

文章编号:1671-6833(2024)01-0021-08

# 基于遗传算法的磨削力模型系数优化及验证

王 栋, 张志鹏, 赵 睿, 张君宇, 乔瑞勇, 孙少锋

(郑州大学 机械与动力工程学院, 河南 郑州 450001)

**摘 要:**在磨削力模型求解问题中,目前大多使用分段算法或列方程组直接计算各个待求系数,不仅计算量大且其精度也无法保证。另外,传统的回归模型容易陷入局部最优,难以描述非线性关系。为此,将遗传算法引入到非线性优化函数参数优化中,基于外圆横向磨削力模型、平面磨削力模型、外圆纵向磨削力模型等现有的模型数据,开展磨削力理论模型的系数优化方法研究。相关性分析结果表明:通过计算得到的 3 种模型磨削力的预测精度提高了 14.69%~42.54%,且 3 种模型所预测的法向磨削力的平均误差分别为 5.9%、9.13%、3.23%,切向力平均误差分别为 6.78%、8.36%、3.69%。经对比知,优化后的模型拟合度较好,模型预测精度显著提高。遗传算法优化后的非线性优化函数 GA-LSQ 算法更适合磨削力模型的求解,可对磨削力的预测及实际加工生产中的参数优化提供参考。

**关键词:**磨削力模型; 外圆磨削; 平面磨削; 经验公式; 模型系数优化; 模型预测; 遗传算法; 非线性优化函数

**中图分类号:**TH16;TG58

**文献标志码:**A

**doi:**10.13705/j.issn.1671-6833.2023.04.010

磨削具有较高的材料去除能力和加工精度,普遍应用于难切削材料的轴类零件加工生产中,尤其是在零件的最终加工阶段,需要保证较好的表面完整性和精确的公差,磨削工艺是实现这一目的的最优加工方法。磨削加工过程中影响加工质量的参数较多,其中磨削力是与磨削参数和磨削质量相关的重要过程变量,常常被用来对磨削质量进行分析和预测。因此,建立科学有效的磨削力理论模型,对磨削力的预测及实际加工生产中的参数选择具有十分重要的意义<sup>[1]</sup>。

近年来,国内外许多学者在影响磨削力的加工参数和预测模型等方面对磨削力进行了诸多研究。Maeng 等<sup>[2]</sup>将磨削分为摩擦、耕犁和切屑 3 个阶段磨削力的模型,预测的力与小接触面积的磨削过程吻合较好,但与大接触面积的实验结果略有偏差。Zhou 等<sup>[3]</sup>使用了 BP 和 GABP 两种模型分别预测钛基复合材料在深磨过程中的磨削力,结果表明, GABP 与传统回归模型和 BP 模型相比具有更好的预测精度。詹友基等<sup>[4]</sup>对纳米硬质合金 GU092 为主的 3 种硬质合金磨削力进行实验研究,并使用

RBF 神经网络对磨削力进行预测,其误差在 5% 以下。Li 等<sup>[5]</sup>根据磨粒与材料的接触摩擦力、塑性变形、剪切应变效应 3 个关键因素建立了平面磨削三段式的磨削力模型,并使用分段比例法求解该模型,最终得到法向和切向磨削力的预测误差分别为 13.6% 和 9.8%。马少奇<sup>[6]</sup>利用锥形磨粒等效模型,计算了动态切削刃密度,并结合塑性堆积和材料去除机理,建立了不同磨削阶段的磨削力预测模型,并使用分段比例法求解模型待求系数,该模型法向和切向磨削力的预测误差分别为 8.7% 和 11.8%。Jamshidi 等<sup>[7]</sup>通过考虑磨粒与工件之间的微观相互作用,针对平面磨削建立了一种考虑不同磨削阶段的磨削力预测模型,该模型切向磨削力和法向磨削力的预测误差分别为 12% 和 11%。Kovač 等<sup>[8]</sup>使用回归分析和遗传算法来求解外圆磨削切削力模型,结果表明,这两种方法均可用于切削力建模,遗传算法略有优势,相比回归分析方法所求解的模型精度提高 34%。

近年来业内关于磨削的研究较多,并且建立起了多种磨削力模型,但针对磨削力理论模型的预测

收稿日期:2023-02-18;修订日期:2023-03-10

基金项目:国家自然科学基金联合基金重点项目(U1804254)

作者简介:王栋(1970—),男,河南沁阳人,郑州大学教授,博士,主要从事关键件的抗疲劳制造技术、精密与超精密加工技术研究,E-mail:wangdong@zzu.edu.cn。

引用本文:王栋,张志鹏,赵睿,等. 基于遗传算法的磨削力模型系数优化及验证[J]. 郑州大学学报(工学版),2024,45(1):21-28. (WANG D, ZHANG Z P, ZHAO R, et al. Coefficient optimization of grinding force model based on genetic algorithm[J]. Journal of Zhengzhou University (Engineering Science), 2024, 45(1): 21-28.)

误差都普遍偏高,基本都处在 10%~15%,对实际工程实践的参考意义有限。目前求解模型时大多使用分段计算法或列方程组直接计算各个待求系数,不仅计算量大且其精度也无法保证。本文在现有磨削理论模型的基础上,基于遗传算法优化的非线性优化函数(genetic algorithm-lsqnonlin,GA-LSQ)求解模型待求系数,对磨削力的预测及实际加工生产中的参数优化提供参考。

### 1 模型分类及选取

目前国内外学者对于磨削力的模型研究方法众多,其大致可分为 4 类:基于力学模型基础的解析法<sup>[5-6]</sup>、基于实验的经验方法<sup>[8-10]</sup>、有限元分析法<sup>[11]</sup>、人工智能预测模型<sup>[12]</sup>。本文主要针对前两种建模方法进行求解。

解析法是通过分析磨削过程中的材料去除机理,剪切应变效应和磨粒分布、形状等建立磨削力的解析模型。通过解析法所建立的磨削力模型主要分为外圆、平面、内圆、成形磨削等,而目前的磨削力模

型研究大多集中于外圆和平面,对内圆的研究很少。经验模型法主要通过建立加工参数和磨削力的非线性指数函数关系来预测磨削力的大小,优点在于简单实用、适用范围广。

目前学者在建立磨削力模型时将过程参数(磨粒形状、磨粒密度、磨粒方向,摩擦系数等)都通过公式推导而整合转化成最终的待求参数 $k(k_1,k_2,\cdots)$ 的形式,即将多个过程参数通过乘积最终转化为一个待求参数。为验证本文计算方法的普适性,分别对 Li 等<sup>[5]</sup>建立的平面磨削力模型、马少奇<sup>[6]</sup>建立的外圆横向磨削力模型、赵静雯<sup>[13]</sup>建立的成形磨削力模型、蔡卫星等<sup>[14]</sup>建立的超声磨削力模型以及 Kovač 等<sup>[8]</sup>建立的外圆纵向磨削力模型进行相应的计算验证,误差均在 10%以下。因此本文所提出的计算方法对不同形式的解析、经验模型都同样适用。

为论述计算方法的详细求解过程以文献[5-6,8]模型作为算法验证对象,根据原文献实验获得并划分的训练集及验证集数据进行求解验证。3 种磨削力模型形式与具体参数如表 1 所示。

表 1 模型形式参数表  
Table 1 Table of model formal parameters

模型分类	方法	训练集/ 验证集	实验 材料	砂轮 型号	待求参 数数量	公式
外圆横向 磨削力模型	解析法 <sup>[5]</sup>	10 组/ 15 组	18CrNiMo7-6	PA60L5V35	12	$\left\{ \begin{aligned} F_t &= k_1' \frac{f_a^{0.5} v_w b}{v_s d_s} \sqrt{\frac{d_s d_w}{d_s + d_w}} + k_3' \left( \frac{v_w}{v_s} \right)^{\alpha_1} f_a^{0.5+\alpha_2} d_s^{\alpha_3} b \cdot \\ &\quad \sqrt{\frac{d_s d_w}{d_s + d_w}} + k_5' f_r^{\alpha_4} f_a^{\alpha_5} \left( \frac{v_w}{v_s} \right)^{\alpha_1} b^{\alpha_6} \\ F_n &= k_2' \frac{f_a^{0.5} v_w b}{v_s d_s} \sqrt{\frac{d_s d_w}{d_s + d_w}} + k_4' \left( \frac{v_w}{v_s} \right)^{\alpha_1} f_a^{0.5+\alpha_2} d_s^{\alpha_3} b \cdot \\ &\quad \sqrt{\frac{d_s d_w}{d_s + d_w}} + k_6' f_r^{\alpha_4} f_a^{\alpha_5} \left( \frac{v_w}{v_s} \right)^{\alpha_1} b^{\alpha_6} \end{aligned} \right.$
平面磨 削力模型	解析法 <sup>[6]</sup>	10 组/ 15 组	FGH96	CBN805E170	14	$\left\{ \begin{aligned} F_t &= k_2' a_p^{0.5} \frac{v_w b}{d_s^{0.5} v_s} + k_3' \left( \frac{v_w}{v_s} \right)^{\alpha_1} a_p^{0.5+\alpha_2} d_s^{0.5+\alpha_3} b \sin \theta + \\ &\quad (k_8' + k_9' \ln(v_w^{\beta_1} v_s^{1-\beta_1} a_p^{\beta_2} d_s^{\beta_3} \cos \theta)) \frac{b^2 v_w a_p^{1.5} d_s^{0.5}}{v_s} \\ F_n &= k_1' a_p^{0.5} \frac{v_w b}{d_s^{0.5} v_s} + k_4' \left( \frac{v_w}{v_s} \right)^{\alpha_1} a_p^{0.5+\alpha_2} d_s^{0.5+\alpha_3} b \tan \theta \sin \theta + \\ &\quad (k_{10}' + k_{11}' \ln(v_w^{\beta_1} v_s^{1-\beta_1} a_p^{\beta_2} d_s^{\beta_3} \cos \theta)) \frac{b^2 v_w a_p^{1.5} d_s^{0.5}}{v_s} \end{aligned} \right.$
外圆纵向 磨削力模型	经验法 <sup>[8]</sup>	10 组/ 14 组	EN 18CrNi8	B60L6V	8	$\left\{ \begin{aligned} F_t &= C_1 \cdot v_r^{x_1} \cdot s_a^{y_1} \cdot a^{z_1} \\ F_n &= C_2 \cdot v_r^{x_2} \cdot s_a^{y_2} \cdot a^{z_2} \end{aligned} \right.$

2 外圆横向磨削力模型求解

本文主要针对外圆横向磨削力理论模型的求解过程进行说明。为了准确预测分析各个磨削参数对磨削力的影响效果,必须较好地拟合出公式中的各个待求系数,本文基于遗传算法优化非线性优化函数(GA-LSQ)针对上述公式进行非线性回归分析。

2.1 遗传算法

遗传算法(GA)是一种基于生物进化原理构想出来的仿生算法,模拟基因重组与进化的自然过程,把待解决问题的参数变成二进制码或其他进制即基因,若干基因组成一个染色体(个体)<sup>[15]</sup>。该算法将随机产生的一代染色体作为候选解并计算其适应度,采用优胜劣汰的方法选择个体进行选择、交叉、变异等遗传操作,保留适应度高的染色体作为新一代种群,向着更优解的方向进化,最终获得最优的一组染色体,从而达到某种预定的优化收敛指标,具有多参数、多组合和随机性强的寻优特点。遗传算法的具体计算步骤如下。

步骤 1 对磨削力公式的待求系数采用实数编码的方式进行编码。由外圆磨削力公式可得待求系数为 12 个,故染色体个体编码长度为 12,从而得到种群中初始染色体。

步骤 2 遗传算法适应度函数取若干组数据误差的二范数作为适应度函数  $S$ ,其误差越小,适应度函数值越小<sup>[16]</sup>。

步骤 3 使用轮盘赌算法在当前种群中选择适应度较高染色体进行复制,进一步产生新的种群。

步骤 4 根据适应度函数,使用轮盘赌算法在当前种群中选择适应度较高染色体作为父代染色体进行选择、交叉、变异等遗传操作,在新产生的一代种群中选择适应度高的染色体作为下一代种群,染色体编码的基因选择概率  $p_x$ <sup>[17]</sup>为

$$p_x = f_x / \sum_{j=1}^N f_j; \tag{1}$$

$$f_x = k / F_x。 \tag{2}$$

式中:  $F_x$  为个体  $x$  的适应度值;  $N$  为种群染色体数量;  $k$  为常数。

步骤 5 第  $k$  条染色体  $A_{kj}$  与第  $l$  条染色体  $A_{lj}$  之间在  $j$  处发生的交叉操作的方法如下:

$$\begin{cases} A_{kj}' = A_{kj}(1 - \alpha) + \alpha A_{lj}; \\ A_{lj}' = A_{lj}(1 - \alpha) + \alpha A_{kj}。 \end{cases} \tag{3}$$

式中:  $\alpha$  为  $[0,1]$  的随机数。

步骤 6 第  $k$  个染色体中的第  $l$  个基因  $a_{kl}$  的变异过程如下:

$$a_{kl} = \begin{cases} a_{kl} + (a_{kl} - a_{\max}) \cdot f(g), & r > 0.5; \\ a_{kl} + (a_{\min} - a_{kl}) \cdot f(g), & r \leq 0.5。 \end{cases} \tag{4}$$

$$f(g) = r_2 \left( 1 - \frac{g}{G_{\max}} \right)^2。 \tag{5}$$

式中:  $a_{\max}$  为基因  $a_{kl}$  中的最大值;  $a_{\min}$  为基因  $a_{kl}$  中的最小值;  $r_2$  为随机数;  $g$  为当前时刻的迭代数;  $G_{\max}$  为最大迭代数;  $r$  为  $[0,1]$  中的随机数。

遗传算法每次迭代就相当于完成了选择、交叉和变异等操作,经过迭代,误差逐渐降低直到满足优化目标,获得相应个体的最优适应度,从而得到最优系数组合并作用于非线性优化函数。其算法流程图如图 1 所示。

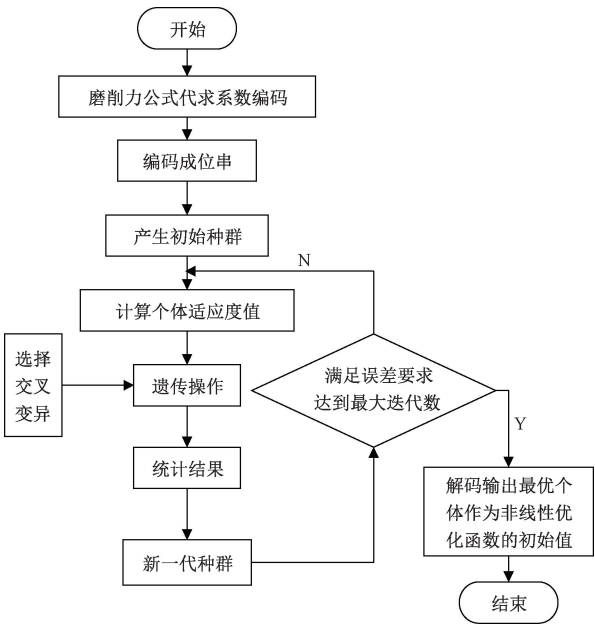


图 1 遗传算法流程图

Figure 1 Genetic algorithm flow chart

2.1.1 确定适应度函数

在遗传算法计算过程中,适应度函数对算法输出的染色体起着至关重要的作用。选取外圆横向模型中 10 组实验得到的数据如表 2 所示。

表 2 系数确定实验表<sup>[6]</sup>

Table 2 Coefficient determination test sheet<sup>[6]</sup>

序 号	进给速度 $f_i / (\text{mm} \cdot \text{s}^{-1})$	工件转速 $n / (\text{r} \cdot \text{min}^{-1})$	磨削宽度 $b / \text{m}$	法向力 $F_n / \text{N}$	切向力 $F_t / \text{N}$
1	0.001 7	60	0.020	9.20	4.81
2	0.005 0	80	0.020	25.28	13.29
3	0.008 3	100	0.020	38.03	20.34
4	0.003 3	120	0.020	22.31	12.57
5	0.006 7	140	0.020	31.37	17.25
6	0.008 3	60	0.035	62.48	33.53
7	0.003 3	80	0.035	28.69	15.08
8	0.006 7	100	0.035	54.69	28.75
9	0.001 7	120	0.035	19.15	10.25
10	0.005 0	140	0.035	45.48	23.94

若  $\delta_i = y_i - \hat{y}_i, i = 0, 1, \dots, 10$ , 取误差的二范数  $\|\delta_i\|_2$ 。在求解磨削力模型的系数时,误差的二范数越小,预测区间越窄,其预测的精度就越高,所以选择文献[6]模型中 10 组数据误差的二范数作为适应度函数  $S$  :

$$S = \|\delta\|_2 = \sqrt{\sum (y_i - \hat{y}_i)^2} \quad (6)$$

式中:  $y_i$  为每次实验磨削力的实际值;  $\hat{y}_i$  为每次实验磨削力的拟合值。

2.1.2 参数设置

本文使用 MATLAB R2020a 作为仿真实验工具,遗传算法迭代次数设置为 100。为了进一步提高迭代进化效率,根据磨削力公式进行试算,为参数设定上下限,其中  $k'_1, k'_2, \dots, k'_6$  取值为 1 000 000~10 000 000,  $\alpha_1, \alpha_2, \dots, \alpha_6$  取值为 -20~20。对于具体实现遗传算法的操作而言,初始种群个数  $N$ 、交叉概率  $P_c$ 、变异概率  $P_m$  这些参数偏大或偏小都会对寻优结果造成影响。为了能够获得最好的个体,首先要确定最佳的参数组合,因此设计一组 3 因素 5 水平的正交参数表进行遗传算法各参数寻优。种群个数 5 水平分别为 80、90、100、110、120;交叉概率 5 水平分别为 0.40、0.45、0.50、0.55、0.60;变异概率 5 水平分别为 0.02、0.04、0.06、0.08、0.10。

由上述正交实验寻优结果可得,当遗传算法参数的组合为  $N=110$ 、 $P_c=0.55$ 、 $P_m=0.04$  时,其对应的最优适应度变化曲线如图 2 所示。在迭代次数达到 81 后,目标的适应度值收敛到最优结果。遗传算法搜寻到 10 组实验数据最小误差的二范数  $S$  的结果为 8.05。对应该参数下搜寻到的外圆横向磨削力模型参数组合  $k'_1, k'_2, \dots, k'_6$  分别为 9 991 050.41、5 741 027.33、1 963 086.61、1 416 058.29、2 759 136.77、5 746 585.79,  $\alpha_1, \alpha_2, \dots, \alpha_6$  分别为 0.3、3.46、3.03、0.84、0.70、0.85。

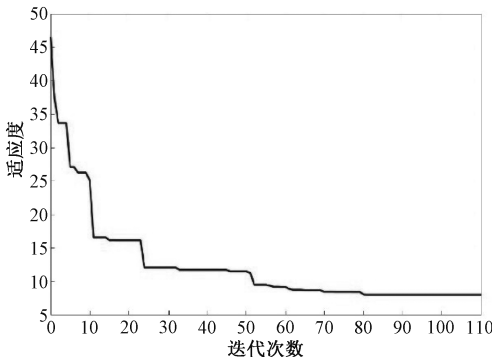


图 2 遗传算法寻优适应度曲线

Figure 2 Optimizing fitness curve by genetic algorithm

2.1.3 非线性优化函数 (lsqnonlin)

将遗传算法得出的最优系数组合作为非线性拟合函数的初始值,进一步求解最优系数组合。非线性优化函数求解公式系数最优组合的原理为搜索 10 组误差范数的最小值,相应数字模型为已知函数矩阵  $F(X) = [f_1(x), f_2(x), \dots, f_n(x)]^T$ , 求  $X$  使得  $\min_x \|f(x)\|_2^2 = \min_x (f_1^2(x) + f_2^2(x) + \dots + f_n^2(x))$ , 其中  $f_n(x) = \delta_i = y_i - \hat{y}_i (i = 0, 1, \dots, 10)$ 。

每一代残差返回值为  $\sum_{k=1}^n f_k^2(x)$ , 结果如图 3 所示。

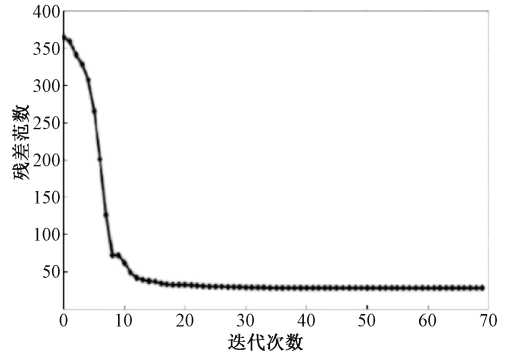


图 3 非线性优化函数残差迭代曲线

Figure 3 Nonlinear optimization function residual iteration curve

从图 3 可以看出,在迭代达到 62 之后,非线性优化函数收敛到最优结果 28.4。非线性优化函数搜寻到 10 组实验数据的最小残差值为 8.05。最终得到外圆横向磨削力模型系数的最优组合  $k'_1, k'_2, \dots, k'_6$  分别为 4 105 391.76、7 131 411.89、3 819 675.5、2 593 089.88、1 000 021.34、2 283 679.89,  $\alpha_1, \alpha_2, \dots, \alpha_6$  分别为 0.57、0.96、-2、0.39、0.62、0.86。

最终得到的外圆磨削力优化模型如式(7)所示。

$$\left\{ \begin{aligned} F_t &= 4\ 105\ 391.76 \frac{f_a^{0.5} v_w b}{v_s d_s} \sqrt{\frac{d_s d_w}{d_s + d_w}} + \\ &\quad 3\ 819\ 675.5 \left(\frac{v_w}{v_s}\right)^{0.57} f_a^{1.46} d_s^{-2} b \sqrt{\frac{d_s d_w}{d_s + d_w}} + \\ &\quad 1\ 000\ 021.34 f_r^{0.39} f_a^{0.62} \left(\frac{v_w}{v_s}\right)^{0.57} b^{0.86}; \\ F_n &= 7\ 131\ 411.89 \frac{f_a^{0.5} v_w b}{v_s d_s} \sqrt{\frac{d_s d_w}{d_s + d_w}} + \\ &\quad 2\ 593\ 089.88 \left(\frac{v_w}{v_s}\right)^{0.57} f_a^{1.46} d_s^{-2} b \sqrt{\frac{d_s d_w}{d_s + d_w}} + \\ &\quad 2\ 283\ 679.89 f_r^{0.39} f_a^{0.62} \left(\frac{v_w}{v_s}\right)^{0.57} b^{0.86} \end{aligned} \right. \quad (7)$$

3 外圆横向磨削力模型预测结果及分析

为了探究基于遗传算法的非线性优化函数求出的系数组合的准确性,将文献[6]中 15 组实验数据代入到外圆磨削力模型中,计算模型预测值并与实验得出的实际值进行比较来验证该方法的拟合效果。曲线拟合效果通常可以用决定系数  $R^2$  来评价<sup>[18]</sup>:

$$R^2 = 1 - \frac{\sum (\hat{y} - y)^2}{\sum y^2}.$$

(8)

式中:  $\hat{y}$  为预测值;  $y$  为实验值。

表 3 为外圆横向磨削力模型各组预测数据的误差对比。其验证数据对比见图 4,其中下标 1、2 分别对应本文模型与文献[6]模型,  $F_n$ 、 $F_t$  分别表示法向磨削力和切向磨削力。下文规则同上。

表 3 外圆横向磨削力模型验证实验表

Table 3 Cylindrical transverse grinding force model validation test table

序 号	进给速度 $f_r/(\text{mm}\cdot\text{s}^{-1})$	工件转速 $n/(\text{r}\cdot\text{min}^{-1})$	磨削宽度 $b/\text{m}$	法向磨削力				切向磨削力				$E_{t1}/\%$	$E_{t2}/\%$
				$F_{n1}$	$F_{n2}$	$F_n$	$E_{n1}/\%$	$E_{n2}/\%$	$F_{t1}$	$F_{t2}$	$F_t$		
1	0.008 3	80	0.020	37.32	32.16	37.79	1.24	14.9	19.62	16.94	19.64	0.08	13.72
2	0.006 7	80	0.020	31.10	27.89	30.64	1.49	8.9	16.34	14.59	15.96	2.36	8.60
3	0.003 3	140	0.020	19.46	23.26	22.76	14.52	2.2	10.29	12.32	12.63	18.52	2.50
4	0.003 3	100	0.020	18.46	19.94	20.30	9.05	1.7	9.74	10.56	11.91	18.20	11.30
5	0.003 3	80	0.020	17.66	17.99	17.02	3.74	5.7	9.31	9.49	8.69	7.08	9.10
6	0.003 3	60	0.020	16.76	15.94	16.65	0.64	4.3	8.84	8.33	8.21	7.63	1.50
7	0.001 7	80	0.020	10.78	12.00	12.97	16.91	7.5	5.73	6.27	5.13	11.70	22.10
8	0.008 3	80	0.035	62.72	53.02	62.85	0.21	15.7	33.26	27.81	33.75	1.45	17.60
9	0.006 7	80	0.035	52.33	46.34	49.59	5.52	6.6	27.71	24.22	30.28	8.47	20.00
10	0.005 0	80	0.035	41.66	38.79	48.01	13.22	19.2	22.07	20.35	23.70	6.86	14.10
11	0.003 3	140	0.035	33.05	39.01	36.78	10.13	6.1	17.58	20.48	18.37	4.29	11.50
12	0.003 3	120	0.035	32.71	36.37	33.20	1.49	9.5	17.38	19.21	16.71	4.01	14.90
13	0.003 3	100	0.035	31.28	33.49	29.17	7.25	14.8	16.61	17.54	15.68	5.94	11.90
14	0.003 3	60	0.035	28.28	26.81	28.12	0.55	4.7	15.02	13.99	14.71	2.13	4.90
15	0.001 7	80	0.035	18.32	20.39	18.81	2.59	8.4	9.80	10.65	9.52	2.93	11.90

说明:下标 1 和 2 分别对应本文和文献[6]模型,  $E$  为误差。

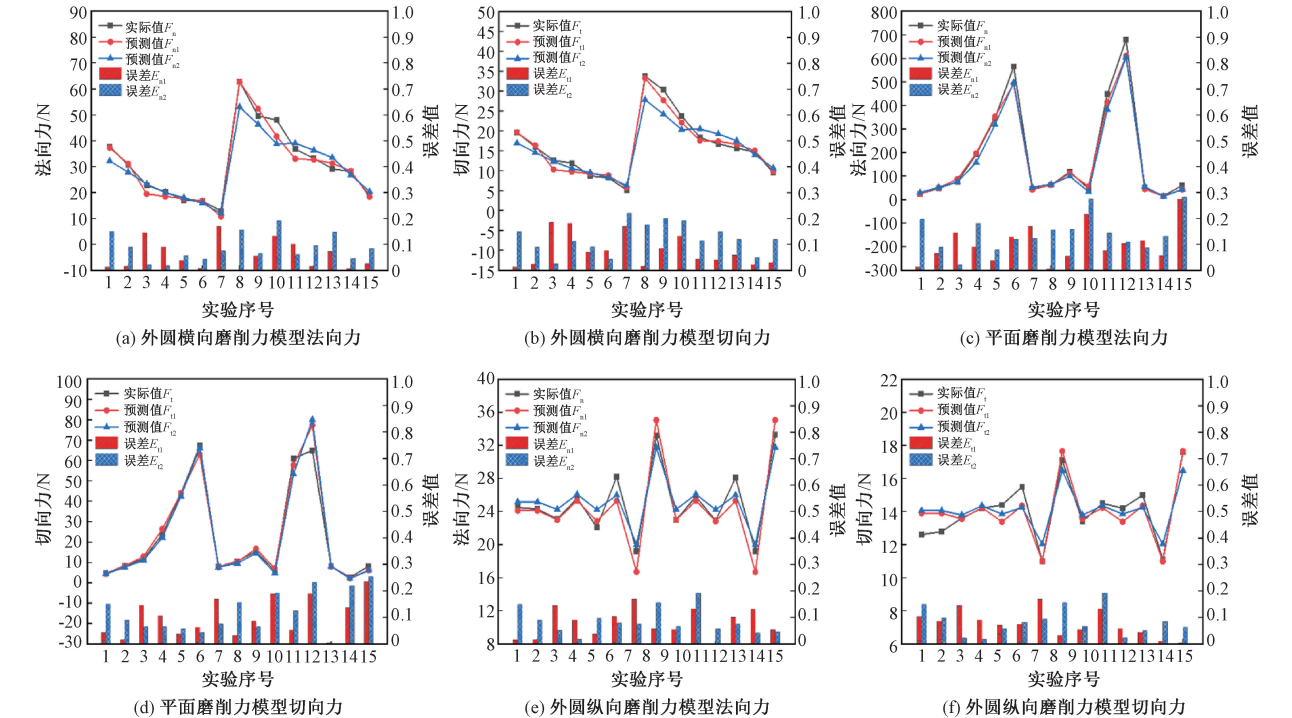


图 4 3 种模型各组验证数据对比图

Figure 4 Comparison of validation data of each group in three models

计算得到外圆横向磨削法向和切向磨削力公式预测结果的决定系数  $R^2$  分别为 0.994 9 和 0.995 2, 较接近 1。通过外圆横向磨削得到法向磨削力和切向磨削力的平均预测误差分别为 5.90% 和 6.78%, 相比于原文中的模型误差分别降低了 32.18%、42.54%, 具体如图 4(a)、4(b) 所示。

### 4 平面磨削力模型与外圆纵向磨削力模型预测结果及分析

平面模型、外圆纵向磨削力模型优化过程本文在此并不详细叙述。本文方法与文献[5,8]方法关于模型的误差对比如图 4(c)~4(f) 所示, 得到法向磨削力平均预测误差分别为 9.13%、3.23%, 切向磨削力的平均预测误差分别为 8.36%、3.69%, 相比于文献[5,8]中的模型, 法向力预测误差分别降低 32.87%、38.48%, 切向磨削力预测误差分别降低 14.69%、31.54%。可见这种计算待求系数的方法同时适用于平面磨削力模型与外圆纵向磨削力模型, 并且能起到一定的优化作用。

最终通过基于遗传算法的非线性优化函数求解平面磨削力模型、外圆纵向磨削力模型如式(9)、(10)所示。

$$\left\{ \begin{aligned} F_t = & 10\,013.64a_p^{0.5} \frac{v_w b}{d_s^{0.5} v_s} + 13\,025.43 \left( \frac{v_w}{v_s} \right)^{1.29} \cdot \\ & a_p^{1.85} d_s^{5.80} b \sin \theta + (130\,991.87 + \\ & 565\,845.57 \ln(v_w^{-12.85} v_s^{13.85} a_p^{-21.27} d_s^{2.77} \cos \theta)) \cdot \\ & \frac{b^2 v_w a_p^{1.5} d_s^{0.5}}{v_s}; \\ F_n = & 42\,517.10a_p^{0.5} \frac{v_w b}{d_s^{0.5} v_s} + \\ & 78\,982.82 \left( \frac{v_w}{v_s} \right)^{1.29} a_p^{1.85} d_s^{5.80} b \tan \theta \sin \theta + \\ & (175\,588.63 + 5\,811\,005.25 \times \\ & \ln(v_w^{-12.85} v_s^{13.85} a_p^{-21.27} d_s^{2.77} \cos \theta)) \frac{b^2 v_w a_p^{1.5} d_s^{0.5}}{v_s}. \end{aligned} \right. \quad (9)$$

$$\left\{ \begin{aligned} F_t = & 62.47v_r^{0.0496} s_a^{0.1225} a^{0.4824}; \\ F_n = & 141.92v_r^{0.1041} s_a^{0.2574} a^{0.6858}. \end{aligned} \right. \quad (10)$$

表 4 为 3 种模型预测数据的误差对比。可以看出, 使用本文所提出的模型优化方法绝大部分误差小于文献[5,8]模型, 决定系数均高于相关文献模型, 因此可以认为本文所提出的优化方法对不同磨

削力模型优化结果都较为适用。

表 4 3 种模型验证误差表

Table 4 Table of validation errors of three models

模型	磨削力	平均误差/%	最大误差/%	最小误差/%	决定系数 $R^2$	优化比例/%
外圆横向磨削力模型	$F_{n1}$	5.90	16.91	0.21	0.994 9	32.18
	$F_{n2}$	8.70	19.20	1.70	0.994 1	32.18
	$F_{t1}$	6.78	18.52	0.08	0.995 2	42.54
	$F_{t2}$	11.80	22.10	1.50	0.977 0	42.54
平面磨削力模型	$F_{n1}$	9.13	27.55	0.44	0.989 8	32.87
	$F_{n2}$	13.60	28.30	1.70	0.985 3	32.87
	$F_{t1}$	8.36	23.69	0.26	0.987 7	14.69
	$F_{t2}$	9.80	25.40	0	0.980 9	14.69
外圆纵向磨削力模型	$F_{n1}$	3.23	8.92	0.30	0.998 2	38.48
	$F_{n2}$	5.25	9.64	0.01	0.997 2	38.48
	$F_{t1}$	3.69	10.26	0.16	0.997 6	31.54
	$F_{t2}$	5.39	11.59	1.03	0.996 4	31.54

### 5 结论

(1) 将外圆横向磨削力模型、平面磨削力模型和外圆纵向磨削力模型的磨削实验结果与理论推导相结合并通过 GA-LSQ 算法经过多点搜索对参数集进行处理, 从而得到输出的最优系数组合。从优化的模型中可直接得出各加工参数与磨削力的关系, 通过控制磨削力从而进一步提高表面质量。

(2) 本文方法具有普遍适用性, 针对平面磨削力模型、外圆横向磨削力模型、成形磨削力模型、外圆纵向磨削力模型等进行了相应的计算验证, 预测的模型误差均在 10% 以下。

(3) 在外圆横向磨削力模型、平面磨削力模型和外圆纵向磨削力模型中, 其法向磨削力预测误差分别为 5.90%、9.13%、3.23%, 切向磨削力的预测误差分别为 6.78%、8.36%、3.69%, 磨削力的预测精度提高了 14.69%~42.54%。

### 参考文献:

[1] PATNAIK DURGUMAHANTI U S, SINGH V, VENKATESWARA RAO P. A new model for grinding force prediction and analysis[J]. International Journal of Machine Tools and Manufacture, 2010, 50(3): 231-240.

[2] MAENG S J, LEE P A, KIM B H, et al. An analytical model for grinding force prediction in ultra-precision machining of WC with PCD micro grinding tool[J]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2020, 7(6): 1031-1045.

- [3] ZHOU H, DING W F, LI Z, et al. Predicting the grinding force of titanium matrix composites using the genetic algorithm optimizing back-propagation neural network model[J]. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 2019, 233(4): 1157–1167.
- [4] 詹友基, 左振, 许永超, 等. 纳米晶硬质合金的磨削力实验与预测[J]. *材料与冶金学报*, 2022, 21(6): 448–455.
- ZHAN Y J, ZUO Z, XU Y C, et al. Experiment and prediction of grinding force of nanosized cemented carbide[J]. *Journal of Materials and Metallurgy*, 2022, 21(6): 448–455.
- [5] LI B K, DAI C W, DING W F, et al. Prediction on grinding force during grinding powder metallurgy nickel-based superalloy FGH96 with electroplated CBN abrasive wheel[J]. *Chinese Journal of Aeronautics*, 2021, 34(8): 65–74.
- [6] 马少奇. 18CrNiMo7-6 钢外圆磨削力及表面完整性研究[D]. 郑州: 郑州大学, 2021.
- MA S Q. Research on grinding force and surface integrity of 18CrNiMo7-6 steel in cylindrical grinding[D]. Zhengzhou: Zhengzhou University, 2021.
- [7] JAMSHIDI H, GURTAN M, BUDAK E. Identification of active number of grits and its effects on mechanics and dynamics of abrasive processes[J]. *Journal of Materials Processing Technology*, 2019, 273: 116239.
- [8] KOVAČ P, PUCOVSKY V, GOSTIMIROVIĆ M, et al. Cutting force during grinding determined by regression analysis and genetic algorithms[J]. *Key Engineering Materials*, 2016, 686: 13–18.
- [9] GUO M X, LI B Z, DING Z S, et al. Empirical modeling of dynamic grinding force based on process analysis[J]. *The International Journal of Advanced Manufacturing Technology*, 2016, 86(9): 3395–3405.
- [10] MISHRA V K, SALONITIS K. Empirical estimation of grinding specific forces and energy based on a modified Werner grinding model[J]. *Procedia CIRP*, 2013, 8: 287–292.
- [11] SU Y H, LIN B, CAO Z C. Prediction and verification analysis of grinding force in the single grain grinding process of fused silica glass[J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 96(1): 597–606.
- [12] AMAMOU R, BEN FREDJ N, FNAIECH F. Improved method for grinding force prediction based on neural network[J]. *The International Journal of Advanced Manufacturing Technology*, 2008, 39(7/8): 656–668.
- [13] 赵静雯. 圆柱形疲劳试样 V 型缺口成形磨削工艺优化研究[D]. 郑州: 郑州大学, 2022.
- ZHAO J W. Optimization study on cylindrical fatigue specimen V-notch of forming grinding process [D]. Zhengzhou: Zhengzhou University, 2022.
- [14] 蔡卫星, 周伟华, 张峰. 21NiCrMo5H 齿轮钢超声磨削力建模研究[J]. *现代制造工程*, 2020(4): 113–118.
- CAI W X, ZHOU W H, ZHANG F. Research on the grinding force model of ultrasonic grinding for 21NiCrMo5H[J]. *Modern Manufacturing Engineering*, 2020(4): 113–118.
- [15] 赵庆岩, 黎杰, 吴顺, 等. 基于遗传算法优化的机械臂动态矩阵预测控制[J]. *郑州大学学报(工学版)*, 2020, 41(1): 32–37.
- ZHAO Q Y, LI J, WU S, et al. Dynamic matrix predictive control of manipulators based on genetic algorithms[J]. *Journal of Zhengzhou University (Engineering Science)*, 2020, 41(1): 32–37.
- [16] 秦娜, 刘凡, 刘亚龙, 等. 基于遗传算法优化 BP 神经网络的钛合金旋转超声磨削力预测[J]. *中国科技论文*, 2017, 12(10): 1128–1131, 1156.
- QIN N, LIU F, LIU Y L, et al. Prediction of grinding force in rotary ultrasonic grinding of titanium alloy based on BP neural network optimized by genetic algorithm[J]. *China Sciencepaper*, 2017, 12(10): 1128–1131, 1156.
- [17] 欧阳海滨, 全永彬, 高立群, 等. 基于混合遗传粒子群优化算法的层次路径规划方法[J]. *郑州大学学报(工学版)*, 2020, 41(4): 34–40.
- OUYANG H B, QUAN Y B, GAO L Q, et al. Hierarchical path planning method for mobile robots based on hybrid genetic particle swarm optimization algorithm[J]. *Journal of Zhengzhou University (Engineering Science)*, 2020, 41(4): 34–40.
- [18] 张翔, 王应刚, 陈泓谕, 等. 基于 BP 神经网络与遗传算法的固结磨具制作工艺参数优化[J]. *表面技术*, 2022, 51(2): 358–366.
- ZHANG X, WANG Y G, CHEN H Y, et al. Optimization of fixed-abrasive tool development parameters based on BP neural network and genetic algorithm[J]. *Surface Technology*, 2022, 51(2): 358–366.

Coefficient Optimization of Grinding Force Model Based on Genetic Algorithm

WANG Dong, ZHANG Zhipeng, ZHAO Rui, ZHANG Junyu, QIAO Ruiyong, SUN Shaozheng

(School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou 450001, China)

**Abstract:** When solving problems in the grinding force model, most of the methods of segmental calculation or column equations were used to calculate each coefficient directly, which not only demanded a large amount of calculation but also could not guarantee its accuracy. In addition the traditional regression model was easy to fall into local optimal, difficult to describe the nonlinear relationship. Therefore, the genetic algorithm was introduced into the parameter optimization of the nonlinear fitting function, and the coefficient optimization method of the theoretical model of grinding force was studied based on the existing model data such as the model of cylindrical transverse grinding, the model of plane grinding and the model of cylindrical longitudinal grinding. Correlation analysis results showed that the predicted accuracy of grinding force of the three models was increased by 14.69%–42.54%. The average error of normal grinding force predicted by the three models was 5.9%, 9.13% and 3.23%, respectively. The mean error of tangential force was 6.78%, 8.36% and 3.69%, respectively. Through comparison, it could be concluded that the optimized model had a better fitting degree, and the prediction accuracy of the model was significantly improved. The nonlinear fitting function GA-LSQ algorithm optimized by genetic algorithm was more suitable for solving grinding force model and could provide reference for predicting grinding force and parameter optimization in actual production.

**Keywords:** grinding force model; cylindrical grinding; surface grinding; empirical formula; model coefficient optimization; model prediction; genetic algorithm; nonlinear optimization function

(上接第 11 页)

A Review of Machine Learning-Based Methods for Database Tuning

SHI Lei<sup>1,2,3</sup>, LI Tian<sup>2</sup>, GAO Yufei<sup>1,3</sup>, WEI Lin<sup>1</sup>, LI Cuixia<sup>1</sup>, TAO Yongcai<sup>2</sup>

(1. School of Cyber Science and Engineering, Zhengzhou University, Zhengzhou 450002, China; 2. School of Computer and Artificial Intelligence, Zhengzhou University, Zhengzhou 450001, China; 3. Songshan Laboratory, Zhengzhou 450046, China)

**Abstract:** Knobs tuning is a key technology that affects the performance and adaptability of databases. However, traditional tuning methods have difficulty in finding the optimal configuration in high-dimensional continuous parameter spaces. The development of machine learning could bring new opportunities to solve this problem. By summarizing and analyzing relevant work, existing work was classified according to development time and characteristics, including expert decision-making, static rules, heuristic algorithms, traditional machine learning methods, and deep reinforcement learning methods. The database tuning problem was defined, and the limitations of heuristic algorithms in tuning problems were discussed. Traditional machine learning-based tuning methods were introduced, including random forest, support vector machine, decision tree, etc. The general process of using machine learning methods to solve tuning problems was described, and specific implementations were provided. The shortcomings of traditional machine learning models in adaptability and tuning capabilities were also discussed. The principles of deep reinforcement learning models were emphasized, and the mapping relationship between tuning problems and deep reinforcement learning models was defined. Recent relevant work on improving database performance, time consumption and model characteristics was introduced, and the process of building and training agents based on deep neural networks was described. Finally, the characteristics of existing work were summarized, and the research hotspots and development directions of machine learning in database tuning were outlined. Distributed scenarios, multi-granularity tuning, adaptive algorithms and self-maintenance capabilities were identified as future research trends.

**Keywords:** database system; knobs tuning; performance optimization; machine learning; reinforcement learning; database maintenance