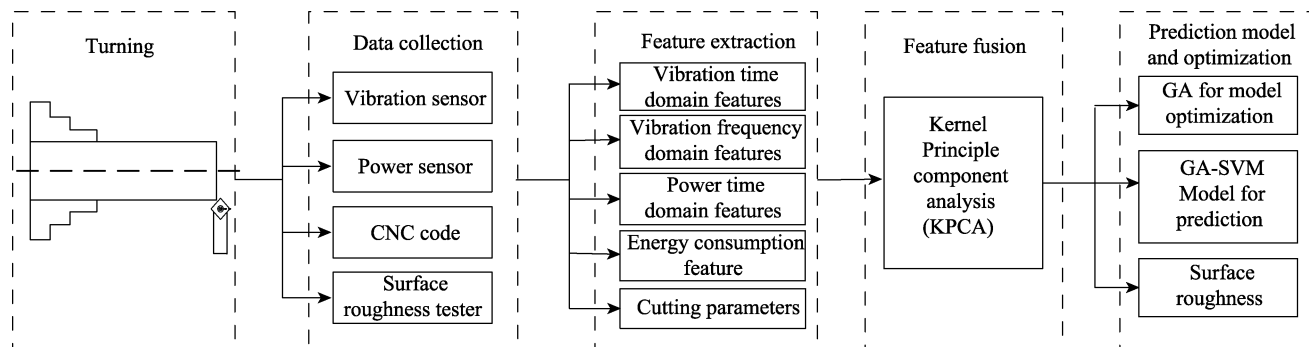


图1 考虑能耗的多传感器融合加工表面粗糙度预测方法

Fig.1 An approach for surface roughness prediction in machining based on multi-sensor fusion considering energy consumption

起电流、功率的变化,功率信号也可通过功率传感器获得。因此在数据采集模块,使用振动传感器和功率传感器分别采集车削过程中的振动信号和功率信号,使用3个加速度传感器分布于刀具的径向、轴向和切向方向上,同时与电荷放大器、NI数据采集卡连接,通过Labview实时采集振动信号,数值保存于电脑中。利用功率传感器实时记录加工过程功率信号,并存储于传感器内方便后续读取。同时读取数控机床的NC代码,记录切削参数。每次加工完毕后使用表面粗糙度仪测量工件的表面粗糙度值。

1.2 特征提取模块

1.2.1 信号截取

实验中采集的振动信号(如图2所示)涵盖了切削开始和结束时的信号,分析时为了降低后续分析的运算量,只需截取一定长度切削时的振动信号(如图3所示)。图4为功率传感器记录的一次加工过程的功率信号。由于零件表面是切削时产生的,因此截取开始切削至退出切削时段的功率信号。




图2 采集的振动信号

Fig.2 The collected vibration signal




图3 截取的振动信号

Fig.3 The intercepted vibration signal




图4 采集的机床功率信号

Fig.4 The power profile of the machine tool

1.2.2 信号预处理

集成经验模态分解(EEMD)是一种新型的基于噪声辅助的信号处理方法^[16]。其核心是利用高斯白噪

声对信号预白化处理和平滑脉冲干扰,经过多次平均后将加入的噪声抵消,最终获得集成平均本征模分量。由于传感器信号可能被各种噪声污染,信噪比下降,因此首先对采集的传感器信号进行去空值和剔奇异值,然后利用EEMD对振动信号滤波处理以降低噪声干扰,将信号自适应分解成多个本征模分量,最后对功率信号减去机床空载功率并平均化处理。

1.2.3 特征提取

1) 基于 EEMD 的振动信号时域特征提取

对经过 EEMD 处理的振动信号提取 7 个时域特征：均值、均方根、峰值、波形因子、峰值因子、脉冲因子和裕度因子（如表 1 所示）。

表 1 振动信号时域特征
Tab.1 The domain features of vibration signal

No. Feature	Equation	No. Feature	Equation
1 Average value	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$	5 Peak factor	$P = \max \frac{ x(i) }{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}$
2 Rms value	$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	6 Impulsion factor	$I = \frac{\max x(i) }{\frac{1}{n} \sum_{i=1}^n x_i }$
3 Peak value	$X_{peak} = \frac{1}{n} \sum_{i=1}^n x_i$	7 Clearance factor	$C = \frac{\max x(i) }{\left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x(i) } \right)^2}$
4 Shape factor	$S = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}{\frac{1}{n} \sum_{i=1}^n x_i }$		

2) 基于小波包变换的振动信号频域特征提取

由于不同切削状态下的振动信号在不同频带内的能量会有较大差别，所以利用小波包分解对预处理后的振动信号进行分解和重构，将分解后各频率段能量占总能量的比值作为振动信号的频域能量特征，如式（1）—（3）所示。

$$f_{E_i^j} = E_i^j / E_i \quad (1)$$

$$E_i^j = \sum_{k=1}^N |c_i^j(k)|^2 \quad (2)$$

$$E_i = \sum_{j=0}^{2^i-1} E_i^j, j = 0, 1, \dots, 2^{i-1} \quad (3)$$

式中： $c_i^j(k)$ 表示小波包分解后振动信号的第 i 层第 j 个小波包的分解重构系数。

3) 功率信号时域特征提取

对预处理后的功率信号进行时域特征提取，选取最大值、最小值与平均值 3 个时域特征反映真实加工过程状态。

4) 能耗特征提取

切削比能（SCE）指去除单位体积材料所消耗的切削能量。Liu 等^[17]利用切削比能预测槽铣过程的表面粗糙度，并取得较好的效果。SCE 可表示为：

$$SCE = \frac{E_{\text{切削}}}{Q} = \frac{\int_0^T P_c dt}{\int_0^T MRR dt} \quad (4)$$

式中， $E_{\text{切削}}$ 为总切削能耗； Q 为去除的材料体积； P_c 为实时切削功率； MRR 为材料去除率； T 为实际

切削时间。

材料去除率由加工参数（主轴转速 n 、切削深度 a_p 、进给速度 f 、工件直径 d ）决定，在车削中它可以表示为：

$$MRR = \frac{f a_p \pi d n}{60} \quad (5)$$

由于每次切削过程中切削参数保持不变，所以 MRR 和平均切削功率 \bar{P}_c 保持不变。式（4）可以改写为：

$$SCE = \frac{\bar{P}_c}{MRR} \quad (6)$$

$$\bar{P}_c = \bar{P}_n - \bar{P}_a \quad (7)$$

式中， \bar{P}_n 为平均正常切削功率， \bar{P}_a 为平均空切削功率。

5) 切削参数特征提取

选取主轴转速、切削深度、进给速度作为切削参数特征。记录每次加工时数控代码中主轴转速、切削深度、进给速度的数值。

1.3 特征合模块

在特征融合模块中，切削三要素、振动时域特征、频域特征、功率时域特征和能耗特征作为初始特征，运用融合算法进行特征融合，选取能够反映表面粗糙度大小的主要信息。

1.3.1 特征融合

核主成分分析是一种常用的高维非线性特征降维方法，基本思路是引入核函数，将输入特征向量通过非线性映射变换到高维特征空间，再在新的空间上做线性主分量分析，提取主要变化的信息，从而达到特征融合降维的目的^[18]。因此运用 KPCA 进行特征融合。

假设原始输入表面粗糙度相关特征数据集有 n 个样本，每个样本有 m 个特征，经过标准化后得到 $\mathbf{X} = \{x_1, x_2, \dots, x_m\}$ ， $\mathbf{X} \in \mathbf{R}^{n \times m}$ 。引入非线性映射函数 ϕ ，将特征数据变化为高维特征空间中的样本点 $\phi(x_i)$ ，且满足中心化条件。得到协方差矩阵：

$$\mathbf{C} = \frac{1}{M} \sum_{i=1}^M f(x_i) f(x_i)^T \quad (8)$$

计算协方差矩阵 \mathbf{C} 的特征值和特征向量 ω ：

$$\mathbf{C}\omega = \lambda\omega \quad (9)$$

其中： λ 为协方差矩阵的特征值， $\omega = \sum_{i=1}^M \alpha_i \phi(x_i)$

为特征向量。

令对称矩阵 \mathbf{K} 为核矩阵， $\mathbf{K}_{ij} = \phi(x_i)^T \phi(x_j)$ ，有：

$$\mathbf{M}\lambda\alpha = \mathbf{K}\alpha \quad (10)$$

式中： α 为特征向量，且 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ 。

将特征值及对应的特征向量降序排列。给定一个阈值，计算特征值的累积贡献率并提取达到阈值的前

k 个主成分作为最终融合特征向量。

1.3.2 归一化

经过融合的特征和表面粗糙度值参数幅值不一致, 参数幅值过大过小都会影响预测模型的预测性能。因此, 通过归一化将特征参数及表面粗糙度变换到一致的范围内, 采用以下归一化方法:

$$X_i^* = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (11)$$

其中: X_i 为第 i 个特征值; X_{\max} 为样本的最大

值; X_{\min} 为样本的最小值。

1.4 表面粗糙度预测模型及其优化

支持向量机是 Vapnik 基于结构风险最小化原则提出的一种回归与分类的机器学习算法, 可以实现小样本、非线性条件下表面粗糙度的预测^[19]。但支持向量机的核函数参数对其预测精度有重要影响。因此本文采用遗传算法优化预测模型, 实现表面粗糙度的准确预测, 所建立的 GA-SVM 学习机和预测机模型如图 5 所示。

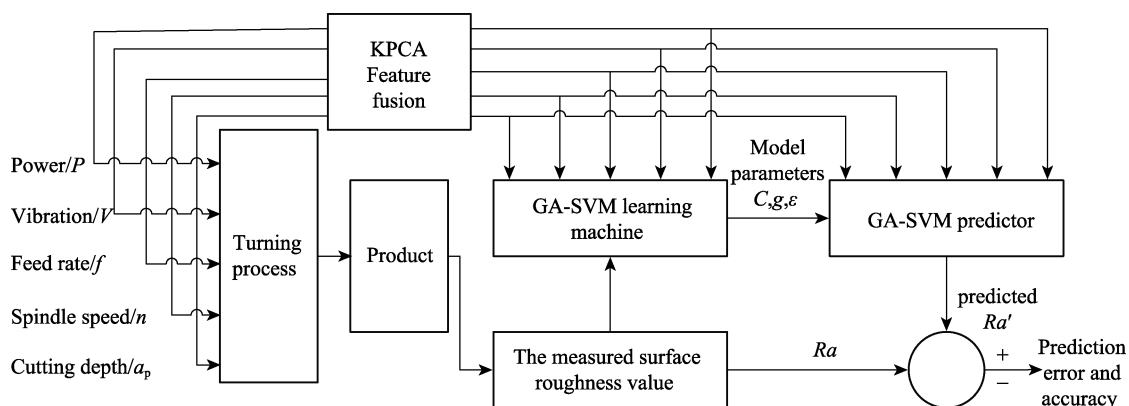


图 5 表面粗糙度预测模型
Fig.5 The surface roughness prediction model

1.4.1 SVM 预测模型

给定训练样本 $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, $x_i \in R^n$ 为融合特征向量, $y_i \in R^1$ 为输出表面粗糙度向量。首先通过将原空间的样本通过非线性变换 ϕ 映射到 M 空间, 在此高维空间求解线性回归问题。

$$f(x) = \omega^T \cdot \phi(x) + b \quad (12)$$

其中, ω 为权向量, b 为阈值。SVM 问题就是不断学习找到合适的函数拟合训练点, 使预测值与实际值之间的误差最小, 最后得到最优模型参数用于预测样本的表面粗糙度预测。

该回归问题可以转换为以下优化问题:

$$\text{Min } \frac{1}{2} \|w\|^2$$

满足:

$$\begin{cases} y_i - (w^T \phi(x_i) + b) \leq \varepsilon \\ (w^T \phi(x_i) + b) - y_i \leq \varepsilon, \forall i \end{cases} \quad (13)$$

引入 ε 、不敏感损失函数 L_ε 、非负松弛变量 ε_i 和 ε_i^* :

$$l_\varepsilon(z) = \begin{cases} 0, & |z| \leq \varepsilon \\ |z| - \varepsilon, & \text{其他} \end{cases} \quad (14)$$

SVM 问题可以重写为:

$$\text{Min } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\varepsilon_i + \varepsilon_i^*)$$

满足:

$$\begin{cases} y_i - (w^T \phi(x_i) + b) \leq \varepsilon + \varepsilon_i \\ (w^T \phi(x_i) + b) - y_i \leq \varepsilon + \varepsilon_i^* \\ \varepsilon_i, \varepsilon_i^* \geq 0, i = 1, \dots, n \end{cases} \quad (15)$$

通过引入拉格朗日函数求解 SVM 的对偶问题得到 SVM 的解:

$$f(x) = \sum (a_i - a_i^*) k(x_i, x_j) + b \quad (16)$$

其中 $k(x_i, x_j)$ 为核函数。

1.4.2 预测模型优化

建立 SVM 模型时, 核函数的类型、宽度 g 、误差惩罚参数 C 和敏感参数 ε 都对 SVM 性能有影响。常用的核函数有线性核函数、多项式核函数、径向基核函数和 Sigmoid 核函数。由于径向基核函数处理复杂非线性回归问题更有优势, 因此本文采用径向基核函数, 其形式如下:

$$K(x_i, x_j) = \exp(-g \|x_i - x_j\|^2), (g > 0) \quad (17)$$

对核函数宽度、误差惩罚参数和敏感参数, 采用 GA 进行优化, 流程图如图 6 所示。

均方误差 (MSE) 是指参数估计值与参数真值之差平方的期望值, 可以评价数据的变化程度, 常用于误差评价。MSE 的值越小, 说明预测模型的精确度越高。因此将均方误差作为适应度函数。

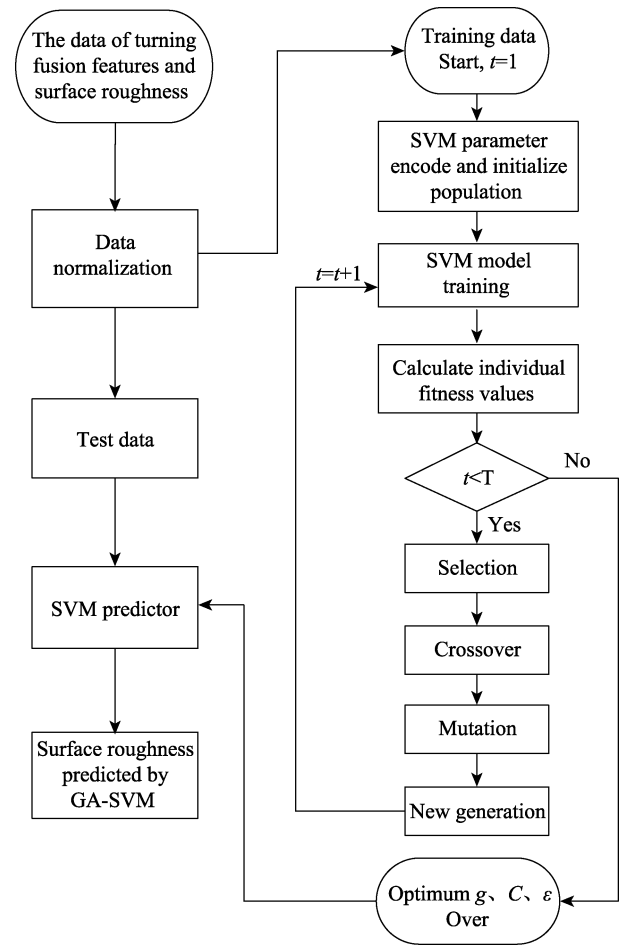



图 6 GA-SVM 模型流程图
Fig.6 The flowchart of GA-SVM model

2 实验研究

实验设备为数控车床 CJK0640，工件材料为 45# 钢，尺寸为：直径 30 mm，长 110 mm。刀具为硬质合金刀具 TNMG160404 NX2525。传感器实验装置如图 7 所示：将加速度传感器 CT1010L 布置于刀架上，通过 NI 采集卡和 Labview 采集加工时工件与刀具径向、轴向和切向的振动信号。同时采用功率传感器福禄克 1735 采集机床的总功率信号，采样频率为 10.24 kHz，并实时显示有效值。实验结束后，利用表



a 振动传感器
b 功率传感器
图 7 传感器实验装置
Fig.7 The experimental setup of sensor

面粗糙度测量仪 TR200 测量表面粗糙度值，取样长度 0.8 mm，评定长度为 5 个连续采样长度。每次测量时，沿着圆周方向依次测 10 个点，10 个点的平均值作为最后的表面粗糙度值。

2.1 实验设计

选取主轴转速、切削深度、进给速度为试验参数，采用全因子实验设计方法，每个因素取 5 个水平（具体参数见表 2），共进行 125 组车削实验。

表 2 实验变量 Tab.2 The experimental variables					
Variables	Level 1	Level 2	Level 3	Level 4	Level 5
Spindle speed (n)/(r·min ⁻¹)	900	1100	1300	1500	2000
Cutting depth (a_p)/mm	0.05	0.10	0.15	0.20	0.25
Feed rate (f)/(mm·r ⁻¹)	0.05	0.06	0.07	0.08	0.09

表征表面粗糙度的参数多达四十多个，给实际应用带来了挑战。常用的基本评定参数有 3 种，轮廓算术平均偏差 Ra 、微观不平度十点高度 Rz 和轮廓最大高度 Ry ，其中 Ra 使用最为广泛。实验中同时测量 Ra 、 Rz 、 Ry 三个参数，利用式(18)对三个评定参数与切削参数进行相关性分析，结果如表 3 所示。 Ra 与加工条件的相关系数均超过 0.9， Rz 与加工条件的相关系数在 0.8 左右， Ry 与加工条件的相关系数接近于 0.2。因此，选取 Ra 作为预测的表面粗糙度参数，满足实际生产加工过程检测需要，部分实验结果如表 4 所示。

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}}$$

(18)

其中： x_i 为表面粗糙度评定参数值； \bar{x} 为表面粗糙度评定参数均值； P_i 为切削参数值； \bar{P} 为切削参数均值； ρ 为相关系数。

表 3 表面粗糙度评定参数与切削参数之间的相关系数
Tab.3 Correlation coefficient between surface roughness evaluation parameters and cutting parameters

Cutting parameters	Evaluation		
	Ra	Rz	Ry
n	0.90	0.83	0.17
a_p	0.91	0.80	0.16
f	0.96	0.85	0.22

2.2 特征提取与融合

2.2.1 振动信号特征提取

首先利用 EEMD 对采集的振动信号进行处理，

表 4 部分实验结果
Tab.4 Part of the experimental results

No	n /(r·min ⁻¹)	a_p /mm	f (mm·r ⁻¹)	Ra /μm	SCE (J·mm ⁻³)	No	n (r·min ⁻¹)	a_p /mm	f (mm·r ⁻¹)	Ra /μm	SCE (J·mm ⁻³)
1	900	0.05	0.05	0.792	23.74	15	1100	0.15	0.09	1.514	5.52
2	900	0.05	0.06	0.874	15.56
3	900	0.05	0.07	0.970	13.51	114	2000	0.15	0.08	1.290	6.54
4	900	0.05	0.08	1.149	13.47	115	2000	0.15	0.09	1.322	6.13
5	900	0.05	0.09	1.468	10.17	116	2000	0.2	0.05	0.747	9.37
6	900	0.10	0.05	0.834	11.94	117	2000	0.2	0.06	1.144	7.43
7	900	0.10	0.06	0.887	9.57	118	2000	0.2	0.07	1.136	6.67
8	900	0.10	0.07	1.038	8.59	119	2000	0.2	0.08	1.230	5.78
9	900	0.10	0.08	1.349	8.91	120	2000	0.2	0.09	1.329	5.64
10	1100	0.10	0.09	1.518	7.69	121	2000	0.25	0.05	0.838	6.70
11	1100	0.15	0.05	0.914	8.07	122	2000	0.25	0.06	1.092	5.83
12	1100	0.15	0.06	1.044	6.45	123	2000	0.25	0.07	1.134	4.55
13	1100	0.15	0.07	1.067	5.45	124	2000	0.25	0.08	1.315	4.62
14	1100	0.15	0.08	1.358	5.20	125	2000	0.25	0.09	1.357	4.29

分解成 9 层固有模态函数 (IMF)，然后对处理后的振动信号提取时域特征。实验振动采样频率为 2 kHz，根据采样定理得出采集有效信号的最高频率为 1 kHz。对不同信号进行傅里叶分析，发现信号的频率主要集中在 500 Hz 以下。根据小波包分解理论，对采样信号利用 db3 小波进行 3 层小波包分解，提取前 4 个频段 (0~500 Hz) 信号的能量特征。以径向振动信号为例，图 8 是部分样本四段频域能量占比图。




图 8 部分振动信号四频段频域能量占比
Fig.8 The four band-energy bar of vibration signal

2.2.2 功率信号特征提取

对采集的功率信号进行时域分析，提取最大值、平均值和最小值作为时域特征。图 9 为时域特征提取结果，从图中可以看出功率随着转速的增加而增加。

2.2.3 能耗特征提取

根据功率信号计算平均正常切削功率 \bar{P}_n 和平均空切削功率 \bar{P}_a ，由式(5)、(6)、(7)得到切削比能，将其作为能耗特征。部分能耗特征数值详见前文表 4。




图 9 功率信号时域特征
Fig.9 The domain features of power signal

2.2.4 特征融合

考虑振动信号 3 个方向的特征，现有 21 个振动时域特征、12 个振动频域特征、3 个功率时域特征、3 个切削参数特征与 1 个能耗特征共 40 个特征。特征经过 KPCA 融合后，得到如图 10 所示的每个主成




图 10 各主成分贡献率及累积贡献率
Fig.10 Contribution rate of the principal component and cumulative contribution rate

分的贡献率，前 8 个主成分的累积贡献率超过 90%，达到 91.93%。因此选取前 8 个主成分作为表面粗糙度预测模型的输入特征。

2.3 表面粗糙度预测结果与分析

2.3.1 表面粗糙度预测模型训练与预测

从融合特征中随机选取 100 组作为训练组，其余 25 组作为测试组。利用图 6 所示的 GA-SVM 预测模型，其主要步骤如下。

1) 将车削实验数据进行归一化处理，利用训练组数据训练 SVM 模型关键参数。

2) 参数编码及初始化种群：针对核函数宽度 g 、惩罚因子 C 和敏感系数 ε ，随机生成染色体序列。设置初始种群数 100，最大进化代数 100。

3) 计算各个体的适应度均方误差值。

4) 当循环次数未达到最大迭代次数时，对种群进行选择、交叉、变异操作生成新一代种群，继续进行 SVM 模型训练。

5) 不断迭代重复步骤 3) 和 4)，直到达到最大进化代数，得到最优 g 、 C 、 ε 。

利用训练得到的参数带入 SVM 模型，得到 SVM 预测机，对测试组数据进行表面粗糙度预测，适应度值的进化过程如图 11 所示。从图中可以看出，在 60 代时 MSE 取得最小值，即核函数宽度 g 、惩罚因子 C 和敏感系数 ε 取得最优值。




图 11 适应度进化过程
Fig.11 The evolution of MSE

2.3.2 表面粗糙度预测结果对比与分析

为了验证考虑能耗的多传感器融合预测方法的有效性，将切削参数、振动特征、功率特征与能耗特征组成两大类预测特征集——多传感器预测和单传感器预测。表 5 为切削参数、振动、功率和能耗特征的代号。选取以下四组特征，其中 Group1 与 Group2 为多传感器预测特征，Group3 与 Group4 为单传感器预测特征：

1) Group1 包含经过 KPCA 融合后的前八个主成分特征。

2) Group2 包含所有切削参数、振动、功率与能耗的联合特征。G2= [$X1, X2, X3, V1, V2, V3, V4, V5, V6, V7, V8, V9, V10, V11, P1, P2, P3, E$]

3) Group3 包含所有切削参数和所有振动的特征。G3= [$X1, X2, X3, V1, V2, V3, V4, V5, V6, V7, V8, V9, V10, V11$]

4) Group4 包含所有切削参数和所有功率的特征。G4= [$X1, X2, X3, P1, P2, P3$]

表 5 各特征代号
Tab.5 The index for features

Index	Feature	Index	Feature
$X1$	Spindle speed	$V7$	Clearance factor
$X2$	Cutting depth	$V8$	Energy proportion of first band
$X3$	Feed rate	$V9$	Energy proportion of second band
$V1$	Average value	$V10$	Energy proportion of third band
$V2$	Rms value	$V11$	Energy proportion of fourth band
$V3$	Peak value	$P1$	The maximum value of power
$V4$	Shape factor	$P2$	The average value of power
$V5$	Peak factor	$P3$	The minimum value of power
$V6$	Impulsion factor	E	Specific cutting energy

将以上四组特征输入训练好的 GA-SVM 预测机，表面粗糙度的预测结果如图 12 所示。图 12 中黑色为实际测量值，其他颜色表示利用不同特征得到的预测值，它们之间的差值即预测误差，在图的下方以相同的颜色展示，对比发现多传感器融合特征具有较小的误差。为了进一步分析各组特征的预测性能，将预测误差分类来定义预测成功或失败。误差小于 $0.05 \mu\text{m}$




图 12 各种预测方法结果对比
Fig.12 The comparative results of different prediction methods

认为预测成功,误差介于 $0.05\sim 0.1\ \mu\text{m}$ 认为可以接受,误差大于 $0.1\ \mu\text{m}$ 认为预测失败。由此得到的误差分类比例见图 13。由图 13 可知,多传感器融合特征与联合特征分别有 84%与 80%的预测结果为可接受,只有 16%与 20%的预测结果为失败。而单功率传感器与单振动传感器都只有 68%的预测结果为可接受,32%的预测结果为失败。因此,多传感器预测效果优于单传感器预测。多传感器融合特征预测效果是四组预测效果中最好的,这表明本文提出的多传感器融合表面粗糙度预测方法具有较好的预测能力。




图 13 各种预测方法误差分类比例

Fig.13 The proportion of error classification for different prediction method

为了定量描述预测精度,利用平均相对误差、最大误差和最大相对误差三大指标比较多传感器融合特征、多传感器联合特征、单传感器特征的预测效果。表 6 总结了四种特征预测的平均相对误差、最大误差和最大相对误差。

表 6 各种预测方法预测精度
Tab.6 The prediction precision of different prediction methods

Feature	The mean relative error/%	The maximum error/ μm	The maximum relative error/%
Multi-sensor fusion feature	4.91	0.111	11.05
Multi-sensor joint feature	5.92	0.211	16.40
Power and cutting parameter features	6.58	0.160	16.78
Vibration and cutting parameter features	6.60	0.302	16.99

综合以上分析结果表明:

1)多传感器融合特征预测具有最高的预测精度,其平均相对误差为 4.91%,最大误差为 $0.111\ \mu\text{m}$,最大相对误差为 11.05%,这三项均为四种预测方法中的最低。

2)比较多传感器融合特征和多传感器联合特征的预测结果与预测时间(分别为 9.24 s 与 14.37 s)可以得出,多传感器融合特征的预测时间比联合特征减

少 35.7%。因此核主成分分析可以有效实现特征融合并消除特征间的冗余,减少特征维数和后续训练及预测的时间,显著提高表面粗糙度预测模型的预测性能。

3)比较融合特征与单传感器特征的平均相对预测误差,融合特征平均相对误差比振动联合特征、功率联合特征均低 1.7%。结果表明多传感器融合特征相较于单一传感器特征有优势。多传感器获取的信息量更大,抗干扰能力更强。

3 结论

1)采集车削过程振动信号和功率信号,分别提取振动时域和频域特征、功率时域特征并计算能耗特征。以上特征与切削参数联合组成特征向量,利用核主成分分析法进行特征融合获取代表总体特征信息的特征作为表面粗糙度预测模型的输入样本,提高了预测的速度与精度。

2)基于特征融合后的特征,采用 SVM 建立表面粗糙度预测模型,实现了小样本条件下车削零件表面粗糙度的准确预测。

3)使用遗传算法对 SVM 预测模型的核函数参数进行优化,进一步提高了预测精度。

参考文献:

- [1] CHEN Y, SUN R, GAO Y, et al. A Nested-ANN prediction model for surface roughness considering the effects of cutting forces and tool vibrations[J]. Measurement, 2017, 98: 25-34.
- [2] 王顺钦, 高延峰, 陶镛光. 金属切削表面粗糙度在线监测研究现状[J]. 山东理工大学学报(自然科学版), 2013, 27(2): 34-37.
WANG Shun-qin, GAO Yan-feng, TAO Yong-guang. The research status of cutting surface roughness on-line monitoring system[J]. Journal of Shandong University of Technology, 2013, 27(2): 34-37.
- [3] KAMARTHI S, SULTORNSANEE S, ZEID A. Recurrence quantification analysis to estimating surface roughness in finish turning processes[J]. The international journal of advanced manufacturing technology, 2016, 87(1-4): 1-10.
- [4] UPADHYAY V, JAIN P K, MEHTA N K. In-process prediction of surface roughness in turning of Ti-6Al-4V alloy using cutting parameters and vibration signals[J]. Measurement, 2013, 46(1): 154-160.
- [5] AYDIN M, KARAKUZU C, UCAR M, et al. Prediction of surface roughness and cutting zone temperature in dry turning processes of AISI304 stainless steel using ANFIS with PSO learning[J]. The international journal of advanced manufacturing technology, 2013, 67(1-4): 957-967.
- [6] BHUIYAN M S H, CHOUDHURYI A, DAHARI M. Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning[J]. Journal of manufacturing systems, 2014, 33(4): 476-487.

- [7] CRUZ C E D, AGUIAR P R D, ÁLISSON R M, et al. Monitoring in precision metal drilling process using multi-sensors and neural network[J]. International journal of advanced manufacturing technology, 2013, 66(1-4): 151-158.
- [8] MORALAARGUELLO P, BARREIRO J, ALEGRE E, et al. Surface roughness prediction from combination of cutting forces, turning vibrations and machining conditions using artificial neural networks[C]//Manufacturing engineering society international conference. [s. l.]: American Institute of Physics, 2012: 510-517.
- [9] MIA M, DHAR N R. Prediction of surface roughness in hard turning under high pressure coolant using artificial neural network[J]. Measurement, 2016, 92: 464-474.
- [10] 陈廉清, 郭建亮, 杨勋, 等. 基于进化神经网络的磨削粗糙度预测模型[J]. 计算机集成制造系统, 2013, 19(11): 2854-2863.
CHEN Lian-qing, GUO Jian-liang, YANG Xun, et al. Grinding roughness prediction model based on evolutionary artificial neural network[J]. Computer integrated manufacturing systems, 2013, 19(11): 2854-2863.
- [11] 孙林, 杨世元. 基于最小二乘支持向量机的成形磨削表面粗糙度预测及磨削用量优化设计[J]. 机械工程学报, 2009, 45(10): 254-260.
SUN Lin, YANG Shi-yuan. Prediction for surface roughness of profile grinding and optimization of grinding parameters based on least squares support vector machine[J]. Journal of mechanical engineering, 2009, 45(10): 254-260.
- [12] ÇAYDAS U, EKICI S. Support vector machines models for surface roughness prediction in CNC turning of AISI 304 austenitic stainless steel[J]. Journal of intelligent manufacturing, 2012, 23(3): 639-650.
- [13] ZHANG N, SHETTY D. An effective LS-SVM-based approach for surface roughness prediction in machined surfaces[J]. Neurocomputing, 2016, 198: 35-39.
- [14] HASHMI S, HALAWANI S M, BARUKAB O M, et al. Model trees and sequential minimal optimization based support vector machine models for estimating minimum surface roughness value[J]. Applied mathematical modeling, 2015, 39(3-4): 1119-1136.
- [15] 王明微, 周竞涛, 敬石开, 等. 基于贝叶斯网络的切削加工表面粗糙度在线监测方法[J]. 计算机集成制造系统, 2014, 20(12): 3075-3081.
WANG Ming-wei, ZHOU Jing-tao, JING Shi-kai, et al. Surface roughness monitoring method based on Bayesian network models[J]. Computer integrated manufacturing systems, 2014, 20(12): 3075-3081.
- [16] ZHAO H W, NORDEN E H. Ensemble empirical mode decomposition: A noise assisted data analysis method[J]. Advances in adaptive data analysis, 2009, 1(1): 1-41.
- [17] LIU N, WANG S B, ZHANG Y F, et al. A novel approach to predicting surface roughness based on specific cutting energy consumption when slot milling Al-7075[J]. International journal of mechanical sciences, 2016, 118: 13-20.
- [18] SMOLA A J. Kernel principal component analysis[C]//International conference on artificial neural networks. [s. l.]: Springer-Verlag, 1997: 583-588.
- [19] VAPNIK V. The support vector method of function estimation[M]. Boston: Kluwer Academic Publishers, 1998: 55-85.