

doi:10.3969/j.issn.1001-3539.2020.04.011

基于径向基函数神经网络和多岛遗传算法的 注射成型质量控制与预测

季宁¹, 张卫星¹, 于洋洋^{1,2}, 贺莹¹, 侯英洪³

(1. 天津大学仁爱学院, 天津 300636; 2. 天津大学内燃机燃烧学国家重点实验室, 天津 300072;

3. 天津市新阳模具制品有限公司, 天津 300350)

摘要: 针对现有多参数、多目标注塑工艺优化应用的遗传算法、粒子群算法等寻优算法存在的实施难度大、求解时间长等缺点, 提出基于最优拉丁超立方试验设计方法并结合径向基函数 (RBF) 神经网络模型和多岛遗传算法 (MIGA) 对注射成型质量进行控制与预测。以充电宝下盖塑件的体积收缩率和缩痕指数为优化控制目标, 以模具温度、熔体温度、保压时间、保压压力、冷却时间为试验因素, 应用最优拉丁超立方试验设计方法获得试验样本, 基于模流分析获得试验结果, 构建试验因素与优化控制目标之间的 RBF 神经网络模型, 基于 MIGA 在试验因素给定的水平范围内获得了一组最优注塑工艺参数组合并给出了优化控制目标的预测值。模拟试验结果证明, 预测值与模拟试验结果基本吻合, 提出的方法能实现注塑成型质量的控制与预测, 减少了寻找最优工艺参数组合的时间, 提高了塑件的生产效率。

关键词: 最优拉丁超立方试验设计; 径向基函数神经网络; 多岛遗传算法; 模流分析; 质量控制与预测

中图分类号: TQ320.66 **文献标识码:** A **文章编号:** 1001-3539(2020)04-0062-07

Quality Control and Prediction of Injection Molding Based on RBF Neural Network and MIGA

Ji Ning¹, Zhang Weixing¹, Yu Yangyang^{1,2}, He Ying¹, Hou Yinghong³

(1. Tianjin University Renai College, Tianjin 300636, China; 2. State Key Laboratory of Engine, Tianjin University, Tianjin 300072, China;

3. Tianjin Xinyang Mould Products Co., Ltd, Tianjin 300350, China)

Abstract: Existing genetic algorithms and particle swarm optimization algorithms used in the optimization of multi-parameter and multi-objective injection molding processes have the disadvantages of difficult implementation and long solution time. The method of quality control and prediction for injection molding based on the optimal Latin hypercube test design method combined with radical basis function (RBF) neural network model and multi-island genetic algorithm (MIGA) was proposed. Taking volume shrinkage rate and shrinkage index of the lower cover of charger as optimization targets, and using the mold temperature, melt temperature, holding time, holding pressure and cooling time as test factors. The optimal Latin hypercube test design method was used to obtain the test samples, the test results were obtained based on the mold flow analysis, and the RBF neural network model between the test factors and the optimization control target was constructed. Based on the MIGA, a set of optimal injection process parameter combinations was obtained within a given range of experimental factors and the predicted values of the optimization goals were given. The simulation test results show that the predicted values are basically consistent with the simulation test results. The method proposed can control and predict the quality of injection molding, shorten the time to find the optimal combination of process parameters, and improve the production efficiency of plastic parts.

Keywords: optimal Latin hypercube; radical basis function neural network; multi-island genetic algorithm; mold flow analysis; quality control and prediction

基金项目: 天津市教委科研计划项目 (2019KJ152, 2018KJ269)

通讯作者: 于洋洋, 在读博士, 讲师, 主要从事机械结构优化方面的研究 E-mail: yangyang80233@126.com

收稿日期: 2020-01-19

引用格式: 季宁, 张卫星, 于洋洋, 等. 基于径向基函数神经网络和多岛遗传算法的注射成型质量控制与预测 [J]. 工程塑料应用, 2020, 48(4): 62-68.

Ji Ning, Zhang Weixing, Yu Yangyang, et al. Quality control and prediction of injection molding based on RBF neural network and MIGA algorithm[J]. Engineering Plastics Application, 2020, 48(4): 62-68.

在注塑生产过程中,注塑工艺参数的选取直接决定塑件的成型质量。影响塑件成型质量的注塑工艺参数较多,工艺参数与成型目标之间存在较为复杂的非线性关系,选取一组满足成型质量要求的工艺参数组合较为困难。实际注塑中,操作人员往往依靠经验通过不断地试模确定最优工艺参数组合,不仅大大延长试模时间,而且还造成了原料的浪费。如何快速获得满足某一塑件成型质量要求的最优工艺参数组合是当前研究的热点。段帅帅等^[1]利用中心复合试验结合建立了回归预测模型,得到了一组最优注塑工艺参数;刘月云^[2]基于响应面法和 Pareto 遗传算法对注塑模冷却水道参数进行了优化,模拟验证后得出冷却水道的最优设计参数组合;黄海松等^[3]基于灰色关联分析方法,针对复杂曲面构件的注塑成型质量进行了多目标优化,取得了理想的优化效果;李月明^[4]基于正交试验并结合三维响应面法求解出塑件的最佳注塑工艺参数;娄天祥等^[5]基于稳健设计并结合均值分析获得了塑件的最优注塑工艺参数组合;栗雪娟等^[6]提出了一种改进的多目标粒子群优化算法,对塑件注塑成型过程中的熔接痕进行了优化;盘承军等^[7]基于正交试验和竞争型神经网络(SOM 神经网络)优化了汽车上饰板的成型工艺参数,满足了生产要求;曹志勇等^[8]利用神经网络模型并结合改进的非支配排序遗传算法进行了多目标的优化求解,得出了最优的注塑工艺设计。

上述文献表明,采用 CAE 技术,并结合建立影响因素与优化目标之间关系的近似模型和应用优化算法,是注塑工艺参数优化常用的方法。

目前基于 CAE 技术的注塑工艺参数优化时,试验样本多采用正交试验获取,但正交试验易出现样本点堆积问题,试验样本有时并不能表征整个变量的取值区域。最优拉丁超立方设计在试验因素的设计空间区域内均匀、随机采样,具有非常好的空间均衡性和填充性,能够用比较少的点获得大量的模型信息。

在构建影响因素与优化目标之间的近似模型时,响应面模型应用广泛,但其缺点是随着样本容量的增大未能有效提高近似精度且随着设计变量的维数和响应阶数的提高,其计算量增加很快^[9]。径向基函数(RBF)神经网络是一种局部逼近网络,对于输入空间的某一局部区域只存在少数的神经元用于决定网络的输出,它在函数逼近能力、分类能力和学

习速度等方面具有很大的优势,因此将它用于复杂的参数预测可取得很好的效果^[10]。


现有多目标遗传算法、粒子群算法等寻优算法存在实施难度较大、求解时间长等缺点。多岛遗传算法(MIGA)是一种基于群体分组的并行性遗传算法,与传统遗传算法相比,多岛遗传算法具有更好的全局求解能力和更高的计算效率^[11]。

针对上述问题,笔者以充电宝下盖塑件的体积收缩率和缩痕指数为优化目标,基于最优拉丁超立方试验设计方法,并结合 RBF 神经网络和 MIGA,对充电宝下盖塑件注射成型质量的多目标进行优化,模流分析结果证明,该方法可行、有效,优化效果明显,缩短了分析时间,提高了分析效率。

1 基于模流分析的初始注塑工艺分析

1.1 塑件模型及材料选用

在 UG10.0 软件中完成充电宝下盖的模型绘制,如图 1a 所示。充电宝下盖外形尺寸为 143.5 mm×78.8 mm×6.6 mm,壁厚较为均匀,平均壁厚 1.5 mm,选用日本孟山都化成公司生产的牌号为 TFX-210 的丙烯腈-丁二烯-苯乙烯塑料(ABS)。导出文件格式为 .stl 并保存,在模流分析软件中打开并对其进行双层面网格划分,三角形网格的全局边长设为 1.5 mm,通过插入节点以及合并节点等网格修复方法,最终得到的网格最大纵横比为 6.12,平均纵横比为 1.25,最小纵横比为 1.13,符合模流分析要求的网格质量标准^[12],网格模型如图 1b 所示。



a—UG 模型图; b—网格模型

图 1 充电宝下盖模型图

1.2 初始注塑工艺参数及分析结果

根据模流分析软件推荐的数值,充电宝下盖的初始分析工艺参数列于表 1,得到优化前的塑件体积收缩率为 6.793%,缩痕指数为 1.156%。

表 1 充电宝下盖的初始分析工艺参数

模具温度 / ℃	熔体温度 / ℃	保压时间 / s	保压压力 / MPa	冷却时间 / s
50	230	20	60	10

2 基于最优拉丁超立方的试验设计

拉丁超立方设计通过科学合理的试验安排,以部分试验替代全面试验,减少了试验次数,提高了分析效率。其试验原理是:在 n 维变量设计空间中,将每维变量区间 $[x_i^{\min}, x_i^{\max}]$ 进行 m 等分,随机选取 $m+1$ 个样本点,以保证每个试验因素的每个水平被研究且仅被研究一次。但拉丁超立方设计的试验可能出现试验点分布不够均匀的情况。最优拉丁超立方设计改进了拉丁超立方试验设计的缺点,使因子和响应的拟合更加精确、真实,它使所有的试验点尽量均匀地分布在设计空间。图2a为拉丁超立方随机生成的试验点分布,图2b为最优拉丁超立方生成的更加均匀的试验点分布^[13]。




图2 拉丁超立方抽样和最优拉丁超立方抽样

将影响塑件成型质量的模具温度(A)、熔体温度(B)、保压时间(C)、保压压力(D)、冷却时间(E)作为试验因素,将塑件的体积收缩率(F)、缩痕指数(G)作为试验优化目标。根据注塑经验和模流分析软件推荐值,各试验因素的水平取值范围列于表2。

表2 试验因素水平取值范围

因素	A/℃	B/℃	C/s	D/MPa	E/s
水平	30~70	200~280	15~30	50~70	15~30

基于最优拉丁超立方抽样方法,按表2试验因素水平的取值范围,获得25组最优拉丁试验样本并通过模流分析软件得到优化目标的结果,最优拉丁试验样本和优化目标的结果列于表3。

3 神经网络模型的建立与验证

3.1 RBF神经网络模型建立

基于RBF神经网络拟合试验因素与优化目标间的非线性关系,建立试验因素与优化目标间的RBF神经网络模型。RBF神经网络是三层前馈神经网络,一般由输入层、隐含层和输出层构成。输入层的作用是接收输入信号并传递到隐含层,输入信号的个数取决于试验影响因素个数,以A、B、C、D、E作为输入层的输入信号。隐含层的作用是通过径向基函数将输入矢量映射到一个新的空间。输出层

表3 最优拉丁试验样本和优化目标结果

试验号	试验因素					模流分析结果	
	A/℃	B/℃	C/s	D/MPa	E/s	F/%	G/%
1	61.76	244.71	30	63.53	23.38	6.863	0.9410
2	45.29	218.82	17.65	69.41	18.53	5.935	0.7589
3	70	256.47	23.82	53.53	20.74	7.705	1.3350
4	39.41	230.59	15	57.06	21.62	6.799	1.3020
5	65.29	254.12	19.41	68.82	20.29	6.782	0.6955
6	32.35	225.88	28.68	64.12	18.09	6.332	1.0610
7	68.82	211.76	22.5	64.71	23.82	5.957	0.8280
8	66.47	240	24.26	56.47	30	7.106	1.2240
9	41.76	216.47	20.29	54.12	29.12	6.563	1.4390
10	51.18	235.29	21.18	50	16.76	7.317	1.6220
11	42.94	200	22.06	58.82	19.41	5.866	1.2300
12	54.71	261.18	18.09	50.59	26.91	8.007	1.5210
13	53.53	207.06	28.24	54.71	26.03	6.249	1.3730
14	46.47	202.35	27.35	67.65	24.71	5.563	0.8562
15	59.41	275.29	25.15	62.94	15.88	7.659	0.9309
16	50	263.53	27.79	51.18	26.47	8.029	1.5300
17	60.59	249.41	15.44	62.35	27.79	7.002	0.9964
18	31.18	232.94	24.71	52.35	22.5	7.117	1.5770
19	44.12	258.82	25.59	70	21.18	6.823	0.7531
20	40.59	268.24	16.32	67.06	22.94	7.232	0.8420
21	47.65	247.06	29.56	55.29	17.21	7.351	1.3570
22	57.06	280	22.94	61.18	25.59	7.892	1.0390
23	34.71	265.88	19.85	58.24	28.68	6.778	1.2920
24	37.06	237.65	29.12	60.59	28.24	6.811	1.2080
25	58.24	270.59	15.88	57.65	18.97	7.853	1.1520

常用线性函数作为传递函数,其作用是为输入层的激活模式提供响应,实现线性加权组合,从而加快学习速度并避免局部极小问题,输出层节点数为优化目标的个数。据此,RBF神经网络的输入节点数为5个,输出节点数为2个,可得到如图3所示的RBF神经网络模型^[14-16]。




图3 RBF神经网络模型

对于RBF神经网络,径向基函数常用式(1)所示的高斯函数:

$$F_i = \exp\left(-\frac{\|X - C_i\|^2}{2\sigma_i^2}\right) \quad i = 1, 2, 3, \dots, m \quad (1)$$

式中: F_i ——隐含层的输出;

X —— n 维输入向量;

C_i ——权值向量,与 X 具有相同的维数;

σ_i ——第 i 个隐含层节点变量,决定了基函数围绕中心点的宽度;

$\|X-C_i\|$ ——向量 $X-C_i$ 的欧几里德范数;

m ——隐含层的节点个数。

3.2 RBF 神经网络模型拟合精度检验

将表 3 中的试验样本作为网络的训练样本,应用 Matlab 神经网络工具箱提供的 newrb() 函数建立 RBF 神经网络模型,程序的格式如下所示:

[net, tr]=newrb(P, T, goal, spread, MN, DF)

程序中:net 为返回的径向基网络;tr 为返回的训练记录;P 表示输入向量组成的矩阵;T 表示输出向量组成的矩阵;goal 表示均方误差,默认为 0,将其值设为 0.000 1;spread 为径向基函数的扩散速度,采用其默认值 1;MN 其值设为 25,表示隐含层节点的最大个数;DF 为两次显示之间所添加的神经元数目,默认为 25。

为了验证 RBF 神经网络模型的拟合精度,基于最优拉丁超立方试验方法设计 10 组检验样本点,通过模流分析,获得塑件的 F 和 G 试验结果列于表 4。

表 4 检验样本

试验号	试验因素					模流分析结果	
	A/℃	B/℃	C/s	D/MPa	E/s	F/%	G/%
1	55.88	223.53	26.03	66.47	15.44	6.150	0.8268
2	30	228.24	21.62	65.88	25.15	6.3	1.0140
3	52.35	242.35	23.38	68.24	29.56	6.619	0.7876
4	38.24	251.76	20.74	61.76	15	7.091	1.1140
5	35.88	272.94	18.97	51.76	19.85	8.260	1.5100
6	33.53	277.65	26.91	59.41	22.06	7.921	1.2180
7	64.12	214.12	18.53	52.94	24.26	6.549	1.3990
8	67.65	209.41	26.47	55.88	17.65	6.285	1.2330
9	48.82	204.71	16.76	65.29	27.35	5.725	0.9377
10	62.94	221.18	17.21	60	16.32	6.435	1.0510

调用 Matlab 中 sim() 函数,其格式为:

net1=sim(net, x1)

程序中:net1 为输入变量对应的预测值,net 为上述生成的径向基网络,x1 为要预测的输入变量。

将表 4 中的检验样本作为输入变量,得到对应的预测值,RBF 神经网络模型预测的体积收缩率的数值用 F_1 表示,预测的缩痕指数数值用 G_1 表示,结果列于表 5。

表 5 RBF 神经网络模型预测结果

试验号	预测值		试验号	预测值	
	F_1 /%	G_1 /%		F_1 /%	G_1 /%
1	6.082	0.801	6	7.858	1.253
2	6.396	0.976	7	6.487	1.456
3	6.490	0.821	8	6.355	1.2
4	6.978	1.086	9	5.706	0.896
5	8.446	1.477	10	6.478	1.014

均方根误差、可决系数常用来评价 RBF 神经网络模型的拟合精度^[17-18]。

(1) 均方根误差。

均方根误差用来衡量预测值同真值之间的偏差。计算公式如式 (2) 所示:

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n |X_i - Y_i|^2 \right)^{1/2} \quad (2)$$

式中:RMSE——均方根误差值;

X_i ——预测值;

Y_i ——模拟值;

n ——试验次数。

均方根误差值越接近于 0,说明模型的拟合精度越高。

(2) 可决系数。

可决系数也被称为拟合优度,用于检验模型对观测值的拟合程度。其计算公式如式 (3) 所示:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - X_i)^2}{\sum_{i=1}^n (Y_i - l_i)^2} \quad (3)$$

式中: R^2 ——可决系数;

l_i ——模拟值的平均值。

将表 4、表 5 中的数据带入式 (2)、式 (3),分别计算得到体积收缩率 RBF 神经网络模型的 $RMSE=0.0963$, $R^2=0.9839$; 缩痕指数 RBF 神经网络模型的 $RMSE=0.0362$, $R^2=0.9742$ 。从计算结果可知, RMSE 值均接近 0, R^2 值均接近 1,说明 RBF 神经网络模型的拟合精度较高,符合分析要求。

为了更直观地分析 RBF 神经网络模型的拟合精度,将体积收缩率和缩痕指数的模拟值与预测值做成折线图,如图 4、图 5 所示。从图 4 和图 5 能够看出,体积收缩率和缩痕指数的模拟值和 RBF 神经网络的预测值几乎重合,进一步证明了 RBF 神经网络模型的拟合精度较高,符合分析要求。




图 4 体积收缩率模拟值与预测值对比图




图5 缩痕指数模拟值与预测值对比图

4 基于多岛遗传算法 (MIGA) 的多目标优化

MIGA 将种群分成了若干个处于不同岛屿、相互隔绝并独立进化的子群。MIGA 通过反复恰当地使用遗传算法的算子和选择原则,从亲代到子代,从子代到孙代,不停繁衍,使得种群对环境的适应性不断升高^[19-20]。MIGA 的流程图如图6所示。




图6 MIGA 流程图

基于 MIGA,在建立的 RBF 神经网络模型内进行全局寻优,试验因素的取值范围见表2, MIGA 的参数设置见表6。

表6 MIGA 参数

参数	数值
岛上个体数	10
岛屿个数	10
迭代次数	100
交叉变异	1
变异概率	0.01
迁移概率	0.01
迁移间隔	5

经过 9 069 次迭代,得到的优化结果如图7所示。

从图7可以得出一组最优工艺参数组合:A

Optimum design point:

Run #	= 9069
Objective	= 302.0020422634804
Penalty	= 0.0
ObjectiveAndPenalty	= 302.0020422634804
A	= 69.99877927824826
B	= 200.0
C	= 21.18997482261387
D	= 70.0
E	= 24.655985351338977
F	= 5.42441465184444
G	= 0.6156261934251674

图7 MIGA 优化结果

为 70 ℃, B 为 200 ℃, C 为 21.19 s, D 为 70 MPa, E 为 24.66 s。MIGA 预测的 F 为 5.424%, G 为 0.6156%。

5 模拟验证分析

将上述得到的最优工艺参数组合经模流分析进行模拟验证,得到的结果如图8、图9所示。




图8 优化后的体积收缩率




图9 优化后的缩痕指数

从图8和图9可以看出,优化后的体积收缩率为 5.374%,优化后的缩痕指数为 0.5868%。

由图7可知, MIGA 预测的体积收缩率为 5.424%,与图8优化后的体积收缩率 5.374%的

相对误差为 0.93%;MIGA 预测的缩痕指数为 0.6156%,与图 9 优化后的缩痕指数 0.5868% 的相对误差为 4.91%。总的来说,相对误差值在 5% 以内,证明建立的 RBF 神经网络模型和采用的 MIGA 是可靠的、准确的。

优化后的体积收缩率 5.374% 比优化前的体积收缩率 6.793% 降低 20.89%;优化后的缩痕指数 0.5868% 比优化前的缩痕指数 1.156% 降低 49.24%,证明所采用的方法具有明显的优化效果。

6 结论

(1) 最大体积收缩率和最大缩痕指数的模流分析结果与 MIGA 预测结果基本吻合,证明提出的应用最优拉丁超立方试验设计结合 RBF 神经网络模型和 MIGA 对注塑成型工艺多目标优化可行、有效。

(2) 优化后的体积收缩率为 5.374% 比优化前的体积收缩率 6.793% 降低 20.89%;优化后的缩痕指数为 0.5868% 比优化前的缩痕指数 1.156% 降低 49.24%,优化效果非常明显。

(3) 提出的该方法可以为注塑工艺质量的控制与预测提供有益的借鉴。

参考文献

- [1] 段帅帅,张亚,李世中. 注塑工艺制品质量影响因素及参数优化[J]. 塑料工业,2019,47(10):86-88,115.
Duan Shuaishuai, Zhang Ya, Li Shizhong. Factors affecting the quality of injection molding products and optimization of parameters[J]. China Plastics Industry, 2019, 47(10):86-88, 115.
- [2] 刘月云. 基于响应面法与 Pareto 遗传算法的注塑模冷却水道参数优化[J]. 中国塑料,2019,33(9):67-71,115.
Liu Yueyun. Optimization of injection mold cooling channel parameters based on response surface method and pareto genetic algorithm[J]. China Plastics, 2019, 33(9):67-71, 115.
- [3] 黄海松,张鲁滨,姚立国. 基于灰色关联分析的注塑成型工艺多目标优化[J]. 塑料科技,2019,47(1):104-110.
Huang Haisong, Zhang Lubin, Yao Ligu. Multi-objective optimization of injection molding process based on grey relational analysis[J]. Plastics Science and Technology, 2019, 47(1):104-110.
- [4] 李月明. 基于鼠标的随形冷却注塑模多目标优化研究[J]. 塑料工业,2016,44(5):66-70.
Li Yueming. Study on multi-objective optimization of the injection mold with conformal cooling channels based on mouse[J]. China Plastics Industry, 2016, 44(5):66-70.
- [5] 娄天祥,何修旭,董娇. 基于稳健设计的注塑成型工艺参数多目标优化[J]. 塑料科技,2017,45(8):63-66.
Lou Tianxiang, He Xiuxu, Dong Jiao. Process parameter multi-objective optimum of injection molding based on Taguchi[J]. Plastics Science and Technology, 2017, 45(8):63-66.
- [6] 栗雪娟,史加荣,杨春晓. 基于 IMOPSO 方法的注塑件熔接痕质量的多目标优化[J]. 塑性工程学报,2016,23(4):173-179.
Li Xuejuan, Shi Jiarong, Yang Chunxiao. Optimizing quality of weld line in injection molding by IMOPSO method[J]. Journal of Plasticity Engineering, 2016, 23(4):173-179.
- [7] 盘承军,李炜,杨达飞. 基于正交试验法和神经网络的上饰板注塑工艺优化[J]. 塑料,2018,47(3):92-97.
Pan Chengjun, Li Wei, Yang Dafei. Optimization analysis of injection molding process of decorative plate based on orthogonal test method and neural network[J]. Plastics, 2018, 47(3):92-97.
- [8] 曹志勇,幸俊龙,夏巨谋,等. 基于改进的 BP-NSGA II 算法的注塑工艺参数优化[J]. 锻压技术,2016,41(11):135-142.
Cao Zhiyong, Xing Junlong, Xia Juchen, et al. Optimization on injection process parameters based on an improved BP-NSGA II algorithm[J]. Forging and Stamping Technology, 2016, 41(11):135-142.
- [9] 潘雷,谷良贤,阎代维. 改进响应面法及其近似性能研究[J]. 宇航学报,2009,30(2):806-810.
Pan Lei, Gu Liangxian, Yan Daiwei. Research on improved response surface method and its performance[J]. Journal of Astronautics, 2009, 30(2):806-810.
- [10] 包子阳. 神经网络与深度学习—基于 TensorFlow 框架和 Python 技术实现[M]. 北京:电子工业出版社,2019.
Bao Ziyang. Neural networks and deep learning—Based on TensorFlow framework and python technology[M]. Beijing:Publishing House of Electronics Industry, 2019.
- [11] 颜雪松,伍庆华,胡成玉. 遗传算法及其应用[M]. 武汉:中国地质大学出版社,2018.
Yan Xuesong, Wu Qinghua, Hu Chengyu. Genetic algorithm and its application[M]. Wuhan:China University of Geosciences Press, 2018.
- [12] 陈艳霞. Moldflow2015 模流分析从入门到精通[M]. 北京:电子工业出版社,2015.
Chen Yanxia. Moldflow 2015 mold flow analysis from entry to the master[M]. Beijing:Publishing House of Electronics Industry, 2015.
- [13] 王安麟,孟庆华,韩继斌. 基于拉丁超立方仿真试验设计的双涡轮变矩器性能分析[J]. 中国工程机械学报,2015,13(4):293-298.
Wang Anlin, Meng Qinghua, Han Jibin. Dual-turbine torque converter performance analysis based on Latin hypercube simulation experiment design[J]. Chinese Journal of Construction Machinery, 2015, 13(4):293-298.
- [14] 陈哲. 基于 RBF 神经网络的注塑成型工艺多目标优化及评价研究[D]. 宁波:宁波大学,2011.
Chen Zhe. Study on injection molding process multi-objective optimization and quality estimation based on RBF neural network[D].

Ningbo:Ningbo University, 2011.

- [15] 邓其贵,黄力,韦彬贵.基于CAE与RBF神经网络的固定体塑件注塑工艺优化[J].塑料,2019,48(1):82-87.

Deng Qigui, Huang Li, Wei Bingui. Optimization of injection molding process of fixed body plastic part based on CAE and RBF neural network[J]. Plastics, 2019, 48(1):82-87.

- [16] 马振锋,黄力,陆大同.基于GRA-RBF神经网络的汽车手套箱成型工艺优化[J].塑料科技,2017,45(9):79-84.

Ma Zhenfeng, Huang Li, Lu Datong. Based on GRA-RBF neural network of optimization analysis for automobile glove box forming process[J]. Plastics Science and Technology, 2017, 45(9):79-84.

- [17] 王江,翟玉玲,马明琰,等.基于径向基神经网络模型预测CuO-ZnO/乙二醇-水混合纳米流体导热系数[J/OL].复合材料学报:1-10[2019-12-15].<https://doi.org/10.13801/j.cnki.fhclxb.20191113.001>.

Wang Jiang, Zhai Yuling, Ma Mingyan, et al. Prediction of thermal conductivity of CuO-ZnO / ethylene glycol-water hybrid nanofluids based on radial basis neural network model[J/OL]. Acta Materiae Compositae Sinica:1-10[2019-12-15].<https://doi.org/10.13801/j.cnki.fhclxb.20191113.001>.

(上接第61页)

Zhou Guofa, Jiang Xiannian, Chao Fangchao. Influence of die wall temperature difference on unbalanced filling flow in water-assisted co-injection molding process[J]. Engineering Plastics Application, 2015, 43(7):40-45.

- [14] 贺茂勇,李振中,王玉龙,等.TPU/PDA-GF复合材料的力学和动态流变性能[J].工程塑料应用,2019,47(10):106-111.

He Maoyong, Li Zhenzhong, Wang Yulong, et al. Mechanical properties and dynamic rheology properties of TPU / PDA-GF composites[J]. Engineering Plastics Application, 2019(10):106-111.

10.13801/j.cnki.fhclxb.20191113.001.

- [18] 张俊红,陈孔武,王健,等.基于EBF神经网络和粒子群算法的注射成型优化设计[J].中国塑料,2015,29(9):54-59.

Zhang Junhong, Chen Kongwu, Wang Jian, et al. Optimization design of injection molding based on EBF neural network and particle swarm algorithm[J]. China Plastics, 2015, 29(9):54-59.

- [19] 郭映华,朱文芳,赵娜,等.基于多岛遗传算法的膛压动态加载实验装置参数优化[J].火炮发射与控制学报,2019,40(3):90-93,110.

Guo Yinghua, Zhu Wenfang, Zhao Na, et al. Parameter optimization of dynamic loading experimental device for chamber pressure based on multi-island genetic algorithm[J]. Journal of Gun Launch and Control, 2019, 40(3):90-93, 110.

- [20] 孙永厚,杨帅,刘夫云,等.基于多岛遗传算法汽车动力总成悬置解耦优化[J].机械设计与制造,2019(12):155-158,162.

Sun Yonghou, Yang Shuai, Liu Fuyun, et al. Decoupling optimization of an automotive powertrain suspension based on multi-island genetic algorithm[J]. Machinery Design and Manufacture, 2019(12):155-158, 162.

- [15] 柳和生,江青松,王都阳,等.基于壁面滑移的薄壁注塑流动三维数值模拟[J].高分子材料科学与工程,2018,34(6):122-126.

Liu Hesheng, Jiang Qingsong, Wang Duiyang, et al. Three dimensional numerical simulation of thin-wall injection Molding Flow Based on Wall Slip[J]. Polymer Materials Science and Engineering, 2018, 34(6):122-126.

- [16] 李伟,崔梦杰,张云奎,等.两种共聚聚丙烯 PPH-M12N 流变性能的对比[J].工程塑料应用,2018,46(5):98-102.

Li Wei, Cui Mengjie, Zhang Yunkui, et al. Comparison of rheological properties of two copolymers of polypropylene PPH-M12N[J]. Engineering Plastics Application, 2018, 46(5):98-102.