

## 基于机器学习的弧齿锥齿轮齿面粗糙度预测方法

李佳宾<sup>1</sup> 陈海锋<sup>1</sup> 刘国亮<sup>2</sup> 周长江<sup>3</sup>

(1. 湖南科技大学 机电工程学院, 湘潭 411201)

(2. 中国航发中传机械有限公司, 长沙 410200)

(3. 湖南大学 机械与运载工程学院, 长沙 410082)

**摘要:**【目的】为解决弧齿锥齿轮齿面粗糙度参数优化与预测精度不足的问题, 进而克服传统方法难以有效处理复杂的非线性关系和多变量影响的局限, 采用机器学习模型对弧齿锥齿轮齿面粗糙度进行预测。【方法】首先, 基于弧齿锥齿轮磨削试验数据集, 分别应用机器学习方法中的决策树(Decision Tree, DT)、支持向量机(Support Vector Regression, SVR)和人工神经网络(Artificial Neural Network, ANN)方法构建弧齿锥齿轮凸面和凹面的粗糙度预测模型, 对比3种机器学习模型的预测结果; 其次, 以此为基础, 采用多元线性回归方法推导了考虑弧齿锥齿轮加工参数的齿面粗糙度预测公式; 最后, 通过机器学习模型解释工具(SHapley Additive exPlanations, SHAP)分析了各输入特征对所预测齿面粗糙度的贡献, 为机器学习服务于高性能齿轮制造提供理论支持。【结果】结果表明, DT、SVR分别表现出欠拟合和过拟合的状态, 预测效果不佳; ANN可以完美地拟合数据并精确预测齿面粗糙度, 但计算效率相对较低, 其预测弧齿锥齿轮凸面和凹面粗糙度的平均相对误差分别为3.5%和6.09%; 各输入加工参数对所预测齿面粗糙度的影响程度依次为磨削速度、磨削深度、展成速度。

**关键词:** 齿面粗糙度预测; 弧齿锥齿轮; 磨削; 机器学习; 超参数; 模型解释

**中图分类号:** V232.8; TP181 **DOI:** 10.16578/j.issn.1004.2539.XXXX.XX.001

## 0 引言

弧齿锥齿轮是实现相交轴间运动传递的基础元件, 被广泛应用于精密机床、高速铁路和航空航天等机械装备中<sup>[1-2]</sup>, 其加工精度和表面质量对于机械装备的性能、寿命和噪声等使役性能具有重要影响<sup>[3-4]</sup>。磨削加工作为弧齿锥齿轮精密加工的主要方法, 利用砂轮工作面上的众多微小磨粒的切削作用来去除材料, 是保证齿轮加工精度和齿面质量的重要工序<sup>[5-6]</sup>。

齿面粗糙度作为齿面质量的重要表征参数, 一直以来都是工业界与学术界的重点关注对象。近年来, 国内外学者对齿面粗糙度的建模方法进行了大量研究。CHEN等<sup>[7-8]</sup>提出了一种展成磨削齿轮中考虑磨粒突出高度随机分布的齿面粗糙度预测新方法,

探讨了沿齿轮渐开线表面粗糙度不均匀的主要原因。WANG等<sup>[9-10]</sup>考虑砂轮磨损引起的材料去除和砂轮与工件之间的离散化生成运动, 提出了螺旋锥齿轮和面齿轮的磨削粗糙度数学模型; WEN等<sup>[11]</sup>提出了一种在成形磨齿中考虑刀具和工件的几何条件对齿面粗糙度分布的计算模型, 并通过成形法齿轮磨削试验验证了计算模型的正确性; 陈小琦等<sup>[12]</sup>基于磨削表面粗糙度的创成机制, 提出考虑局部磨削条件变化的齿轮成形磨削表面粗糙度建模方法。虽然现有的模型能够很好地从理论上考虑磨削过程中材料去除机制及磨粒随机分布等因素的影响, 但由于加工过程中热变形、机床振动等因素的影响, 理论模型的预测结果与实际加工结果存在一定的误差。

近年来, 由于机器学习模型具有可以根据所提

收稿日期: 2024-12-26

基金项目: 工信部高质量发展专项(2023ZS20230005); 中国航发自主创新专项资金项目(ZZCX-2022-024); 湖南省自然科学基金项目(2023JJ30241); 湖南省教育厅重点项目(23A0375)

作者简介: 李佳宾, 男, 2000年生, 山西朔州人, 硕士研究生; 主要研究方向为齿轮高效精密制造; jiabin\_li0@163.com。

陈海锋(通信作者), 男, 1986年生, 湖南湘潭人, 博士, 副教授; 主要研究方向为齿轮高效精密制造; chenhf1986@126.com。

引用格式: 李佳宾, 陈海锋, 刘国亮, 等. 基于机器学习的弧齿锥齿轮齿面粗糙度预测方法[J]. 机械传动, XXXX, XX(X): 1-9.

LI Jiabin, CHEN Haifeng, LIU Guoliang, et al. Prediction method for spiral bevel gear tooth surface roughness based on machine learning[J]. Journal of Mechanical Transmission, XXXX, XX(X): 1-9.

供的数据自动学习和输出、识别非线性变量之间复杂关系的优点<sup>[13]</sup>,机器学习方法在磨削表面粗糙度建模方面的应用越来越广泛。UCAR等<sup>[14]</sup>基于机器学习方法中的高斯过程回归(Gaussian Process Regression, GPR)提出了LM25/SiC/4p复合材料磨削表面粗糙度预测模型,能够对预测值进行不确定性评估。MIRIFAR等<sup>[15]</sup>采用带有贝叶斯反向传播的前馈神经网络进行建模,预测磨削表面粗糙度并验证了理论模型的准确性。FU等<sup>[16]</sup>通过卷积神经网络建立了一种基于动态磨削力模型的氮化硅陶瓷磨削表面粗糙度预测模型,验证说明预测理论模型具有较高的泛化能力。ABYANEH等<sup>[17]</sup>考虑St37钢合金在磨削过程中的各种修整和冷却参数,采用人工神经网络方法模拟和预测表面粗糙度,结果显示,该方法比传统分析公式具有更高的精度;还可以通过丰富数据库并进行网格搜索和交叉验证,进一步增强机器学习的预测能力<sup>[18]</sup>。目前,在弧齿锥齿轮磨削加工领域,获取大量用于齿面粗糙度建模的样本数据面临诸多困难,试验数据集少并且稀疏,将机器学习方法用于考虑加工工艺参数与弧齿锥齿轮齿面粗糙度的预测研究也较少,因此,利用非常有限的训练样本提取数据特征来研究各个机器学习模型在不同加工工艺参数下弧齿锥齿轮的齿面粗糙度质量是有必要的。

为了探究不同机器学习模型在弧齿锥齿轮齿面粗糙度建模方面的适应性,充分挖掘小样本数据集中蕴含的信息,精准揭示磨削加工参数与弧齿锥齿轮齿面粗糙度之间复杂的关联规律,进而实现对弧齿锥齿轮齿面粗糙度的精确预测以及加工参数的优化,本文基于数控齿轮磨削机床的正交试验数据,采用经验方法、网格搜索技术和交叉验证相结合的方式,构建最优的DT、SVR和ANN 3种机器学习模型,对3种机器学习模型的稳定性、精确性及响应速度进行了对比分析;在此基础上,提出基于多元回归的齿轮凸面和凹面的粗糙度预测公式。同时,借助SHAP分析了各输入特征对所预测齿面粗糙度的贡献,有效解决了机器学习模型黑盒特性导致物理意义缺失的问题,为制造高性能弧齿锥齿轮提供了理论支持。

## 1 弧齿锥齿轮齿面粗糙度试验数据处理

弧齿锥齿轮磨齿为分度加工,以“假想产型轮”原理进行加工,即通过假想产型轮与被切齿轮进行啮合,在齿轮工件上加工出所需齿形。在弧齿锥齿轮磨削前,热处理工艺对齿面硬度的形成具有决定

性作用,而齿面硬度的变化进一步影响齿面粗糙度参数。故为了确保弧齿锥齿轮在磨削前具备良好的机械性能,并优化最终表面质量,需要采用合理的热处理工艺,具体包括以下3个步骤:①在900℃下进行渗碳处理,持续420 min,渗碳层深度约为1.5 mm;②将齿轮加热至800℃并保持80 min后,进行油冷淬火;③在200℃下进行回火,持续200 min,随后自然空冷。在磨削过程中,直口杯SG砂轮绕主轴高速旋转;同时,弧齿锥齿轮工件以设定的展成速度按特定的轨迹相对砂轮运动,其凸面和凹面分别与砂轮内、外侧所接触,从而磨削出弧齿锥齿轮齿面的廓形,如图1所示。本文选取黄迪青<sup>[19]</sup>针对材料为18Cr2Ni4WA的弧齿锥齿轮磨削加工的试验数据(表1),该试验于Gleason-600G数控齿轮磨削机床上开展,选用了粒度为46的诺顿直口杯SG砂轮。试验装置如图2所示,并使用CCILITE-M112白光干涉仪来测定磨削加工后的表面粗糙度。 $Sa$ 是一种区域参数,被广泛用于表面粗糙度的评估,其通过白光干涉仪中相干光干涉原理来分析干涉条纹的特征,从而准确地获取表面测量区域每个点的高度偏差;根据所测高度数据,对所测表面区域的高度偏差绝对值进行积分,计算出表面的粗糙度。计算式为:

$$Sa = \frac{1}{A} \iint |z(x, y)| dx dy \quad (1)$$

式中, $A$ 为对整个表面的测量区域面积; $|z(x, y)|$ 为表面高度与基准平面的偏差的绝对值。




图1 SG砂轮磨削弧齿锥齿轮示意图

Fig. 1 Schematic diagram of the SG grinding wheel grinding spiral bevel gear

机器学习技术凭借其能够依据给定训练数据自动学习并生成输出结果的特性,在人工智能领域发挥着重要作用。尤其是在面对有限训练样本数据集的情况下,为了深入挖掘其中蕴含的关键信息,精确揭示磨削加工参数与弧齿锥齿轮齿面粗糙度之间错综复杂的关联规律,进而预测弧齿锥齿轮齿面粗糙度,应用了DT、SVR和ANN这3种常用于解决回

归问题的机器学习算法。

表1 不同加工参数下的粗糙度数据

Tab. 1 Roughness data under different processing parameters

序号	磨削速度 $v_s/(m/s)$	展成速度 $w/[(^\circ)/s]$	磨削深度 $a_p/mm$	凸面粗糙度 $Sa/\mu m$	凹面粗糙度 $Sa/\mu m$
1	15	8	0.05	0.657	0.450
2	15	10	0.03	0.567	0.423
3	15	12	0.07	0.633	0.439
4	20	8	0.03	0.527	0.416
5	20	10	0.07	0.586	0.429
6	20	12	0.05	0.520	0.414
7	25	8	0.07	0.550	0.429
8	25	10	0.05	0.502	0.392
9	25	12	0.03	0.451	0.352
10	20	6	0.03	0.585	0.435
11	20	10	0.03	0.485	0.399
12	20	10	0.05	0.547	0.415




图2 弧齿锥齿轮磨削试验装置

Fig. 2 Spiral bevel gear grinding test device

为了更好地比较不同机器学习模型的性能, 考虑到本研究数据样本有限, 分布相对稀疏, 可能出现缺少重要信息和数据相互作用的影响, 本文根据表1基于磨削速度、展成速度和磨削深度对弧齿锥齿轮磨削表面粗糙度进行的正交试验和单因素试验来选择训练和测试数据集。具体地, 数据集以3: 1的比例被分割为训练数据和测试数据, 正交试验数据(试验1~9)为机器学习的训练集, 单因素试验数据(试验10~12)则用于模型的拟合和验证训练方案的结果。

## 2 基于机器学习的弧齿锥齿轮齿面粗糙度建模

### 2.1 DT

基于树模型的可解释性、易于理解且分类数据能力强而广受欢迎<sup>[20]</sup>。决策树方法提供的树结构(图3)可以容易地可视化和理解。决策树在回归构建过程中是一个递归的过程, 将变量空间划分为 $D$ 个区域, 即 $R_d=1, \dots, R_d=D$ , 通过选择最佳的属性来进行数据划分, 使得划分后子集的输出值尽可能接近

真实值。

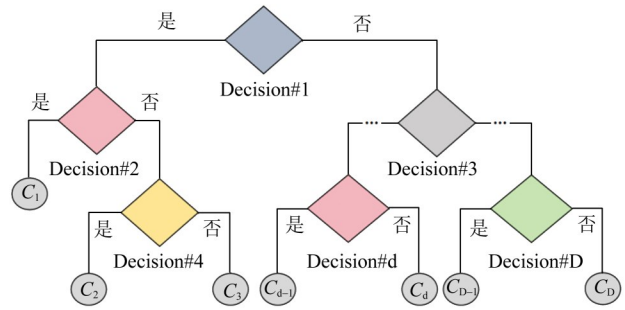


图3 决策树模型示意图

Fig. 3 Schematic diagram of the decision tree model

### 2.2 SVR

支持向量机回归(图4)的核心原理如下: 通过最小化预测误差来拟合数据, 并且在拟合过程中在线性函数两侧制造一个“间隔带”, 最后根据最小化总损失和最大化间隔得出优化后的模型。最终所得的模型函数为 $f(x) = wx + b$ , 其中, 函数的优化目标为

$$\min_{w,b} \frac{1}{2} w^2 \quad (2)$$

位于边界内的点需满足条件

$$|y_i - (wx_i + b)| \leq \varepsilon \quad (3)$$




图4 支持向量机模型示意图

Fig. 4 Schematic diagram of support vector machine model

### 2.3 ANN

ANN是从信息处理角度对人脑神经网络进行模拟计算的模型(图5), 其由大量的处理单元互连接而成, 每个神经元都可以看作是一个独立的学习模型; 接收多个输入值, 根据权重和激励函数处理这些信号, 不断迭代训练和更新, 以减少预测值和实际值之间的误差; 每次迭代后的误差将通过链式法则迭代计算每层的梯度, 更新下一次迭代的权值, 最终得到输出值。

### 2.4 模型调整

在机器学习模型训练过程中, 超参数对模型的




图5 神经网络模型示意图

Fig. 5 Schematic diagram of artificial neural network model

性能和泛化能力具有重要影响。由于超参数是在模型训练前由用户预先定义，因此，合理的超参数设置可以显著提升模型的预测准确性。本文通过经验方法、网格搜索技术和交叉验证等方法对各模型的超参数进行系统调校，以优化模型在本数据集上的预测性能。表2所示为在超参数取值范围内经过充分调优后，3种机器学习模型在回归评价指标中获得最佳表现时的超参数设定。

DT模型的超参数主要影响树的复杂度，从而对模型的泛化能力和训练时长产生影响。在该模型中，最大深度(max-depth)是主要的超参数之一，调整范围设定为2~5，其决定了树的最大层级数。经过调整后，最小叶子节点样本数(Minimum Number of Samples Required for a Leaf Node, min-samples-leaf)和最小样本分裂数(Minimum Number of Samples Required for Splitting, min-samples-split)均被设定为2，从而确保模型在复杂度和泛化能力之间取得良好的平衡。支持SVR的超参数设定主要影响分类边界的确定和优化过程。在本研究中，采用了径向基核函数(Radial Basis Function Kernel, Rbf)，并通过网格搜索方法调整了正则化参数 $C$ ，设定其值为1，以缓解过拟合并优化分类边界，进而增强支持向量机在测试数据上的泛化能力和稳定性。ANN模型具备较高灵活性，其超参数涵盖网络结构、训练流程及优化方法等多个层面，在本研究中，输入层包含3个神经元，每个输入参数由1个神经元表示，输出层包含1个神经元。经过求解将隐藏层数调整为3层，且每层神经元数量(Hidden-layer-sizes)分别为(5, 3, 3)，除此之外，还将控制随机选择的参数(random-state)设为34，最大迭代次数(Maximum Number of Iterations, Max-iter)设为100，求解器(Solver)选用拟牛顿法中的Ibfgs算法变种，激活函数(Activation Function)采

用双曲正切函数(Hyperbolic Tangent Function, Tanh)，以确保神经网络在训练和验证数据集上表现出良好的收敛性和泛化能力。

表2 回归评价函数最高的超参数值  
Tab. 2 Highest hyperparameter value of the regression evaluation function

模型	超参数	最优超参值
决策树	Max-depth	3
	Min-samples-leaf	2
	Min-samples-split	2
支持向量机	Kernel-Function	Rbf
	C	1
神经网络	Solver	Ibfgs
	Activation Function	Tanh
	Hidden-layer-sizes	(5, 3, 3)
	Max-iter	100
	Random-state	34

### 3 机器学习模型的评估

#### 3.1 机器学习稳定性分析

对机器学习数据进行数据集归一化以确保收敛性，再进行模型训练。归一化公式为

$$x' = \frac{x - X_{\min}}{X_{\max} - X_{\min}} \quad (4)$$

式中， $x'$ 为归一化数据； $x$ 为原始数据； $X_{\max}$ 和 $X_{\min}$ 分别为 $x$ 所在数据列的最大值和最小值。

为了深入了解机器学习模型的准确性，通过DT、SVR和ANN 3种模型预测弧齿锥齿轮齿面粗糙度在20次运行后的结果，并选择均方根误差(Root Mean Squared Error, RMSE)和决定系数(Coefficient of Determination,  $R^2$ )作为评估指标。其中，RMSE越小， $R^2$ 越接近1，预测性能越好。

$R^2$ 回归评价函数也称为决定系数，通常用于比较同一问题不同模型的回归质量，是残差平方和与总平方和之比的差值，公式如下

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

式中， $\hat{y}_i$ 、 $y_i$ 和 $\bar{y}$ 分别为预测值、实际值和平均值。若 $R^2=1.0$ ，表示模型与数据拟合较好； $R^2=0.0$ ，表示预测值是不变的，即为训练数据的平均值。除此之外， $R^2$ 的得分可能为负数，则表示模型拟合效果较差。

RMSE是预测值与真实值偏差的平方与观测次数 $n$ 比值的平方根，公式如下

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (6)$$

式中,  $n$  为拟合样本总数。

图6为表示3种模型RMSE和 $R^2$ 的分布的小提琴图。可以发现, 3种机器学习方法中, DT稳定性最差, 训练集和测试集都比较高, 表现出欠拟合状态, 当数据集样本规模较小时, 决策树模型并不太适用; SVR在训练集效果较好, 但测试集表现略低, 呈现典型的过拟合状态, 出现该情况可能与模型本身的工作过程有关或者特征中包含大量噪声和冗余特征所造成的; 而ANN在训练集和测试集上的评价指标得分都比较优秀, 且优于其他模型, 说明模型完美拟合数据。

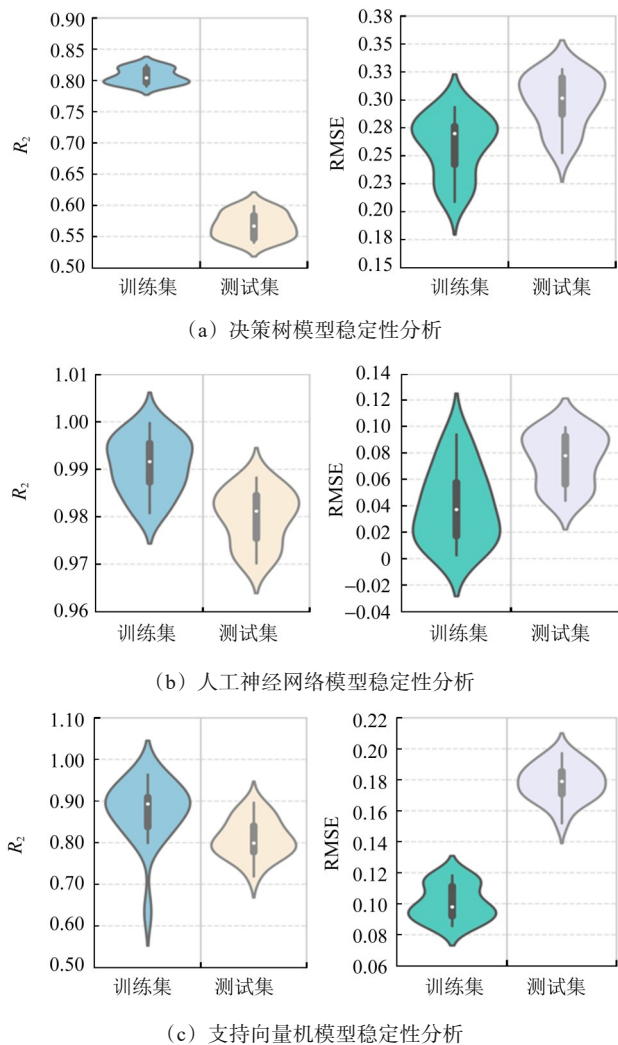


图6 机器学习模型的稳定性

Fig. 6 Stability of machine learning models

### 3.2 机器学习对粗糙度预测的线性回归分析

为了对上述模型训练的准确性进行验证, 对3种机器学习模型下弧齿锥齿轮凸面和凹面粗糙度预测进行了线性回归分析。

图7所示为决策树(DT)对弧齿锥齿轮齿面粗糙度预测的线性回归分析。训练集和测试集的数据点在对角线附近较为分散, 不能够很好地拟合数据, 说明该模型对问题领域的理解不足, 导致在数据理解、特征工程和模型评估中出现偏差或错误。图8所示为ANN对弧齿锥齿轮齿面粗糙度预测的线性回归分析。其所有数据点都集中在对角线附近, 可以完美拟合数据, 精确地对弧齿锥齿轮齿面粗糙度进行预测分析。相比上述两个机器学习模型, SVR对弧齿锥齿轮齿面粗糙度预测精度介于其他两种模型之间(图9), 造成此现象的原因可能与数据中缺失值、异常值或噪声数据有关, 从而影响模型的训练和泛化能力。线性回归分析结果说明, ANN的预测模型精度较高, DT拟合效果最差, SVR次之, 验证了3种机器训练模型的准确性。

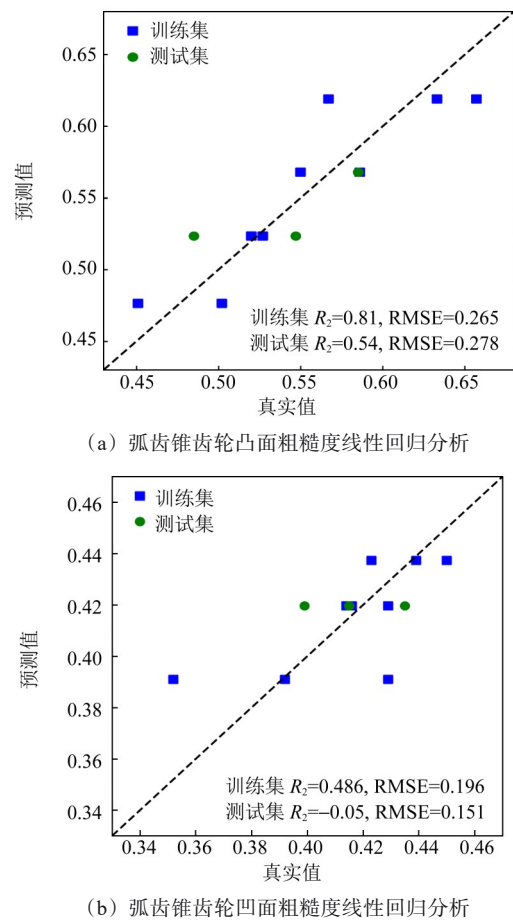



图7 决策树对弧齿锥齿轮齿面粗糙度预测的线性回归分析


Fig. 7 Decision tree linear regression analysis for predicting surface roughness of spiral bevel gears

### 3.3 机器学习模型响应速度分析

机器学习模型的响应速度在实际生产中举足轻重图10所示为3种机器学习模型的拟合时间和预测时间, 其训练集和测试集的响应时间均为20次运行



(a) 弧齿锥齿轮凸面粗糙度线性回归分析



(b) 弧齿锥齿轮凹面粗糙度线性回归分析


图8 神经网络对弧齿锥齿轮齿面粗糙度预测的线性回归分析

Fig. 8 Artificial neural network linear regression analysis for predicting surface roughness of spiral bevel gears

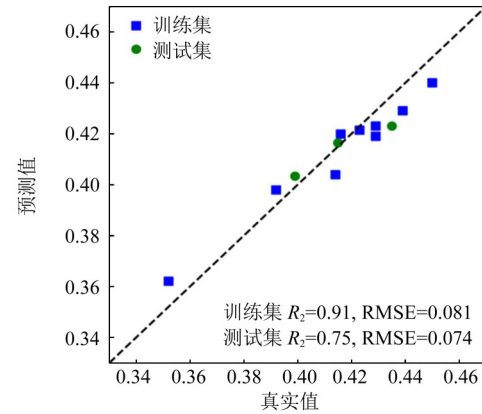
花费的平均时间。在3种机器学习模型运算中,都具有较短的拟合时间和预测时间,这可能是由于本研究的数据样本数量较少。通过对比,SVR和DT模型显示出较大的拟合速度效率,但其本身的预测精度较低;而ANN拟合速度效率最低,出现这种情况可能与ANN的反向传播性质有关。

### 3.4 基于ANN模型的齿面粗糙度预测公式

基于上述3种机器学习方法对弧齿锥齿轮齿面粗糙度的预测,考虑了磨削速度、展成速度和磨削深度等加工参数对齿面粗糙度的影响规律。为了进一步提升预测模型的可解释性和适应性,采用多元线性回归分析方法,定量表征各个加工参数与弧齿锥齿轮齿面粗糙度之间的映射关系。在建模过程中,以磨削速度、展成速度和磨削深度等3个加工参数为设计变量,设定其数值范围,如表3所示。首先,利用ANN模型建立较高精度的训练样本数据;随后,通过最小二乘法求解回归系数并建立多元线性回归模型,从而拟合出各个加工参数与弧齿锥齿轮凸面



(a) 弧齿锥齿轮凸面粗糙度线性回归分析



(b) 弧齿锥齿轮凹面粗糙度线性回归分析

图9 支持向量机对弧齿锥齿轮齿面粗糙度预测的线性回归分析

Fig. 9 Support vector regression linear regression analysis for predicting surface roughness of spiral bevel gears




图10 3种机器学习模型的响应时间

Fig. 10 Response time of three machine learning models

和凹面粗糙度之间的函数关系式,即

$$Sa_{凸} = 1.4220 - 0.0522x_1 - 0.0588x_2 + 2.1000x_3 + 0.0007x_1^2 + 0.0006x_2^2 + 0.0015x_1x_2 + 0.0433x_1x_3 + 0.1000x_2x_3 \quad (7)$$

$$Sa_{凹} = 1.2828 - 0.0230x_1 - 0.0944x_2 - 6.1833x_3 + 0.0030x_2^2 + 0.0008x_1x_2 + 0.1967x_1x_3 + 0.3333x_2x_3 \quad (8)$$

式中,  $x_1$ 、 $x_2$ 、 $x_3$  分别为加工参数中磨削速度、齿轮展成速度和磨削深度的值;  $S_{a凸}$  和  $S_{a凹}$  分别为弧齿锥齿轮凸面和凹面的粗糙度预测值。

表3 设计变量的取值范围

Tab. 3 Range of design variables is defined

设计变量	磨削速度 $v_s/(m/s)$	展成速度 $w/[(^\circ)/s]$	磨削深 $a_p/mm$
取值范围	10~25	5~15	0~0.1

通过 Matlab 软件得到的三维模型拟合曲面如图 11 所示。

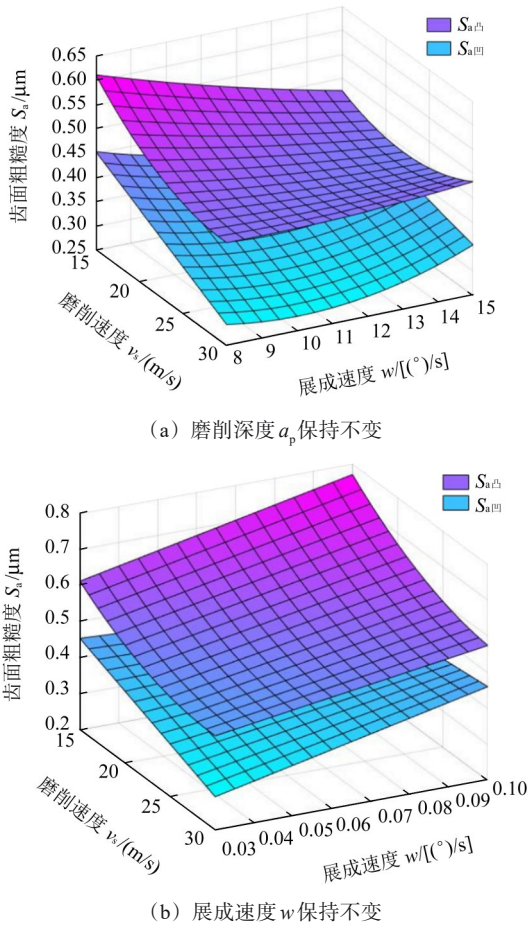


图 11 不同磨削工艺参数下齿面粗糙度拟合曲面

Fig. 11 Fitting of surface roughness of tooth profile under different grinding process parameters

使用该模型对不同磨削工艺参数下弧齿锥齿轮凸面和凹面粗糙度数据集中的 3 组测试数据集进行验证预测精度。图 12 为测试数据集中 3 组粗糙度预测误差图。可以看出, 3 组预测的齿轮凸面粗糙度值最大相对误差为 7.2%, 弧齿锥齿轮凸面和凹面的平均相对误差分别为 3.5% 和 6.09%, 公式预测精度满足要求, 可以用于弧齿锥齿轮齿面粗糙度参数的优化设计。

#### 4 输入特征参数的重要性分析

在进行磨削试验时, 磨削速度、磨削深度和齿




图 12 齿面粗糙度预测误差

Fig. 12 Prediction error of tooth surface roughness

轮展成速度都会对弧齿锥齿轮的表面粗糙度产生影响。为了更全面地探究各因素对齿轮凸面和凹面粗糙度的影响程度和主次关系, 且由于机器学习模型黑盒特性带来的物理意义的缺失, 在本研究中对试验数据进行了详细的处理和分析。使用 SHAP 分析了模型中各输入特征对弧齿锥齿轮齿面粗糙度的贡献, 该模型基于博弈论中的 Shapley 值来确定每个特征对博弈总体结果的贡献。对于特征集  $S$  中的特征  $i$ , Shapley 值计算如下

$$\phi_i = \sum_{s \subseteq N \setminus \{i\}} \frac{|S|!(|N| - |S| - 1)!}{|N|} [v(S \cup \{i\}) - v(S)] \quad (9)$$

式中,  $N$  为所有特征的集合;  $S$  为不包含特征  $i$  的任何一个特征子集;  $|S|$  为集合  $S$  中的特征数;  $v(S)$  为特征集  $S$  对模型预测输出的贡献;  $v(S \cup \{i\})$  为包含特征  $i$  的特征集 ( $S \cup \{i\}$ ) 对模型预测输出的贡献。

图 13、图 14 所示为输入参数对输出目标特征的影响。其中, 纵轴根据所有样本的 SHAP 值进行排名, 表示这些特征对模型预测的贡献程度; 横轴为 SHAP 值, 表示输入特征对模型输出影响的分布。观察可知, 磨削速度的特征值散点分布离中心线最远, 那么, 该特征对模型预测影响最大, 磨削深度对模型的影响程度次之, 齿轮展成速度最小。

#### 5 总结

基于磨削弧齿锥齿轮不同加工参数的正交试验数据, 采用机器学习方法建立了弧齿锥齿轮凸面和凹面粗糙度的预测模型, 探究了磨削加工参数对齿面粗糙度的影响规律, 并对弧齿锥齿轮凸面和凹面的粗糙度进行预测, 得到以下结论:

- 1) 通过经验方法、网格搜索技术和交叉验证进




图 13 输入特征对弧齿锥齿轮凸面粗糙度重要性分析

Fig. 13 Analysis of the importance of input features on convex surface roughness of spiral bevel gears




图 14 输入特征对弧齿锥齿轮凹面粗糙度重要性分析

Fig. 14 Analysis of the importance of input features on concave surface roughness of spiral bevel gears

行超参数优化所建立的DT、SVR和ANN这3种最优机器学习模型，对其进行训练可知，DT和支持向SVR分别表现出欠拟合和过拟合的状态，因此，不推荐使用；ANN模型可以完美地拟合试验数据，但拟合速度效率相比其它两个模型较低；对3种模型训练的准确性进行了线性回归验证，有助于实现弧齿锥齿轮齿面粗糙度的预测。

2) 提出了基于多元回归的弧齿锥齿轮凸面和凹面的粗糙度与磨削加工参数中磨削速度、展成速度以及磨削深度之间的关系式，对所得凸面和凹面3组测试数据集预测的平均相对误差分别为3.5%和6.09%。

3) 通过机器学习模型解释工具(SHAP)探究出各因素对齿轮凸面和凹面粗糙度的影响程度为磨削速度>磨削深度>展成速度，表明了各输入特征对所预测齿面粗糙度的贡献。

基于有限试验数据的机器学习模型预测对制造业有很重要的意义，通过选择合适的训练数据，可以预测特征变量与目标的相对关系，从而快速实现工艺优化。

#### 参 考 文 献

[1] 钱露露, 刘海鸥, 高鉴, 等. 航空弧齿锥齿轮接触印痕主动设计与试验验证[J]. 机械传动, 2024, 48(5): 122-130.  
QIAN Lulu, LIU Haiou, GAO Jian, et al. Active design of contact pattern and experimental verification of the aero spiral bevel gear [J]. Journal of Mechanical Transmission, 2024, 48(5): 122-130.

[2] 张旭阳, 王三民, 李林林, 等. 航空弧齿锥齿轮副风阻功率损失分析与优化[J]. 航空动力学报, 2023, 38(4): 976-985.  
ZHANG Xuyang, WANG Sanmin, LI Linlin, et al. Analysis and optimization of windage power loss for aeronautical spiral bevel gear pair [J]. Journal of Aerospace Power, 2023, 38(4): 976-985.

[3] WEI J, PAN Z, LIN X, et al. Copula-function-based analysis model and dynamic reliability of a gear transmission system considering failure correlations [J]. Fatigue & Fracture of Engineering Materials & Structures, 2019, 42(1): 114-128.

[4] 刘斌, 剡昌锋, 魏理林, 等. 弧齿锥齿轮复合磨粒磨削性能仿真与分析[J]. 机械强度, 2023, 45(3): 684-691.  
LIU Bin, YAN Changfeng, WEI Lilin, et al. Simulation and analysis of compound abrasive grinding performance of spiral bevel gears [J]. Journal of Mechanical Strength, 2023, 45(3): 684-691.

[5] 彭先龙, 赵朋辉, 胡锡文, 等. 基于四轴数控机床床面齿轮磨削方法[J]. 航空动力学报, 2021, 36(5): 1113-1120.  
PENG Xianlong, ZHAO Penghui, HU Xiwen, et al. Grinding method for face gear based on four-axis CNC machine tool [J]. Journal of Aerospace Power, 2021, 36(5): 1113-1120.

[6] MA X F, CAI Z Q, YAO B, et al. Prediction model for surface generation mechanism and roughness in face gear grinding [J]. The International Journal of Advanced Manufacturing Technology, 2022, 120(7): 4423-4442.

[7] CHEN H F, TANG J Y, ZHOU W. Modeling and predicting of surface roughness for generating grinding gear [J]. Journal of Materials Processing Technology, 2013, 213(5): 717-721.

[8] CHEN H F, TANG J Y, ZHOU W H, et al. The equal theoretical surface roughness grinding method for gear generating grinding [J]. The International Journal of Advanced Manufacturing Technology, 2017, 90(9): 3137-3146.

[9] WANG Y Z, CHEN Y Y, ZHOU G M, et al. Roughness model for tooth surfaces of spiral bevel gears under grinding [J]. Mechanism and Machine Theory, 2016, 104: 17-30.

[10] WANG Y Z, LIU Y, CHU X M, et al. Calculation model for surface roughness of face gears by disc wheel grinding [J]. International Journal of Machine Tools and Manufacture, 2017, 123: 76-88.

[11] WEN J, TANG J Y, ZHOU W H. Study on formation mechanism and regularity of residual stress in ultrasonic vibration grinding of high strength alloy steel [J]. Journal of Manufacturing Processes, 2021, 66: 608-622.

[12] 陈小琦, 唐成, 廖祥贵, 等. 考虑局部磨削条件变化的齿轮成形磨削表面粗糙度建模研究[J]. 机械传动, 2023, 47(8): 9-15.  
CHEN Xiaoqi, TANG Cheng, LIAO Xianggui, et al. Study on tooth surface roughness modeling of form grinding considering the change of the local grinding condition [J]. Journal of Mechanical Transmission, 2023, 47(8): 9-15.

[13] MAHMOOD M A, VISAN A I, RISTOSCU C, et al. Artificial neural network algorithms for 3D printing [J]. Materials, 2020, 14(1): 163.

[14] UÇAR F, KATI N D. Machine learning based predictive model for

- surface roughness in cylindrical grinding of al based metal matrix composite [J]. *European Journal of Technic*, 2020, 10 (2) : 415-430.
- [15] MIRIFAR S, KADIVAR M, AZARHOUSHANG B, et al. First steps through intelligent grinding using machine learning *via* integrated acoustic emission sensors[J]. *Journal of Manufacturing and Materials Processing*, 2020, 4(2) : 35.
- [16] FU H, JIANG L P, SONG Q H, et al. Grinding surface roughness prediction for silicon nitride ceramics: a dynamic grinding force and frequency domain approach[J]. *Ceramics International*, 2023, 49(22) : 35239-35253.
- [17] ABYANEH M D, NARIMANI P, HADAD M, et al. Using machine learning and optimization for controlling surface roughness in grinding of St 37 Authors[J]. *Energy Equipment and Systems*, 2023, 11(3) : 321.
- [18] LIU X, LIU T Q, FENG P. Long-term performance prediction framework based on XGBoost decision tree for pultruded FRP composites exposed to water, humidity and alkaline solution[J]. *Composite Structures*, 2022, 284: 115184.
- [19] 黄迪青. 螺旋伞齿轮磨削表面完整性实验与仿真研究[D]. 北京:北京理工大学, 2018; 29-35.  
HUANG Diqing. 螺旋伞齿轮磨削表面完整性实验与仿真研究 Experimental and simulation study on grinding surface integrity of spiral bevel gear [D]. Beijing: Beijing Institute of Technology, 2018.
- [20] SONG Y Y. Decision tree methods: applications for classification and prediction[J]. *Shanghai Archives of Psychiatry*, 2015, 27(2) : 130-135.

## Prediction method for spiral bevel gear tooth surface roughness based on machine learning

LI Jiabin<sup>1</sup> CHEN Haifeng<sup>1</sup> LIU Guoliang<sup>2</sup> ZHOU Changjiang<sup>3</sup>

(1. School of Mechanical and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201, China)

(2. AECC Central Transmission Machinery Co., Ltd., Changsha 410200, China)

(3. College of Mechanical and Vehicle Engineering, Hunan University, Changsha 410082, China)

**Abstract:** [Objective] To address the issues of parameter optimization and prediction accuracy of the surface roughness of spiral bevel gears, and to overcome the limitations of traditional methods in effectively handling complex nonlinear relationships and the influence of multiple variables, machine learning model is used to predict the surface roughness of the spiral bevel gears. [Methods] Firstly, based on the spiral bevel gear grinding test dataset, decision tree (DT), support vector machine (SVR), and artificial neural network (ANN) methods are applied to construct roughness prediction models for the convex and concave surfaces of spiral bevel gears, and the prediction results of the three machine learning models are compared. Secondly, based on this, a multiple linear regression method is used to derive a tooth surface roughness prediction formula that considers the processing parameters of spiral bevel gears. Finally, the contribution of each input feature to the predicted tooth surface roughness is analyzed using the machine learning model explanation tool (SHAP), providing theoretical support for the application of machine learning in high-performance gear manufacturing. [Results] The results show that the DT and SVR exhibit underfitting and overfitting, respectively, leading to poor prediction performance. The ANN accurately fits the data and predicts tooth surface roughness with high precision, but its computational efficiency is relatively low. The average relative errors in predicting the roughness of the convex and concave surfaces of the spiral bevel gear are 3.5% and 6.09%, respectively. The influence of the input processing parameters on the predicted tooth surface roughness follows the order of grinding speed, grinding depth, and generating speed.

**Key words:** Tooth surface roughness prediction; Spiral bevel gear; Grinding; Machine learning; Hyperparameter; Model interpretation

(编辑: 刘星泽)