

基于统计提升准则的注塑工艺参数优化

谭 帅¹, 彭 俊¹, 李 闯²

(1.东北大学 信息科学与工程学院, 沈阳 110004; 2.中能电力科技开发有限公司, 北京 100034)

摘要: 为了同时改善生产平板型注塑制品时的总体收缩度和收缩均匀度, 提出基于统计提升准则的注塑成型工艺参数的多目标优化方法, 寻找平衡两个质量指标的优化设计. 首先利用小规模实验设计方法获得建模数据集, 针对应用中存在的建模数据奇异点问题提出一种数据预处理方法, 并依此分别建立两个指标的初始替代模型, 用于代替优化过程中代价高昂的计算分析; 随后依据 Pareto 统计提升准则寻找新的采样点加入建模数据集来重新建模, 使寻优结果不断趋近真实的 Pareto 前沿. 仿真结果表明, 较常规的建模优化方法, 本文提出的方法能使用较少的采样数据, 显著地改善平板制品的收缩质量. 对于 HDPE 材质的矩形制品, 保压曲线先恒定后线性递减可以获得好的收缩均匀度, 使用压力上限值恒定保压可以获得好的平均收缩度.

关键词: 注塑成型; 收缩; 多目标优化; 统计提升准则; Kriging 模型

中图分类号: TQ 320.66 **文献标志码:** A **文章编号:** 1005-0299(2014)02-0068-07

Multi-objective optimization of injection molding process parameters based on statistical improvement criterion

TAN Shuai¹, PENG Jun¹, LI Chuang²

(1.School of Information Science & Engineering, Northeastern University, Shenyang 110004, China;

2.ZhongNeng Power Technology Development Co. Ltd., Beijing 100034, China)

Abstract: To improve the shrinkage and evenness of the production of injection molded slab, this article introduces an iterative multi-objective optimization method based on Kriging surrogate model to find the Pareto set of the optimization problem. The idea of the iterative optimization method is first to establish two approximation function relationships between those index and process parameters by a small size of design of experiment (DOE) with surrogate model to alleviate the expensive computational expense in the optimization iterations. And then statistical improvement criterion of Pareto front is used to provide direction in which additional training samples could be added to better the surrogate model. This process will loop and bring the optimization result close to the ideal Pareto front. Simulation results show that a much better shrinkage quality of molded part can be achieved with the proposed method with smaller amount of samples compared with traditional modeling and optimization method. For rectangular HDPE products, good evenness can be gotten using linear decreasing pressure curve after a period of constant value, and good shrinkage can be gotten using holding pressure with upper limits.

Keywords: injection molding; shrinkage; multi-objective optimization; statistical improvement criterion; kriging model

制品收缩是注塑成型工艺中的重要质量指

标.影响收缩指标的最关键工艺是保压阶段,保压压力的大小及其作用时间对制品的收缩有显著影响^[1-2].X.Chen、C.Li等^[3-4]采用收缩均匀度为指标,将保压曲线作为优化变量,未考虑其他工艺参数.K.M.B.Jansen等^[5]通过实验分析得到,对于半结晶材料,各工艺参数中保压压力对收缩影响最大,

收稿日期: 2013-10-02.

基金项目: 中央高校基本科研专项资金资助项目(N120304004);
中国博士后科学基金资助项目(2013M530937).

作者简介: 谭 帅(1983-),女,博士.

通信作者: 谭 帅, E-mail: tanshuai@ise.neu.edu.cn.

模具温度次之;但论文只给出各参数对总体收缩影响程度的定性分析,并未在工艺参数可行范围内,给出最优的工艺设定解。

使收缩均值和均匀度都尽可能达到最优,是一个双目标优化问题。对于这类问题,往往无法找出能够同时使 2 个指标都达到最优的可行解,取而代之的是求出一组非支配解集(Pareto 解集),解集内任一解均部分优于其他解,该解集对应的目标函数曲线被称为 Pareto 前沿^[6]。获取 Pareto 解集最简单的方法是标量化方法,比如目标加权法^[7];另一种方法是一次性求取 Pareto 解集的多目标优化方法,NSGA-II 是此类方法的代表^[8-9]。以上两类方法都建立在精确的优化模型基础上,可利用替代模型来拟合真实模型^[10]。建立精确的替代模型需要大量建模数据,为进一步减少计算代价,J.Knowles 等^[11]提出了一种多目标迭代优化方法,但由于采用标量化方法来转化多目标问题,因此也继承了标量化方法的缺点。为克服这个缺点,A.J.Keane 等^[12]提出一类 Pareto 统计提升(SI)准则,折衷算法的全局和局部搜索能力,将局部搜索和全局收缩能力结合到一起,迭代结果可以覆盖整个 Pareto 前沿。

本文采用基于 Kriging 替代模型的迭代寻优方法,并引用 Pareto SI 准则,来解决双目标优化问题;同时,针对应用中存在的一类数据奇异点,分析了其对迭代寻优过程的恶劣影响,并提出了一种数据预处理方法,用于克服这种影响;最后,将带有数据预处理的迭代优化方法,用于基于制品收缩均值和均匀度指标的双目标优化问题,并从工艺角度对寻优结果进行分析解释。

1 替代模型

1.1 Kriging 模型

Kriging 模型实际上是一种插值模型,该模型的优势在于它不仅能给出行域任意点的预测值,还能够给出该预测值的不确定度。已知可行域内的 N 个 k 维样本点 $[x^{(1)}, x^{(2)}, \cdots, x^{(N)}]$, 其对应的输出响应 $y = [y^{(1)}, y^{(2)}, \cdots, y^{(N)}]^T$, 定义样本点 $x^{(i)}$ 与可行域内任一点 x 对应响应值的相关函数为

$$\psi(\|x^{(i)} - x\|) = \exp\left(-\sum_{m=1}^k \theta_m |x_m^{(i)} - x_m|^{p_m}\right), \tag{1}$$

那么可行域内任一点的预测值 $\hat{y}$ 可表示为

$$\hat{y}(x) = \hat{\mu} + \Psi^T \Psi^{-1}(y - I\hat{\mu}). \tag{2}$$

式中: θ_m 和 p_m 为第 m 维输入对应的待定模型参数; I 为 N 维单位列向量;

$\Psi = [\psi(\|x^{(1)} - x\|), \cdots, \psi(\|x^{(N)} - x\|)]^T$, 可逆矩阵 $\Psi_{i,j} = \psi(\|x^{(i)} - x^{(j)}\|)$, $i, j = 1, 2, \cdots, N$, 常数

$$\hat{\mu} = \frac{I^T \Psi^{-1} y}{I^T \Psi^{-1} I}. \tag{3}$$

如果将确定的函数 $y(x)$ 视为满足高斯分布的随机过程 $Y(x)$ 的一个实现,那么对于目前已知的输出响应 y (满足高斯分布), $Y(x)$ 在任一点 x 处的均值和方差分别为式(2)和

$$s^2(x) = \sigma^2 \left[I - \Psi^T \Psi^{-1} \Psi + \frac{I - I^T \Psi^{-1} \Psi}{I^T \Psi^{-1} I} \right], \tag{4}$$

其中

$$\hat{\sigma}^2 = \frac{(y - I\hat{\mu})^T \Psi^{-1} (y - I\hat{\mu})}{N}. \tag{5}$$

该方差表示预测值(均值) $\hat{y}$ 的不确定度^[13-14]。

1.2 Pareto SI 准则

设待插值的 2 个函数为 $f_{1e}(x)$ 和 $f_{2e}(x)$, 对应输出响应为 y_1 和 y_2 , 由 N 个初始采样得到包含 M_0 个采样的初始 Pareto 解集

$$f_{1,2} = \{ [f_{1e}^{(1)}(x^{(1)}), f_{2e}^{(1)}(x^{(1)})], [f_{1e}^{(2)}(x^{(2)}), f_{2e}^{(2)}(x^{(2)})], \cdots, [f_{1e}^{(M_0)}(x^{(M_0)}), f_{2e}^{(M_0)}(x^{(M_0)})] \},$$

其对应的 Pareto 前沿如图 1 所示。




图 1 Pareto 前沿及其支配区域示意图

假设由 N 个训练数据对,分别插值得到的一对 Kriging 替代模型 $\hat{y}_1(x)$ 和 $\hat{y}_2(x)$ 彼此是独立的,可行域内任意点 x 对应预测值和及其标准差分别为 μ_1, μ_2 和 s_1, s_2 , 那么 $\hat{y}_1(x)$ 和 $\hat{y}_2(x)$ 对应的二维联合概率密度函数为

$$\phi(\hat{y}_1, \hat{y}_2) = \frac{1}{s_1(x) \sqrt{2\pi}} \exp\left\{-\frac{1}{2} \frac{[\hat{y}_1 - \mu_1(x)]^2}{s_1^2(x)}\right\} \times \frac{1}{s_2(x) \sqrt{2\pi}} \exp\left\{-\frac{1}{2} \frac{[\hat{y}_2 - \mu_2(x)]^2}{s_2^2(x)}\right\}.$$

显然,当采样点响应值位于图 1 中 S_{dom} 区域时,初始 Pareto 前沿提升较大,因此这里要找到可行域内最有可能落入 S_{dom} 中的点作为新加入点,即最

大化概率提升

$$P[I] = \iint_{S_{\text{dom}}} \phi(\hat{y}_1, \hat{y}_2) d\hat{y}_1 d\hat{y}_2. \tag{4}$$

除了概率提升,还可以最大化期望提升.考虑指标提升的幅度

$$D(x) = \sqrt{[\hat{y}_1(x) - f_{1e}^*(x^*)]^2 + [\hat{y}_2(x) - f_{2e}^*(x^*)]^2},$$

参见图 1,这里 $\bar{\hat{y}}_1, \bar{\hat{y}}_2$ 为质心的坐标,它们可表示为

$$\bar{\hat{y}}_1 = \frac{\iint_{S_{\text{dom}}} \hat{y}_1 \phi(\hat{y}_1, \hat{y}_2) d\hat{y}_1 d\hat{y}_2}{\iint_{S_{\text{dom}}} \phi(\hat{y}_1, \hat{y}_2) d\hat{y}_1 d\hat{y}_2},$$
$$\bar{\hat{y}}_2 = \frac{\iint_{S_{\text{dom}}} \hat{y}_2 \phi(\hat{y}_1, \hat{y}_2) d\hat{y}_1 d\hat{y}_2}{\iint_{S_{\text{dom}}} \phi(\hat{y}_1, \hat{y}_2) d\hat{y}_1 d\hat{y}_2},$$

而 $f_{1e}^*(x^*) f_{2e}^*(x^*)$ 是当前 Pareto 解集中距离质心最近点的坐标,那么期望提升可表示为^[12]

$$E[I] = P[I] D(x). \tag{5}$$

由于考虑了预测误差的不定度,2 个统计提升函数 $E[I]$ 和 $P[I]$ 都具备全局搜索能力.但 $E[I]$ 考虑了指标提升的幅度,因此实际优化时它的搜索幅度较 $P[I]$ 更大,并且 $E[I]$ 也与 2 个指标的加权系数有关,而 $P[I]$ 则无关.

2 优化策略的实现

2.1 数据预处理

基于替代模型的多目标迭代优化过程可概括为,利用初始采样数据建模,再根据 Pareto SI 准则寻找新的加入点,加入训练数据集后重新建模,如此循环直至满足收敛准则,显然建模准确与否是迭代优化能否正确进行的基础.尽管 Kriging 方法适用于插值高度非线性模型,但前提是被插值模型是光滑和连续的^[14],然而在实际的寻优问题中,常会在可行域内出现一些数值相对较大或较小的奇异点,如图 2(a) 所示,这将直接影响建模结果,从而影响迭代寻优过程.




图 2 带有奇异点的函数及其分段压缩过程

为了限制奇异点的幅值,同时又不改变响应

值的相对大小,这里采用奇异点线性变换的方法来解决该问题.基本思想如图 2(b) 所示,首先根据初始采样数据的分布,设定监测来判断奇异点,一旦新采样超过监测限,则进行数据压缩,即把从压缩限到奇异点的响应值,线性变化到压缩限与监测限之间.这样做就把奇异点压缩到正常范围,从而保证建模和迭代寻优过程的进行.

2.2 迭代优化策略的流程

带有数据预处理步骤的多目标迭代优化方法的实现流程如图 3 所示,具体步骤如下:




图 3 带预处理步骤的双目标迭代优化流程图

1) 数据产生.使用拉丁超立方方法产生 N 个初始采样点,拉丁超立方是一种实验设计方法,具有抽样次数少结果稳定的特点^[15].再通过实验产生与输入对应的 N 对响应值.

2) 首次数据预处理.分别根据两种指标的响应值,计算出指标对应的监测限和压缩限,并对超出压缩限数据进行压缩.令监测上下限为 R_u 和 R_d ,压缩上下限为 C_u 和 C_d ,具体定义如下:

$$R_u = m + 3d, R_d = m - 3d;$$
$$C_u = m + 2d, C_d = m - 2d.$$

式中, m 为 N 个响应的均值, d 为标准差.如果最大值响应 $y^{(s)}$ (奇异点) 超出 R_u , $\tilde{y}^{(s)}$ 为 $y^{(s)}$ 压缩后的数值,设 $y^{(i)}$ 为待压缩的采样值, $\tilde{y}^{(i)}$ 为 $y^{(i)}$ 压缩后的结果,那么

$$\tilde{y}^{(i)} = C_u + \frac{\tilde{y}^{(s)} - C_u}{y^{(s)} - C_u} (y^{(i)} - C_u). \tag{6}$$

实际上, $\tilde{y}^{(s)}$ 是人为设定的数据压缩边界,它可在 C_0 到 R_0 之间选取.利用式(6)对所有超出 C_0 的采样都进行变换,未超出的则保持不变,这样就完成了奇异值超出监测上限情况下的数据压缩过程,而超出下限的情况处理方法与其类似.

3) 建立模型.分别利用采样数据对,建立 2 个指标的 Kriging 模型,即采用极大化似然函数的方法^[14],获得式(1)中的待定参数 p 和 θ .

4) 寻找加入点.在可行域内优化式(4)或式(5),找到当前插值模型下的一个全局提升加入点.

5) 终止准则.如果加入点数达到初始采样个数 N 的一到两倍的时候,迭代寻优终止,否则进入步骤 6.

6) 获取新响应值后,再进行处理.对新加入采样要先获取其对应响应值,如果其超出当前压缩限,先对其进行压缩,若压缩后仍超出监测限(新的最大值出现),则用它替换掉式(6)中的 $y^{(s)}$,再用式(6)对所有超出压缩限的采样重新压缩,之后回到步骤 3,重新进行建模.

3 迭代优化实例

本例选取多目标函数^[8]

$$f_1(x) = 1 - e^{-4x_1} \sin^6(6\pi x_1),$$
$$f_2(x) = g(x) (1 - (f_1(x)/g(x))^2).$$

式中, $g(x) = 1 + 9 (\sum_{i=1}^m x_i/4)^{0.25}$, 自变量个数 $m=2$, 作为优化对象.分别采用不带有和带有数据预处理步骤的两种迭代优化策略对其进行优化,初始采样个数 $N=20$,数据压缩边界 $\tilde{y}^{(s)} = m + 2.9d$,建模时为减少计算量将 p 取为 2,只优化 θ ,加入点依据 Pareto EI 准则选取,当加入点总数到达 40 时迭代停止.最终得到的 Pareto 前沿如图 4 所示,可见使用带有预处理步骤的方法得到的前沿与理想的前沿几乎重合,远远好于不带预处理步骤的方法.这是因为 $f_2(x)$ 存在函数值突变的区域,而且 $f_2(x)$ 的最优值就在该区域内,一旦由提升准则确定的加入点进入该区域后,Kriging 模型迅速恶化,最终导致优化解向真实前沿靠近缓慢.

图 5 和图 6 分别给出了 Kriging 模型参数随迭代进行的变化情况,这里实线和虚线分别表示带有和不带有预处理步骤时的情况,而细线表示 θ_1 参数,粗线表示 θ_2 参数.从图 6 中可明显看出:当迭代进行到 10 次之后,不带预处理步骤时拟合出的模型参数迅速到达边界,这说明模型已经不能正确描述实际函数 $f_2(x)$ 了;而带有预处理步骤的参数则一直在正常的范围内波动.同时,在

$f_2(x)$ 的 Kriging 模型恶化之后, $f_1(x)$ 的 Kriging 模型参数也开始加剧震荡,进而 Pareto EI 准则也随之失效,Pareto 前沿很难再向理想前沿靠近了.




图 4 带有和不带有预处理步骤优化所得的 Pareto 前沿




图 5 函数 $f_1(x)$ 的 Kriging 模型参数随迭代的变化情况




图 6 函数 $f_2(x)$ 的 Kriging 模型参数随迭代的变化情况

4 平板型制品质量的多目标优化

4.1 优化模型

本文用于研究保压曲线优化的注塑制品形状如图 7 所示,它是一个规格为 150 mm×30 mm×2 mm 带有扇形浇口的矩形制品.材料选用 Dow Chemical USA 生产的牌号为 Dowlex IP-10 的 HDPE.制品总体收缩指标采用制品顶出时各点体积收缩率的均值来表示,而均匀度指标则采

用标准差表示.这里在图 7 中等间隔选取 18 个点,来计算收缩率的 2 个统计量:

$$\text{shrinkage} = \frac{1}{18} \sum_{i=1}^{18} v_i;$$
$$\text{Evenness} = \sqrt{\frac{\sum_{i=1}^{18} (v_i - \bar{v})^2}{17}}.$$

式中: v_i 表示图中第 i 个点的体积收缩; $\bar{v}$ 表示所有检测点收缩的均值,显然,该指标越小制品质量越均匀.

根据注塑工艺分析,保压曲线是影响 2 个收缩指标最关键的因素;而相对模具温度和熔体温度,注射速度对 2 个指标的影响最为间接.针对 HDPE 材质的矩形制品,Jansen 等人^[5]通过收缩指标影响因素分析实验,也给出了相似的结论.因此,这里确定优化变量为保压曲线、模具温度和熔体温度.




图 7 矩形制品及其浇注系统的 Fusion 网络模型

保压曲线定义为先恒压后线性递减的形式.恒压压力设定为注塑机合模力可承受的上限^[4],这里选为 100 MPa;最大保压时间应保证大于在最高的模具温度 θ_{mold} 和熔体温度 θ_{melt} 下的浇口封死时间,这里选为 10 s.这样,保压曲线就可以由保压曲线转折时间 t ,以及曲线的下降倾角 ϕ 两个参数来描述,如图 8(a) 所示.该描述可以表示恒定保压($\phi=0^\circ$ 或 $\phi=90^\circ$) 和先恒定后递减保压($0^\circ<\phi<90^\circ$),此外还可表示保压时间小于 10 s 的情况,如图 8(b) 所示.




图 8 保压曲线的两种形式

至此,优化问题可以描述为

$$\text{find} \quad x = [\theta_{\text{mold}}, \theta_{\text{melt}}, t_{\text{turn}}, \phi]$$
$$\text{minimize} \quad F = [\text{shrinkage}(x), \text{evenness}(x)]$$
$$\text{s.t.} \quad 20^\circ\text{C} \leq \theta_{\text{mold}} \leq 60^\circ\text{C}$$
$$200^\circ\text{C} \leq \theta_{\text{melt}} \leq 240^\circ\text{C}$$
$$3\text{ s} \leq t_e \leq 10\text{ s}$$
$$0^\circ \leq \phi \leq 90^\circ$$

(7)

4.2 优化结果及分析

按照 2.2 节流程图,首先取 40 组初始输入采样,而后使用 Moldflow 对制品生产进行仿真分析获取收缩均值和均匀度,获得 Pareto 解集,如表 1 所示.仿真时,保压曲线形状参数以外其它的工艺参数设定如下:恒定注射速度 40 mm/s.应用带有数据预处理方法的多目标迭代优化策略对过程进行优化,并将 2 个指标分别进行规一化处理,使 Pareto EI 准则不带有偏好,数据压缩边界仍取为 $\tilde{y}^{(s)} = m + 2.9d$.经过 60 次迭代,获得一个由实际采样组成的 Pareto 解集,如表 2 所示,其中最优收缩均值和均匀度,分别对应于 1 号和 8 号工艺设计.解集对应 Pareto 曲线如图 9 中的实线所示,与初始 40 个采样对应的 Pareto 曲线(如图 9 中虚线所示)比较,迭代使 Pareto 前沿有了显著的提升.

表 1 初始采样对应的 Pareto 解集

序号	模具温度/℃	熔体温度/℃	转折时间/s	下降倾角/(°)	平均收缩/%	均匀度/%
1	24.9	219.9	9.0	73.6	0.370 8	0.075 87
2	29.0	220.9	8.2	71.7	0.437 5	0.070 42
3	36.6	231.5	7.5	75.4	0.462 2	0.069 58
4	37.0	235.2	7.1	72.9	0.469 3	0.053 09
5	47.2	228.4	6.5	70.3	0.557 1	0.046 52
6	54.1	239.0	5.5	71.8	1.092 8	0.024 95

表 2 基于收缩指标的注射工艺参数双目标优化问题的 Pareto 解集

序号	模具温度/℃	熔体温度/℃	转折时间/s	下降倾角/(°)	平均收缩/%	均匀度/%
1	20.1	220.8	9.6	84.1	0.335 2	0.075 96
2	22.3	215.5	9.0	78.2	0.339 3	0.070 90
3	26.9	218.6	8.3	74.6	0.415 6	0.054 06
4	31.0	225.6	7.2	72.1	0.522 3	0.038 97
5	38.5	235.5	7.3	70.4	0.586 9	0.031 78
6	38.7	230.2	6.0	74.1	0.827 4	0.010 57
7	57.0	238.0	5.9	70.8	1.065 4	0.002 96
8	57.7	236.0	5.8	71.5	1.119 6	0.002 64




图 9 初始采样和迭代优化后采样的 Pareto 前沿

由表 2 可知,最优收缩均匀度设计对应解集中最低的模具温度和较低的熔体温度,而最小平均收缩设计正与之相反。这是因为较高的模具温度使得制品的凝固时间增长,对于收缩均值,这将使得 HDPE 制品的结晶度较高,从而加大制品的总体平均收缩;而对于收缩均匀度,这将导致保压压力对制品作用时间长且传递较均匀;因此制品收缩分布会随温度升高而变得更加均匀。熔体温度对制品收缩的影响与模具温度相似,但是却没有模具温度作用显著。这从表 2 中 2 个收缩指标随着 2 个温度变化的趋势和程度上就可以看出。

最优收缩均值和均匀度设计对应的保压曲线分别如图 10(a)和(b)所示。




图 10 最优指标对应的保压曲线

表面上看,两者都是先恒定后线性递减的保压曲线,但如果考虑制品浇口封死时间,那么两者的实际作用时间都会缩短。通过 Moldflow 仿真可知,对于图 10(a)该时间为 6.2 s,而对于图 10(b)则为 8.5 s。这样最优均值设计的保压曲线等价于恒定保压曲线,而最优均匀度设计的保压曲线仍是先恒定后递减型的,解集里其余的设计则是两者之间的过渡。前者容易理解,因为若想使制品总体收缩最小,必然要使用恒定的最大保压曲线来保压;后者则不然,远浇口(图 7 中制品 B 处)未冻结之前,即 5.8 s 之前应采取最大保压压力,以使制品各处收缩最均匀,但从此刻开始直到浇口

封死,则应采用递减保压曲线,以使远近浇口的收缩差异减小,令制品更均匀^[4]。

4.3 决策制定

获得 Pareto 解集后,必须从中选取一个解作为最终的优化结果,这个过程通常被称为决策制定。一种简单的决策方法是,分别计算 Pareto 解集内的解与理想点的距离,选择距离理想点距离最小的解作为最终决策解。对于本文的双目标优化问题理想点是[0.335 2, 0.002 64],为消除目标幅值对距离的影响,先对 Pareto 解集及理想点归一化之后,再进行数据点差异程度计算,结果如表 3 所示,显然应选择数值最小的设计 4 作为最终优化解。

表 3 理想点与 Pareto 解集内各点之间的差异程度								
序号	1	2	3	4	5	6	7	8
差异程度	1	0.931	0.637	0.511	0.550	0.709	0.931	1

上述方法只考虑了 Pareto 解集内各点与理想点的距离,从注塑工艺角度看,这未必是最优的。实际生产中,除了希望优化两个收缩指标外,还希望注塑成型周期尽可能短,或者最优解的鲁棒性强等等。如果考虑成型周期就可以选择模具温度和熔体温度较低,所需保压和冷却时间短的设计;如果考虑最优解的鲁棒性,就要通过进一步的灵敏度实验来分析判别。具体用哪种策略,需要根据实际生产的需求来确定。

5 结 论

本文针对注塑制品收缩指标的双目标优化问题,采用基于 Kriging 替代模型的迭代寻优方法。该方法在迭代过程中使用现有采样数据及 Pareto SI 准则,来确定新的数据加入点,使得采样集的 Pareto 前沿不断趋于理想前沿。此外本文还提出了一种数据预处理方法,用于克服奇异点对该迭代寻优过程的坏影响。实际应用结果表明,迭代优化方法通过初始采样以外的 60 次实验,使得 Pareto 前沿显著提升。

通过对 Pareto 解集的工艺分析可知,对于 HDPE 材质的矩形制品,若想获得最优收缩均匀,模具温度越高越好,保压曲线应为先恒定后线性递减;若想获得最优的平均收缩,模具温度越低越好,保压曲线应使用压力上限值恒定保压。最终进行决策制定时,应考虑实际生产需求,从 Pareto 解集中选择最能满足实际需求的解作为最优设计。

参考文献:

[1] ROSATO D V, ROSATO M G. Injection Molding

- Handbook [M]. 3rd ed. Boston: Kluwer, 2000.
- [2] 周云郊, 兰凤崇, 黄信宏, 等. 钢铝板材压力连接模具几何参数多目标优化[J]. 材料科学与工艺, 2011, 19(6): 86-99.
- ZHOU Yunjiao, LAN Fengchong, HUANG Xinhong, et al. Multi-objective optimization of geometry of clinching tools for steel-aluminum blank sheets[J]. Materials Science and Technology, 2011, 19(6): 86-93.
- [3] CHEN Xi, GAO Furong. A study of packing profile on injection molded part quality[J]. Materials Science Engineering: A, 2003, 358(1/2): 205-213.
- [4] LI Chuang, WANG Fuli, CHANG Yuqing, et al. A modified global optimization method based on surrogate model and its application in packing profile optimization of injection molding process[J]. Int J Adv Manuf Technol, 2010, 48(5): 505-511.
- [5] JANSEN K M B, Van DIJK D J, HUSSELMAN M H. Effect of processing conditions on shrinkage in injection molding[J]. Polymer Engineering Science, 1998, 38(5): 838-846.
- [6] KNOWLES J, CORNE D, DEB K. Multiobjective Problem Solving from Nature: from Concepts to Applications[M]. Berlin: Springer-Verlag, 2007.
- [7] KIM I Y, De WECK O L. Adaptive weighted sum method for multiobjective optimization: a new method for Pareto front generation[J]. Struct Multidisc Optim, 2006, 31(2): 105-116.
- [8] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.
- [9] 金溪, 高金良, 张杰, 等. 利用 NSGA-II 算法求解供水管网优化改造模型[J]. 哈尔滨工业大学学报, 2008, 40(12): 1969-1976.
- JIN Xi, GAO Jinliang, ZHANG Jie, et al. Optimal rehabilitation model of water supply network with non-dominated genetic algorithm-II[J]. Journal of Harbin Institute of Technology, 2008, 40(12): 1969-1976.
- [10] WILSON B, CAPPELLERI D, SIMPSON W, et al. Efficient pareto frontier exploration using surrogate approximations[J]. Optimization Engineering, 2001, 2: 31-50.
- [11] KNOWLES J, HUGHES E J. Multiobjective optimization on a budget of 250 evaluations[J]. Evolutionary Multi-Criterion Optimization, LNCS, 2005, 3410: 176-190.
- [12] KEANE A J. Statistical improvement criteria for use in multiobjective design optimization[J]. AIAA Journal, 2006, 44(4): 879-891.
- [13] RASMUSSEN C E, WILLIAMS C K I. Gaussian Processes for Machine Learning[M]. Massachusetts: The MIT Press, 2006.
- [14] FORRESTER A I J, KEANE A J. Recent advances in surrogate-based optimization [J]. Progress in Aerospace Sciences, 2009, 45(1/2/3): 50-79.
- [15] SACKS J, WELCH W J, MITCHELL T J, et al. Design and Analysis of Computer Experiments[M]. Berlin: Springer-Verlag, 2003.

(编辑 程利冬)