

文章编号: 1000-5013(2010)03-0241-05

注塑件体积收缩率变化的数值模拟优化与预报

许建文, 刘斌

(华侨大学 机电及自动化学院, 福建 泉州 362021)

摘要: 运用 Moldflow 分析软件, 结合田口方法的实验设计, 对注塑成型过程进行数值模拟计算, 得到各个工艺参数对体积收缩率变化的影响次序及最优化的工艺参数组合. 利用 BP(Back Propagation) 人工神经网络对注塑件的体积收缩率的变化进行预测, 以最优化的工艺参数组合为基准, 通过微调各个工艺参数来安排正交实验, 并将结果作为神经网络的样本数据. 经过训练后的神经网络能够准确地预测体积收缩率的变化, 从而达到以较少的试验实现注塑成型工艺的优化与控制.

关键词: 注塑件; 体积收缩率; Moldflow; 田口方法; BP 神经网络

中图分类号: TQ 320.66; TP 183

文献标识码: A

注塑件的收缩行为对产品的最终尺寸和形状起着重要的作用, 注塑件的收缩率及其分布是衡量注塑件质量的重要指标^[1]. 对注塑件收缩率有影响的因素主要来自 3 个方面, 即注塑材料特性、注塑工艺条件和模具成形结构^[2]. 材料和模具结构确定以后, 成型工艺参数就直接影响到模具内熔体的状态和最终塑件的质量, 因此, 获取优化的工艺参数是成型高质量塑件的前提. 本文结合田口实验设计方法与 BP(Back Propagation) 神经网络技术, 模拟分析注塑件的体积收缩率变化.

1 优化与预测方法

1.1 田口实验设计方法

为降低注塑件体积收缩率变化的大小, 需要研究各个工艺参数对变形的影响. 首先, 利用 Moldflow 软件进行模拟分析, 确定适宜的工艺参数范围; 然后, 针对模具温度、熔体温度、注射时间、保压时间、冷却时间和保压压力 6 个参数, 选取 5 个水平作为实验方案. 对每个方案进行模拟, 以得到体积收缩率变化的大小. 通过分析, 得到工艺参数对体积收缩率变化的影响大小和最优的工艺参数组合^[3].

1.2 BP 神经网络^[4]

1.2.1 网络输入与输出层的确定 BP 网络在学习(训练)过程中采用误差向后传播算法, 由输入层、隐层和输出层组成, 层与层之间采用全互连方式, 同一层单元之间不存在相互连接. 对于任何闭区间内的一个连续函数, 可用单隐层的 BP 网络逼近, 因而一个 3 层 BP 网络就可以完成任意的 n 维到 m 维的映射^[5]. 为了研究注塑件体积收缩率变化与成型工艺参数之间的关系, 选取模具温度、熔体温度、注射时间、保压时间、冷却时间和保压压力 6 个工艺参数作为输入, 注塑件体积收缩率变化作为输出.

1.2.2 隐层的设计 隐层的神经元数目选择是一个十分复杂的问题, 往往需要根据设计者的经验和多次实验来确定. 隐单元的数目与问题的要求、输入/输出单元数目都有着直接的关系. 采用经验式^[5]求隐层的神经元数目, 即

$$n_1 = \sqrt{n + m} + a. \quad (1)$$

式(1)中: m , n 分别为输出、输入神经元数目; a 为 [1, 10] 之间的常数. 由于输入神经元数目为 6, 输出为 1, 则隐层的神经元的数目为 4~13. 为了寻找比较好的隐层神经元数目, 在 MATLAB 编一个循环程

收稿日期: 2009-01-10

通信作者: 刘斌(1972), 男, 副教授, 主要从事聚合物材料注塑成型的研究. E-mail: mold_bin@hqu.edu.cn.

基金项目: 福建省自然科学基金资助项目(E0810040); 福建省青年创新基金资助项目(2004J033)

序,选择网络性能较好所对应的作为隐层神经元数目.经比较,选取隐层的神经元数目为4的网络结构,如图1所示.

1.2.3 传递函数的选择 网络隐层和输出层的神经元传递函数分别采用S型正切函数、S型对数函数.(1)对于S型正切函数(tan sig),MATLAB 7按照如下形式计算该双曲正切传递函数的值,即

$$\tan \operatorname{sig}(c)=\frac{2}{1+\exp (-2 c)}-1 .$$

(2)

式(2)中: c 为变量.(2)对于S型对数函数(log sig),则有

$$\log \operatorname{sig}(d)=\frac{1}{1+\exp (-d)}-1 .$$

1.2.4 训练函数的选择 训练函数选取 Trainlm,即采用 Levenberg-Marquardt 算法进行网络训练.

1.2.5 学习函数的选择 学习函数则选取 Learngdm.该函数为梯度下降动量学习函数,通过利用神经元的输入误差、权值或阈值的学习速率和动量常数,来计算权值或阈值的变化率.

1.2.6 性能函数的选择 性能函数选用均方误差性能函数 mse.

1.2.7 网络训练与检验 把田口实验设计得到的最优化工艺参数组合作为基准条件,微调各个工艺参数来安排正交实验进行模拟分析,得到神经网络的训练和检验样本.用训练样本对神经网络进行训练,网络权值确定后,采用检验样本检验此网络.如果网络对检验样本的输出误差可以接受,说明神经网络的训练成功;否则,需要重新进行神经网络的训练.

1.2.8 数据的预处理 由于系统是非线性的,初始值对于学习是否能够收敛的关系很大.因此,考虑到输入数据和输出数据范围分布很大,需要进行数据的归一化处理.这不仅能够避免由于输入参数不均匀性而引起的输出失真和网络麻痹现象,还可以在在一定程度上缩短网络训练时间.其归一化式^[6]为

$$\hat{x}_i=0.05+0.9 \frac{x_i-\min x_i}{\max x_i-\min x_i} .$$

(3)

式(3)中: x_i, \hat{x}_i 分别为归一化前、后的数据; $\min x_i$ 与 $\max x_i$ 则分别为该工艺变量的最小值与最大值.

2 田口实验设计

2.1 实验方案

选用非球面塑料光学透镜作为成型零件,材料选用聚甲基丙烯酸甲酯(PMMA).优化后的浇注系统及冷却系统,如图2所示.在确定冷却系统和浇注系统后,根据材料推荐的参数和初步的模拟结果,选取各个工艺参数的水平,如表1所示.表1中, $A \sim F$ 分别表示模具温度、熔体温度、注射时间、保压时间、冷却时间和保压压力6个工艺参数.

表 1 工艺参数水平安排

Tab.1 Arrangement of process parameter level

工艺参数	水平				
	1	2	3	4	5
$A/^{\circ}\text{C}$	40	50	60	70	80
$B/^{\circ}\text{C}$	240	250	260	270	280
C/s	4.2	4.7	5.2	5.7	6.2
D/s	11	12	13	14	15
E/s	37	38	39	40	41
F/MPa	15	20	25	30	35

采用6参数5水平的 $L_{25}(5^6)$ 正交表来安排实验.用 Moldflow 模拟分析,得到注塑件在不同工艺参数组合设置下的体积收缩率(η)变化结果,如表2所示.




图 1 神经网络结构

Fig.1 Structure of neural network




图 2 注塑件模型图

Fig.2 Drawing of the model of an injection molding product

表 2 实验模拟分析结果

Tab.2 Analysis result of experimental simulation

序号	A/℃	B/℃	C/s	D/s	E/s	F/MPa	η/%
1	40	240	4.2	11	37	15	3.718 4
2	40	250	4.7	12	38	20	4.164 4
3	40	260	5.2	13	39	25	4.668 8
4	40	270	5.7	14	40	30	5.001 8
5	40	280	6.2	15	41	35	5.248 5
6	50	240	4.7	13	40	35	4.201 3
7	50	250	5.2	14	41	15	4.198 9
8	50	260	5.7	15	37	20	4.518 1
9	50	270	6.2	11	38	25	4.893 0
10	50	280	4.2	12	39	30	5.277 8
11	60	240	5.2	15	38	30	4.074 7
12	60	250	5.7	11	39	35	4.491 2
13	60	260	6.2	12	40	15	4.458 2
14	60	270	4.2	13	41	20	4.780 6
15	60	280	4.7	14	37	25	5.181 8
16	70	240	5.7	12	41	25	3.921 7
17	70	250	6.2	13	37	30	4.416 2
18	70	260	4.2	14	38	35	4.813 1
19	70	270	4.7	15	39	15	4.679 5
20	70	280	5.2	11	40	20	5.050 8
21	80	240	6.2	14	39	20	3.895 9
22	80	250	4.2	15	40	25	4.354 1
23	80	260	4.7	11	41	30	4.778 3
24	80	270	5.2	12	37	35	5.056 0
25	80	280	5.7	13	38	15	4.896 9

2.2 结果分析与讨论

使用田口实验设计法中的变量分析(ANOVA),可以计算出各个工艺参数对体积收缩率变化的影响次序和最优的工艺参数组合^[7].

对实验结果进行直观分析,即将各工艺参数在 5 个水平下的体积收缩率变化进行平均,有

$$y = \frac{1}{b} \sum_{i=1}^n z_{i.} \tag{4}$$

式(4)中: y 为工艺参数在某水平下的平均值; b 为该水平下出现的次数; z_i 为工艺参数在此水平下的体积收缩率变化量. 由各工艺参数最大平均值和最小平均值之差可计算出极差 R , 结果如表 3 所示.

表 3 直观分析表

Tab.3 Table of direct analysis

工艺参数	水平					R	排序
	1	2	3	4	5		
A	4.560 4	4.617 8	4.597 3	4.576 3	4.596 2	0.057 4	3
B	3.962 4	4.325 0	4.647 3	4.882 2	5.131 2	1.168 8	1
C	4.588 8	4.601 1	4.609 8	4.565 9	4.582 4	0.043 9	5
D	4.586 3	4.575 6	4.592 8	4.618 3	4.575 0	0.043 3	6
E	4.578 1	4.568 4	4.602 6	4.613 2	4.585 6	0.044 8	4
F	4.390 4	4.482 0	4.603 9	4.709 8	4.762 0	0.371 6	2

通过以上的分析可以得到如下两点结论:

(1) 由极差的大小可直观得出,各工艺参数对体积收缩率变化的影响由大到小的次序: 熔体温度、保压压力、模具温度、冷却时间、注射时间与保压时间. 其中: 熔体温度与保压压力是显著的影响因素,而其他因素则影响不大.

(2) 在考察的工艺参数水平上,最优化的工艺参数组合是,模具温度为 40℃、熔体温度为 240℃、注射时间为 5.7 s、保压时间为 15 s、冷却时间为 38 s 和保压压力为 15 MPa. 在此工艺条件下,获得的体

积收缩率变化为 3.314 0%, 与做过的实验相比, 该工艺条件所得变化确实最小.

3 BP 神经网络预测体积收缩率变化

以最优化工艺参数组合作为基准, 围绕基准微调 6 个因素, 安排 7 个水平, 如表 4 所示. 采用 8 参数 7 水平的 $L_{49}(7^8)$ 正交表进行 Moldflow 模拟分析. 由于实际只有 6 个因素, 正交表的最后两列空出, 可得到 49 组数据, 其中的 40 组数据作为神经网络的训练样本数据, 其余的 9 组数据为检验样本数据.

表 4 工艺参数水平安排

Tab. 4 Arrangement of process parameter level

工艺参数	实验水平						
	1	2	3	4	5	6	7
$A/^{\circ}\text{C}$	36	38	40	42	44	46	48
$B/^{\circ}\text{C}$	240	243	246	249	252	255	258
C/s	4.8	5.1	5.4	5.7	6.0	6.3	6.6
D/s	13.5	14.0	14.5	15.0	15.5	16.0	16.5
E/s	36.5	37.0	37.5	38.0	38.5	39.0	39.5
F/MPa	15	17	19	21	23	25	27

设定网络的目标误差为 0.001, 40 组的训练样本在训练了 32 次后, 其网络输出的最小误差减小为 0.001, 神经网络经过训练后的训练误差 e 曲线, 如图 3 所示(n 为训练次数). 学习后目标为 0.001, 性能为 0.000 892 406. 归一化后的 9 组检验样本对网络性能的测试结果, 如图 4 所示. 图 4 中: e 为误差; N 为样本号. 从图 4 可知, 误差在 $-0.03 \sim 0.05$ 之间, 且大部分分布在 $-0.03 \sim 0$ 之间, 网络整体性能不错, 能够对输入数据进行较为精确的预测.




图 3 神经网络训练误差

Fig. 3 Error of neural network training




图 4 检验样本的误差

Fig. 4 Error of test sample

计算出的实际预测值, 如表 5 所示. 表 5 中: η_M , η_F 分别为体积收缩率的模拟值和预测值; e_a , e_r 分别为体积收缩率的绝对误差值和相对误差值. 从表 5 可知, 其绝对误差在 $-0.019\ 5\% \sim 0.033\ 2\%$ 之间, 相对误差则在 $0.088\ 5\% \sim 0.895\ 8\%$ 之间, 误差在可接受的范围之内, 预测准确度较好.

表 5 神经网络预测体积收缩率变化

Tab. 5 Prediction of volumetric shrinkage variation by neural network

序号	$A/^{\circ}\text{C}$	$B/^{\circ}\text{C}$	C/s	D/s	E/s	F/MPa	$\eta_M/\%$	$\eta_F/\%$	$e_a/\%$	$e_r/\%$
1	36	252	6.0	15.5	38.5	23	3.760 5	3.749 4	- 0.011 1	0.295 2
2	38	246	5.7	15.5	39.0	27	3.593 7	3.574 2	- 0.019 5	0.542 6
3	40	240	5.4	15.5	39.5	17	3.434 4	3.420 2	- 0.014 2	0.413 5
4	40	255	4.8	14.5	38.5	27	3.825 6	3.816 7	- 0.008 9	0.232 6
5	42	249	6.6	14.5	39.0	17	3.706 2	3.739 4	0.033 2	0.895 8
6	44	243	6.3	14.5	39.5	21	3.537 4	3.561 8	0.024 4	0.689 8
7	44	258	5.7	13.5	38.5	17	3.887 1	3.870 9	- 0.016 2	0.417 6
8	46	252	5.4	13.5	39.0	21	3.728 4	3.725 1	- 0.003 3	0.088 5
9	48	246	5.1	13.5	39.5	25	3.563 8	3.548 8	- 0.015 0	0.420 9

对已训练好的神经网络输入 2 组数据: (1) 39 ℃(模具温度), 250 ℃(熔体温度), 5.0 s(注射时间), 14 s(保压时间), 38 s(冷却时间), 22 MPa(保压压力); (2) 43 ℃(模具温度), 245 ℃(熔体温度), 6.0 s(注射时间), 16 s(保压时间), 39 s(冷却时间), 20 MPa(保压压力)。

结果表明, 神经网络预测出的体积收缩率变化量为 0.538 1(3.626 9%) 和 0.455 3(3.563 3%), Moldflow 模拟分析得到的体积收缩率变化量为 3.637 0%, 3.568 6%, 绝对误差分别为- 0.010 1% 与 - 0.005 3%, 相对误差分别为 0.277%, 0.148 5%, 说明网络的输出值可以接受。

4 结束语

神经网络结合田口实验设计方法, 可对注塑件的体积收缩率变化进行优化和预测。在进行最少次数试验的结果上, 可以得到各个工艺参数对体积收缩率变化的影响次序, 以及最优化的工艺参数组合; 然后以此为基准, 微调各个工艺参数安排正交试验, 得到的神经网络样本数据。经过训练后的神经网络能够对体积收缩率变化进行较为准确的预测, 达到了注塑成型工艺的优化及控制。

参考文献:

- [1] 王利霞, 杨杨, 王蓓, 等. 注塑成型工艺参数对制品体收缩率变化的影响及工艺参数优化[J]. 高分子材料科学与工程, 2004, 20(3): 173-176.
- [2] 祝铁丽, 王敏杰. 注塑成形制品收缩过程的数值模拟[J]. 机械工程学报, 2002, 38(9): 145-149.
- [3] MONTGOMERY D C. Design and analysis of experiments[M]. New York: John Wiley Sons, 1997.
- [4] 张云波, 胡云昌. 人工神经网络的建设工期定客户地域分类[J]. 华侨大学学报: 自然科学版, 2004, 25(3): 270-274.
- [5] 飞思科技产品研发中心. 神经网络理论与 MATLAB 7 实现[M]. 北京: 电子工业出版社, 2005.
- [6] 陈桂明, 戚红雨, 潘伟. MATLAB 数理统计(6.x)[M]. 北京: 科学技术出版社, 2002.
- [7] 王利霞, 张娜, 申长雨, 等. 应用 Taguchi 实验设计法最小化注塑成型制品沉降斑[J]. 塑料工业, 2004, 32(4): 26-28.

Optimization and Forecast of Numerical Simulation of Volumetric Shrinkage Variation for Injection Molding Products

XU Jian-wen, LIU Bin

(College of Mechanical Engineering and Automation, Huaqiao University, Quanzhou 362021, China)

Abstract: The influence order of each process parameter on volumetric shrinkage variation of injection molding products and optimum process parameters can be obtained by numerical simulation and calculation of injection molding process with combination of experimental design of Taguchi method and Moldflow software. The volumetric shrinkage variation of injection molding products is predicted by back propagation neural network, in which the arrangement of orthogonal trials by adjusting each process parameter is made on the basis of optimum process parameters and the experimental results are used as the sample data of neural network. The trained neural network can accurately predict the volumetric shrinkage variation so that the optimization and control of injection molding process could be achieved using fewer experiments.

Keywords: injection molding product; volumetric shrinkage variation; Moldflow; Taguchi method; back propagation neural network

(责任编辑: 陈志贤 英文审校: 郑亚青)