

叶片生产过程的非线性轮廓控制方法研究

杨雅棠, 陈富民, 何帅, 李建华

(西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 针对叶身型线轮廓特征参数间相关关系复杂、历史批次数据不足等原因造成的生产过程型面几何轮廓质量控制困难的问题,提出一种叶片生产过程非线性轮廓控制方法。该方法以叶身型线三坐标值为基础数据进行分析,首先构建叶身型线轮廓差异度量指标,并基于测量数据进行指标参数提取及标准化处理,作为非线性轮廓控制对象;其次以受控状态下的差异度量指标分类准确率为优化目标,通过自适应粒子群算法(PSO)优化高斯核函数及惩罚系数;然后联合优化参数及受控指标数据训练支持向量数据描述(SVDD)模型,获得超球体半径作为控制限,构建基于超球体核距离的非线性轮廓控制图;最后计算待测轮廓指标数据点到超球体中心的内核距离,得到控制图标绘点,进而判断叶片生产过程是否异常。仿真结果表明,相比于传统方法,该方法可有效表征型线不同区域质量特征对轮廓形状的综合影响,且对不同均值偏移都具有更强的异常波动检测力,并能有效解决中小批量生产过程控制中数据量不足的问题。

关键词: 非线性轮廓控制;差异度量指标;自适应粒子群算法;支持向量数据描述

中图分类号: TH16 **文献标志码:** A

DOI: 10.7652/xjtuxb202008012 **文章编号:** 0253-987X(2020)08-0091-09



OSID 码

Nonlinear Profile Control Method for Blade Production Process

YANG Yatang, CHEN Fumin, HE Shuai, LI Jianhua

(State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A nonlinear profile control method for blade production process is proposed to deal with the problem that the quality control of the surface contour of production process is difficult due to the complex relationship between the profile parameters of blade body and lack of historical data. According to three-coordinate data of blade profile, the blade body profile difference metrics are constructed, and the index parameter extraction and standardization processing are performed based on the measured data, which are taken as the nonlinear contour control objects. Then the classification accuracy of the difference metrics under controlled state is considered as the optimization goal, and the parameters of Gaussian kernel function are optimized by the adaptive particle swarm optimization. The SVDD model is trained by combining the optimized parameters and controlled index data to obtain the radius of the hypersphere as the control limit, and the nonlinear profile control chart based on the hypersphere kernel-distance is constructed. The distance between the measured contour index data point and the center of the hypersphere is calculated to obtain the statistical point of the control chart, and then it is determine whether the blade production process is abnormal. Compared with the traditional methods, the proposed method can effectively characterize the comprehensive influence of the quality characteristics of

different regions of the profile on the contour shape, and has a stronger detection ability for abnormal fluctuation of different mean deviation to solve the difficulty of insufficient data in the process control for small and medium-sized batch production.

Keywords: nonlinear profile control; difference metric; adaptive particle swarm optimization; support vector data description

叶片属于精密部件,是汽轮机及航空发动机等动力装置的“心脏”。叶身型面是保证叶片气动性能的关键,为此对叶身型面轮廓形状的准确性控制尤为重要^[1-2]。区别于传统的统计过程控制(SPC),这种通过函数关系对产品轮廓形状进行描述,并对描述函数的参数进行控制的方法称为轮廓控制^[3]。轮廓控制分为线性及非线性轮廓控制,叶身型面是自由曲面,由多条复杂曲线堆叠而成,属于典型的非线性轮廓控制^[4]。实际叶片检测过程中,通过三坐标数据对叶身型线进行表征,为此基于坐标数据如何对叶身型线进行非线性轮廓控制成为当前研究的热点。

不同机组的叶片设计尺寸不尽相同,总体来说叶片生产属于中小批量生产^[5],而同一型面不同截面高度上的型线具有规格参数不一致的特点。为此在叶片生产过程控制中存在两个关键问题:①叶身不同截面处型线的理论规格参数有差异,控制统计量不一致;②生产过程数据量较少,控制参数的均值及协方差估计不准。对于第1个问题,可参照成组技术^[6]中质量特征数据变换方法,对轮廓各差异度量指标实施母体标准化,消除不同设计公差带来的影响,为后续控制理论实施奠定基础。非线性轮廓控制可分为基于模型参数度量与基于非参数度量两种。对于第2个问题,文献[7]引入非参数度量概念,即通过历史轮廓测点数据拟合出平均基准轮廓,并与样本轮廓进行对比,采用传统单值控制原理构造基于偏差极值的非参数轮廓控制图;文献[8]给出6种常用的差异度量方法,通过比较差异指标与仿真设定的控制线阈值实施监控,避免了统计参数的估计。

基于上述研究,文献[9]根据待测样本轮廓坐标与基准轮廓型线间的偏差极值作为统计量,结合传统控制理论进行叶片加工过程质量控制,验证了此方法在较大偏移波动中的有效性。上述基于差异度量的非线性轮廓控制方法,一定程度上可避免因数据量不足而导致的统计超参数估计不准问题,但对于叶片生产过程,文献[9]的指标难以全面表征叶身轮廓型线不同区域质量特性,且忽略了不同型线所

允许的加工公差;同时仅通过当前实测偏差指标判断是否失控,无法检出过程的微小偏移。

随着人工智能的发展,支持向量机(SVM)^[10]、人工神经网络(ANN)^[11]等智能算法得到广泛应用。文献[12]利用SVM对刨花板制造过程表面轮廓质量进行监测,SVM作为二分类算法,需要收集正常及异常两种样本数据,这对于异常发生较少的生产过程并不适用;文献[13]提出一种ANN算法在非线性轮廓监控中的应用,但需要大量的历史训练数据。

综上,基于型线坐标数据,本文提出一种叶片生产过程非线性轮廓控制方法。首先构建叶身轮廓关键质量控制指标,采用随机抽样一致性算法(RANSAC)及距离阈值法进行叶身型线区域划分,求解各指标相对理论型线的偏差值,并进行标准化处理;然后利用自适应粒子群算法优化SVDD参数,基于正常状态指标数据训练超球体模型,构建非线性轮廓控制图;最后计算待测样本到超球体中心的内核距离,实现生产过程稳态监控。以汽轮机叶片生产过程为例,对比传统多元控制方法,本文方法可有效表征叶身型线不同区域质量特征对轮廓形状的综合影响,不仅对数据微小均值漂移具有更好的异常检测能力,且适用于中小批量生产模式下数据量不足的情况。

1 叶身型线轮廓差异度量指标构建

为有效表征叶身型线不同区域特征对轮廓形状的影响,参考航空叶片检测标准HB 5647-98及相关型线结构设计文献^[14-15],构建以下11个差异度量指标,用于叶片生产过程的轮廓状态监控,如表1所示。

1.1 叶身型线区域划分

实际叶身轮廓由三坐标测量得到,在获取叶身型线坐标数据后分别按叶盆、叶背、前缘、后缘4个区域对数据进行划分,型线结构区域如图1所示。

图1中的叶身型线,即基于实测坐标点进行NURBS曲线拟合^[16]后所得。根据叶身型线结构特点,提出一种型线区域划分方法,划分步骤如下。

表 1 叶身型线差异度量指标

差异度量特征参数	符号
前缘最大、最小偏差	q_{d1}, q_{d2}
后缘最大、最小偏差	h_{d1}, h_{d2}
叶背最大、最小偏差	b_{d1}, b_{d2}
叶盆最大、最小偏差	p_{d1}, p_{d2}
弦长差	E_{ch}
最大厚度差	E_{th}
面积差	E_s




图 1 叶身型线结构区域特征示意图

步骤 1:叶盆叶背数据初划分。搜索型线数据投影于 X 坐标的最小点 P_1 及最大点 P_2 作为数据的分界(相关标记见图 1),基于此将坐标数据分为 A、B 两部分,A、B 为按顺时针排列的有序点集;分别计算 A、B 中各数据到直线 P_1P_2 的最大距离 d_A 及 d_B ,若 $d_A > d_B$,则点集 A 为叶背数据,点集 B 为叶盆数据。

步骤 2:前、后缘数据初划分。从点集 A 和点集 B 中取部分首尾数据,定为初始前、后缘数据集。

步骤 3:前、后缘数据精筛选。根据 RANSAC 算法,从初始前、后缘数据集中准确筛选出属于前、后圆弧的数据点。

以前缘数据为例,筛选过程如下。

(1)设初始前缘圆弧所属数据点数为 n ,令计数标记 $N=0$,初始集合标记 X_1, X_q 。

(2)随机从初始前缘数据集中取 3 个点 A_1, A_2, A_3 ,并求解其圆弧圆心 O_1 及半径 R_1 。

(3)计算初始前缘中 n 个数据点到圆心 O_1 的距离 R' ,及 R' 与 R_1 的差异绝对值 e ;设差异阈值 $\varphi=0.05$,若 $e \leq \varphi$,则此点属于前缘圆弧数据集 X_1 ; n 次计算后属于前缘圆弧的数据点个数为 V 。

(4)如果 $V > N$,则令 $N=V, X_q=X_1$,并重置 $X_1=\{\}$ 。

(5)若每次从前缘中抽取 3 个数据点,依据排列组合原理,在 n 个数据点中,共有 r 种组合方式,即

$$r = V_n^1 V_{n-1}^1 V_{n-2}^1 / A_3^3 \tag{1}$$

(6)依次取 r 种组合方式中的一组数据点,重复过程(2)~(4) k 次后,得到最终归属于前缘圆弧的数据集 X_q ;同理可求取后缘数据集 X_h 。

步骤 4:叶身型线区域精划分。将前后缘数据集从初始叶盆及叶背数据集中剔除,得到精确区域数据集。

1.2 轮廓差异度量指标参数计算

根据国内某汽轮机公司的叶片质量检测部门的相关检测文件数据可知,三坐标测量机配套软件可输出表 1 中的叶身型线最大厚度、叶盆、叶背以及弦长这 4 个特征参数,并计算其理论值与实测值的差作为差异度量指标数据。因此,在划分好的叶身型线区域点集基础上,给出表 1 中剩余 5 个差异度量指标求解方法。

计算前缘、后缘相对于理论型线的偏差极值,有

$$E_{\max} = sd_{\max}; E_{\min} = sd_{\min} \tag{2}$$

式中: $E_{\max}, E_{\min}$ 为偏差极值(指标符号为 q_{d1}, q_{d2} 及 h_{d1}, h_{d2}); s 为偏差相对位置; $d_{\max}, d_{\min}$ 为测量点集到理论点集的距离极值。式(2)中各参数求解方法,可参照课题组在本刊发表的文献[16]。

提出面积差异度量指标,以保证理论与实测叶身型线之间相关关系,消除扭转叶片各截面理论型线不同的影响。指标定义如下

$$E_s = (S_2 - S_1) / S_1 \tag{3}$$

式中: S_1 及 S_2 分别为型线所围面积。该面积由实测及理论数据通过非均匀有理 B 样条(NURBS)曲线拟合后,利用 MATLAB 的 polyarea 函数计算得到。

1.3 标准化处理

叶身型面不同高度的区域截面型线形状有所不同,且特征参数的加工公差要求也不一致,为此对差异度量指标进行标准化处理,标准化后偏差为

$$E = \frac{\Delta}{U - D} \tag{4}$$

式中: Δ 为实测值与标准值的差; U 与 D 分别对应此指标质量特性的上规格界限及下规格界限。

2 基于核距离的非线性轮廓控制图

对于具有多质量特性的产品,若分别使用各变量的一元控制方法进行过程控制会增大过程状态误

判率,因此提出使用多元统计控制理论(MSPC)进行过程控制^[17]。MSPC的应用基础是变量间服从独立或联合正态分布假设,但无法兼顾各漂移范围的异常检测灵敏度。叶身型线具有11个质量特性差异度量指标,指标间存在相关关系复杂、假设分布未知、历史样本数据少的情况,为此MSPC的适用性有所限制。考虑到SVDD算法具有对数据分布形式无要求且训练数据需求量少的特点,本文结合SVDD算法,引入高斯核函数,构建基于核距离的非线性轮廓控制图,从而弥补传统MSPC控制方法的局限性。

2.1 支持向量数据描述算法

支持向量数据描述算法(SVDD)是一种基于支持向量机理论发展起来的单值分类方法^[18],其思想是:训练一个中心为 $\mathbf{a}$ 、半径为 R 的最小紧致超球体 F ,并尽量使最多的被描述对象 $\mathbf{X}_i$ 都包含在内。

假定 $\mathbf{X}$ 是 n 个维度为 m 的目标类训练样本,即 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{im}] (i=1, 2, \dots, n)$ 。定义该超球体的结构风险为

$$F(R, \mathbf{a}) = R^2 \quad (5)$$

限制条件为

$$\|\mathbf{X}_i - \mathbf{a}\|^2 \leq R^2 \quad (6)$$

为避免因训练样本的敏感奇异点与质量异常数据点间的边界交叠而造成的分类误判,为此引入松弛变量 ξ_i 。此时原问题转换为

$$\left. \begin{aligned} \min F(R, \mathbf{a}, \xi) &= R^2 + C \sum_{i=1}^n \xi_i \\ \text{s. t. } \|\mathbf{X}_i - \mathbf{a}\|^2 &\leq R^2 + \xi_i, \xi_i \geq 0, \\ i &= 1, 2, \dots, n \end{aligned} \right\} \quad (7)$$

式中: C 为惩罚系数,对错分样本惩罚程度起到限制的作用。

引入Lagrange函数,转为无约束最优问题,即

$$\begin{aligned} L(R, \mathbf{a}, \alpha, \gamma, \xi) &= R^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i (R^2 + \xi_i - \\ &\quad \|\mathbf{X}_i - \mathbf{a}\|^2) - \sum_{i=1}^n \gamma_i \xi_i \end{aligned} \quad (8)$$

式中:Lagrange乘子 $\alpha_i \geq 0, \gamma_i \geq 0$ 。

分别对 L 的参数 R 、 $\mathbf{a}$ 及 ξ_i 求偏导数并令其为0,可以得到

$$\left. \begin{aligned} \frac{\partial L}{\partial R} &= 0 \\ \frac{\partial L}{\partial \mathbf{a}} &= 0 \\ \frac{\partial L}{\partial \xi_i} &= 0 \end{aligned} \right\} \Rightarrow \left. \begin{aligned} \sum_{i=1}^n \alpha_i &= 1 \\ \mathbf{a} &= \sum_{i=1}^n \alpha_i \mathbf{X}_i \\ \gamma_i &= C - \alpha_i \end{aligned} \right\} \quad (9)$$

将式(14)代入式(13)并转化为对偶问题,得

$$\max L = \sum_{i=1}^n \alpha_i (\mathbf{X}_i \cdot \mathbf{X}_i) - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j (\mathbf{X}_i \cdot \mathbf{X}_j) \quad (10)$$

为降低高维空间运算复杂度,根据Vapnik所提理论^[18],引入核函数 $k(\mathbf{x}_i, \mathbf{x}_j)$ 代替内积 $(\mathbf{X}_i \cdot \mathbf{X}_j)$ 进行计算,则式(10)变为

$$\left. \begin{aligned} \max L &= \sum_{i=1}^n \alpha_i Q_{i,i} - \alpha^\top Q \alpha \\ \text{s. t. } \sum_{i=1}^n \alpha_i &= 1, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, n \end{aligned} \right\} \quad (11)$$

式中: Q 为核矩阵。转换为二次规划基本形式进行求解,可得最优解 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$,其中满足 $0 \leq \alpha_i \leq C$ 的 α_i 对应的 $\mathbf{x}_i$ 即为支持向量。

超球体半径 R 可根据任意支持向量 $\mathbf{x}_{sv}$ 求出,即

$$\begin{aligned} R^2 &= k(\mathbf{x}_{sv}, \mathbf{x}_{sv}) - 2 \sum_{i=1}^n \alpha_i k(\mathbf{X}_i, \mathbf{x}_{sv}) + \\ &\quad \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j k(\mathbf{X}_i, \mathbf{X}_j) \end{aligned} \quad (12)$$

2.2 基于核距离的非线性轮廓控制图设计

基于核距离的非线性轮廓控制图设计主要包括控制标绘点、控制限设计及其相关参数择优3个部分,设计流程如图2所示。




图2 基于核距离的叶片非线性轮廓控制图设计流程

对正常生产状态下叶片非线性轮廓的差异度量指标数据进行标准化处理后,通过APSO及SVDD算法联合高斯核函数训练,得到正常状态下的超球体参数 R 及 $\mathbf{a}$,定义超球体半径 R 为新的控制限。对于待监测样本数据,计算其到超球体球心的核距离作为控制标绘点,从而将叶片多质量特征参数转为一维表征量以实现生产过程质量控制。

2.2.1 控制标绘点及控制限设计 根据SVDD算法的原理引入超球体核距离^[19] D_k ,将待测样本 $\mathbf{z}$ 对超球体的核距离作为叶片生产过程控制标绘点,即

$$D_k(\mathbf{z}) =$$

$$\sqrt{k(\mathbf{z}, \mathbf{z}) - 2 \sum_{i=1}^n \alpha_i k(\mathbf{X}_i, \mathbf{z}) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j k(\mathbf{X}_i, \mathbf{X}_j)} \quad (13)$$

控制限可定义为:通过历史叶片正常生产状态下的型线轮廓偏差度量样本训练而成的最小超球体边界。控制限表示如下

$$\left. \begin{aligned} C_U = R &= (k(\mathbf{x}_{sv}, \mathbf{x}_{sv}) - 2 \sum_{i=1}^n \alpha_i k(\mathbf{X}_i, \mathbf{x}_{sv}) + \\ &\sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j k(\mathbf{X}_i, \mathbf{X}_j))^{-1} \\ C_L &= 0 \end{aligned} \right\} \quad (14)$$

对于测试样本 $\mathbf{z}$, 有如下决策函数

$$f(x) = R - D_k \quad (15)$$

当 $f(x) \geq 0$ 时, 表示目前生产过程处于受控状态, 否则生产过程发生异常波动。

2.2.2 基于 APSO 的设计参数择优 由式(13)(14)可知, 控制标绘点及控制限的确定主要取决于超球体模型训练中的核函数 $k(\mathbf{x}_i, \mathbf{x}_j)$ 及支持向量 α, α_i 的取值与惩罚系数 C 相关, 需要首先对核函数进行选择。

常用核函数分为高斯径向基核函数、多项式核函数以及 Sigmoid 核函数 3 种。叶身型线属于非线性轮廓且质量特征参数相关性复杂, 样本数据中的非线性映射关系难以获得。目前研究中, 高斯径向基核函数不仅可实现非线性映射, 同时可使模型边界具有更优的紧致性^[20], 为此本文采用高斯核函数进行计算。表达式如下

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2) \quad (16)$$

式中: σ 为高斯核宽度参数。此时, 高斯核函数参数 σ 及惩罚系数 C 是 SVDD 模型训练时需要确定的关键计算参数, 需对 σ 及 C 进行优化选择。

鉴于传统网格搜索法计算效率低、受划分精度影响大, 本文提出一种以正常测试样本落在控制限内的准确率为目标的 SVDD 参数择优方法。参数择优计算过程如下。

步骤 1: 定义适应度函数为

$$f = g(\sigma, C) = \frac{C_{in}}{C_{in} + C_{out}} \quad (17)$$

式中: C_{in} 、 C_{out} 为代入 σ 、 C 参数训练得到的 SVDD 模型中正常测试样本落在控制限内、外的数量。

步骤 2: 问题描述。待优化参数对象为 σ 、 C , 粒子的群属性可描述为 $P = [N_1, \dots, N_n]$, $N_l = [\mathbf{X}_l, \mathbf{V}_l]$ ($l=1, 2, \dots, n$) 为每个粒子个体属性, 由粒子位

置及速度组成; 二维 ($m=2$) 搜索空间中粒子位置及速度可表示为 $\mathbf{X}_l = [x_{l1}, x_{l2}]$, $\mathbf{V}_l = [v_{l1}, v_{l2}]$ 。

步骤 3: 算法参数设定。初始种群数 $n=50$, 迭代数 $k_{\max}=50$, 最大权重 $w_{\max}=0.9$, 最小权重 $w_{\min}=0.2$, 自我学习因子 $c_1=0.5$, 群体学习因子 $c_2=0.5$; 根据 σ 及 C 的常用取值范围^[20], 设 σ 及 C 的位置参数取值范围分别为 $x_\sigma = [x_{l1}^{\max}, x_{l1}^{\min}] = [0.01, 3]$ 、 $x_C = [x_{l2}^{\max}, x_{l2}^{\min}] = [0.02, 2]$, 则速度参数范围由关于位置参数的函数确定, 有

$$\mathbf{v}_\sigma = b(x_{l1}^{\max} - x_{l1}^{\min}); \quad \mathbf{v}_C = b(x_{l2}^{\max} - x_{l2}^{\min}) \quad (18)$$

式中: b 取 0.15, 有 $\mathbf{v}_\sigma = [-0.45, 0.45]$, $\mathbf{v}_C = [-0.297, 0.297]$ 。

步骤 4: 初始化种群位置及速度可表示为

$$\mathbf{X}_l^k = [x_{l1}^k, x_{l2}^k]; \quad \mathbf{V}_l^k = [v_{l1}^k, v_{l2}^k] \quad (19)$$

步骤 5: 将各粒子位置代入适应度函数式(17)中, 并更新个体历史最佳适应度值 f_l^{best} 及个体历史最佳位置 $\mathbf{X}_l^{\text{best}}$; 更新群最佳适应度值 f_n^{best} 及群历史最佳位置 $\mathbf{X}_n^{\text{best}}$ 。

步骤 6: 根据个体粒子及种群历史最佳位置调整并更新粒子速度, 更新后的第 $k+1$ 次迭代的粒子速度为

$$\mathbf{V}_l^{k+1} = w^k \mathbf{V}_l^k + c_1 r(\mathbf{X}_l^{\text{best}} - \mathbf{X}_l^k) + c_2 r(\mathbf{X}_n^{\text{best}} - \mathbf{X}_l^k) \quad (20)$$

式中: r 为 (0,1) 的随机数; w^k 为避免算法陷入局部最优而设置的自适应惯性权重^[21]

$$w^k = w_{\max} - k(w_{\max} - w_{\min}) / k_{\max} \quad (21)$$

此时, 更新后的粒子位置为

$$\mathbf{X}_l^{k+1} = \mathbf{X}_l^k + \mathbf{V}_l^{k+1} \quad (22)$$

步骤 7: 为加快算法收敛速度且避免跳过最优解, 对边界速度及位置进行处理, 即

$$\mathbf{V}_l^{k+1} = \begin{cases} \mathbf{V}_{\max}, & \mathbf{V}_l^{k+1} \geq \mathbf{V}_{\max} \\ \mathbf{V}_{\min}, & \mathbf{V}_l^{k+1} \leq \mathbf{V}_{\min} \end{cases} \quad (23)$$

$$\mathbf{X}_l^{k+1} = \begin{cases} \mathbf{X}_{\max}, & \mathbf{X}_l^{k+1} \geq \mathbf{X}_{\max} \\ \mathbf{X}_{\min}, & \mathbf{X}_l^{k+1} \leq \mathbf{X}_{\min} \end{cases} \quad (24)$$

步骤 8: 循环步骤 5~7 $k_{\max}$ 次, 直到迭代完成, 得到种群历史最佳适应度即为最优分类准确率, 其对应的群位置即为模型最优参数 σ 及 C 。

3 仿真分析及方法对比

以汽轮机某型号叶片的叶身型面加工过程为例, 基于多元轮廓差异度量指标进行叶片生产过程非线性轮廓控制, 并与传统的 T^2 多元控制图及针对过程均值微小漂移的 MEWMA 控制图^[22] 进行对比, 验证所提方法的有效性。

3.1 控制图建立

由前期收集到的 100 条正常加工状态下的型线坐标数据,按照 1.1~1.3 节所示步骤依次进行处理,得到 100 组标准化的型线轮廓差异度量指标。基于预处理后的正常样本数据,利用自适应粒子群算法进行 SVDD 模型参数择优。

(1)样本划分。依据机器学习-数据划分原则,从 100 组样本中抽取 70 组作为训练集,剩下 30 组作为测试集。

(2)适应度求解。通过 2.2.2 节算法对参数 σ 、 C 进行择优,其中适应度函数计算过程为:将式(19)随机生成的参数 σ 及 C 代入 70 组正常样本数据,按照式(12)进行 SVDD 模型训练,获取超球体参数 R 及 a ;然后采用式(13)计算每组测试样本到超球体中心的核距离,并判断是否超出控制限 R ;当 30 组测试样本完成判断后,返回 30 组测试样本处于控制限内的比例作为当前个体适应度。

(3)迭代择优。循环上述过程,完成当前迭代的种群最佳适应度计算,并按式(20)(22)更新种群粒子 σ 、 C 的位置及速度,进入下一次迭代求解;当迭代数满足 $k_{\max}=50$ 时,停止搜寻,输出历史种群最佳适用度及其所对应的最佳位置值。

最佳适应度的实质可解释为:以最佳位置即最优参数 σ 及 C 所训练的 SVDD 模型而得到的超球体半径 R 作为控制限时,正常样本具有的受控状态正确判断率最佳值。

为此,基于 APSO 择优算法对比网格搜索法进行 SVDD 模型参数优化。APSO 的迭代优化过程曲线及优化结果如图 3、图 4 所示,网格优化结果如图 5 所示,表 2 给出对应的优化参数值及最佳适应度对比结果。




图 3 自适应粒子群算法迭代结果

根据对比结果可看出:自适应粒子群算法对正常样本的受控状态准确率判断达 99.62%,而网格




图 4 自适应粒子群算法参数优化云图




图 5 网格划分法参数优化云图

划分法仅为 95.26%;自适应粒子群算法在迭代到 35 代后,训练结果的平均适应度值已经稳定并与最大适应度值相等,达到最优解。

表 2 SVDD 模型参数优化方法对比

方法	σ	C	受控判断 准确率/%
自适应粒子群	1.559	0.026	99.62
网格划分	0.943	0.416	95.26

因此,本文采用核函数参数 σ 为 1.559、惩罚系数 C 为 0.026 作为 SVDD 模型训练参数,联合式(9)(11)(12)(14),计算得到此型号叶片生产过程的非线性轮廓图的控制限 $C_U=0.0132$, $C_L=0$ 。在此控制限下,对正常生产样本数据的受控状态判断准确率 γ 为 99.62%,则其误报率 $\alpha=1-\gamma=0.38\%$ 。所以,非线性轮廓控制图的受控状态平均运行链长为

$$L_0 = \frac{1}{\alpha} = 263.2$$

(25)

3.2 方法对比

平均运行链长 L 是评价控制图优劣性能的重要指标^[23],分为受控平均运行链长 L_0 和失控平均运行链长 L_1 。 L_0 越大表示过程受控时控制图稳定性越高,对正常数据的误报率越低; L_1 越小表示控制图对生产过程异常波动的检出力越强,对异常数据的漏报率越低。

为与传统多元控制方法进行性能对比,以所提

方法计算得到的 L_0 为基准,展开后续对比分析。求取正常生产状态下 T^2 及 MEWMA 控制图在 $L_0 \approx 263$ 时的控制限,并基于此控制限仿真对比过程发生异常偏移时的失控平均运行链长 L_1 。

前期收集的正常测量数据为 100 组,无法满足 L_0 仿真所需数据量,因此需仿真生成 200 组正常样本。计算收集到的实测正常样本中 100 条型线的 20 000 个偏差,对偏差绘制直方图,结果如图 6 所示,整体偏差均值 μ 为 0.056 9,标准差 σ' 为 0.024 1。




图 6 正常状态实测型线偏差直方图

由正态分布 $N(0.056\ 9,0.024\ 1^2)$ 随机生成 200 组偏差,通过等距点公式,基于理论型线数据仿真生成正常测试型线样本。仿真得到 $L_0 \approx 263$ 时, T^2 控制限 $H=27.54$,MEWMA 控制限 $H=25.18$ 。

利用随机模拟方法计算 L_1 ,对比本文所提方法与上述两种控制方法的异常检出力,仿真过程如下。

步骤 1:异常样本构造。由于生产过程异常数据难以收集,因此假设生产过程出现异常,整体轮廓偏差的均值按 $\Delta u = \delta \sigma'$ (偏移量系数 $\delta = 0.25, 0.5, 1, 1.5, 2, 2.5$) 发生漂移,分别以正态分布参数 $(\mu + \Delta \mu, \sigma'^2)$ 各生成 400 组偏差,并按等距点公式生成异常型线样本数据,且令每批样本容量为 2,共 200 批。

步骤 2:数据预处理。获取标准化后的差异度量指标数据组,每组样本数据有 11 个度量指标元素。

步骤 3:设定生产过程从第 25 个样本开始发生波动,分别利用 3 种控制方法进行质量控制,计算不同漂移下的失控状态平均运行链长 L_1 。

步骤 4:乱序步骤 2 中数据,循环仿真 2 000 次,每次仿真结果记为 $L_{1,k,i}, i=1, \dots, 2\ 000; k=1, 2, 3$ 表示所用控制方法。

步骤 5:计算各控制方法下的失控状态平均运行链长 $\bar{L}_{1,k,i} = \frac{1}{2\ 000} \sum_{i=1}^{2\ 000} L_{1,k,i}$ 。

3.3 结果分析

在不同均值漂移情况下,采用本文方法及传统多元控制方法分别进行叶身型线非线性轮廓控制。仿真得到 3 种不同控制方法的失控平均运行链长 L_1 变化趋势如图 7 所示,平均运行链长数据如表 3 所示。




图 7 不同控制方法运行链长对比

表 3 不同控制方法运行链长的对比结果

δ	L			灵敏度/%
	T^2	MEWMA	本文方法	
0.00	262.600	262.800	263.200	
0.25	136.285	79.823	28.627	64.14
0.50	63.752	40.635	17.919	55.90
1.00	14.551	11.273	5.804	48.51
1.50	4.504	4.137	2.690	34.98
2.00	2.025	2.126	1.520	24.94
2.50	1.132	1.346	1.010	10.78

从表 3 可以看出:在过程均值发生微小偏移的情况下,MEWMA 控制图的异常检出力明显优于 T^2 控制图,而当过程转为大偏移时,MEWMA 控制图由于小的平滑系数导致其异常报警滞后,此时 T^2 控制图性能优于 MEWMA 控制图;本文方法在各偏移范围内的异常检灵敏度均优于其他两种方法,可有效弥补 T^2 控制图在小偏移下的异常检测不敏感及 MEWMA 控制图对大偏移异常检测滞后性的问题。

4 结 论

通过构建叶身型线轮廓差异度量指标,联合高斯核函数及支持向量数据描述算法,建立基于核距离的叶片生产过程非线性轮廓控制方法,并与传统方法进行对比,主要结论如下。

(1)根据叶身型线结构特点,构建 11 个轮廓差

异度量指标;基于实测坐标数据,提出型线区域划分及各度量指标偏差计算方法,引入数据标准化思想以消除不同叶身截面型线的公差差异。

(2)利用支持向量数据描述算法,联合高斯核函数训练超球体模型,构建非线性轮廓控制图,并以生产样本数据到超球体中心的核距离作为控制标绘点,进行过程稳态判断。

(3)基于自适应粒子群算法优化高斯核函数参数及惩罚系数,与网格划分寻优方法进行对比,优化了超球体模型,使控制图达到最优统计性能。

(4)支持向量数据描述算法具有小样本适用性的特点,可避免传统方法在中小批量生产数据不足而导致的控制图统计量参数估计不准的问题。

(5)为验证本文方法的控制性能,仿真生成不同范围的偏差均值漂移样本,与传统方法的叶身型线加工过程异常检出力进行对比。结果表明,本文方法在各偏移下的异常检出力均优于传统方法,且在微小偏移下灵敏性高,对中小批量生产模式下的叶片生产过程具有更好的适用性。

参考文献:

- [1] CHEN Lei, LI Bing, JIANG Zhuangde, et al. Parameter extraction of featured section in turbine blade inspection [C]// 2010 IEEE International Conference on Automation and Logistics. Piscataway, NJ, USA: IEEE, 2010: 501-505.
- [2] YANG Xu, LIU Xiaolong, LIU Jiming, et al. Matching algorithm for profile error calculation of blade surface [J]. Advanced Materials Research, 2016, 1136: 630-635.
- [3] KHEDMATI M, NIAKI S T A. Monitoring simple linear profiles in multistage processes by a MaxEWMA control chart [J]. Computers & Industrial Engineering, 2016, 98: 125-143.
- [4] 何帅, 陈富民, 杨雅棠, 等. 基于点云数据的自由曲面加工误差评定 [J]. 西安交通大学学报, 2019, 53(10): 135-142.
HE Shuai, CHEN Fumin, YANG Yatang, et al. Machining error evaluation of free-form surface based on point cloudy data [J]. Journal of Xi'an Jiaotong University, 2019, 53(10): 135-142.
- [5] 余忠华, 吴昭同. 面向小批量制造过程的质量控制方法研究 [J]. 机械工程学报, 2001, 37(8): 60-64.
YU Zhonghua, WU Zhaotong. Algorithm of quality control in small batch manufacturing process [J]. Chinese Journal of Mechanical Engineering, 2001, 37(8):

60-64.

- [6] 陈鑫, 陈富民. 面向多品种小批量生产的贝叶斯动态质量控制方法 [J]. 西安交通大学学报, 2019, 53(6): 17-22.
CHEN Xin, CHEN Fumin. Bayesian dynamic quality control method for multi-variety and small batch production [J]. Journal of Xi'an Jiaotong University, 2019, 53(6): 17-22.
- [7] VAGHEFI A, TAJBAKHS S D, NOOROSSANA R. Phase II monitoring of nonlinear profiles [J]. Communications in Statistics-theory and Methods, 2009, 38(11): 1834-1851.
- [8] ZHANG Y, HE Z, FANG J T, et al. Nonparametric control scheme for monitoring phase II nonlinear profiles with varied argument values [J]. Chinese Journal of Mechanical Engineering, 2012, 25(3): 587-597.
- [9] 张阳. 复杂产品制造过程中轮廓控制方法研究 [D]. 天津: 天津大学, 2013: 45-49.
- [10] 唐浩, 屈梁生. 基于支持向量机的发动机故障诊断 [J]. 西安交通大学学报, 2007, 41(9): 1124-1126.
TANG Hao, QU Liangsheng. Fault diagnosis of engine based on support vector machine [J]. Journal of Xi'an Jiaotong University, 2007, 41(9): 1124-1126.
- [11] HOSSEINIFARD S Z, ABDOLLAHIAN M, ZEEP-HONGSEKUL P. Application of artificial neural networks in linear profile monitoring [J]. Expert Systems with Applications, 2011, 38(5): 4920-4928.
- [12] MOGUERZA J M, MUÑOZ A, PSARAKIS S. Monitoring nonlinear profiles using support vector machines [M]// Lecture Notes in Computer Science: Volume 4756. Berlin, Germany: Springer, 2007: 574-583.
- [13] PAPOUTSIDAKIS M G, PIPE A G, CHAMILOTHORIS G E. A supervised learning method of neural networks in a non-linear and time depended control process [C]// 21st Mediterranean Conference on Control and Automation. Piscataway, NJ, USA: IEEE, 2013: 1526-1531.
- [14] 虞跨海, 李立州, 岳珠峰. 基于解析及特征造型的涡轮冷却叶片参数化设计 [J]. 推进技术, 2007, 28(6): 637-640, 656.
YU Kuahai, LI Lizhou, YUE Zhufeng. Parametric design for cooling turbine blades based on analytic and feature modeling [J]. Journal of Propulsion Technology, 2007, 28(6): 637-640, 656.
- [15] MA Wenqi, LIU Shugui. The research on the methods of the aero engine blades evaluation [J]. Applied Mechanics and Materials, 2013, 333-335(1): 322-326.

(下转第 162 页)

- 38-44.
- QIAO Yang, DU Liping, XIAO Dongguang. A comparative study of different polarity chromatographic column in analysis of aroma components in black tea [J]. *Journal of Tea Science*, 2016, 36(1): 38-44.
- [13] CAO Jianping, WESCHLER C J, LUO Jiajun, et al. Cm-history method, a novel approach to simultaneously measure source and sink parameters important for estimating indoor exposures to phthalates [J]. *Environmental Science & Technology*, 2016, 50(2): 825-834.
- [14] XIONG Jianyin, CAO Jianping, ZHANG Yiping. Early stage C-history method: rapid and accurate determination of the key SVOC emission or sorption parameters of indoor materials [J]. *Building and Environment*, 2016, 95: 314-321.
- [15] ZHANG Xu, CAO Jianping, WEI Jingya, et al. Improved C-history method for rapidly and accurately measuring the characteristic parameters of formaldehyde/VOCs emitted from building materials [J]. *Building and Environment*, 2018, 143: 570-578.
- [16] 沈隽, 曹连英, 黄占华. 密闭小室测定建材有机挥发物散发特性的研究 [J]. *北京林业大学学报*, 2011, 33(3): 111-114.
- SHEN Jun, CAO Lianying, HUANG Zhanhua. Emission characteristics of volatile organic compounds of building materials in small airtight chamber [J]. *Journal of Beijing Forestry University*, 2011, 33(3): 111-114.
- [17] 曾海东, 张寅平, 王庆苑, 等. 用密闭小室测定建材 VOC 散发特性 [J]. *清华大学学报(自然科学版)*, 2004, 44(6): 778-781.
- ZENG Haidong, ZHANG Yiping, WANG Qingyuan, et al. Measuring VOC emission characteristics of building materials in an airtight chamber [J]. *Journal of Tsinghua University (Science and Technology)*, 2004, 44(6): 778-781.

(编辑 杜秀杰)

(上接第 98 页)

- [16] 何帅, 陈富民, 李建华, 等. 叶身型线轮廓度评定方法研究 [J]. *西安交通大学学报*, 2019, 53(8): 175-182.
- HE Shuai, CHEN Fumin, LI Jianhua, et al. Profile evaluation method for blade pattern [J]. *Journal of Xi'an Jiaotong University*, 2019, 53(8): 175-182.
- [17] 贾新章, 游海龙, 顾铠. 统计过程控制理论与实践 [M]. 北京: 电子工业出版社, 2017: 142-153.
- [18] TAX D M J, DUIN R P W. Support vector data description [J]. *Machine Learning*, 2004, 54(1): 45-66.
- [19] GANI W, LIMAM M. Performance evaluation of one-class classification-based control charts through an industrial application [J]. *Quality and Reliability Engineering International*, 2013, 29(6): 841-854.
- [20] 武千惠, 黄必清. 基于支持向量数据描述的剩余寿命预测方法 [J]. *计算机集成制造系统*, 2018, 24(11): 2725-2733.
- WU Qianhui, HUANG Biqing. Remaining useful life prediction based on support vector data description [J]. *Computer Integrated Manufacturing Systems*, 2018, 24(11): 2725-2733.
- [21] LI Mi, CHEN Huan, WANG Xiaodong, et al. An improved particle swarm optimization algorithm with adaptive inertia weights [J]. *International Journal of Information Technology and Decision Making*, 2019, 18(3): 833-866.
- [22] FARAZ A, HEUCHENNE C, SANIGA E. Optimal T2Control chart with a double sampling scheme-an alternative to the MEWMA chart [J]. *Quality and Reliability Engineering International*, 2012, 28(7): 751-760.
- [23] 郑辉, 张伟, 张峻霞, 等. 多元动态控制图的性能对比分析与选择 [J]. *计算机集成制造系统*, 2017, 23(11): 2335-2343.
- ZHENG Hui, ZHANG Wei, ZHANG Junxia, et al. Performance comparison and selection of multi-variate adaptive control chart [J]. *Computer Integrated Manufacturing Systems*, 2017, 23(11): 2335-2343.

(编辑 杜秀杰)