

## 基于 SVM 的机器人高精度磨削建模

杨 扬<sup>1</sup>, 宋亦旭<sup>1</sup>, 梁 伟<sup>1</sup>, 王家彦<sup>1</sup>, 齐立哲<sup>2</sup>

(1. 清华大学计算机科学与技术系, 北京 100084; 2. 廊坊智通机器人系统有限公司, 河北 廊坊 065001)

**摘要:** 为了改进机器人磨削过程中对磨削量的控制, 提出了一种基于 SVM 回归的磨削过程建模方法, 通过分析与磨削量相关的一组可测变量——机器人进给速率、接触力、工件表面曲率, 利用机器学习的方法建立回归模型, 对磨削量进行预测。这种方法可以避免逐一分析复杂的动力学参数。实验结果表明, 该方法可以取得良好的效果, 模型的预测精度达到 90% 以上, 基本满足实际加工的要求。

**关键词:** SVM; 机器人; 磨削; 回归; 建模

中图分类号: TP242.2

文献标识码: A

## Modeling for Robot High Precision Grinding Based on SVM

YANG Yang<sup>1</sup>, SONG Yixu<sup>1</sup>, LIANG Wei<sup>1</sup>, WANG Jiaxin<sup>1</sup>, QI Lizhe<sup>2</sup>

(1. Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China;

2. Inter Smart Robotic Systems Co., Ltd, Langfang 065001, China)

**Abstract:** To improve the removal control for robot grinding process, we propose a modeling method based on SVM (support vector machine) regression. By analyzing a group of measurable variables relevant to grinding removal, such as robot's speed, contact force and curvature of the workpiece's surface, a regression model is built using machine learning method to predict the grinding removal. In this way, the analysis on a series of complicated dynamic variables could be avoided. The experimental results show that this method could achieve good performance. The prediction accuracy of the model reaches higher than 90%, which basically meets the demand of practical grinding.

**Keywords:** SVM (support vector machine); robot; grinding; regression; modeling

## 1 引言 (Introduction)

传统的复杂曲面工件(如叶片)的磨削加工主要有以下几种方式: 人工磨削、专用机床磨削和数控机床磨削。这几种方式都存在一定的缺点: 人工磨削比较费时, 而且加工的一致性得不到保证; 专用机床通用性不好, 只适合批量生产; 数控机床的加工成本较高。此外, 机床加工还有一个明显的通弊, 就是缺乏柔性, 设备使用范围窄, 可拓展范围小<sup>[1]</sup>。针对这些问题, 机器人在磨削加工领域开始受到人们的重视, 并得到了越来越广泛的应用。与市场上较为典型的 5 轴磨削加工机床相比, 机器人磨削加工系统具有灵活性高、通用性强、易于扩展等优点。

目前, 大多数加工复杂曲面工件的机器人磨削系统仍然处于实验室研究阶段, 主要研究目的是用于打磨和抛光。近年来, 结合工业界需求, 人们提出

了机器人修型磨削问题。机器人修型磨削是指通过机器人系统对复杂曲面工件外表面进行砂带磨削加工, 使之达到设计尺寸公差和表面质量的一种精加工过程。这种工艺不仅强调其加工柔性, 也可充分发挥机器人磨削的精度优势, 进一步提升了机器人在磨削领域的技术档次。

修型磨削的关键问题在于对磨削量的控制。机器人磨削系统与磨削机床等高刚度的磨削系统不同, 在高刚度的磨削系统中, 基本认为进给量即等于磨削量, 而在机器人磨削中, 由于磨削系统在加工面法向方向具有一定柔性, 进给量和磨削量的关系更为复杂, 无法简单地将两者等同, 这就给磨削量的控制带来了困难。在现有的技术条件下, 无法使用在线测量实时地获得磨削量的反馈, 因此对磨削量的直接控制难以实现。

另一种途径是考虑使用模型的方法对磨削量进行估计。但是, 各种动力学参数对磨削过程的影响

十分复杂, 而且呈现高度耦合强非线性的特点, 很难基于磨削机理进行建模.

对磨削过程建模不仅是提高加工精度的需要, 也是针对机器人大工作空间进行加工轨迹优化、提高加工效率的前提. 针对基于机理建模困难的问题, 本文采用了一种基于 SVM 回归的建模方法. 这种方法回避了逐一分析复杂的动力学参数, 而是利用磨削过程中的实际测量数据, 选择与磨削量相关的一组可测变量, 建立以这些可测变量为输入、以磨削量为输出的数学模型. 通过对叶片进行磨削和回归建模, 验证了该方法的有效性.

## 2 回归原理 (Principle of regression)

随着统计机器学习方法的发展, 非线性回归技术手段越来越丰富. 尤其是 Vapnik 等人<sup>[2-3]</sup>于 1995 年提出支持向量机 (SVM) 方法后, 非线性机器学习中核方法得到了广泛深入的研究, 并且很多思想被直接推广, 用于解决函数拟合问题<sup>[4-5]</sup>. 与神经网络等方法相比, SVM 的优点在于它基于结构风险最小化原则, 泛化能力较强, 可以避免过学习和陷入局部极小点等问题, 而且 SVM 所需的样本数较少, 尤其适合小样本训练<sup>[6]</sup>.

SVM 回归原理可简述如下: 给定训练样本集  $(\mathbf{x}_i, y_i)$ ,  $i = 1, 2, \dots, n$ ,  $\mathbf{x}_i \in \mathbb{R}^d$ ,  $d$  为样本数据的属性维数; 所求的最优线性回归函数为  $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$ ,  $\mathbf{w}$  为权向量,  $b$  为偏移量. 可以将这个问题转化为如下的二次规划问题:

$$\begin{aligned} & \min \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ & \text{s.t. } \begin{cases} y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \varepsilon + \xi_i \\ \mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \varepsilon + \xi_i^* \end{cases} \end{aligned} \quad (1)$$

其中,  $i = 1, 2, \dots, n$ ,  $\varepsilon$  为不敏感损失函数的误差,  $\xi_i, \xi_i^* \geq 0$  是两个非负的松弛因子, 常数  $C > 0$  为惩罚因子, 表示对超出  $\varepsilon$  管道的惩罚程度. 利用优化方法将上述问题转化为:

$$\begin{aligned} & \min \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle \mathbf{x}_i, \mathbf{x}_j \rangle - \\ & \quad \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) + \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) \\ & \text{s.t. } \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C, \quad i = 1, 2, \dots, n \end{cases} \end{aligned} \quad (2)$$

相应的回归函数为:

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \mathbf{x}_i, \mathbf{x} \rangle + b^* \quad (3)$$

这里  $\alpha_i, \alpha_i^*$  为拉格朗日乘子, 其中只有部分  $\alpha_i - \alpha_i^*$  不为 0, 它们对应的样本即为支持向量.

以上是线性的情况. 对于非线性的情况, 只需用核函数  $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j) \rangle$  代替式(3)中的内积项  $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$  即可, 这里  $\varphi(\cdot)$  表示从样本空间到高维特征空间的映射. 常用的核函数有多项式核函数、径向基(高斯)核函数(radial basis function, RBF)、多层次感知器核函数等. 本文采用 RBF 核函数, 它对非线性特性、高维数据有较好的适应性. 其数学表达式如下:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{|\mathbf{x}_i - \mathbf{x}_j|^2}{2\sigma^2}\right)$$

其中  $\sigma$  为核宽度.

## 3 基于 SVM 进行磨削过程建模 (Modeling the grinding process based on SVM)

### 3.1 样本特征选取

采用 SVM 方法建模, 首先要解决样本特征选取问题. 样本特征的选取并没有一个统一的方法, 一般是凭经验来选取. 在修型磨削加工过程中, 影响磨削量的因素有很多, 从机床高精度磨削研究来看, 工件材料、砂轮材料、温度、工件表面曲率、工件旋转速度、接触力、砂轮表面质量、砂轮旋转速度等因素都会对磨削量造成影响. 相对而言, 机器人砂带磨削的精度要求比较低, 许多条件不像机床高精度磨削要求那么苛刻, 只要抓住影响磨削量的主要控制量, 合理忽略其他次要因素, 也可以保证加工精度.

试验发现, 对于机器人加工系统, 接触力、机器人进给速率这两个可控制参量对磨削量的影响十分明显. 其中, 接触力为砂带与工件表面的压力, 机器人进给速率为机器人末端移动速度的大小. 在固定其它条件的情况下, 接触力、机器人进给速率与磨削量均满足一定函数关系. 另一方面, 当对复杂曲面工件进行磨削时, 即使接触力和机器人进给速率保持不变, 在工件表面曲率不同的地方, 磨削量也不一样, 这种影响在曲率大的地方尤为显著, 如叶片的叶根和叶缘部分. 因此, 本文选取接触力、机器人进给速率和工件表面曲率作为样本特征, 综合考虑这三个因素对磨削量的影响.

### 3.2 模型训练过程中的参数选择

基于 SVM 的建模过程成功与否, 很大程度上依赖于所选择的参数是否合适. 与建模相关的参数主要有: 惩罚系数  $C$ 、RBF 核函数中的  $\sigma$ 、不敏感损失函数中的  $\varepsilon$ . 惩罚系数  $C$  表示对经验误差的惩

罚, 它的作用是在置信范围与经验误差之间取一个折中,  $C$  值过大会导致过学习,  $C$  值过小会导致欠学习; 核参数  $\sigma$  表示核的宽度, 主要影响样本数据在高维特征空间中的分布; 不敏感损失函数参数  $\epsilon$  决定了支持向量的数目,  $\epsilon$  越小, 支持向量的数目越多, 函数估计的精度也越高, 但训练的时间也越长.

一般使用网格搜索和交叉验证的方法来寻找最优参数. 首先, 根据经验确定参数的初始取值, 然后用 2 倍的指数方式渐次增大或减小参数的值. 将样本数据分为  $N$  份, 依次选取其中的  $N - 1$  份用于训练, 剩余的 1 份用于测试. 比较不同参数下模型的预测误差, 选取误差最小的一组作为模型参数.

## 4 磨削实验与建模结果分析 (Grinding experiment and modeling result analysis)

### 4.1 磨削实验配置与实验数据获得过程

对某钛合金叶片进行修型磨削加工, 获得模型训练与测试所需的样本数据.

实验采用的机器人磨削系统由 ABB 公司生产的工业机器人与自制的气缸磨削机组成, 如图 1 所示. 接触力和机器人进给速率为磨削系统的可控参数, 可通过磨削控制系统程序人机界面进行调整和监控. 磨削量通过 LVDT (linear variable differential transformer) 位移传感器测量得到, 通过对同一点磨削前与磨削后的位移量求差, 得到所求点的磨削量; 使用 3 维激光扫描系统对加工面进行扫描, 通过对该系统产生的曲面表面点云数据进行估算得到给定加工点的曲率.

实验过程如下: 对于一个标定完毕的机器人磨削系统, 首先设定机器人的磨削轨迹, 然后改变接触力和机器人进给速率的值, 对同一工件进行反复磨削. 将相同接触力和机器人进给速率下的实验称为一组, 每组实验分为以下 4 个步骤: 1) 设定接触力和机器人进给速率; 2) 使用 LVDT 沿规划路径测量待磨工件表面, 得到位移量数据; 3) 使用 3 维激光扫描系统扫描待磨工件表面, 得到工件曲面的表面点云数据; 4) 对待磨工件沿规划路径进行一次磨削. 然后重复上述过程.

实验中, 接触力和机器人进给速率的取值应满足一定分布, 以保证在加工所需的力和速率的限制范围内都有实验数据分布. 基于实际的加工经验, 此处设置机器人接触力的范围为  $2.5 \text{ N} \sim 125 \text{ N}$ , 采样间隔为  $2.5 \text{ N}$ ; 机器人进给速率范围为  $10 \text{ cm/s} \sim 45 \text{ cm/s}$ , 采样间隔为  $5 \text{ cm/s}$ . 根据二者的不同组合, 共进行 40 组实验. 部分数据如表 1 所示.



图 1 机器人磨削系统

Fig.1 The robot grinding system

### 4.2 建模结果与分析

图 2 显示了磨削量与工件表面曲率的关系. 由图 2 可以看到, 磨削量受曲率影响明显, 其大小变化基本与曲率的走势保持一致.

图 3 显示的是磨削量与接触力和机器人进给速率二者的关系. 由图中可以明显地看到, 在接触力一定的情况下, 磨削量的值随着机器人进给速率的增大而减小; 在机器人进给速率一定的情况下, 磨削量的值随着接触力的增大而增大. 即磨削量与机器人进给速率成负相关关系, 与接触力成正相关关系.

这些结果说明本文选择的样本特征是基本合理的.

使用 LibSVM 对 4.1 节所获得的数据进行回归建模. 以机器人进给速率、接触力和工件加工点曲面曲率为模型输入, 以磨削量为模型输出. 训练所采用的参数分别为:  $C = 64$ ,  $\sigma = 0.707$ ,  $\epsilon = 0.0039$ . 为了验证 SVM 建模方法的通用性和稳定性, 共进行 10 次实验. 每次实验从样本数据中随机抽取一半用作训练, 另一半用作测试. 使用最小均方误差 (minimum square error, MSE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 两个指标对预测结果进行评价. 实验结果如表 2 所示.

由表 2 可以看到, 该方法的迭代次数较少, 耗时较小, 稳定性较强, 对不同的训练数据和测试数据均能获得很好的效果. 从 10 次实验的平均结果来看, 磨削量预测的 MSE 仅为  $2.87e-04$ , MAPE 仅为 8.16%. 若以 MAPE 作为评价指标, 模型的预测精度在 90% 以上.

表 1 部分原始数据  
Tab.1 Part of original data

磨削量 /mm	曲率	接触力 /N	速率 /(m/s)	磨削量 /mm	曲率	接触力 /N	速率 /(m/s)
0.073	0.2813	25	0.2	0.24	0.0942	75	0.1
0.0515	0.1305	25	0.2	0.339	0.0868	75	0.1
0.0605	0.0957	25	0.2	0.366	0.0988	75	0.1
0.0575	0.0974	25	0.2	0.3625	0.1086	75	0.1
0.066	0.0945	25	0.2	0.3555	0.1036	75	0.1
0.0385	0.0775	25	0.2	0.3555	0.086	75	0.1
0.0575	0.0576	25	0.2	0.3355	0.0656	75	0.1
0.039	0.0419	25	0.2	0.3115	0.048	75	0.1
0.066	0.0306	25	0.2	0.2985	0.0356	75	0.1
0.056	0.0219	25	0.2	0.321	0.0262	75	0.1
0.056	0.0157	25	0.2	0.321	0.0204	75	0.1
0.046	0.0126	25	0.2	0.353	0.0158	75	0.1

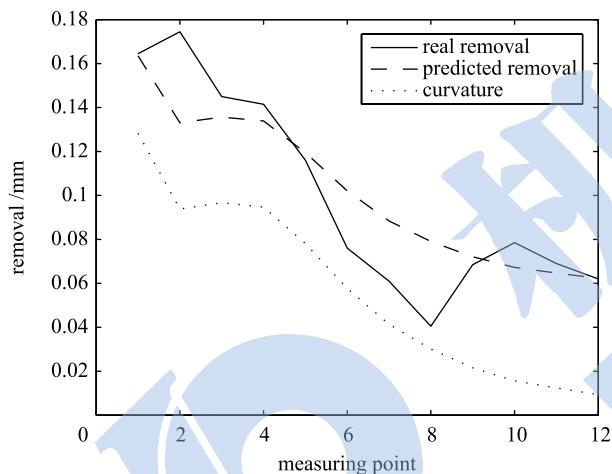


图 2 磨削量与曲率的关系

Fig.2 Relation between removal and curvature

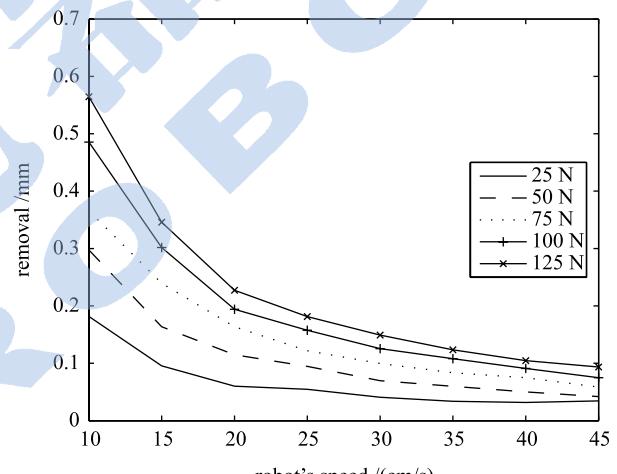


图 3 磨削量与速率、接触力的关系

Fig.3 Relation between removal and speed/contact force

表 2 模型训练与预测结果  
Tab.2 Results of training and prediction

	训练样本数	支持向量数	迭代次数	MSE	MAPE
1	166	117	1 166	3.07e-04	0.083 903
2	166	132	1 115	2.64e-04	0.077 742
3	166	140	1 214	2.50e-04	0.077 034
4	166	132	879	4.42e-04	0.097 457
5	166	127	912	2.42e-04	0.076 864
6	166	131	965	2.81e-04	0.081 285
7	166	126	1 027	2.66e-04	0.079 11
8	166	126	1 249	3.15e-04	0.086 07
9	166	121	1 356	2.42e-04	0.075 799
10	166	131	1 192	2.62e-04	0.080 922
平均值	166	128.3	1 107.5	2.87e-04	0.081 619

## 5 结论 (Conclusion)

针对难以基于磨削机理进行建模的问题,本文采用一种基于 SVM 回归的方法对机器人修型磨削过程进行建模。研究了对磨削量影响较大的几个因素——机器人进给速率、接触力、工件表面曲率,并以它们作为模型输入,以磨削量作为输出,利用实际测量的样本数据,建立起磨削过程的动力学模型。实验结果表明了该方法的有效性,模型的预测精度基本满足工业加工的要求。

## 参考文献 (References)

- [1] Huang H, Gong Z M, Chen X Q, et al. Smart robotic system for 3D profile turbine vane airfoil repair[J]. The International Journal of Advanced Manufacturing Technology, 2003, 21(4): 275-283.
- [2] Vapnik V. The nature of statistical learning theory[M]. New York, USA: Springer-Verlag, 1995.
- [3] Cortes C, Vapnik V. Support vector network[J]. Machine Learning, 1995, 20(3): 273-297.
- [4] 杜树新, 吴铁军. 用于回归估计的支持向量机方法 [J]. 系统仿真学报, 2003, 15(11): 1580-1585,1633.
- [5] Du Shuxin, Wu Tiejun. Support vector machines for regression[J]. Journal of System Simulation, 2003, 15(11): 1580-1585,1633.
- [6] 朱国强, 刘士荣, 俞金寿. 支持向量机及其在函数逼近中的应用 [J]. 华东理工大学学报, 2002, 28(5): 555-559,568.
- Zhu Guoqiang, Liu Shirong, Yu Jinshou. Support vector machine and its applications to function approximation[J]. Journal of East China University of Science and Technology, 2002, 28(5): 555-559,568.
- [7] 刘江华, 程君实, 陈佳品. 支持向量机训练算法综述 [J]. 信息与控制, 2002, 31(1): 45-50.
- Liu Jianghua, Cheng Junshi, Chen Jiapin. Support vector machine training algorithm: A review[J]. Information and Control, 2002, 31(1): 45-50.

## 作者简介:

- 杨 扬 (1984-), 男, 硕士. 研究领域: 基于统计的回归建模.  
宋亦旭 (1972-), 男, 博士后, 讲师. 研究领域: 机器人智能控制.  
梁 伟 (1981-), 男, 硕士. 研究领域: 多目标智能优化方法.