

doi:10.3969/j.issn.1001-3539.2025.10.013

基于贝叶斯正则化神经网络的卡车轮罩横梁 注塑工艺多目标优化

张晗¹, 王明伟¹, 蔡世铭¹, 王宗强¹, 于峻伟¹, 叶星辉²

(1. 大连工业大学机械工程与自动化学院, 辽宁大连 116034; 2. 浙江凯华模具有限公司, 浙江台州 318020)

摘要: 以大型塑件卡车轮罩横梁的体积收缩率(Y_1)和Z方向(装配方向)最大翘曲变形量(Y_2)为响应目标,选取熔体温度、模具温度、第一段保压时间、第二段保压时间、第一段保压压力、第二段保压压力为试验变量,通过最优拉丁超立方试验设计100组样本,利用Moldex3D模流分析软件进行模拟。利用贝叶斯正则化神经网络(BRNN)建立 Y_1 和 Y_2 的回归预测模型,这两个模型的决定系数(R^2)分别为0.991和0.989;通过非支配排序遗传算法II(NSGA-II)对模型进行多目标优化,得到最优试验变量参数。将最优试验变量参数在Moldex3D中进行模拟和现场实际应用,发现对于 Y_1 和 Y_2 ,模拟结果与BRNN-NSGA-II预测的最优结果之间的误差分别为0.14%和7.28%,与初始模拟结果相比分别降低了3.16%和64.42%;实际塑件成型质量良好,满足生产要求。上述结果表明提出的BRNN结合NSGA-II的方法可有效解决大型复杂塑件的注塑工艺多目标优化问题。

关键词: 注塑;多目标优化;卡车轮罩横梁;最优拉丁超立方试验;贝叶斯正则化神经网络;非支配排序遗传算法II(NSGA-II)

中图分类号: TQ320.66 文献标识码: A 文章编号: 1001-3539(2025)10-0095-09

Multi-objective optimization of injection molding processes for truck wheel cover cross beams based on Bayesian regularized neural networks

ZHANG Han¹, WANG Mingwei¹, CAI Shiming¹, WANG Zongqiang¹, YU Junwei¹, YE Xinghui²

(1. School of Mechanical Engineering and Automation, Dalian Polytechnic University, Dalian 116034, China;

2. Zhejiang Kaihua Mould Co., Ltd., Taizhou 318020, China)

Abstract : Taking the volume shrinkage rate (Y_1) and Z-direction (assembly direction) maximum warpage deformation of a large plastic part—truck wheel cover cross beams—as the response objectives, the following experimental variables were selected: melt temperature, mould temperature, first holding pressure time, second holding pressure time, first holding pressure, and second holding pressure. A optimal Latin hypercube design was employed to generate 100 sample sets, which were simulated using Moldex3D mold flow analysis software. Bayesian regularized neural network (BRNN) was employed to establish regression prediction models of Y_1 and Y_2 , the coefficient of determination (R^2) values of the two models were 0.991 and 0.989 respectively. Multi-objective optimization of the models was performed using nondominated sorting genetic algorithm II (NSGA-II) to derive optimal experimental variable parameters. The optimized experimental parameters were simulated in Moldex3D and applied in actual production. For Y_1 and Y_2 , the errors between the Moldex3D simulated results and BRNN-NSGA-II predicted optimal outcomes are 0.14% and 7.28%, respectively, representing reductions of 3.16% and 64.42% compared to initial simulations. The actual molded part quality is excellent and meets production requirements. Thus, the proposed BRNN combined with NSGA-II method can effectively solve the multi-objective optimization problem for injection molding processes of large complex plastic parts.

Keywords : injection molding ; multi-objective optimization ; truck wheel arch cross beam ; optimal Latin hypercube sampling ; Bayesian regularized neural network ; nondominated sorting genetic algorithm II (NSGA-II)

通信作者: 王明伟, 博士, 教授, 主要从事材料成型加工、智能制造等方面研究

收稿日期: 2025-09-10

引用格式: 张晗, 王明伟, 蔡世铭, 等. 基于贝叶斯正则化神经网络的卡车轮罩横梁注塑工艺多目标优化[J]. 工程塑料应用, 2025, 53(10): 95–103.

ZHANG Han, WANG Mingwei, CAI Shiming, et al. Multi-objective optimization of injection molding processes for truck wheel cover cross beams based on Bayesian regularized neural networks[J]. Engineering Plastics Application, 2025, 53(10): 95–103.

注塑工艺因其高效率、高精度的复杂结构成型能力,已成为车身轻量化零部件制造的核心工艺^[1-2]。大多车身轻量化零部件,须同时满足高强度和高精度的要求。采用纤维增强复合材料,可显著提升塑件的拉伸强度^[3],但由非均匀收缩引起的翘曲变形问题仍严重制约着塑件的成型质量。为达到高成型质量的要求,需对注塑工艺参数(如熔体温度、模具温度、保压压力等)进行多目标协同优化^[4-5]。传统优化注塑工艺参数主要依赖操作人员通过试错法反复调整注塑机参数,但这种方法存在经验依赖性强、成本控制困难、优化周期冗长的缺点^[6-8]。随着计算机辅助模拟技术的不断提高,现可通过Moldex3D和Moldflow等模流分析软件实现对注塑过程的数值模拟,从而预测塑件的熔接线、体积收缩率和翘曲变形量等关键质量指标。根据模拟结果,对塑件的成型工艺参数进行优化,从而提高试模效率和缩减试模成本^[9-10]。

在注塑工艺参数优化的前沿研究中,大多采用代理模型结合多目标优化算法的方式优化注塑工艺。Liu等^[11]以玻璃纤维增强塑料产品-泵固定支架为研究对象,以翘曲变形量为优化目标,利用Moldflow进行模流分析,采用响应面法(RSM)进行试验设计,并建立了RSM、反向传播神经网络(BPNN)、遗传算法优化反向传播神经网络(GA-BPNN)和自适应增强的遗传算法优化反向传播神经网络(AdaBoost-GA-BP)模型,通过对比模型精度,最终选择AdaBoost-GA-BP模型,并通过粒子群算法获得最优的参数组合,对最优组合进行模拟,相对误差为0.6%,与优化前相比,最大翘曲变形量降低了8.41%。Li等^[12]以短纤维增强复合材料注塑制件的翘曲变形量、体积收缩率和残余应力为优化目标,以纤维含量、纤维宽比、熔体温度、注射压力和冷却时间为试验变量,在正交试验设计的基础上进行方差分析得到各参数对3个目标影响的重要程度;然后,通过响应面法和非支配排序遗传算法II(NSGA-II)算法对注塑工艺进行多目标优化,得到最优工艺参数。印磊等^[13]以汽车B柱外饰件的翘曲变形量和体积收缩率为研究目标,通过最优拉丁超立方试验进行数据采样并建立克里金模型,利用邻域栽培遗传算法(NCGA)算法对代理模型进行优化;优化后的翘曲变形量较原始工艺降低了18.56%,体积收缩率降低了50.94%。Hong等^[14]提

出一种基于BP神经网络和NSGA-II算法的优化方法,以接线盒外壳的体积收缩率和翘曲变形量为研究对象,优化后的体积收缩率和翘曲变形量分别下降了33.2%和3.8%,优化效果显著。

在现有的注塑工艺参数优化研究中,多数为小型塑件,在大型复杂塑件上的研究较少,且大多在设计试验时采用正交试验、响应面等离散组合的方法,各试验变量参数水平较少,无法完全覆盖参数空间,易导致关键参数遗漏。最优拉丁超立方试验设计通过分层抽样的方式,可保证各个变量因素的所有区间均有样本,参数空间覆盖更均匀^[15-16]。因此,笔者以大型塑件(卡车轮罩横梁)的体积收缩率和Z方向(装配方向)的翘曲为研究对象,利用最优拉丁超立方试验设计100组样本,并通过皮尔逊相关性分析得到各试验变量对研究对象的影响大小和排序;为保证模型的预测准确性,选择贝叶斯正则化神经网络建立回归预测模型;最后,通过NSGA-II对其进行多目标优化,并在寻优迭代过程中模拟实际注塑机调参,限制各变量参数均为整数,优化流程如图1所示。此方法流程清晰、效果显著,可为同类型复杂塑件的注塑工艺参数优化提供一定的借鉴。




图1 注塑工艺参数优化流程图

Fig. 1 Optimization flowchart for injection molding process parameters

1 试验对象与初始分析

1.1 卡车轮罩横梁有限元模型

笔者以卡车轮罩横梁为研究对象,利用Moldex3D软件进行仿真模拟。塑件所用材料为质

量分数30%长玻璃纤维(E玻璃纤维)增强聚丙烯(生产厂家为加拿大 Polystar 公司,型号为 80GL6-BK772),材料性能见表1。卡车轮罩横梁整体尺寸较大(1 459 mm×772 mm×303 mm)且材料为纤维复合材料,为避免流长比过大导致塑件出现成型缺陷,所以采用“9点阀式热流道(Ø22 mm)+U型冷流道(12 mm×8 mm)+搭接浇口(16 mm×1.2 mm)/直浇口(Ø6 mm)”的浇注系统,冷却系统采用13组“直通式(Ø15 mm)+隔板式(Ø24 mm)”相结合的循环水路以加强冷却效果^[17]。塑件的二维尺寸图和有限元模型如图2和图3所示。

表1 材料性能

Tab. 1 Material properties

Properties	Values
Fiber density/(g·cm ⁻³)	2.55
Modulus of elasticity E_1 (fiber direction)/GPa	72
Poisson's ratio ν_{12}	0.2
Shear modulus G_{12} /GPa	30
Melt temperature/°C	200~270
Mould temperature/°C	80~120




图2 卡车轮罩横梁二维尺寸图

Fig. 2 2D dimensional drawing of truck wheel cover cross beam




图3 卡车轮罩横梁有限元模型

Fig. 3 Finite element model of truck wheel cover cross beam

1.2 初始成型工艺参数设置

塑件的外观面需要较高的成型质量,所以采用流动波前(网格节点)的方式控制阀式热流道的开启,开启节点位置设置在浇口沿流动方向约80 mm处,此控制方式可使熔体呈现“接力式”流动并避免

与前锋熔体产生冲突^[18]。熔体温度和模具温度采用材料厂商推荐的初始参数,保压压力和保压时间采用分段式保压,此保压方式可有效降低塑件内部的残余应力,并减少成型缺陷,成型工艺参数和阀式热流道的开启时间见表2。

表2 初始成型工艺参数和阀式热流道的开启时间

Tab. 2 Initial molding process parameters and opening times of valved hot runners

Molding process parameters	Value	Valve Sequence	Starting time/s
Melt temperature/°C	250	G1	0.000
Mould temperature/°C	110	G2	1.558
First holding time/s	10	G3	1.558
Second holding time/s	5	G4	1.987
First holding pressure/MPa	45	G5	1.987
Second holding pressure/MPa	30	G6	3.720
Cooling time/s	25	G7	3.720
		G8	3.340
		G9	3.586

1.3 初始分析

采用 Moldex3D 软件对卡车轮罩横梁进行了初始分析,如图4所示。由图4a和图4b可知,塑件在4.432 s完整充填,整体充填等值线较为均匀,说明塑件无短射和滞留现象;由图4c可知,由于塑件具有较多的异向结构,导致熔体流动方向多变,纤维取向集中在0.6~0.8范围内,部分结构处的纤维取向可达到0.9。由图4d可知,塑件外观面无明显熔接线,其余位置熔接线主要由孔结构导致,无法避免^[19];浇注系统设计合理,且符合塑件外观要求。由图4e和图4f可知,主要影响塑件装配精度的Z方向最大翘曲变形量为5.051 mm,未达到装配要求(小于5 mm);次要影响的体积收缩率最大值为10.307%,但大部分处于5%~7%范围内,最大值集中在直浇口处。为使塑件达到较高的装配精度和提高一次试模的成功率,需尽量降低影响塑件成型质量的Z方向翘曲变形量和体积收缩率的最大值。

2 注塑工艺参数优化

2.1 最优拉丁超立方试验设计和相关性分析

合理地选择注塑工艺参数是提高塑件成型质量的关键,笔者根据以往生产经验和相关文献^[20~22],选取熔体温度(A)、模具温度(B)、第一段保压时间(C)、第二段保压时间(D)、第一段保压压力(E)、第二段保压压力(F)为试验变量,体积收缩率(Y_1)和Z方向最大翘曲变形量(Y_2)为响应目标,每个试验变量的参数范围由材料属性和初始分析结果设定,见表




图4 初始分析结果

Fig. 4 Initial analysis results

3. 试验共有6个因素($A-F$),且呈非线性关系,为避免样本点出现堆叠现象并使试验覆盖所有试验变量参数空间,以及提高神经网络模型的泛化能力,故采用最优拉丁超立方试验设计方法设计试验^[23]。

表3 试验变量的参数范围

Tab. 3 Parameter ranges for test variables

Experimental factors	Levels	
	Low	High
Melt temperature/ $^{\circ}\text{C}$	245	255
Mould temperature/ $^{\circ}\text{C}$	105	115
First holding time/s	8	10
Second holding time/s	6	8
First holding pressure/MPa	45	55
Second holding pressure/MPa	30	40

为避免神经网络模型出现欠拟合现象,样本点数量应远大于试验变量数量,应满足 $N > 10K$ (N 为样本点数量, K 为试验变量总数量),且样本数据分割为训练集75%,测试集25%。经综合考虑,样本点数量设计为100组。图5为采样点三维空间分布示意图,可以看出样本在三维空间上的分布较为均匀,无堆叠现象。通过Moldex3D软件对100组样本进行模拟,模拟结果见表4。对100组样本进行皮尔逊相关性分析,分析各试验变量与响应目标之间的相关性,当皮尔逊相关系数处于 $[0, 1]$ 范围时,变量与响



(a) Melt temperature (A), mould temperature (B), and first stage holding time (C) sampling(b) Second stage holding time (D), first stage holding pressure (E), and second stage holding pressure (F) sampling

图5 采样点三维空间分布示意图

Fig. 5 Schematic of three-dimensional spatial distribution of sampling points

表4 模拟结果
Tab. 4 Simulation results


No.	A/°C	B/°C	C/s	D/s	E/MPa	F/MPa	Y_1 /%	Y_2 /mm
1	247	112	10	6	49	34	10.347	4.935
2	248	108	8	6	48	35	10.434	4.693
3	251	109	10	6	51	35	10.417	4.684
4	251	115	9	7	50	31	10.684	4.381
5	254	112	9	7	54	33	10.609	5.083
6	247	111	10	6	54	38	9.984	4.634
7	252	113	10	6	47	38	10.409	4.685
8	253	109	8	8	51	37	10.512	4.605
9	253	115	10	7	51	36	10.457	4.382
10	248	111	9	6	52	32	10.386	5.172
11	254	108	8	6	46	37	10.603	4.805
12	252	113	10	6	48	32	10.647	4.954
13	252	110	10	7	51	40	10.244	4.300
14	245	108	9	7	48	34	10.408	3.807
15	250	111	8	6	51	39	10.213	4.822
16	253	106	9	8	47	32	10.916	2.324
17	246	113	9	8	49	30	10.632	4.984
18	246	107	9	8	51	31	10.609	2.647
19	255	109	9	6	47	36	10.664	4.782
20	250	107	8	8	54	34	10.531	3.396
...	...	...	...	...	...	...	...	...
100	252	110	8	8	49	31	10.874	5.126

应目标成正相关关系,即变量增大时,相应目标增大;当皮尔逊相关系数处于 $[0, -1]$ 范围时,变量与响应目标成负相关关系,即变量增大时,相应目标减小^[24-25]。图6为两个响应目标 Y_1 和 Y_2 的皮尔逊相关性热图,可以看出试验变量 A (0.50)和 D (0.12)与 Y_1 成正相关,试验变量 B (-0.17), C (-0.03), E (-0.32), F (-0.76)与 Y_1 成负相关,各试验变量对 Y_1 的影响排序为 $F > A > E > B > D > C$;试验变量 A (0.09)和 B (0.73)与 Y_2 成正相关,试验变量 C (-0.14), D (-0.22), E (-0.04), F (-0.13)与 Y_2 成负相关,各试验变量对 Y_2 的影响排序为 $B > D > C > F > A > E$ 。


2.2 贝叶斯正则化神经网络训练

2.2.1 贝叶斯正则化神经网络框架

为准确构建试验变量和响应目标间的非线性映射关系,采用神经网络建立回归预测模型。该模型的经典训练算法有莱文贝格-马夸特法(LM)、贝叶斯正则化法(BR)、量化共轭梯度法(SCG)等,LM^[26]是基于高斯-牛顿法的二阶导数信息和梯度下降法建立的,并通过动态调整阻尼因子平衡二阶优化精度和一阶优化稳定性,其优势是收敛速度快,适合中小规模网络和非线性最小二乘问题;SCG^[27]是通过动态步长调整机制和量化参数,避免传统方法中耗时的线性搜索步骤,其优点是适合大规模网络和



(a) Pearson correlation heatmap (ABCDE vs Y_1)



(b) Pearson correlation heatmap (ABCDE vs Y_2)

图6 Y_1 和 Y_2 皮尔逊相关性热图

Fig. 6 Pearson correlation heatmap of Y_1 and Y_2

实时性要求不高的分类任务;BR^[28-29]的原理是在损失函数中引入权重衰减项(L2正则化),并通过贝叶斯证据框架自动优化正则化参数 α 与 β ,实现模型复杂性和数据拟合的平衡,适合小数据集的分类或回归任务。

鉴于笔者研究的数据集仅包含100组样本,属于典型的小数据集,所以选择BR训练神经网络,从而提高模型的泛化能力。BR神经网络的训练程序如下^[30-32]。

第1步:数据预处理,采用Min-Max归一化将试验变量与响应目标映射至 $[-1, 1]$ 区间,消除量纲差异,Min-Max归一化的数学表达式见式(1)。

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中: X 是原始数据; $X_{\min}$ 是数据集中的最小值;

$X_{\max}$ 是数据集中的最大值; X_{norm} 是归一化后的结果。

第2步:网络架构设计,网络采用单隐藏层,神经元数量通过1~3个循环测试择优选取。隐藏层激活函数为双曲正切 Sigmoid 函数(tansig),输出层激活函数采用线性函数(purelin),数学表达式见式(2)至式(4)。模型训练算法为贝叶斯正则化(trainbr),数学表达式见式(5)至式(8),设置最大迭代次数为1 000次。

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (2)$$

$$x = \sum w_i a_i + b \quad (3)$$

$$\text{purelin}(x) = x \quad (4)$$

式中: w_i 为权重; a_i 为前层输出; b 为偏置。

$$E = \beta E_D + \alpha E_w \quad (5)$$

$$E_D = \frac{1}{2} \sum (y_{\text{true}} - y_{\text{pred}})^2 \quad (6)$$

$$E_w = \frac{1}{2} \sum w_i^2 \quad (7)$$

$$\Delta w = -(\mathbf{J}^T \mathbf{J} + \mu \mathbf{I})^{-1} \mathbf{J}^T e \quad (8)$$

式中: E 为正则化后的总误差; β 为数据误差权重; α 为权重衰减权重; E_D 为数据误差项; y_{true} 为样本真实值; y_{pred} 为模型预测值; E_w 为权重衰减项; $\mathbf{J}$ 为雅可比矩阵; μ 为阻尼因子; $\mathbf{I}$ 为单位矩阵; e 为误差向量(每个样本的预测值与真实值之差)。

第3步:训练网络,计算循环测试(1~3个神经元的)测试集决定系数(R^2)和均方根误差(RMSE),数学表达式见式(9)和式(10),并选择 R^2 最大和 RMSE 最小的神经元个数为最终模型所用个数,模型训练结束,保存最终模型且封存为网络函数。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (9)$$

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (10)$$

式中: y_i 为第 i 个样本的真实值; $\hat{y}_i$ 为第 i 个样本的预测值; $\bar{y}_i$ 为真实值的均值; n 为样本数量; E_{RMS} 为均方根误差。


2.2.2 贝叶斯正则化神经网络训练结果

1~3个神经元循环测试结果见表5, Y_1 模型最终选择3个神经元,测试集的 R^2 为0.991, RMSE 为0.02; Y_2 模型最终选择2个神经元,测试集的 R^2 为0.989, RMSE 为0.097。 Y_1 和 Y_2 的测试集误差曲线如图7所示,两个模型拟合的效果均符合要求($R^2 >$


表5 1~3个神经元循环测试的 R^2 和 RMSE

Tab. 5 R^2 and RMSE for 1~3 neuron cycling test

Number of neurons	Results of Y_1 model		Results of Y_2 model	
	R^2	RMSE	R^2	RMSE
1	0.977	0.031	0.921	0.254
2	0.970	0.035	0.989	0.097
3	0.991	0.020	0.978	0.135



(a) Y_1 test set error curves



(b) Y_2 test set error curves

图7 Y_1 和 Y_2 的测试集误差曲线

Fig. 7 Test set error curves for Y_1 and Y_2

0.9), 可为下一步优化提供良好的预测能力。

2.3 基于NSGA-II的多目标优化遗传算法

为避免在优化时陷入局部最优解和满足求解时的试验变量为整数的约束要求,所以选择 NSGA-II 对贝叶斯正则化神经网络进行最优解求解。NSGA-II 是基于进化原理的多目标全局优化算法,通过非支配排序和拥挤度距离评估个体优先级,结合选择、交叉和变异操作迭代优化,最终生成 Pareto 最优解集^[33-34], NSGA-II 算法流程图如图8所示,图中 g 为当前迭代代数, G 为迭代更新次数, $G_{\max}$ 为最大进化代数。

将 Y_1 和 Y_2 的两个网络函数结合成一个函数进行多目标优化,根据 Y_1 、 Y_2 对塑件装配精度的影响程度设置不同的权重大小, Y_1 对应的权重为0.4, Y_2 对应的权重为0.6。NSGA-II 的种群规模为200,最大




图8 NSGA-II流程图
Fig. 8 NSGA-II flowchart

迭代次数为500,函数容忍度设置为 1×10^{-10} ,并添加约束为每次迭代时试验变量均为整数。

NSGA-II经过102次迭代,达到设置的终止条件(1×10^{-10}),NSGA-II优化的帕累托最优解如图9所示,求出的最优试验变量组合为熔体温度为245℃,模具温度为105℃,第一段保压时间为10 s,第二段保压时间为8 s,第一段保压压力为55 MPa,第二段保压压力为40 MPa,预测的最优工艺参数组合下的体积收缩率为9.995%,Z方向最大翘曲变形量为1.675 mm。




图9 帕累托前沿解
Fig. 9 Pareto frontier solution

3 结果验证

将NSGA-II优化得到的最优试验变量参数组合,代入Moldex3D中进行模拟,模拟结果如图10所示,Z方向最大翘曲变形量为1.797 mm,体积收缩率最大为9.981%。表6对比了初始模拟结果、贝叶斯正则化神经网络(BRNN)-NSGA-II优化结果和

Moldex3D模拟结果,由表6可得Moldex3D模拟结果与BRNN-NSGA-II优化的结果误差:Z方向最大翘曲变形量的误差为7.28%,体积收缩率的误差为0.14%,均在10%之内,符合要求。与初始分析结果(Z方向最大翘曲变形量5.051 mm,体积收缩率10.307%)相比,Moldex3D模拟的两个结果分别降低了64.42%和3.16%。根据最优试验变量组合进行实际试模验证,实际样件如图11所示,可以发现样件无短射、流痕和熔接线等外观缺陷;样件与检具间的间隙经通规($\varnothing 4\text{ mm}$)和止规($\varnothing 6\text{ mm}$)检测,均满足设计要求(5 mm),各孔位经定位销检测均符合要求,实现一次试模成功。




图10 最优工艺参数的模拟结果

Fig. 10 Simulation results of optimum process parameters

表6 初始模拟、BRNN-NSGA-II优化和Moldex3D模拟结果的对比
Tab. 6 Comparison of initial simulation, BRNN-NSGA-II optimization, and Moldex3D simulation results

Objectives	Initial simulation	BRNN-NSGA-II optimization	Moldex3D simulation
$Y_1/\%$	10.307	9.995	9.981
Y_2/mm	5.051	1.675	1.797




图11 卡车轮罩横梁实际样件

Fig. 11 Truck wheel cover cross beam actual sample

4 结论

(1)基于最优拉丁超立方试验设计100组试验样本,并通过皮尔逊相关性分析得到:试验变量 A 和 D 与 Y_1 成正相关,其他试验变量与 Y_1 成负相关,各试验变量对 Y_1 的影响排序为 $F>A>E>B>D>C$;试验变量 A 和 B 与 Y_2 成正相关,其他试验变量与 Y_2 成负相关,各试验变量对 Y_2 的影响排序为 $B>D>C>F>A>E$ 。

(2)分别建立 Y_1 和 Y_2 的贝叶斯正则化神经网络模型,对其进行1~3个神经元循环测试,最优神经元个数分别为3个和2个,模型的 R^2 分别为0.991和0.989, RMSE分别为0.02和0.097。通过NSGA-II寻优得到最优工艺参数为:熔体温度为245℃,模具温度为105℃,第一段保压时间为10 s,第二段保压时间为8 s,第一段保压压力为55 MPa,第二段保压压力为40 MPa,在该最优注塑工艺参数组合下的体积收缩率为9.995%, Z 方向最大翘曲变形量为1.675 mm。

(3)对最优注塑工艺参数进行Moldex3D模拟验证和试模验证, Moldex3D模拟结果为体积收缩率9.981%, Z 方向最大翘曲变形量1.797 mm,与NSGA-II最优结果的误差分别为0.14%和7.28%;相对于初始模拟分析结果, Moldex3D模拟得到的体积收缩率和 Z 方向最大翘曲变形量分别降低了3.16%和64.42%。试模后实际样件表面无外观缺陷并满足装配要求。因此,证明采用贝叶斯正则化神经网络模型结合NSGA-II可有效解决大型复杂塑件在注塑中的多目标优化问题,可为该类型材料和产品在注塑工艺设计时提供一定的借鉴。

参考文献

- [1] YAN L Q, XU H T. Lightweight composite materials in automotive engineering: State-of-the-art and future trends[J]. Alexandria Engineering Journal, 2025, 118:1–10.
- [2] PANG L F, ZHANG C S, DONG H X, et al. Research on lightweight injection molding (CAE) and numerical simulation calculate of new energy vehicle[J]. Applied Mathematics and Nonlinear Sciences, 2023, 8(1):789–798.
- [3] MOHAMMADI H, AHMAD Z, MAZLAN S A, et al. Lightweight glass fiber-reinforced polymer composite for automotive bumper applications: A review[J]. Polymers, 2022, 15(1). DOI: 10.3390/polym15010193.
- [4] GIM J, TURNG L S. A review of current advancements in high surface quality injection molding: Measurement, influencing factors, prediction, and control[J]. Polymer Testing, 2022, 115. DOI:10.1016/j.polymertesting.2022.107718.
- [5] CHEN J Y, TSENG C C, HUANG M S. Quality indexes design for online monitoring polymer injection molding[J]. Advances in Polymer Technology, 2019, 2019(1). DOI:10.1155/2019/3720127.
- [6] ABDUL R, GUO G J, CHEN J C, et al. Shrinkage prediction of injection molded high density polyethylene parts with taguchi/artificial neural network hybrid experimental design[J]. International Journal on Interactive Design and Manufacturing (IJIDeM), 2020, 14:345–357.
- [7] HAIDIEZUL A H M, HAZWAN M H M, LEE W S, et al. Shrinkage optimisation on the 3D printed part using Full Factorial Design (FFD) optimisation approach[J]. IOP Conference Series: Materials Science and Engineering, 2020, 932(1). DOI: 10.1088/1757-899X/932/1/012109.
- [8] MEHAT N M, MOHD KASSIM S, KAMARUDDIN S. Investigation on the effects of processing parameters on shrinkage behaviour and tensile properties of injection moulded plastic gear via the Taguchi method[J]. Journal of Physics: Conference Series, 2017, 908(1). DOI:10.1088/1742-6596/908/1/012049.
- [9] SAHA U, MOKHTAR W. Quality improvement of polycarbonate medical device by Moldex3D and Taguchi DOE[J]. Journal of Manufacturing and Materials Processing, 2025, 9(1). DOI:10.3390/jmmp9010016.
- [10] CHAUHAN V, KÄRKI T, VARIS J. Optimization of compression molding process parameters for NFPC manufacturing using taguchi design of experiment and moldflow analysis[J]. Processes, 2021, 9(10). DOI:10.3390/pr9101853.
- [11] LIU X, FAN X Y, GUO Y H, et al. Warpage optimization of the GFRP injection molding process parameters[J]. Microsystem Technologies, 2021, 27(12):4 337–4 346.
- [12] LI K, YAN S L, ZHONG Y C, et al. Multi-objective optimization of the fiber-reinforced composite injection molding process using Taguchi method, RSM, and NSGA-II[J]. Simulation Modelling Practice and Theory, 2019, 91:69–82.
- [13] 印磊, 苏小平, 潘杰. 基于NCGA的汽车外饰件注塑成型工艺参数多目标优化[J]. 塑料工业, 2024, 52(8):95–100, 164.
- [14] YIN Lei, SU Xiaoping, PAN Jie. Multi-objective optimizations of the injection molding process parameters for automotive exterior parts based on NCGA[J]. China Plastics Industry, 2024, 52(8):95–100, 164.
- [15] HONG T J, HUANG D, DING F J, et al. Multi-objective optimization of injection molding process parameters for junction boxes based on BP neural network and NSGA-II algorithm[J]. Materials, 2025, 18(3). DOI:10.3390/ma18030577.
- [16] 季宁, 张卫星, 于洋洋, 等. 基于最优拉丁超立方抽样方法和NSGA-II算法的注射成型多目标优化[J]. 工程塑料应用, 2020, 48(3):72–77.
- [17] JI Ning, ZHANG Weixing, YU Yangyang, et al. Multi-objective optimization of injection molding based on optimal Latin hypercube sampling method and NSGA-II algorithm[J]. Engineering Plastics Application, 2020, 48(3):72–77.

- [16] 皮卫,熊建武.基于RBF神经网络断路器注塑成型工艺优化[J].塑料科技,2023,51(6):70–74.
PI Wei, XIONG Jianwu. Injection molding process optimization of circuit breaker based on RBF neural network[J]. *Plastics Science and Technology*, 2023, 51(6):70–74.
- [17] 叶星辉,梁正华,赖尚涛.内置钢管式塑料托盘注塑模具设计及承重仿真分析[J].工程塑料应用,2024,52(3):103–111.
YE Xinghui, LIANG Zhenghua, LAI Shangtao. Design and load-bearing simulation analysis of injection mould for built-in steel pipe plastic tray[J]. *Engineering Plastics Application*, 2024, 52(3):103–111.
- [18] TSAI H H, LIAO Y L. Feasibility study of the flatness of a plastic injection molded pallet by a newly proposed sequential valve gate system[J]. *Polymers*, 2022, 14(3). DOI:10.3390/polym14030616.
- [19] 王明伟,妙磊,吴迪,等.汽车后阅读灯外壳的双色注塑模具设计[J].工程塑料应用,2025,53(3):133–139.
WANG Mingwei, MIAO Lei, WU Di, et al. Two-color injection mould design for automobile rear reading lamp shell[J]. *Engineering Plastics Application*, 2025, 53(3):133–139.
- [20] 张文超,吴迪,王明伟,等.基于Critic权重法多目标优化汽车B柱上饰板注塑成型工艺[J].工程塑料应用,2024,52(4):83–88.
ZHANG Wenchao, WU Di, WANG Mingwei, et al. Multi-objective optimization of automotive B-pillar upper trim plate injection molding process based on critic weight method[J]. *Engineering Plastics Application*, 2024, 52(4):83–88.
- [21] 周纪委,郭昊亮,张文超,等.基于灰色关联理论的副仪表板扶手底座注塑工艺多目标优化[J].工程塑料应用,2022,50(12):61–66.
ZHOU Jiwei, GUO Haoliang, ZHANG Wenchao, et al. Multi-objective optimization of sub-dashboard armrest base injection molding process based on gray correlation theory[J]. *Engineering Plastics Application*, 2022, 50(12):61–66.
- [22] 孙庆东,杜晋,池根才,等.汽车地毯压条检修盖成型仿真与工艺参数优化[J].工程塑料应用,2025,53(7):83–89.
SUN Qingdong, DU Jin, CHI Gencai, et al. Simulation and process parameter optimization of automotive carpet strip inspection cover forming[J]. *Engineering Plastics Application*, 2025, 53(7):83–89.
- [23] PARK J, RYU I, RYU D, et al. An efficient near-optimal Latin hypercube design for large datasets[J]. *Journal of Mechanical Science and Technology*, 2025, 39(1):315–328.
- [24] 刘健,刘宇航,王涛,等.基于皮尔逊系数的黄土隧道预留变形量预测[J].安徽建筑大学学报,2024,32(4):64–70.
LIU Jian, LIU Yuhang, WANG Tao, et al. Prediction of reserved deformation in loess tunnel based on pearson coefficient[J]. *Journal of Anhui Jianzhu University*, 2024, 32(4):64–70.
- [25] 秦海波,赵哲源,刘兵,等.基于皮尔逊系数的防窃电系统建设方案[J].电气技术与经济,2024(6):1–3.
QIN Haibo, ZHAO Zheyuan, LIU Bing, et al. Construction scheme of anti-theft of electricity system based on Pearson coefficient[J]. *Electrical Equipment and Economy*, 2024(6):1–3.
- [26] ALI S, RIAZ S, SAFOORA, et al. A Levenberg-Marquardt based neural network for short-term load forecasting[J]. *Computers, Materials and Continua*, 2023, 75(1):1 783–1 800.
- [27] LIN C Y, KOSTINA V, HASSIBI B. Differentially quantized gradient methods[J]. *IEEE Transactions on Information Theory*, 2022, 68(9):6 078–6 097.
- [28] KAYRI M. Predictive abilities of Bayesian regularization and Levenberg-Marquardt algorithms in artificial neural networks: A comparative empirical study on social data[J]. *Mathematical and Computational Applications*, 2016, 21(2). DOI: 10.3390/mca21020020.
- [29] TRUONG T T, AIRAO J, HOJATI F, et al. Data-driven prediction of tool wear using Bayesian regularized artificial neural networks[J]. *Measurement*, 2024, 238. DOI: 10.1016/j.measurement.2024.115303.
- [30] NGUYEN T, LY K D, NGUYEN-THOI T, et al. Prediction of axial load bearing capacity of PHC nodular pile using Bayesian regularization artificial neural network[J]. *Soils and Foundations*, 2022, 62(5). DOI:10.1016/j.sandf.2022.101203.
- [31] KIM R, MIN J, LEE J S, et al. Development of Bayesian regularized artificial neural network for airborne chlorides estimation[J]. *Construction and Building Materials*, 2023, 383. DOI: 10.1016/j.conbuildmat.2023.131361.
- [32] HAJEB M, HAMZEH S, ALAVIPANAH S K, et al. Simultaneous retrieval of sugarcane variables from Sentinel-2 data using Bayesian regularized neural network[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 116. DOI:10.1016/j.jag.2022.103168.
- [33] 陈川,吕永锋.基于响应面设计及改进NSGA-II的变模温注塑成型工艺多目标优化[J].塑料工业,2023,51(6):75–81.
CHEN Chuan, LYU Yongfeng. Multi-objective optimization of dynamic mold temperature injection molding process based on response surface model and improved NSGA- II algorithm[J]. *China Plastics Industry*, 2023, 51(6):75–81.
- [34] 陶诗豪,刘影,苏小平.基于BP-NSGA-II的汽车仪表板注塑工艺优化[J].工程塑料应用,2022,50(5):89–93,100.
TAO Shihao, LIU Ying, SU Xiaoping. Optimization of injection molding process of automobile dashboard based on BP-NSGA-II [J]. *Engineering Plastics Application*, 2022, 50(5):89–93, 100.