

基于贝叶斯正则化神经网络的夹芯注层间界面控制

王涛 傅建 周盛

(西华大学材料科学与工程学院,成都 610039)

摘要 鉴于夹芯注射成型充模流动过程属多相分层流动,其影响因素错综复杂,很难用线性关系将工艺参数与层间界面形状关联起来;人工神经网络具有很强的信息综合能力,具有良好的非线性逼近功能两方面的情况。针对具体层间界面形状,基于贝叶斯正则化神经网络预测工艺参数,并借助 MPI 软件的 co-injection 模块检验。结果表明其误差完全达到了工程实用的精度,证明提出的贝叶斯正则化神经网络可应用于研究夹芯注塑中的非线性函数映射问题。

关键词 夹芯注射成型 层间界面 人工神经网络 贝叶斯正则化神经网络

芯层熔体穿透深度和穿透宽度为芯壳层间界面形状的重要表征,是衡量夹芯注塑制品质量的主要标准之一。夹芯注射成型充模流动过程属多相分层流动,其影响因素错综复杂,很难用线性关系将工艺参数与层间界面形状关联起来^[1-4]。因而若要得到某种层间界面形状,多是靠经验反复调试。

人工神经网络具有很强的信息综合能力,可以快速处理大量的信息,具有良好的非线性逼近功能。尝试将这一具有高度非线性函数映射的方法用于夹芯注塑的工艺参数设置。由于神经网络的初始权值、网络结构以及网络的学习参数难以确定,往往需要反复训练,这样会导致在应用中出现过拟合问题,降低泛化能力。提高神经网络泛化能力关键在于寻找合适的网络结构和网络连接权^[5-7]。贝叶斯正则化神经网络通过对网络权值的限制,可以有效地改善网络结构,从而限制过拟合,提高泛化能力。

1 贝叶斯正则化神经网络原理

贝叶斯正则化神经网络是指采用贝叶斯正则化方法训练的 BP 网络。所谓贝叶斯正则化是指通过修正神经网络的性能函数来提高其推广能力的过程。

一般 BP 算法,神经网络的训练性能函数采用均方误差函数 mse,即^[5-7]:

$$\text{mse} = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (1)$$

式中: e_i ——一个训练实例中的第 i 个训练时,目标值 t_i 与输出值 a_i 之差。

正则化方法中,网络的性能函数 (msereg) 经改进变为如下形式:

$$\text{Msereg} = \gamma \cdot \text{mse} + (1 - \gamma) \text{msw} \quad (2)$$

式中: γ ——比例系数;

msw——所有网络权值 (W) 平方和的平均值,

$$\text{即 } \text{msw} = \frac{1}{N_j} \sum_{j=1}^N (W_j)^2。$$

常规的正则化方法通常很难确定比例系数 γ 的大小,采用贝叶斯正则化方法则可以在网络的训练过程中自适应地调节比例系数 γ 的大小,并使其达到最优。可以在保证网络误差尽可能小的情况下,使得网络的有效权值尽可能小,这实际上相当于自动缩小了网络的规模。网络规模 (通常指隐层神经元的数目) 的缩小,在训练样本集大小一定的情况下,使得神经网络的规模远小于训练样本集的大小,则发生过拟合训练的机会就会很小,从而有利于提高网络的推广能力。

2 研究对象和材料的选取

研究对象为 100 mm × 100 mm × 5 mm 的矩形板,浇口位置取在 100 mm × 5 mm 面 (A 面) 的几何中心,如图 1 所示。




图1 研究对象

夹芯注塑的壳层材料选用 GE Plastic 公司的 (丙烯腈/丁二烯/苯乙烯) 共聚物 (ABS) (Cyclocac CTB 3530), 芯层材料选用 BP Chemicals 公司的聚丙烯 (PP) (BP Amoco 10-1046)。在熔体温度 220℃、剪切速率 10^3 s^{-1} 条件下,二者粘度分别为 194.7 Pa·s 和 101.0 Pa·s,芯、壳层粘度比为 0.519 1。

3 贝叶斯正则化神经网络的建立

3.1 网络训练样本特征参数的选取

人工神经网络实质上是一个由 m 维欧氏空间到 n 维空间的高维非线性映射。选择合适的样本特征参数作为神经网络的输入参数是预测成败的关键^[5-7]。

定义过浇口且垂直于 A 面和矩形板的平面为 B 面(见图 1)。最终产品芯、壳层间界面距离 A 面的最大距离为穿透深度 x , 距离 B 面的最大距离为穿透宽度 y 。选取 x 、 y 为网络输入参数, 以此表征最终芯、壳层熔体层间界面形状。影响界面形状的因素很多, 综合考虑企业生产实际和目前研究成果^[1-4], 选取壳、芯层熔体注射温度, 模具温度, 壳、芯层熔体注射速率 5 者为网络输出参数。

3.2 网络训练样本的获得

利用 MPI 软件的 co-injection 模块, 就表 1 选定的正交实验因子与水平进行数值模拟实验。 A 、 B 为壳、芯层熔体注射温度, C 为模具温度, D 、 E 为壳、芯层熔体注射速率。其中第一、二次物料切换点分别定为 60%、85%。物料切换是指当熔体充模总量(用体积百分数表示)达到标定值时, 开始注射另一种材料。

表 1 实验因子与水平

水平	因 子				
	$A/^{\circ}\text{C}$	$B/^{\circ}\text{C}$	$C/^{\circ}\text{C}$	$D/(\text{mm})^3 \cdot \text{s}^{-1}$	$E/(\text{mm})^3 \cdot \text{s}^{-1}$
1	210	200	45	50	50
2	220	210	50	100	100
3	230	220	55	150	150
4	240	230	60	200	200
5	250	240	65	250	250

根据实验因子个数和实验水平个数, 采用正交表 $L_{25}(6^5)$ 拟定正交实验方案。方案及数值模拟实验结果见表 2。将表 2 中数据作为网络训练样本。

3.3 数据归一化

对神经网络的输入和输出数据归一化, 可以加快网络的训练速度。归一化公式为^[5]:

$$P_n = 2 \times (P - \min p) / (\max p - \min p) - 1 \quad (3)$$
$$T_n = 2 \times (T - \min t) / (\max t - \min t) - 1 \quad (4)$$

式中: P 、 T ——原始输入数据;
 $\max p$ 、 $\max t$ 和 $\min p$ 、 $\min t$ ——分别是 P 、 T 中的最大值和最小值;
 P_n 、 T_n ——归一化后的输入数据。归一化后的数据将分布在 $[-1, 1]$ 。

表 2 正交实验方案和数值模拟结果

实验	影响因子					实验结果	
	$A/^{\circ}\text{C}$	$B/^{\circ}\text{C}$	$C/^{\circ}\text{C}$	$D/(\text{mm})^3 \cdot \text{s}^{-1}$	$E/(\text{mm})^3 \cdot \text{s}^{-1}$	x/mm	y/mm
1	210	200	45	50	50	89.45	43.25
2	210	210	50	100	100	86.39	41.25
3	210	220	55	150	150	86.51	40.71
4	210	230	60	200	200	87.47	40.72
5	210	240	65	250	250	86.39	40.70
6	220	200	50	150	200	83.01	41.24
7	220	210	55	200	250	83.16	40.75
8	220	220	60	250	50	86.49	43.02
9	220	230	65	50	100	88.24	43.42
10	220	240	45	100	150	87.44	41.23
11	230	200	55	250	100	82.32	43.01
12	230	210	60	50	150	86.45	43.91
13	230	220	65	100	200	85.55	43.01
14	230	230	45	150	250	84.52	42.39
15	230	240	50	200	50	85.29	42.91
16	240	200	60	100	250	83.14	44.01
17	240	210	65	150	50	82.34	45.60
18	240	220	45	200	100	82.33	44.06
19	240	230	50	250	150	83.06	43.04
20	240	240	55	50	200	86.47	43.95
21	250	200	65	200	150	79.29	44.06
22	250	210	45	250	200	80.25	43.08
23	250	220	50	50	250	84.54	45.51
24	250	230	55	100	50	82.33	46.24
25	250	240	60	150	100	82.34	45.51

训练结束后, 还需对网络的输出进行恢复。恢复被归一化数据的公式为:

$$T = 0.5 \times (T_n + 1) \times (\max t - \min t) + \min t \quad (5)$$

3.4 神经网络的训练

理论上已经证明, 具有一个对数 sigmoid 型隐含层和线性输出层的三层 BP 神经网络, 能够逼近任何有理函数^[5]。综合考虑网络模拟精度和训练时间, 笔者所用的神经网络选用三层网络结构: 一个输入层、一个隐含层、一个输出层; 输入层选取 2 节点(x 、 y)、隐含层选取 12 节点, 输出层选取 5 节点(表 2 所示 5 因子)。

通过 MATLAB 7.0 神经网络工具箱内置函数 trainbr 实现贝叶斯正则化训练 BP 网络。隐层传递函数采用正切 sigmoid 函数, 输出层函数采用线性函数 purelin。训练次数为 1 000 布, 网络性能指标 1×10^{-6} , A 精度 Marquardt 调整参数为 0.005, 训练参数中的动量因子 mu 的下降因子为 0.1, 上升因子为 10, 最大值 1×10^{-10} 。网络训练中, 网络误差性能降低到目标值或调整参数 mu 的最大值达到时, 网络训练停止。

当训练迭代至 431 步时,网络训练收敛,此时 SEE 和 SSW 均为恒值,有效网络参数(有效权值和阈值)个数为 13.6365。

3.5 神经网络的检验

输入表 3 中的检验样本进行网络仿真,得到表 4 所示输出值。将表 4 中数值输入 MPI 的 co-injection 模块进行有限元数值模拟,模拟结果及其相对检验样本的误差见表 5。

表 3 检验样本		
检验组	输入值	
	x/mm	y/mm
1	89.45	43.25
2	88.33	44.12
3	86.55	44.37
4	84.26	45.55
5	82.22	43.66

表 4 贝叶斯正则化神经网络的输出值					
	输出值				
	$A/^{\circ}C$	$B/^{\circ}C$	$C/^{\circ}C$	$D/(mm)^3 \cdot s^{-1}$	$E/(mm)^3 \cdot s^{-1}$
1	218.776	228.459	55.776	70.364	118.918
2	225.692	227.158	56.186	70.895	111.333
3	231.482	224.369	56.129	92.563	116.595
4	243.073	221.310	56.602	104.493	109.883
5	238.908	216.321	55.066	175.614	153.920

表 5 模拟结果及其相对检验样本的误差				
	数值模拟结果		误差	
	x/mm	y/mm	$x/\%$	$y/\%$
1	88.34	42.76	-1.24%	-1.13%
2	86.52	44.13	-2.05%	0.94%
3	85.71	43.58	-0.97%	-1.78%
4	83.15	45.57	-1.32%	0.04%
5	82.34	42.89	0.15%	-1.76%

从表 5 可以看出,最大相对误差值为 -2.05%,此误差完全达到了工程实用的精度。这说明基于贝叶斯正则化神经网络来控制夹芯注塑的层间界面形状是可行的。以此来调整工艺参数,可以避免盲目的反复调试,大大节省生产成本和时间。

4 结语

针对夹芯注塑中具体芯壳层间界面形状,利用贝叶斯正则化神经网络可以预测相应的工艺参数,且其误差完全达到了工程实用的精度,大大节省生产成本和时间。这表明提出的贝叶斯正则化神经网络可应用于研究夹芯注塑中的非线性函数映射问题。

参考文献

[1] 周国发,柳和生,何成宏,等. 共注成型芯壳层熔体粘度对芯壳层界面和移动前沿形貌的影响[J]. 复合材料学报,2004,21(4):24-28.

[2] 钟序光,孙懋,张效迅,等. 共注成型芯壳层熔体前沿突破研究[J]. 工程塑料应用,2003,31(12):21-26.

[3] Selden R. Co-injection molding: effect of processing on material distribution and mechanical properties of a sandwich molded plate[J]. Polymer Engineering and Science,2000,40(5):1165-1176.

[4] Mark P, Paul T. Co-injection molding of pvc with other thermoplastics: processing, properties and applications[J]. Journal of Vinyl & Additive Technology,2002,8(3):202-208.

[5] 周开利,康耀红. 神经网络模型及其 MATLAB 仿真程序设计[M]. 北京:清华大学出版社,2004.

[6] 武妍,张立明. 神经网络的泛化能力与结构优化算法研究[J]. 计算机应用研究,2002(6):22-24.

[7] 吴启勋,胡树青. 贝叶斯正则化神经网络预测金属晶体结合能的研究[J]. 计算机与应用化学,2004,21(4):604-608.

THE CONTROL OF LAYER INTERFACE OF SEQUENTIAL CO-INJECTION
BASED ON BAYESIAN-REGULARIZATION NEURAL NETWORKS

Wang Tao, Fu Jian, Zhou Sheng

(School of Materials Science and Engineering, Xihua University, Chengdu 610039, China)

ABSTRACT Melt flow of sequential co-injection molding belong to multifluid flow, whose influencing factors were so complex that it was difficult to linearly correlate processing parameter with layer interface of sequential co-injection. Artificial neural network (ANN) was capable of synthesizing the information and treating the nonlinear relation all right. For the specific layer interface, the processing parameter was forecasted based on bayesian-regularization neural networks(BRNN), which was certificated by means of the co-injection module in the software of Moldflow Plastics Insight. The error reached the precision of engineering practice, which indicated that BRNN established could be applied to the research on nonlinear problem of sequential co-injection molding.

KEYWORDS sandwich injection molding, layer interface, artificial neural network, bayesian-regularization neural networks