AHPSO-SVM 预测超声内圆磨削 ZTA 陶瓷的边界损伤

赵明利　　李博涵　　聂立新　　吕晓峰　　赵　波

（河南理工大学机械与动力工程学院，焦作　454003）

文　摘　为解决普通加工方式易出现工程陶瓷边缘碎裂的问题，本文对超声内圆磨削工程陶瓷边界损伤预测系统进行了研究。在 35 kHz 轴向超声磨削与普通磨削两种条件下独立进行试验，运用支持向量机研究工艺参数与边界损伤影响规律，采用改进的粒子群算法优化支持向量机，建立采用混合核函数的 AHPSO-SVM 预测模型。研究结果表明，超声激励下试件边界损伤降幅为 10.05%～21.23%，AHPSO-SVM 预测模型 MSE 为 0.378 4、平均相对误差为 1.369 0%、30 次适应度值标准差为 0.020 2。相比于普通磨削，超声磨削可使 ZTA 陶瓷边界损伤值显著降低；建立的 AHPSO-SVM 模型具有较好的学习能力、泛化性能与良好的稳定性。

关键词　粒子群算法，支持向量机，超声内圆磨削，ZTA 陶瓷，边界损伤

中图分类号：TG663；TH145.1　　DOI：10. 12044/j. issn. 1007-2330. 2019. 02. 014

AHPSO-SVM Prediction of Boundary Damage of Ultrasonic Internal Grinding of ZTA Ceramics

ZHAO Mingli　　LI Bohan　　NIE Lixin　　LV Xiaofeng　　ZHAO Bo

（College of Mechanical & Power Engineering，Henan Polytechnic University，Jiaozuo　454003）

Abstract　In order to solve the problem that there is prone to edge cracking of engineering ceramics with common processing，this paper studies the boundary damage prediction system of ultrasonic internal grinding. The experiment was carried out independently under the conditions of 35 kHz axial ultrasonic grinding and ordinary grinding. The support vector machine was used to study the influence of the process parameters to boundary damage. The improved particle swarm optimization algorithm was used to optimize the support vector machine and the hybrid kernel function AHPSO-SVM predict model was established . The results show that the reduction of boundary damage of the specimen under ultrasonic is 10.05%～21.23%，the MSE of the AHPSO-SVM prediction model is 0.3784，the average relative error is 1.3690%，and the standard deviation of the 30-time fitness value is 0.0202. Compared with ordinary grinding，ultrasonic grinding can significantly reduce the boundary damage value of ZTA ceramics.The established AHPSO-SVM model has better learning ability，generalization performance and good stability.

Key words　Particle swarm optimization，Support vector machine，Ultrasonic internal grinding，ZTA ceramics，Boundary damage

0　引言

ZTA 陶瓷具有高强度、高韧性及较好的化学稳定性，广泛应用于高新技术工程领域，但在加工过程中易发生崩裂、破碎，其中边界损伤情况尤为明显[1-2]。超声内圆磨削加工过程中，由于磨削力小、工具磨损小，且相邻磨粒移动路径随机干涉程度较大，加工表面网纹结构得到改善，进而表面质量得到提高[3-4]。

文献[2，5]通过研究表明，在超声磨削过程中加工参数及材料特性会影响边界损伤，且在磨削深度较大时由于干涉较深，易导致陶瓷材料出现崩裂现象。文献[6]将纵向进给量、工件速度、修整深度与修整导程作为特征向量，利用 LS-SVM 对外圆纵向磨削表面粗糙度预测，精度较高，但其没有利用启发式算法、交叉验证等方法对惩罚因子 C、核参数 σ 搜索，而

收稿日期：2018-06-08

基金项目：国家自然科学基金（E51175153）；河南理工大学博士基金（B2016-27）

第一作者简介：赵明利，1975 年出生，副教授，博士，研究方向为难加工材料的精密与特种加工技术。E-mail：zhaomingli@ hpu.edu.cn

是直接选取,不易于推广。文献[7]利用遗传算法与支持向量机(Support Vector Machine, SVM)建立刀具状态监测模型,对砂带状态预测,通过实验发现结果精度较高。文献[8]以少量样本条件下基于支持向量机建立预测超声振动研磨放电加工表面粗糙度模型,与试验值对比后发现误差较小、模型可靠。

本文利用支持向量在小样本、高维度、非线性预测领域的良好应用效果,使用改进的自适应混合粒子群算法(Adaptive Hybrid Particle Swarm Optimization, AHPSO)对拥有混合核函数的支持向量机正则化参数(C、σ、η)进行寻优,并建立回归预测模型。

1 混合核函数与支持向量机基本理论

1.1 回归支持向量机基本原理

用于回归的支持向量机,其基本原理为通过核函数将训练集中样本数据映射到高维特征空间中,使其成为一个线性回归问题。

构造一个凸二次规划问题:

$$\min\left[\frac{1}{2}\|w\|^2 + C\sum_{i=1}^{l}(\xi_i + \xi_i^*)\right]$$
$$s.t.\begin{cases} y_i - w\varphi(x_i) - b \leqslant \varepsilon + \xi_i \\ -y_i + w\varphi(x_i) + b \leqslant \varepsilon + \xi_i^* \\ \xi_i \geqslant 0, \xi_i^* \geqslant 0, i = 1,2,\cdots,l \end{cases} \tag{1}$$

式中,w 为权值向量,$\varphi(x)$表示非线性映射函数,b 为偏置;ε 为不敏感损失函数;ξ_i、ξ_i^* 为松弛变量;$C>0$ 为惩罚系数,C 越大表示对目标函数的惩罚就越大,其泛化能力就越差。其中定义的 ε 不敏感损失函数为:

$$L_\varepsilon(y,f(x,\alpha)) = \begin{cases} 0, & |y - f(x,\alpha)| \leqslant \varepsilon \\ |y - f(x,\alpha)| - \varepsilon, & \text{other} \end{cases} \tag{2}$$

式中,$f(x)$为训练集构造的回归估计函数,即

$$f(x) = w\varphi(x) + b \tag{3}$$

对于式(1),引入拉格朗日乘子法,将该凸二次规划问题转化为对偶形式,即

$$\max_{\alpha_i,\alpha_i^*}\left[-\frac{1}{2}\sum_{i=1}^{l}\sum_{j=1}^{l}(\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(x_i,x_j) - \sum_{i=1}^{l}\varepsilon(\alpha_i + \alpha_i^*) + \sum_{i=1}^{l}y_i(\alpha_i - \alpha_i^*)\right]$$
$$s.t.\begin{cases} \sum_{i=1}^{l}(\alpha_i - \alpha_i^*) = 0 \\ 0 \leqslant \alpha_i \leqslant C, 0 \leqslant \alpha_i^* \leqslant C, i = 1,2,\cdots,l \end{cases} \tag{4}$$

式中,只有当训练样本作为支持向量(Support Vector, SV)时,其参数 $(\alpha_i - \alpha_i^*)$不为 0,所以得到最后的回归估计函数:

$$f(x) = \sum_{x_j \in sv}(\alpha_j, \alpha_j^*)K(x,x_i) + b^* \tag{5}$$

1.2 线性组合的混合核函数

在支持向量机中,常用核函数有线性核函数、多项式核函数、RBF 核函数、Sigmoid 核函数等,可分为全局核函数和局部核函数。多项式核函数与 Sigmoid 核函数具有全局特性,能够提取数据集中全局的信息,泛化性能强,但其局部拟合能力较差、学习能力较弱。RBF 核函数具有局部性,局部拟合能力非常好,学习能力强,但泛化性能较弱。除了常用核函数之外,核函数的研究还有构造特定核函数、合成核函数方法两个方面;根据核函数的构造方法,可将两个满足 Mercer 条件的核函数进行线性组合,本文选取多项式核函数与 RBF 核函数进行组合[9-10],其表达式为:

$$K(x,x_i) = \eta(\gamma_1(xx_i)^d + 1) + (1 - \eta)\exp(-\gamma_2\|x - x_i\|^2) \tag{6}$$

式中,η 为比例系数,取值范围为[0,1]。

2 AHPSO 优化 SVM 理论模型

2.1 AHPSO 算法

支持向量机的参数选取对模型结果有较大的影响,在训练集相同的情况下,不同的参数对回归预测的准确性有严重的影响。本文将粒子群算法(Particle Swarm Optimization,PSO)应用在支持向量机优化建模,主要利用该算法种群内部的信息共享机制,使问题的求解从随机到有序进行演变,得到问题的最优解。该算法中各个粒子的速度与位置按如下公式进行更新:

$$v_{id}(t+1) = w(t)v_{id}(t) + c_1r_1(p_{id}(t) - x_{id}(t)) + c_2r_2(g_{id}(t) - x_{id}(t)) \tag{7}$$
$$x_{id}(t+1) = x_{id}(t) + v_{id}(t) \tag{8}$$

式中,r_1、r_2 为在[0,1]独立均匀分布的随机因子;w 为惯性权重,决定对当前粒子速度的继承程度;c_1、c_2 为调节个体最佳与全局最佳的学习因子。惯性权重决定了粒子当前速度对下一次速度的影响程度,当惯性权重较大时有利于提高离群体的探索能力,较小时有利于提高群体的开发能力。

为了平衡 PSO 算法的“探索-开发”,以确定其效率与准确性,本文引入信息素、状态转移概率等概念,以解决自适应惯性权重问题,其更新公式为:

$$\tau_{id}(t+1) = (1 - \rho)\tau_{id}(t) + f_{id} \tag{9}$$
$$p_{id}(t) = \frac{\tau_{id}(t) - \tau_{\min}}{\tau_{\min}} \tag{10}$$

$$w_{id}(t+1)=\begin{cases} w_{\min}-w_{id}(t)p_{id}(t)\mu, & p<p_0 \\ w_{\max}-\dfrac{(w_{\max}-w_{\min})t}{T_{\max}}, & \text{other} \end{cases} \quad (11)$$

式中，τ 为信息素，ρ 为信息素蒸发系数，f_{id} 为当前适应度值；p 为状态转移概率；$w_{\max}$、$w_{\min}$ 分别为最大、最小惯性系数；μ 为放大系数，$T_{\max}$ 为最大迭代次数。

为了提高算法的认知能力，防止算法陷入局部最优，产生早熟现象，在 PSO 算法中添加自适应粒子位置变异算子，即选择一定比例的粒子，重新对其位置的某一维度在设定范围内随机分布。各个粒子的自适应粒子位置变异算子公式：

$$x_{id}=\begin{cases} (x_{\max,d}-x_{\min,d})r+x_{\min,d}, & \delta<CR \\ x_{id}(t), & \text{other} \end{cases} \quad (12)$$

式中，$x_{\max,d}$、$x_{\min,d}$ 为粒子的取值范围，δ 为变异因子。

2.2 AHPSO-SVM 模型参数优化

AHPSO-SVM 模型综合了 AHPSO 算法高效的搜索能力与支持向量机良好的泛化能力，可以很好的应用在超声内圆磨削 ZTA 陶瓷边界损伤预测。

选取公式(6)为核函数，为了减少 AHPSO 算法搜索维度、提高模型精度，令参数 $\gamma_1=\gamma_2$，$d=2$，只需搜索惩罚因子 C、核参数 γ 与比例系数 η。该模型具体步骤：

(1)读取样本数据，对数据进行归一化，消除各类指标间量纲的影响，并产生训练集、测试集。

(2)程序初始化。初始化粒子速度与位置，初始速度为 0，初始位置为搜索空间内随机分布。

(3)按照公式(9)(10)计算信息素与状态转移概率，并通过公式(11)得出惯性系数。

(4)由式(7)(8)得出当前粒子速度与位置，并利用公式(12)使部分粒子的某一维度进行重置变异。

(5)计算适应度值，并判断是否符合条件。若符合条件，结束程序，输出搜索结果；如不符合条件，返回至步骤(3)。

(6)输出最优参数，建立回归支持向量机模型，对测试集进行预测，得到结果。

3 超声内圆磨削 ZTA 陶瓷边界损伤试验

3.1 装置与方案

为考察超声作用对边界损伤值的影响，本文选用 35 kHz 轴向圆锥过渡阶梯形复合变幅杆，在加装超声磨削装置的 VMC850E 机床上进行 ZTA 陶瓷内圆磨削试验，如图 1 所示。

分别在 35 kHz 轴向超声磨削和普通磨削的条件下进行试验，其中经多次测试发现超声磨削装置尾部轴向振幅为 8.3 μm 左右。以小进给量精磨试件内圆方式进行预磨削处理，磨削试验后超声清洗试件，并用 SH4000M 扫描电镜观测试件边界损伤。为了具体分析磨削加工参数对 ZTA 陶瓷边界损伤深度值的影响，对 ZTA 陶瓷在两种条件下进行正交试验与单因素试验。

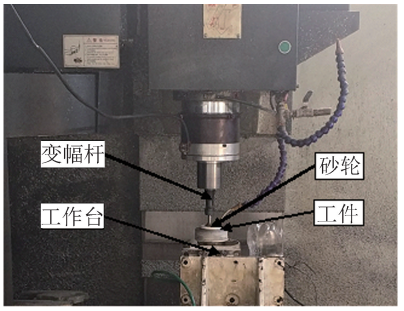


图 1 试验现场

Fig.1 Experimental site

3.2 结果与分析

正交试验主要是为了考察各个加工参数对边界损伤深度值的影响，结果如表 1 所示。为了具体分析超声激励、磨削深度两种加工参数对边界损伤深度值的影响，在单因素试验中砂轮速度与工件转速保持不变，且选取正交试验中这两种加工参数的第二水平为试验参数，以减少对试验结果的影响，即在单因素试验中砂轮速度为 3.27 m/s、工件转速为 0.5 m/s。单因素试验边界损伤深度值如表 2 所示。

表 1 正交试验边界损伤值数据

Tab.1 The boundary damage data of orthogonal experiment

试验号	超声频率 /kHz	砂轮速度 /m·s^{-1}	工件转速 / m·s^{-1}	磨削深度 /μm	边界损伤值/μm
1	0	1.31	0.28	15	34.6
2	0	1.31	0.5	20	36.7
3	0	1.31	0.72	25	41.8
4	0	3.27	0.5	15	33.4
5	0	3.27	0.72	20	35.3
6	0	3.27	0.28	25	40.3
7	0	5.23	0.72	15	32.5
8	0	5.23	0.28	20	34.8
9	0	5.23	0.5	25	38.1
10	35	1.31	0.28	15	30.9
11	35	1.31	0.5	20	32.1
12	35	1.31	0.72	25	37.6
13	35	3.27	0.5	15	28.1
14	35	3.27	0.72	20	30.3
15	35	3.27	0.28	25	33
16	35	5.23	0.72	15	25.6
17	35	5.23	0.28	20	28.5
18	35	5.23	0.5	25	32.3

表 1 中，普通磨削 ZTA 陶瓷边界损伤普遍比超声磨削下严重，且超声磨削下 ZTA 陶瓷的边界损伤情况显著降低，降幅最小为 10.05%、最大为 21.23%，其原因为磨粒在 35 kHz 轴向超声振动作用下，短时间内

对加工区域反复切除的结果,与普通磨削相比得到边界质量相对较好。由表 2 可知,从边界损伤深度趋势看出边界损伤对磨削深度的变化较为敏感,随着磨削深度的增大其对边界损伤的影响越明显。其原因为随着磨削深度增大,砂轮与 ZTA 陶瓷接触面积变大,砂轮的单颗磨粒未变形切削量不断变厚,ZTA 陶瓷加工区域的切削抗力不断增加,尤为关键的是砂轮在切入 ZTA 陶瓷内圆壁时,对其边界产生极大的瞬时挤压力,极易引起 ZTA 陶瓷内圆壁边界的崩碎和断裂。

表 2　单因素试验边界损伤值数据

Tab.2　Boundary damage data of single factor experiment

试验号	超声频率/kHz	磨削深度/μm	边界损伤深度值/μm
1	0	10	32
2	0	15	33.4
3	0	20	35.6
4	0	25	39.7
5	0	30	43.9
6	35	10	25.9
7	35	15	28.1
8	35	20	30.8
9	35	25	33.2
10	35	30	38.4

4　仿真试验及预测结果分析

4.1　最优预测结果分析

为了验证本文提出的自适应混合粒子群算法对支持向量机的优化能力及对 ZTA 陶瓷边界损伤的预测性能,选用表 1 为训练集进行建模、表 2 为验证集进行检验,选取粒子群算法、网格搜索(CV)优化支持向量机进行对比。AHPSO-SVM 选用公式(6)为核函数,PSO-SVM 与 CV-SVM 采用 RBF 核函数,且各模型的损失系数 $\varepsilon=0.01$,惩罚因子 C、核参数 σ 取值范围均为 $[2^{-10},2^{10}]$。AHPSO 算法参数设置为种群数量为 20,最大迭代次数 $T_{max}=200$,惯性权重因子 $w_{max}=0.9$、$w_{min}=0.4$,学习因子 $c_1=c_2=1.49$,信息素蒸发系数为 $\tau=0.9$,转移概率常数为 $\rho=0.1$,放大系数为 $\mu=5$,自适应变异系数为 $p_0=0.7$;PSO 算法与 AHPSO 算法设置相同参数。网格搜索算法将待寻优参数(C、σ)在指定范围内划分网格形成节点,并遍历所有节点以寻找最优参数。

对各模型的最优解与试验值对比分析,并计算每组预测结果的相对误差,以验证模型预测精度,其中 AHPSO-SVM 模型最优解的寻优参数为 $C=8\ 1.159\ 8$、$\gamma=27.836\ 1$、$\eta=0.200\ 2$,结果如表 3 所示。

表 3　仿真结果与相对误差

Tab.3　Simulation results and relative errors

序号	试验值	AHPSO-SVM		PSO-SVM		CV-SVM	
		预测值/mm	相对误差/%	预测值/mm	相对误差/%	预测值/mm	相对误差/%
1	32	31.6305	1.1547	30.4354	4.8894	30.0612	6.0588
2	33.4	33.5766	0.5287	33.4694	0.2078	33.2820	0.3533
3	35.6	36.1546	1.5579	36.5053	2.5430	36.5107	2.5581
4	39.7	39.2166	1.2176	39.5422	0.3975	39.7452	0.1138
5	43.9	42.7555	2.6071	42.5789	3.0093	42.9835	2.0877
6	25.9	26.2443	1.3293	24.5792	5.0996	24.0959	6.9656
7	28.1	28.2156	0.4114	27.6091	1.7470	27.3059	2.8260
8	30.8	30.7027	0.3159	30.6418	0.5136	30.5251	0.8925
9	33.2	33.7047	1.5202	33.6760	1.4337	33.7513	1.6605
10	38.4	37.2298	3.0474	36.71108	4.3982	36.9826	3.6911

由表 3 可知,AHPSO-SVM 模型最优预测结果与试验值数据基本吻合,各组预测数值的相对误差较小,其相对误差最大为 3.047 4%,远小于 PSO-SVM 模型、CV-SVM 模型最大相对误差 5.099 6%、6.965 6%。

4.2　预测结果稳定性分析

由于本文所提出的 AHPSO 算法属于启发式算法,具有一定的随机性,单次预测的结果不能代表 AHPSO-SVM 模型的稳定性;由此,在相同环境下对上述三种模型进行仿真试验,各模型独立运算 30 次,并从预测结果中选取最优解、平均解、最差解的均方误差 MSE 及平均相对误差两种性能指标,并计算每种模型适应度值的标准差,以验证模型的稳定性,结果如表 4 所示。

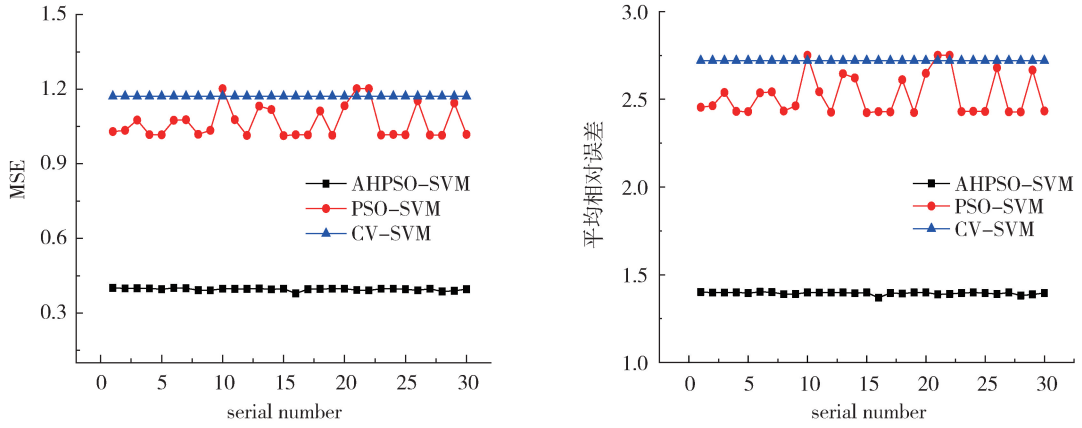
AHPSO-SVM 模型的 MSE 与平均相对误差两种性能指标最优解、平均解、最差解均明显小于 PSO-SVM 模型与 CV-SVM 模型,即 AHPSO-SVM 模型预测能力最佳,具有高精度的拟合能力。AHPSO-SVM 模型每次预测结果有一些偏差,其适应度值的标准差为 0.0202,略大于 CV-SVM 模型,但同样具有良好的稳定性。

为了直观的分析 AHPSO-SVM 的预测精度与稳定性,画出上述三种模型 30 次重复独立运算的 MSE 与平均相对误差两种性能指标对比曲线,如图 2 所示。对于两种性能指标对比曲线,其位置越向下模型预测能力越强,其越平缓则模型越稳定。

表 4　各算法 30 次性能指标

Tab.4　30 times performance index of each algorithm

仿真算法	AHPSO-SVM		PSO-SVM		CV-SVM	
性能指标	MSE	平均相对误差/%	MSE	平均相对误差/%	MSE	平均相对误差/%
最优解	0.3784	1.3690	1.0133	2.4240		
平均解	0.3954	1.3956	1.0572	2.4335	1.1718	2.7208
最差解	0.4006	1.4015	1.2022	2.7507		
适应度值标准差	0.0202		0.8038		0	



(a)　MSE　　(b)　平均相对误差

图 2　两种性能指标对比曲线

Fig.2　Comparison index of two performance indicators

由图 2 得出,CV-SVM 模型稳定性最佳,但其预测能力在三种模型中相对较差;PSO-SVM 模型 MSE 与平均相对误差曲线起伏较大,稳定性较差,且预测精度不及 AHPSO-SVM 模型;AHPSO-SVM 模型的两种性能指标曲线均在最下方,且两种曲线趋势平缓,即其具有优异的预测能力与良好的稳定性。综合表 3、表 4 数据及图 2 可知本文所提出的 AHPSO-SVM 模型是一种预测能力优异,稳定性良好的超声内圆磨削 ZTA 边界损伤预测模型。

5　结论

(1)在 35 kHz 轴向超声磨削与普通磨削两种条件下独立进行正交试验与单因素试验后,发现 ZTA 陶瓷边界损伤深度值显著降低,降幅最小为10.05%、最大为 21.23%,且磨削深度对边界损伤影响随着磨削深度增大而增大。

(2)在相同环境下 AHPSO-SVM 模型、PSO-SVM 模型、CV-SVM 模型独立运行 30 次,发现 AHPSO-SVM 模型最优解、平均解、最差解的 MSE 与平均相对误差均优于 PSO-SVM 模型、CV-SVM 模型,且 30 次预测结果的适应度值标准差为 0.020 2,即 AHPSO-SVM 具有更好的学习能力、泛化性能与良好的稳定性,是一种有效的边界损伤预测模型。

参考文献

[1] 唐修检. 田欣利. 吴志远.等 工程陶瓷边缘碎裂行为与机理研究进展[J]. 中国机械工程,2010, 21(1): 114-119.

[2] 赵明利, 赵波, 王裕清. 超声磨削工程陶瓷边界损伤试验研究[J]. 金刚石与磨料磨具工程,2010, 30(04): 67-70.

[3] 李伯民, 赵波. 现代磨削技术[M]. 北京:机械工业出版社, 2003.

[4] 李亚敏. 超声 ELID 复合内圆磨削 ZTA 陶瓷磨削力和表面质量的研究[D]. 河南理工大学, 2014.

[5] 郭秋成. 超声辅助磨削工程陶瓷边界损伤机理研究[D]. 河南理工大学, 2016.

[6] 黄吉东, 王龙山, 李国发,等 基于最小二乘支持向量机的外圆磨削表面粗糙度预测系统[J]. 光学精密工程, 2010, 18(11): 2407-2412.

[7] PANDIYAN V, CAESERENDRA W, TJAHJOWIDODO T, et al. In-process tool condition monitoring in compliant abrasive belt grinding process using support vector machine and genetic algorithm[J]. Journal of Manufacturing Processes, 2018, 31:199-213.

[8] YANG G M, ZHANG Y P, LI K Y, et al. A processing predictive model of ultrasonic vibration grinding assisted electric discharge machining based on support vector machines[J]. Advanced Materials Research, 2014, 941-944: 1928-1931.

[9] SMIST G F,JORDAAN E M. IMPROVED SVM regression using mixtures of kernels[C]// International Joint Conference on Neural Networks. IEEE Xplore, 2002: 2785-2790.

[10] 石礼娟, 谢彪彪, 谢新港, 等. 基于组合核函数的籼稻重度不宜存检测模型[J]. 农业机械学报, 2013, 44(8): 165-168