

基于 IPSO-WRF 的选择性激光烧结件气泡溶解时间预测模型

张天瑞^{1,2} 魏铭琦¹ 高秀秀¹

1 沈阳大学机械工程学院 沈阳 110041

2 东北大学机械与自动化学院 沈阳 110819

(tianjiangruixue@126.com)

摘要 针对选择性激光烧结(Selective Laser Sintering, SLS)件成型过程中因气泡导致的质量缺陷问题,提出一种基于改进粒子群(Improved Particle Swarm Optimization, IPSO)算法优化的加权随机森林(Weighted Random Forest, WRF)预测方法,用于实现气泡溶解时间的有效预测。该方法利用 IPSO 算法优化 WRF 分裂属性个数和决策树数量两个关键参数,构建 IPSO-WRF 预测模型。数值实例表明,与 PSO-RF, PSO-KELM 预测模型的预测结果相比,基于相同的训练样本和测试样本,气泡溶解时间 IPSO-WRF 的预测模型能够获得误差更小且更接近于实际值的输出结果。MAE, MAPE, RMSE 指标表明, IPSO-WRF 预测模型具有比 PSO-RF 模型和 PSO-KELM 模型更高的非线性拟合能力和预测精度。最后,通过敏感性分析确定对气泡溶解时间影响最显著的输入参数,为 SLS 技术的发展提供理论依据。

关键词: 选择性激光烧结; 气泡溶解时间; 改进粒子群算法; 加权随机森林; 参数敏感性分析

中图分类号 TH164

Prediction Model of Bubble Dissolution Time in Selective Laser Sintering Based on IPSO-WRF

ZHANG Tian-rui^{1,2}, WEI Ming-qi¹ and GAO Xiu-xiu¹

1 School of Mechanical Engineering, Shenyang University, Shenyang 110041, China

2 School of Mechanical Engineering and Automation, Northeastern University, Shenyang 110819, China

Abstract In order to solve the problem of mass defects caused by bubbles during selective laser sintering (SLS), a weighted random forest (WRF) prediction method based on improved particle swarm optimization algorithm (IPSO) was proposed to predict the dissolution time of bubbles effectively. In this method, two key parameters of WRF, the number of split attributes and the number of decision trees, were optimized by IPSO algorithm to construct the prediction model of IPSO-WRF. Numerical examples show that compared with the prediction results of PSO-RF and PSO-KELM prediction models, IPSO-WRF prediction model based on the same training samples and test samples can get the output results of bubble dissolution time with smaller error and closer to the actual value. MAE, MAPE and RMSE indexes show that IPSO-WRF prediction model has higher nonlinear fitting ability and prediction accuracy than PSO-RF model and PSO-KELM model. Finally, the most significant input parameters affecting the bubble dissolution time are determined by sensitivity analysis, which provides a theoretical basis for the development of SLS technology.

Keywords Selective laser sintering, Bubble dissolution time, Improved particle swarm optimization algorithm, Weighted random forest, Parameter sensitivity analysis

选择性烧结^[1]是一种通过逐层添加粉末材料形成三维实体形状的一种快速成型技术,其成型方式是采用激光有选择性地对粉末状材料进行逐层烧结。SLS 因成型工艺简单、原材料价格便宜、成型速度快,且符合柔性制造等突出优势,已成为国内外应用最为广泛的增材制造技术之一。但是使用 SLS 技术制造的固体结构存在许多缺陷,如存在孔隙度和裂纹或者缺乏融合^[2-3],这些缺陷的存在可以依靠成型过程中发生的不同物理现象的复杂性和耦合来解释,例如熔化、聚结、气体扩散和结晶^[4]。

SLS 技术最重要的缺陷之一是制造部件中存在气泡^[5],

气泡的初始尺寸越大,需要的溶解时间就越长。气泡溶解时间的影响因素包括激光功率、扫描速度、预热时间、扫描间距、光斑大小、铺粉层厚度、加工室温度等多个工艺参数的设定。目前已有文献利用 BP 神经网络^[6-7]建立选择性激光烧结成型件的精度预测模型。Cai 等^[8]建立了基于粒子群寻优的支持向量机的 SLS 成型件密度预测模型,通过数值实例验证了 SVR 回归预测模型的优越性。尽管此类方法能够实现 SLS 的质量预测,但其预测精度和速度仍有待提升。

随机森林算法(Random Forest, RF)目前被誉为最好的机器学习算法之一,有望解决此类问题^[9]。RF 算法因其预测

基金项目:工信部重大专项(201675514);辽宁省自然科学基金计划项目(20180551001)

This work was supported by the Major Master of MIT (201675514) and National Natural Science Foundation of Liaoning Province (20180551001).

通信作者:魏铭琦(weimingqi111@163.com)

精度高、收敛速度快已被广泛应用于许多领域^[10-15]。对于不同的预测对象,RF的 ntree(决策树)数量和 mtry(分裂属性)个数具有差异性,并且两者是影响 RF 分类性能和预测的重要因素。目前确定 ntree 数量和 mtry 个数的主要方法是试凑^[16]和网络搜索^[17],但这两种方法的取值效果并不理想。此外 RF 的预测性能受参数影响较大,因此 RF 算法对参数的优化对预测结果起到至关重要的作用。

粒子群算法(Particle Swarm Optimization, PSO)由于灵活性、简单性、分布性以及易与其他算法融合等优点成为调节机器学习算法参数的重要工具。Yang 等^[18]利用评估区间质量的指标构建粒子群算法的适应度函数,用于优化核极限学习机的输出权重,构建 PSO-KLEM 模型,并通过实例仿真验证了该预测具有很强的鲁棒性。Li 等^[19]引入粒子群算法为核极限学习机选择核参数和正则化系数,建立 PSO-KLEM 模型并利用 IGMAS 的数据验证了算法的有效性。Kang 等^[20]通过粒子群算法优化 BP 神经网络的初始权值和偏差,以改善 BP 神经网络陷入局部最优的问题,并用大量样本的预测结果验证了经过粒子群优化后的 BP 神经网络的预测结果更加精准。Wang 等^[21]建立粒子群优化随机森林算法对电机故障状态进行预测,并通过与其他算法的预测结果来对比验证了该算法的有效性。

目前,将气泡溶解时间作为影响 SLS 制造件质量的关键因素的相关研究较少,基于此,本文提出一种改进粒子群算法优化的 WRF 预测方法,利用 IPSO 算法优化 WRF 算法中的决策树数量和分裂属性个数两个重要参数,构建 IPSO-WRF 质量预测模型。通过仿真实验,将 4080 组样本的预测结果与 PSO-RF 质量预测模型、PSO-KELM 质量预测模型进行对比,验证本文提出的 IPSO-WRF 质量预测模型对 SLS 制造件的气泡溶解时间预测的准确性和高效性。

1 IPSO-WRF 预测模型

1.1 改进粒子群算法

PSO 算法对目标空间中的一组粒子进行随机初始化,采用更新迭代的方式找到空间中的近似最优方案。

定义第 i 个粒子在第 t 次迭代时的位置为 $x_i^t = (x_{i1}^t, x_{i2}^t, \dots, x_{in}^t)$,速度为 $v_i^t = (v_{i1}^t, v_{i2}^t, \dots, v_{in}^t)$,第 $t+1$ 次迭代时的粒子速度更新公式为:

$$v_i^{t+1} = \omega v_i^t + c_1 r_1 (p_i^t - x_i^t) + c_2 r_2 (g^t - x_i^t) \quad (1)$$

其中,当 $v_i^t > V_{\max}$ 时,取 $v_i^t = V_{\max}$,当 $v_i^t < -V_{\min}$ 时,取 $v_i^t = -V_{\min}$ 。

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2)$$

其中, p_i^t 是第 i 个粒子迭代 t 次的最佳位置, g^t 是第 t 次迭代时的全局最佳位置, r_1 和 r_2 是 $[0,1]$ 范围内的随机值, ω 是惯性权重且满足 $0 < \omega < 1$, c_1 和 c_2 表示学习因子。由粒子速度更新公式可知,新一代粒子的速度取决于上一代粒子速度 ωv_i^t 、个体记忆 $c_1 r_1 (p_i^t - x_i^t)$ 和群体粒子的影响 $c_2 r_2 (g^t - x_i^t)$,其中惯性权重的大小决定了上一代粒子速度对新一代粒子速度的影响程度,当 $g^t \neq x_i^t$ 时:

$$\omega = \omega_{\text{final}} + (\omega_{\text{initial}} - \omega_{\text{final}}) \left(1 - \frac{T}{T_{\max}}\right) \quad (3)$$

当 $g^t = x_i^t$ 时:

$$\omega = \omega_{\text{final}} \quad (4)$$

其中, T 是迭代次数, $T \in [0, T_{\max}]$, T_{\max} 为最大迭代次数,

ω_{initial} 为初始惯性权重, ω_{final} 则为最大迭代次数时的惯性权重。

因为特征向量通常具有高维的特点,所以容易陷入局部最优,无法到达全局最优,故本文借鉴文献^[21]中的方法,引入收缩因子 k ,使算法的收敛速度随迭代次数的增加而减慢,从而实现后期的精细搜索,具体如下:

$$v_i^{t+1} = k [\omega v_i^t + c_1 r_1 (p_i^t - x_i^t) + c_2 r_2 (g^t - x_i^t)] \quad (5)$$

收缩因子函数如下:

$$k = \frac{\cos((\pi/T_{\max}) \times T) + 2.5}{4} \quad (6)$$

根据式(5)可知,惯性权重和收缩因子共同影响算法的搜索速度和收敛速度,为进一步提升算法搜索效果,对惯性权重和收缩因子同时进行改进,改进后的 PSO 惯性权重和收缩因子同步变化,将式(5)和式(6)合并得到式(7)。

$$v_i^{t+1} = \left(\frac{\cos(\pi \times T/T_{\max}) + 2.5}{4} \right) \times [\omega \times v_i^t + c_1 r_1 (p_i^t - x_i^t) + c_2 r_2 (g^t - x_i^t)] \quad (7)$$

1.2 加权随机森林算法

随机森林算法是一种将多个弱分类器组合成强分类器的分类算法,该算法的本质是组合,它是一种基于多个弱分类器及其误差减小的分类算法。一般的随机森林模型如图 1 所示,从模型中很容易理解,随机森林从每一棵树中得到建议,这将有助于提高最终结果的准确性。

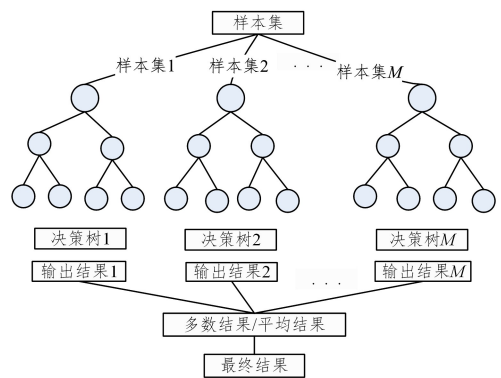


图1 随机森林模型

Fig.1 Model diagram of random forest

随机森林建模的基本思想是基于统计抽样理论,即从原始样本中有放回地随机抽取 M 个子样本,对每一个子样本进行决策树建模,获得 M 个决策树模型的预测结果,根据少数服从多数的原则确定最终结果,即:

$$H(x) = \arg \max_Y \sum_{m=1}^M \{I[h_m(X)=Y]\} \quad (8)$$

其中, $H(x)$ 表示最终分类结果, $h_m(x)$ 表示每个子样本 m 的决策树分类结果, Y 表示被预测变量, $I(\cdot)$ 表示示性函数,即 $h_m(x)=Y$,则 $I(\cdot)=1$,反之 $I(\cdot)=0$ 。对随机抽样的训练样本输入向量 (X, Y) ,边际函数为:

$$mg(X, Y) = av_m I(h_m(X)=Y) - \max_{y \in Y} av_m I(h_m(X)=y) \quad (9)$$

其中, $I(h_m(X)=Y)$ 表示将 X 判定正确的平均投票数, $av_m I(h_m(X)=y)$ 为票数最多的判定错误的平均投票数,边际函数度量了对输入 X 产生的最低正误偏差,分类可信度随着边际值的增加而增加,从而可得泛化误差:

$$PE^* = P_{X,Y}(mg(X, Y) < 0) \quad (10)$$

式(10)中,下角标 X 和 Y 表明误差的概率是在 (X, Y) 空

间中获得。通过大数定律可知,当随机森林中树的数量增加时,随机序列 $\theta_1, \theta_2, \dots, \theta_m, PE^*$ 收敛于式(11)。

$$P_{X,Y}(P_\theta(h_m(X)=Y) - \max_{y \in Y} P_\theta(h_m(X)=y) < 0) \quad (11)$$

BootStrap的样本集中的样本数量取决原始样本集的大小,当原始样本集数量充分时,BootStrap的样本集中的样本数量为原始样本数量的63.2%,剩余部分样本称作袋外样本(OOB),OOB是度量变量重要程度的有效依据。因此,通过以下步骤计算特征 x_j 的特征重要性度量 D_j 。假设有 B 个样本, $b=1, 2, \dots, B$ 。

(1)设置 $b=1$,使用训练数据集创建一个决策树 T_b ,OOB数据集表示为 L_b^{out} ;

(2)使用 T_b 对数据集 L_b^{out} 进行分类,并将计数正确分类的数字表示为 R_b^{out} ;

(3)对于每个特征 x_j ,随机更改 L_b^{out} 中的数据,并将更改后的数据集表示为 L_{bj}^{out} ,使用 T_b 对更改后的数据集 L_{bj}^{out} 进行分类,并将计数正确分类的数字表示为 R_{bj}^{out} ;

(4)设置 $b=2, 3, \dots, B$ 时,重复步骤1-步骤3的过程,基于式(12)确定特征值的特征重要性度量。

$$D_j = \frac{1}{B} \sum_{b \in B, j \in J} (R_b^{out} - R_{bj}^{out}) \quad (12)$$

然而,由于随机森林中各决策树的分类能力不同,一些决策树可能具有较好的分类效果,另一部分决策树的分类效果可能相对较差,为此,本文对每个决策数赋予权重值,权重大小取决于每棵决策树的决策能力,决策能力越好权重就越大。精确加权随机森林模型的核心是将训练样本划分为训练样本和预测样本,其中训练样本用于所有决策树的训练,剩余部分可作为预测样本。当这部分决策树完成后,对所有决策树进行测试,并计算分类的准确性,如式(13)所示:

$$\omega_l = \frac{X_l^{correct}}{X_L}, l=1, 2, \dots, L \quad (13)$$

其中, $X_l^{correct}$ 是第 l 个决策树中正确预测的样本数, X_L 是预测样本数, ω_l 是第 l 个决策树的正确分类。以 ω_l 作为相应决策树的权重,随机森林中的每一棵决策树在再次投票时都需要乘以其相应的权重,决策树和随机森林模型的输出可以表示为:

$$f_l^{rec}(x) = i \quad (14)$$

$$f(x) = \arg \max_{i=1, 2, \dots, c} \{sum(\omega_l)\} \quad (15)$$

其中, x 代表加权随机森林, c 代表整个森林的类数。此权重选取方式可以避免使用 out-of-bag 方法造成的不公平性,而是采用预测试样本进行权值计算,不需要进行额外的公平性考虑,简化模型计算的复杂度,提高运行速度。

1.3 改进粒子群优化加权随机森林模型

基于 IPSO-WRF 算法的 SLS 表面气泡溶解时间预测流程如图 2 所示。

一般来说,在 RF 中,预测样本树 X 、剪枝阈值 ϵ 、决策树数量 L 、随机属性数 m 的初值等都需要调整后才能达到 RF 的最佳性能。本文利用改进的粒子群算法对 WRF 模型的基本参数进行调整,从而有效地优化模型的参数,具体步骤如下:

Step1 将算法的参数初始化,随机设置预测样本数 X 、剪枝阈值 ϵ 、决策树数量 L 、随机属性数 m 的初值等。

Step2 通过 BootStrap 方法进行采样,随机生成 L 个训练集,并在每个训练集中选择 X 个预测试样本。

Step3 将每个训练集剩余的样本分别生成 L 棵决策树,并在全部属性中选择 m 个属性作为当前节点的决策属性。

Step4 若节点包含的样本数小于剪枝阈值 ϵ ,则将该点作为叶子节点,并返回目标函数的众数作为该决策树的分类结果。

Step5 生成所有的决策树后,测试每棵树,并根据式(13)计算分类精度,即决策树权值。

Step6 利用式(15)计算模型的综合分类结果。

Step7 将输出结果作为总体精度值,利用改进粒子群算法对空间参数向量进行迭代优选。

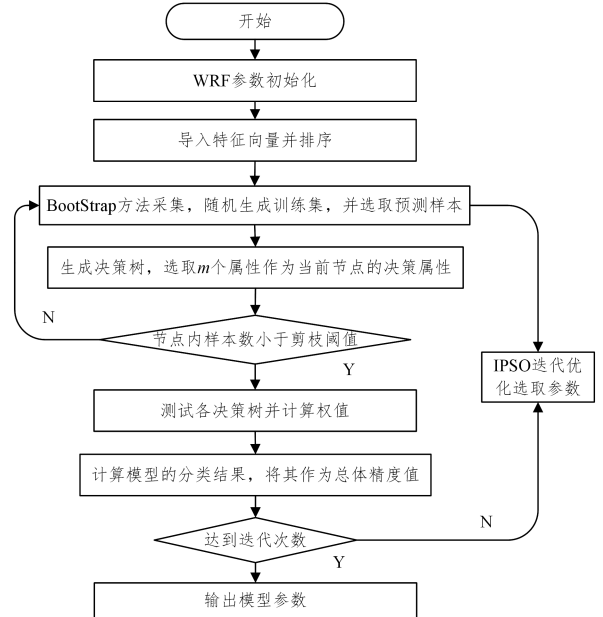


图2 IPSO-WRF 算法的流程图

Fig. 2 IPSO-WRF algorithm flow chart

2 实例仿真

2.1 参数设置

选择性激光烧结成型件表面气泡的收缩问题是由动力学或物理学等决定的,因此选择性激光烧结成型过程中工艺参数的变化都会对成型件气泡溶解时间产生影响,本文采用的实验仪器为华科三维 HK-S320,选取的实验材料为聚苯乙烯,实验样件为长 15 mm、宽 10 mm、高 20 mm 的长方体。研究多个工艺参数对气泡溶解时间的影响,因此设定输入参数为激光功率、扫描速度、预热时间、扫描间距、光斑大小、铺粉层厚度和加工室温度,输出参数为气泡溶解时间(T)。根据实验器性能以及材料特性设定工艺参数的具体范围,如表 1 所列。根据给定的参数范围,基于正交法打印试样,得到有效样本数 4080 组,将其中的 70% 的样本作为模型的训练样本,将剩余的 30% 的样本作为测试样本,以验证模型的有效性。

表 1 工艺参数取值

Table 1 Process parameter value

参数	最小限制	最大限制
激光功率 I_1/W	10	30
扫描速度 $I_2/(mm \cdot s^{-1})$	1000	3000
预热时间 I_3/min	60	180
扫描间距 I_4/mm	0.05	0.2
光斑大小 I_5/mm	0.1	0.5
铺粉层厚度 I_6/mm	0.1	0.25
加工室温度 $I_7/^\circ C$	75	95

为了进一步验证 IPSO-WRF 模型在预测 SLS 制造件表面气泡溶解时间时的性能,与原始的 PSO-RF 以及当前应用广泛的 PSO-KELM 模型的预测值进行对比。将 IPSO-WRF, PSO-RF 与 PSO-KELM 的模型参数进行如下设定,最大迭代次数为 100,其中种群规模为 30, $c_1=c_2=2$, $\omega=0.857$; $m_{tree}=500$, $n_{tree}=5$;隐层节点数 $L=20$,实验室硬件环境为 Intel 奔腾处理器 1.73GHz,512MB 内存,软件环境为 Windows XP。

2.2 算法预测效果评估

将训练好的模型在此进行预测验证,IPSO-WRF 模型、PSO-RF 模型和 PSO-KELM 模型的气泡溶解时间输出值和单个样本的预测偏差如图 3 所示。基于模型预测结果可知,

IPSO-WRF 模型、PSO-RF 模型和 PSO-KELM 模型均能实现对 SLS 气泡溶解时间的预测,但在预测结果的准确度上本文提出的 IPSO-WRF 模型优于 PSO-RF 模型和 PSO-KELM 模型的预测结果。通过观察图 3(a)~图 3(c)可以看出,相比 IPSO-WRF 模型、PSO-RF 模型的输出结果,PSO-KELM 模型的输出值与实际值之间的差距较大。进一步对比图 3(d)~图 3(f)的结果可知,IPSO-WRF 模型下单个样本的误差范围为 $[-3,15]$,PSO-RF 模型下单个样本的误差范围为 $[-8,19]$,PSO-KELM 模型下单个样本的误差范围为 $[-2,32]$,由此可知 IPSO-WRF 模型的预测误差小于 PSO-RF 模型和 PSO-KELM 模型的预测误差。

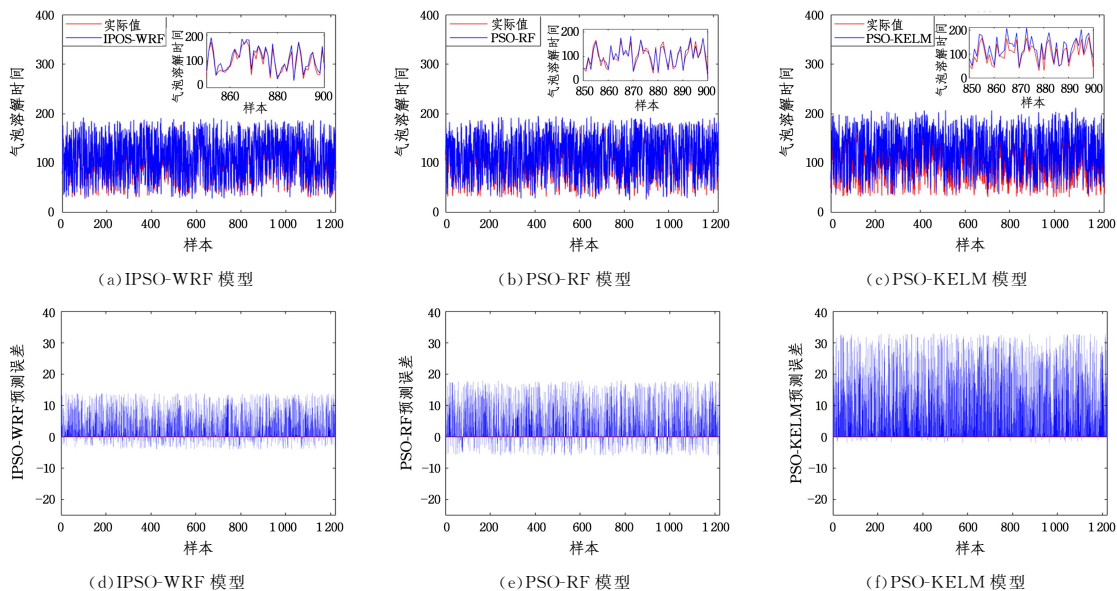


图 3 预测模型输出

Fig. 3 Forecast model output

为进一步分析算法的预测效果,并使得各预测模型之间可以相互比较,采用均方根误差(RMSE)、平均误差百分比(MAPE)和平均绝对误差(MAE),对以上各预测模型的预测精确性进行评价。假设样本的数量为 N ,预测值为 f_i ,真实值为 F_i 。

$$MAE = \frac{1}{N} \sum_{i=1}^N |f_i - F_i| \quad (16)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - F_i)^2} \quad (17)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{f_i - F_i}{F_i} \right| \times 100\% \quad (18)$$

通过对测试样本进行 100 次运行计算,得到各优化算法下的误差均值和波动情况。IPSO-WRF 模型、PSO-RF 模型和 PSO-KELM 模型各自独立运行 100 次得到气泡溶解时间平均预测值的 MAE, MAPE, RMSE 箱线图如图 4 所示。表 2 列出了 IPSO-WRF 模型、PSO-RF 模型和 PSO-KELM 模型在测试样本下的误差均值和波动情况。




图 4 气泡溶解时间预测值的 MAE, MAPE, RMSE 箱线图

Fig. 4 Predicted bubble dissolution time of MAE, MAPE, RMSE box plot

表 2 各预测模型的预测误差结果对比

Table 2 Comparison of prediction error results of each prediction model

评价指标	MAE		MAPE		RMSE		运行时间/s	
	Mean	SD	Mean	SD	Mean	SD	Mean	SD
IPSO-WRF	7.772	1.2902	0.1380	0.0196	13.3212	1.2632	2.58	0.46
PSO-RF	11.029	2.1781	0.1629	0.0236	16.2142	1.7234	4.54	0.80
PSO-KELM	13.548	3.8180	0.1867	0.0243	18.7956	2.9418	3.99	0.57

由表 2 可知, PSO-RF 模型和 PSO-KELM 模型对 SLS 气泡溶解时间预测的 MAPE 均值分别为 16.29% 和 18.67%, 然而, 本文提出的模型的 MAPE 均值为 13.80%, 与两种当前主流的预测方法相比, 其 MAPE 值分别降低了 2.49%, 4.87%。同时, IPSO-WRF 方法的 RMSE 和 MAE 值也显然小于其他两种方法的误差值。此外, IPSO-WRF 算法的运行平均时间为 2.58s, PSO-RF 算法和 PSO-KELM 算法的平均运行时间分别为 4.54s 和 3.99s, 因此 IPSO-WRF 算法的收敛速度明显优于 PSO-RF 和 PSO-KELM 算法。

实验结果表明, 所提模型的预测精度明显优于其他两种主流方法的精度, 基于 IPSO-WRF 的 SLS 气泡溶解时间预测模型可以提取数据的高层次特征, 获得了较主流方法更好的非线性函数逼近效果, 在一定程度上提高了算法的精度和泛化能力。经过改进粒子群算法优化的加权随机森林算法, 不仅提高了网络的收敛速度, 还提高了模型的预测精度, 即减小了模型的误差值。实验结果充分表明, 基于 IPSO-WRF 模型在选择性激光烧结的大数据挖掘中能够表现出良好的特征学习能力。在构建预测模型时, 不同的网络结构会导致不同的预测结果, 因此在模型性能优化过程中, 根据不同的应用领域、不同的数据构建不同的 WRF 模型, 利用 IPSO 优化算法寻找最优网络参数设置, 确定 WRF 预测模型的最优网络设置。

2.3 输入参数的敏感性分析

气泡溶解时间受到多个参数共同作用, 激光功率(I_1)、扫描速度(I_2)、预热时间(I_3)、扫描间距(I_4)、光斑大小(I_5)、铺粉层厚度(I_6)、加工室温度(I_7)等输入参数与气泡溶解时间存在高度耦合和非线性的关系。通过单因素敏感性分析, 可以有效确定单个输入变量对输出参数的影响程度。若在输入的特征向量中去除一个变量对预测结果不产生影响, 或影响微弱, 便可减少输入空间的变量。对影响气泡溶解时间的变量进行依次排除, 共产生了 8 种情况, 并对每组进行了 100 次运行的模拟, 结果如表 3 所列。

表 3 输入参数对 MAE, MAPE, RMSE 的灵敏性分析

Table 3 Sensitivity analysis of input parameters to MAE, MAPE and RMSE

误差	除去输入变量	Min	Max	Mean	SD
MAE	未除去变量	5.7177	9.9662	7.7721	1.2902
	I_1	32.2116	35.4001	34.4492	1.3260
	I_2	21.4228	26.1503	24.9033	1.3617
	I_3	11.4681	15.6104	13.8973	1.3670
	I_4	16.1372	22.9025	17.4826	1.4550
	I_5	7.8612	11.8320	8.9340	1.2743
	I_6	9.5503	13.3883	12.0062	1.2502
	I_7	58.7335	63.1182	61.3994	1.3846
MAPE	未除去变量	0.10268	0.17215	0.1380	0.0296
	I_1	0.4021	0.4583	0.4337	0.0254
	I_2	0.3204	0.3711	0.3591	0.0277
	I_3	0.2183	0.2567	0.2253	0.0225
	I_4	0.2450	0.2857	0.2583	0.0183
	I_5	0.1549	0.1947	0.18042	0.0248
	I_6	0.1328	0.1868	0.1581	0.0239
	I_7	0.6355	0.7843	0.6830	0.0387
RMSE	未除去变量	11.0093	15.2190	13.3212	1.2632
	I_1	38.0527	44.1105	40.4681	1.5704
	I_2	27.0207	34.1700	31.4482	1.8010
	I_3	19.7104	24.4404	22.6300	1.4203
	I_4	22.8851	28.4025	25.8000	1.4987
	I_5	17.0481	21.4271	19.5583	1.3950
	I_6	12.4529	19.3362	17.0439	1.5941
	I_7	87.4302	96.4463	82.4027	1.9303

基于统计数据可知, 在 100 次运行结果中当去除变量 I_7

时得到了 MAE, MAPE, RMSE 的最大平均值, 即 $MAE = 61.3994$, $MAPE = 0.6830$, $RMSE = 82.4027$, 此时与未除去变量的 MAE, MAPE, RMSE 的值相比增大了 53.6273, 0.545, 69.0815; 当去除 I_5 时, 得到 MAE 的最小平均值即 $MAE = 8.9340$, 比未除去变量的 MAE 增加了 1.1619; 当去除变量 I_6 时, 得到 MAPE, RMSE 的最小平均值, 此时比未除去变量的 MAPE, RMSE 分别增加了 0.0201, 3.7227。综上所述可知, 加工室温度(I_7)对气泡溶解时间的预测结果的影响最显著, 其次铺粉层厚度(I_6)、光斑大小(I_5)对气泡溶解时间的预测结果的影响较小。通过对标准偏差进行分析可知, 就模型稳定性而言, 未除去变量的模型稳定性均优于除去变量的预测模型。对运行结果进行进一步统计, 得到 MAE, MAPE, RMSE 的直方图拟合曲线, 如图 5 所示。

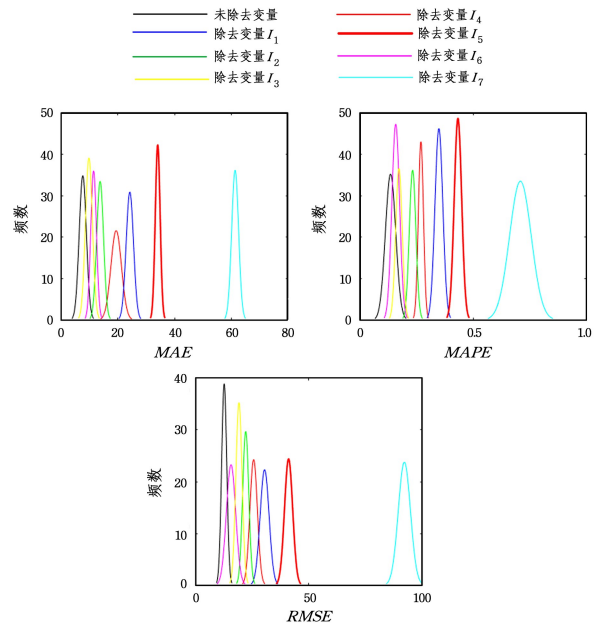


图 5 MAE, MAPE, RMSE 直方图拟合曲线

Fig. 5 MAE, MAPE, RMSE histogram fitting curve

图 5 给出了 100 次模拟下预测误差的 MAE, MAPE 和 RMSE 值直方图拟合曲线, 横坐标表示模型预测误差, 纵坐标表示误差出现的频数。模拟曲线的宽度表示预测误差的变化范围, 高度为相应变化范围出现的次数。通过图 5 可以很明显的看出各输入变量对模型预测精确度的影响, 由此可得出各输入变量对模型预测结果的影响程度, 影响程度由大到小排序依次为加工室温度(I_7)、激光功率(I_1)、扫描速度(I_2)、扫描间距(I_4)、预热时间(I_3)、光斑大小(I_5)、铺粉层厚度(I_6)。

结束语 本文基于 SLS 选择性激光烧结件的成型原理, 采用预测方法对成型件表面气泡溶解时间进行预测, 不仅为质量优化提供了理论依据, 还可以进一步确定不同变量对气泡溶解时间的影响程度。

(1) 依据改进粒子群算法良好的全局搜索能力和加权随机森林的强分类集成器, 结合二者的优点, 本文提出 SLS 成型件气泡溶解时间预测模型, 利用 IPSO 算法对 WRF 关键参数进行优化, 并对 4080 组数据进行预测。


(2) 仿真实验结果表明, IPSO-WRF 模型对气泡溶解时间的预测精度优于 PSO-RF 和 PSO-KELM 模型, 具有较高的预测精度和收敛速度, 可以有效构建输入一个描述变量与输出

变量关系的非线性预测模型,能够实现 SLS 成型件气泡溶解时间的有效预测。

(3) 基于 100 次模拟运行结果得到依次除去单个变量的 MAE, MAPE, RMSE 值及其直方图拟合曲线,通过敏感性分析确定各输入变量对预测结果的影响程度,其中以加工室温度(I_7)对预测结果的影响最为显著,以上结果能为 SLS 选择性激光烧结件的研究提供参考和借鉴。

参 考 文 献

- [1] NELSON J C. Selective laser sintering : A Definition of the Process and an Empirical Sintering Model[D]. Austin: University of Texas at Austin, 1993.
- [2] WEI Q, ZHONG J, XU Z, et al. Microstructure Evolution and Mechanical Properties of Ceramic Shell Moulds for Investment Casting of Turbine Blades by Selective Sintering[J]. Ceram Int, 2018, 44(1): 12088-12097.
- [3] SHI Y S, HUANG S H, PAN C Y. Research on Intelligent Optimization Method of Selective Laser Sintering Process Parameters[J]. Mechanical Science and Technology, 2003, 22(2): 259-263.
- [4] BOURELL D L, WATT T J, LEIGH D K, et al. Performance Limitations in Polymer Laser Sintering[J]. Physicals Proceeds, 2014, 56(3): 147-156.
- [5] KONTOPOULOU M, VLACHOPOULOS J. Bubble Dissolution in Molten Polymers and Its Role in Rotational Molding[J]. Polym Engineering, 1999, 39(6): 1189-1198.
- [6] LIU Z P, WANG H S, XIE H P. Precision prediction of selective laser sintering of coated sand based on BP neural network[J]. Hot Working Technology, 2016, 45(21): 91-93.
- [7] REN J W, YIN J J, DONG L J. Precision prediction of selective laser sintering of coated sand based on BP neural network[J]. Machine Tool & Hydraulics, 2016, 45(21): 15-18.
- [8] CAI C Z, PEI J F, WEN Y F. Support vector regression prediction of selective laser sintering molding density[J]. Acta Physica Sinica, 2009, 58(special issue): 8-14.
- [9] BREIMAN L. Random Forests [J]. Machine Learning , 2001, 45(1): 5-32.
- [10] WEN B E, DONG W H, XIE W J. Parameter optimization of random forest based on improved grid search algorithm[J]. Computer Engineering and Applications, 2018, 54(10): 154-157.
- [11] LAI C G, CHEN X H, ZHAO S W. Flood risk assessment model based on random forest and its application[J]. Journal of Hydraulic Engineering, 2015, 46(1): 58-53
- [12] LU W X, WU H C, WAN L Y. Prediction of Precipitation by PLS Based on Fusion of Random Forest Algorithm[J]. Statistics & Decision, 2020, 18(3): 27-31.
- [13] JI Y J, YONG X Y, LIU Y L. Quality analysis and prediction method of hot rolled strip steel based on random forest[J]. Journal of Northeast University, 2019, 40(1): 11-15.
- [14] ZHAO T, WANG L T, ZHANG Y. Recognition of user power consumption related factors and power consumption prediction method using mutual information and random forest algorithm [J]. Proceedings of the CSEE, 2016, 36(3): 604-614.
- [15] HE J, WEN X T, NIE W X. Using Random Forest Algorithm to Predict Crack Development Zone[J]. Oil Geophysical Prospecting, 2020, 55(1): 161-166.
- [16] WEN T X, ZHANG B, SHAO L S. Random forest model of coal and gas outburst prediction[J]. Computer Engineering and Applications, 2014, 50(10): 233-237.
- [17] CHEN Y P, LUO M, PENG J H. Land use classification of industrial and mining reclamation areas based on network search random forest algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(14): 250-257.
- [18] YANG X Y, GUAN W Y, LIU Y Q. Wind power interval prediction method based on particle swarm optimization kernel extreme learning machine model[J]. Proceedings of CSEE, 2015, 35(supplement): 146-153.
- [19] LI W T, BIAN S F, REN Q Y. Beidou ultra-fast clock error prediction based on particle swarm optimization kernel extreme learning machine[J]. Journal of Astronautics, 2019, 40(9): 1080-1088.
- [20] KANG S A, YU J C, ZHANG J. Direct Route Drag Prediction of Chain-structured Underwater Vehicle Based on Neural Network Optimized by Particle Swarm Optimization[J]. Journal of Mechanical Engineering. 2019, 55(21): 32-38.
- [21] WANG X X, BIAN S F, REN Q Y. Motor Fault Diagnosis Method Based on Particle Swarm Optimization and Random Forest[J]. Small & Special Electrical Machines, 2019, 47(10): 42-45.
- [22] KISI O, KHOSRAVINIA P, HEDDAM S, et al. Modeling wetting front redistribution of drip irrigation systems using a new machine learning method: Adaptive neuro-fuzzy system improved by hybrid particle swarm optimization-Gravity search algorithm[J]. Agricultural Water Management, 2021, 256(12): 107067-107083.



ZHANG Tian-rui, born in 1985, Ph.D, associate professor, master supervisor. His main research interests include operational research and optimization.



WEI Ming-qi, born in 1995, postgraduate master. His main research interests include quality prediction and supply chain management.