

基于 CAE 和神经网络的注射成型工艺参数优化^{*}

刘斌 许建文 江开勇

(华侨大学模具技术研究中心, 泉州 362021)

摘要 通过 CAE 数值模拟计算,研究了注射成型工艺参数对翘曲变形的影响,以工艺参数为输入参数,以翘曲变形量作为输出参数,构建神经网络模型。以 CAE 分析结果作为训练样本和校验样本,结合正交实验方法对注塑工艺参数进行优化。这种方法把 CAE 模拟技术、正交实验技术和神经网络技术有机结合,可以明显缩短优化工艺参数的时间,提高工艺设计效率,能获得比单纯使用正交实验和有限元分析更好的结果。

关键词 翘曲变形 优化 计算机辅助工程 注射成型

材料特性、模具结构和工艺参数是影响注塑制品质量的三大要素。在材料和模具结构确定的情况下,如果工艺参数选用不当,就会导致诸如短射、翘曲、飞边等制品缺陷。随着人们对塑料制品外观质量和使用性能要求的越来越高,翘曲变形程度作为衡量制品质量的主要指标之一,也越来越多地受到产品设计师、用户的关注和重视。因此针对生产中急需解决的问题,研究注射成型工艺参数对制品翘曲变形的影响规律,并在此基础上研究工艺参数的优化方法,得出最佳的工艺参数组合以减小制品翘曲变形和其它缺陷,就具有重要的理论意义和实践应用价值^[1-4]。

注塑工艺参数的优化方法主要有两种^[5]:

(1) Taguchi 试验法。该方法采用正交排列和信噪比分析法将各参数不同水平的设计值进行组合,利用较少的实验次数收集尽可能多的较全面的信息,从中获得各参数的最优值。这种优化方法是注塑领域较早使用的方法之一,具有较好的优化效果。

(2) 基于人工神经网络技术的工艺参数优化。人工神经网络是一种分布式并行处理系统,其处理结果以权值形式分布、存储在矩阵中,具有自组织、自学习、自适应和非线性动态处理等特性,可以实现人脑的概括、类比和推理能力,因而可以从大量数据中提取规则,通过联想记忆和推理等来获取所需数据。理论分析表明,一个三层 BP 网络可以按任意精度逼近任意非线性连续函数。

笔者现将注塑制品的翘曲变形量作为评判指标,以 CAE 分析结果为基础数据,把神经网络和正交实验技术有机结合,对工艺参数进行优化,得出一组最佳工艺参数组合,并利用 Moldflow 软件对优化结果进行分析验证。

1 神经网络模型构建

采用 BP 网络作为建模工具。BP 网络是一种具有三层或三层以上的神经网络,包括输入层、中间层(隐含层)和输出层。上下层之间实现全连接,而每层神经元之间无连接。当将一对学习样本提供给网络后,神经元的激活值从输入层经各中间层向输出层传播,在输出层的各神经元获得网络的输入响应。按照减少目标输出与实际误差的方向,从输出层经过各中间层逐层修正各连接权值,最后回到输入层,这种算法称为“误差逆传播算法”。随着这种误差逆的不断被传播修正,网络对输入模式响应的正确率也不断上升。模型的建立是使用 MATLAB 软件中的神经网络工具箱实现的。

1.1 网络输入、输出参数及结构的确定

输入输出参数是建立神经网络模型中的关键环节。参数的选择应当既反映被模仿系统的行为规律又力求简洁。对于输出为注塑制品翘曲变形量的预测模型,选用的注塑工艺参数主要有熔体温度(料温) T_1 、模具温度 T_2 、注射时间 t_1 、保压时间 t_2 、相对保压压力 P (相对于最高注塑压力)。所以输入量为这 5 个工艺参数,即输入层有 5 个节点。而实验指标只有一个即翘曲变形量,因此输出只有翘曲变形量,即输出层只有 1 个节点。因此,可以得到的 BP 三层神经网络模型如图 1 所示。增加层数虽然可进一步降低误差、提高精度,但同时也使网络复杂化,增加了网络权值的训练时间。而误差精度的提高实际上也可通过增加隐含层的神经元数目来获得,其训练效果也比增加层数更容易观察和调整,实践证明三层网络的精度已经足够^[6]。

^{*} 福建省自然科学基金项目(E0540002)

收稿日期:2007-08-15




图 1 BP 三层网络模型

1.2 训练样本和检验样本的选取

学习样本和检验样本的选择也是至关重要的,充足而正确的学习样本才能够正确反映系统的性能。要训练注塑工艺参数优化神经网络,首先要获得一批实际注射成型中不同工艺条件下的实验数据,而这些数据完全通过实验来获得是很困难的,一方面受实验设备条件的限制,另一方面实验过程需要耗费大量的物力,考虑到当前的模塑 CAE 软件已有很高的模拟精度,因而可以采用计算机仿真注射成型过程来获得。笔者现利用 CAE 软件 Moldflow 模拟实验获得不同条件下的学习样本,即选取不同的注塑工艺参数及与参数对应的翘曲变形结果。采用的样本为基于 CAE 模拟的 25 组实验数据。

1.3 传递函数的选择

采用 Sigmoid 函数(S 型的正切函数)作为输入层与隐含层之间的传递函数,采用 Purelin 函数(线性函数)作为隐含层与输出层之间的传递函数。

1.4 训练函数和隐含层神经元数的选择

在 BP 网络应用中,对某一特定的问题很难确定哪种训练算法最快,因为这取决于问题的复杂性、训练样本数、网络权重和阈值个数及期望误差等多种因素。而对于隐含层节点数的选择,它关系到误差精度的要求,因此也是一个十分重要的指标。

另外,网络的推广能力是衡量神经网络性能好坏的重要指标。为了提高 BP 神经网络的推广性能,采用正则化方法进行优化,即利用新的性能指标函数 Msereg 可以在保证网络训练误差尽可能小的情况下使网络具有较小的权值,使网络的有效权值尽可能小些。本研究先通过 Matlab 编程实现了对各种算法及其隐含层的误差评价,以便于选择合适的算法及隐含层数。通过对实验结果的分析、比较确定了训练函数采用弹性算法,隐含层处取 18 个节点,训练误差取 0.015 mm,至此完成了神经网络模型的建模工作。

2 基于 CAE 的正交实验

为了获得神经网络模型需要的训练样本和检验

样本,以注塑制品的翘曲变形量为实验指标,以注射成型工艺参数为试验因子构建正交实验表,对各个实验进行 CAE 数值模拟仿真计算,以获取各种注塑工艺参数组合下的制品翘曲变形量,作为神经网络模型的样本。在进行翘曲变形分析之前先通过 CAE 软件对浇注系统和冷却系统进行优化,从而可保证在最优的模具结构下来研究注塑工艺参数对制品翘曲变形的影响。

2.1 前处理

以某变压器盒盖的注射成型为分析实例。该制品模型尺寸为 150 mm × 72 mm × 15 mm,最薄壁厚为 0.7 mm,属于薄壳零件,其三维模型如图 2 所示,材料为聚苯醚(PPE)。在对模型进行有限元网格划分之后,分别利用 Moldflow 软件的 Gate Location 模块和冷却分析模块分析了塑料件的最佳浇口位置和温度分布情况,最后得出经过优化的浇注系统和冷却系统的 CAE 模型(如图 3 所示),完成正交实验分析前的准备工作。



图 2 变压器盒盖三维模型




图 3 优化的浇注系统和冷却系统的 CAE 模型

2.2 实验因子选择与取值范围确定

影响制品翘曲变形的工艺因素有注塑压力、背压、模具温度、料温、保压压力、注射时间、冷却时间和保压时间等。其中注塑压力与成型过程的模具和时间有关,它是一个活动的量,不能进行直接的控制,故不予考虑。许多研究表明,背压对产生收缩有一定的影响,但并不十分显著。故主要选择熔体温度(料温)、模具温度、注射时间、保压时间和相对保压压力作为实验因子。

在工艺参数优化过程中,设计因子的取值范围

相当重要,因为它不仅关系到所选范围是否包含最优解或者次优解,而且也影响到优化过程的搜索效率。Moldflow 的成型工艺窗口定义了能够生产合格制品的成型工艺条件范围。如果成型工艺条件位于这个范围之内,那么就可以生产出质量较好的制品。有了成型窗口之后,必要时工艺人员就可以在这个范围内对成型条件做出适当的修改以期获得最好的制品。分析结果显示,模具温度范围为 47 ~120℃,熔体温度范围为 280 ~320℃,注射时间范围为 0.1 ~1.0 s,保压时间范围为 5 ~25 s,相对保压压力为 70% ~90%。

2.3 正交实验表构建

将熔体温度(料温) T_1 、模具温度 T_2 、注射时间 t_1 、保压时间 t_2 、相对保压压力 P 依次简称为 A、B、C、D、E,并假设各因子之间不存在交互作用。在上述的取值范围内,每个因子较均匀地取 5 个水平,具体如表 1 所示。

表 1 多参数正交实验的因子及水平

水平	因 子				
	$T_1 / ^\circ\text{C}$	$T_2 / ^\circ\text{C}$	t_1 / s	t_2 / s	$P / \%$
1	280	48	0.10	5	70
2	290	61	0.35	10	75
3	300	74	0.60	15	80
4	310	87	0.85	20	85
5	320	100	1.10	25	90

根据实验设计,选用 $L_{25}(5^6)$ 的 6 因素、5 水平正交表,其中 6 个因素只使用 5 个,因此只使用正交表的前五列,第六列空出不用,但这并不影响正交实验的分析。经过 CAE 模拟、数据采集,得到如表 2 所示的正交实验表。

为了得到最佳的工艺参数组合,对上述实验数据进行极差分析^[7],结果如表 3 所示。

根据实验指标(翘曲变形量)的要求,注塑制品的翘曲量越小越好,因此其各因子在各水平的平均值也是越小越好,至此,可以得到各因子的最佳工艺参数组合,如表 4 所示。

3 神经网络与正交实验相结合的工艺参数优化

3.1 模型训练与检验

在完成 CAE 分析得出实验数据后,即可将这些数据作为训练样本,对上述建立的神经网络模型进行训练。训练 1149 次后达到了目标误差曲线,模型稳定。而后对此神经网络的可靠性进行检验。给定 5 组检验样本,将其代入神经网络模型进行预测,得出如表 5 所示的结果。

表 2 正交实验方案与结果

实验 序号	因 子					
	$T_1 / ^\circ\text{C}$	$T_2 / ^\circ\text{C}$	t_1 / s	t_2 / s	$P / \%$	翘曲量 Δ / mm
1 [#]	280	48	0.10	5	70	0.8118
2 [#]	290	48	0.35	10	75	0.7428
3 [#]	300	48	0.60	15	80	0.6909
4 [#]	310	48	0.85	20	85	0.6311
5 [#]	320	48	1.10	25	90	0.5925
6 [#]	280	61	0.35	20	80	0.7376
7 [#]	290	61	0.60	25	85	0.6802
8 [#]	300	61	0.85	5	90	0.6847
9 [#]	310	61	1.10	10	70	0.7042
10 [#]	320	61	0.10	15	75	0.6271
11 [#]	280	74	0.60	10	90	0.6712
12 [#]	290	74	0.85	15	70	0.7481
13 [#]	300	74	1.10	20	75	0.6868
14 [#]	310	74	0.10	25	80	0.6225
15 [#]	320	74	0.35	5	85	0.7553
16 [#]	280	87	0.85	25	75	0.7373
17 [#]	290	87	1.10	5	80	0.7141
18 [#]	300	87	0.10	10	85	0.6220
19 [#]	310	87	0.35	15	95	0.6254
20 [#]	320	87	0.60	20	70	0.7145
21 [#]	280	100	1.10	15	85	0.6420
22 [#]	290	100	0.10	20	90	0.6161
23 [#]	300	100	0.35	25	70	0.7534
24 [#]	310	100	0.60	5	75	0.7859
25 [#]	320	100	0.85	10	80	0.6472

表 3 极差分析 mm

项 目	A	B	C	D	E
第一水平平均值	0.720	0.694	0.660	0.750	0.746
第二水平平均值	0.700	0.687	0.723	0.677	0.716
第三水平平均值	0.688	0.697	0.709	0.667	0.682
第四水平平均值	0.674	0.683	0.690	0.677	0.666
第五水平平均值	0.667	0.689	0.668	0.677	0.638
极 差	0.053	0.014	0.063	0.083	0.108

表 4 最佳工艺参数组合

$T_1 / ^\circ\text{C}$	$T_2 / ^\circ\text{C}$	t_1 / s	t_2 / s	$P / \%$
320	87	0.10	15	90

表 5 检验样本和神经网络模型预测结果

样本	因 子					实验 值/mm	预测 值/mm	误差/%
	$T_1 / ^\circ\text{C}$	$T_2 / ^\circ\text{C}$	t_1 / s	t_2 / s	$P / \%$			
1	280	48	0.2	5	70	0.8263	0.7583	8.23
2	320	61	0.2	15	75	0.6609	0.6863	3.84
3	310	74	0.2	25	80	0.6574	0.6795	3.36
4	300	87	0.2	10	85	0.6536	0.6659	1.88
5	290	100	0.2	20	90	0.6479	0.6641	2.50

由表 5 可见,神经网络模型对工艺参数的映射结果与数值模拟结果基本吻合。可以认为该神经网络模型的精度已经达到,对在工艺参数取值范围内的任何组合,神经网络模型可代替 CAE 模拟软件。

3.2 工艺参数优化

假设从工艺参数到注塑制品翘曲变形量的非线性

性映射关系为: $D = f(x_1, x_2, x_3, \dots)$, 那么基于正交实验技术所得到的最佳工艺参数组合是在 $D = f(x_1, x_2, x_3, \dots)$ 中取的离散点中的极佳, 在极佳附近也可能存在比上述所得参数组合更优的点(即工艺参数组合)。再利用已建好的神经网络模型结合正交实验作为进一步优化工艺参数的工具。

对于上述所得的最佳工艺参数组合, 在其邻域内微调各个工艺参数的值, 同样利用正交实验表安排实验, 如表 6 所示。由此得到一组新的、较为准确的训练样本数据。

表 6 正交实验因子与水平

水平	因 子				
	$T_1 / ^\circ\text{C}$	$T_2 / ^\circ\text{C}$	t_1 / s	t_2 / s	$P / \%$
1	300	81	0.08	13	88
2	305	84	0.09	14	89
3	320	87	0.10	15	90
4	315	90	0.11	16	91
5	310	93	0.12	17	92

同样选用 $L_{25}(5^6)$ 的 6 因素、5 水平正交表, 其中 6 个因素只使用 5 个, 只使用正交表的前五列, 第六列空出不用。只要用这些数据作为神经网络输入参数, 就可以由神经网络模型得出相应的注塑制品的翘曲变形量, 对其进行极差分析, 其结果如表 7 所示。

表 7 神经网络预测结果极差分析 mm

项 目	A	B	C	D	E
第一水平平均值	0.658	0.668	0.664	0.664	0.670
第二水平平均值	0.660	0.667	0.664	0.663	0.667
第三水平平均值	0.671	0.663	0.664	0.663	0.663
第四水平平均值	0.668	0.662	0.664	0.664	0.661
第五水平平均值	0.664	0.659	0.663	0.666	0.658
极 差	0.015	0.009	0.001	0.003	0.012

从表 7 可以看出, 经神经网络和正交实验联合优化, 可得出比上述得到的最佳工艺参数组合更合适的工艺参数组合 A4B1C1D5E1, 即熔体温度为

315 $^\circ\text{C}$, 模具温度为 81 $^\circ\text{C}$, 注射时间为 0.08 s, 保压时间为 13 s, 相对保压压力为 92%。

3.3 工艺参数优化神经网络的验证

为了验证所得工艺参数组合对制品翘曲变形量的影响是否优于用正交实验方法得出的结果, 把 A4B1C1D5E1 这一参数组合作为工艺条件, 经 Mold-flow 软件模拟分析, 得出总的翘曲变形量为 0.535 mm, 小于上述的优化结果(0.554 mm), 说明所建神经网络模型和优化方法是正确、有效的。

4 结论

将正交实验技术和人工智能方法有机地结合起来, 提出了基于 CAE 的神经网络注射成型工艺参数优化方法, 采用有限元数值模拟和实验验证相结合的方法进行注射成型工艺参数优化神经网络的训练和检验; 将通常复杂的神经网络输入参数综合为几个关键参数, 即熔体温度、模具温度、注射时间、保压时间和相对保压压力, 从而大大简化了神经网络模型。

参 考 文 献

[1] 王蓓, 王利霞, 李倩, 等. 基于神经网络的注塑成型工艺优化[J]. 塑料工业, 2003, 31(5): 31-34.

[2] 申长雨, 王利霞, 张勤星. 神经网络与混合遗传算法结合的注塑成型工艺优化[J]. 高分子材料科学与工程, 2005, 21(5): 23-27.

[3] 郭志英, 李德群. 注塑制品翘曲变形的研究[J]. 塑料科技, 2001(1): 22-24.

[4] 李海梅, 刘永志, 申长雨, 等. 注塑件翘曲变形的 CAE 研究[J]. 中国塑料, 2003, 17(3): 53-58.

[5] 郑生荣, 辛勇, 杨国泰, 等. 注塑参数优化研究方法[J]. 中国塑料, 2003, 17(4): 1-7.

[6] 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.

[7] 郑少华, 姜奉华. 试验设计与数据处理[M]. 北京: 中国建材工业出版社, 2004.

PARAMETRIC OPTIMIZATION OF INJECTION MOLDING PROCESSING
BASED ON CAE AND ARTIFICIAL NERVE NETWORK

Liu Bin, Xu Jianwen, Jiang Kaiyong

(Research Center of Mold and Die Technology, Huaqiao University, Quanzhou 362021, China)

ABSTRACT Through CAE numerical simulation, the effects of injection molding technical parameter on warpage were discussed, and the model of nerve network was established by technical parameter as import paeameter and the capacity of warpage as export parameter. Thus technical parameters were optimized by CAE analysis result as training sample and verified sample combined with Taguchi DOE. The method, which united CAE simulation technology, Taguchi DOE and nerve network technology organically, could shorten the time of optimizing technical parameters, improve efficiency of technics design and obtain better result compared with using Taguchi DOE and the finite element analysis simply.

KEYWORDS warpage, optimization, CAE, injection molding