

[研究·设计]

DOI:10.3969/j.issn.1005-2895.2017.01.008

# 基于神经网络的阻力墙参数对转向节 锻件充填影响研究

霍文军, 刘淑梅, 何文涛, 赵毅

(上海工程技术大学材料工程学院, 上海 201620)

**摘要:**为研究阻力墙结构参数对转向节锻件长叉充填的定量影响,设计了广义回归(GR)人工神经网络模型。用“舍一法”训练了模型,并采用3个样本对模型进行预测检验,散点图表明预测值和实验值拟合较好。统计学指标为:均方误差  $M_1$  为 0.898 0, 相对均方误差  $M_2$  为 0.167 0%, 拟合分值  $V$  为 1.973 9, 说明人工神经网络具有较高的预测精度。最后用神经网络分析阻力墙关键参数对锻件长叉充填的定量影响,结果表明:长叉侧边桥部宽度和阻力墙斜度的增加对长叉充填作用不明显;阻力墙间隙的加大不利于长叉充填;阻力墙宽度对长叉充填的影响呈抛物线关系,先增大后减小,存在一个极大值。GR人工神经网络模型能够定量预测各阻力墙参数对长叉充填的影响。

**关键词:**转向节;锻件充填;阻力墙;定量影响;GR神经网络

中图分类号: TG156; TP183 文献标志码: A 文章编号: 1005-2895(2017)01-0036-05

## Influence of Resistance Wall Parameters on Filling of Steering Knuckle Based on GR Neural Network

HUO Wenjun, LIU Shumei, HE Wentao, ZHAO Yi

(School of Materials Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

**Abstract:** In order to study the influence of the structural parameters of the resistance wall on the long cross filling of the steering knuckle, a generalized regression (GR) artificial neural network model was designed. "Leave-one out" method was used to train the ANN model and 3 samples were used to test the model, and the scatter plots showed that the predicted values and the experimental values fitted well. Statistical indicators were  $M_1 = 0.898 0$ ,  $M_2 = 0.167 0\%$ ,  $V = 1.973 9$ , which showed that the prediction results of ANN model had high prediction accuracy. The quantitative effects of resistance wall key parameters on the long cross filling were analyzed by artificial neural network model. The results showed that increase of the bridge width and resistance wall slope had less influence on the long cross filling, and the increase of the resistance wall clearance was not conducive to long cross filling, the influence of resistance wall width to the long cross filling was parabola, first increased and then decreased, and there was a maximum value. GR artificial neural network model could be used to predict the impact of the parameters of the resistance wall quantitatively on the long cross filling.

**Keywords:** steering knuckle; forging filling; resistance wall; quantitative effects; GR neural network

金属塑形变形过程中材料的流动主要受模具形状的影响及控制,模具几何尺寸对锻件金属充填效果、变形均匀程度、成形载荷、锻造缺陷等有着直接关系。即

模具结构参数对锻件成形工艺有着重要影响,两者之间有着密切的联系。若能准确把握模具结构参数对锻件成形工艺的影响规律,建立模具结构参数与成形工

收稿日期:2016-06-28;修回日期:2016-09-30

基金项目:上海工程技术大学研究生科研创新项目(16KY0514);上海工程技术大学大学生创新训练项目(cs1605006)。

第一作者简介:霍文军(1992),女,河南周口人,硕士研究生,主要研究方向为模具 CAD/CAE/CAM。E-mail:hwj1974789683@163.com

艺之间的定量关系模型,便可以为合理选定模具结构尺寸、控制锻件质量提供科学依据和理论指导。

而转向节的热模锻成形是一个十分复杂的过程,虽主要受模具形状的影响,但模具形状尺寸因素众多(如阻力墙宽度、阻力墙斜度、阻力墙间隙等),各影响因素之间高度非线性且交互影响。采用回归分析等传统方法很难准确地反映模具形状尺寸与成形工艺间的关系。人工神经网络属于一种智能处理系统,适合处理多变量多响应间存在复杂的多元非线性问题,为解决复杂过程的建模问题带来了新的思路和途径<sup>[1-2]</sup>。

笔者采用广义回归神经网络(generalized regression neural network, GRNN),来研究转向节锻模阻力墙参数对其充填效果的定量影响,本研究有利于指导转向节锻造模具的设计,达到提高锻件质量、降低材耗、减少试验成本的目的,为锻造模具的优化设计提供参考。

## 1 锻模阻力墙结构

### 1.1 阻力墙结构及布局

IMV 转向节长叉距离模膛中心线较远,金属充填难度较大,利用阻力墙结构可阻止坯料金属流动速度过快而过早形成飞边,从而促使金属向未充满的方向流动,以达到合理分配坯料促进充填的目的,解决转向节长叉充不满的问题。图 1 为转向节锻模中阻力墙结构及布局。

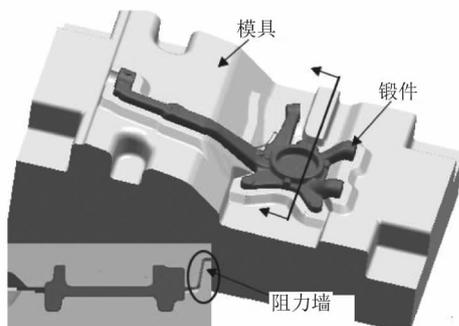


图 1 阻力墙结构及布局

Figure 1 Structure and layout of resistance wall

### 1.2 阻力墙设计变量

图 2 为阻力墙结构参数模型,图中  $R_1$  为桥部入口圆角,  $R_2$  为过渡圆角,  $R_3$  为根部圆角,  $B, b$  为桥部宽度,  $h$  为阻力墙高度,  $\beta, \alpha$  为阻力墙斜度,  $n$  为阻力墙间隙,  $r$  为两墙面拐角处圆角,  $L$  为阻力墙宽度。由图可知,影响转向节成形的阻力墙结构参数较多,通过手册查

询、前期研究<sup>[3]</sup>和部分试验分析,综合考虑筛选出对转向节成形工艺影响较显著的 4 个阻力墙关键参数:桥部宽度  $b$ 、阻力墙斜度  $\beta$ 、阻力墙间隙  $n$ 、阻力墙宽度  $L$ 。其它参数根据现有研究和工程实际进行确定<sup>[4]</sup>。

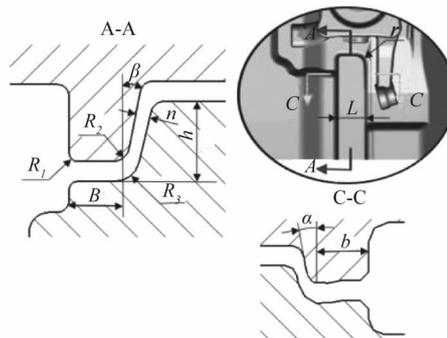


图 2 阻力墙结构参数模型

Figure 2 Model of structural parameters of resistance wall

## 2 网络模型的建立

由于转向节分叉较多,且长叉较长,在成形过程中充填困难,易产生塌角,如图 3 所示。为探究模具结构与转向节长叉充填的关系,本节建立神经网络模型分析阻力墙 4 个关键参数对转向节充填的影响规律。

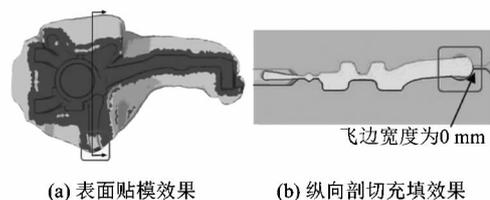


图 3 转向节成形情况

Figure 3 Forming condition of steering knuckle

### 2.1 试验数据采集

由上文可知,确定要研究的 4 个阻力墙结构关键参数为:桥部宽度  $b$ 、阻力墙斜度  $\beta$ 、阻力墙间隙  $n$ 、阻力墙宽度  $L$ 。对 4 个关键参数进行拉丁超立方抽样,根据下式确定最小样本容量<sup>[5]</sup>:

$$k = \frac{(m+1)(m+2)}{2}$$

式中  $m$  为变量个数。

对于本次抽样,取  $m = 4$ ,可知所需最小抽样容量是 15,综合考虑计算时间等因素确定本次抽取 16 个样本点,并对各试验方案进行数值模拟得到长叉末端飞边宽度,各样本点及其响应值如表 1 所示。

表1 阻力墙参数与飞边宽度数据  
Table 1 Data of parameters of resistance wall and flying edge width

序号	阻力墙参数				目标
	$b/mm$	$\beta/(\circ)$	$n/mm$	$L/mm$	飞边宽度/mm
1	24.27	6.67	3.47	41.67	14.00
2	19.87	14.67	3.07	35.00	8.37
3	20.60	18.67	3.73	48.33	5.33
4	22.07	17.33	2.67	58.33	7.93
5	17.67	1.33	3.33	36.67	8.74
6	14.00	13.33	3.60	45.00	5.83
7	25.00	10.67	3.87	56.67	10.60
8	22.80	2.67	2.80	55.00	12.70
9	23.53	16.00	2.13	43.33	21.60
10	16.20	12.00	3.20	60.00	6.16
11	21.33	4.00	2.27	38.33	5.47
12	14.73	8.00	2.40	40.00	6.11
13	19.13	5.33	4.00	50.00	8.35
14	18.40	9.33	2.00	53.33	7.17
15	15.47	0.00	2.93	51.67	10.10
16	16.93	20.00	2.53	46.67	21.30

### 2.2 人工神经网络结构设计

广义回归神经网络 (GRNN) 是在 1991 年提出的一种基于非线性回归理论的新型神经网络模型, 是 RBF 神经网络的一种变化形式<sup>[6]</sup>。有研究表明, 在中小规模网络中且训练样本数量相等的情况下, 相对于 BP 神经网络来说, GR 神经网络的逼近能力更强、精度更高、收敛速度更快, 且参数设置也要比 BP 神经网络简单的多, 减少了人为干扰, 这意味着它是 BP 神经网络的改进<sup>[7]</sup>。

笔者设计的 GR 神经网络结构示意图如图 4 所示, 由输入层、隐含层和输出层 3 层构成。输入层有 4 个神经元: 桥部宽度  $b$ 、阻力墙斜度  $\beta$ 、阻力墙间隙  $n$  和阻力墙宽度  $L$ ; 输出层有 1 个神经元, 为长叉末端飞边宽度; 隐含层的神经元数在训练过程中调整到最佳值。

### 2.3 人工神经网络模型训练

#### 2.3.1 数据处理

为了提高预测精度和改善训练效率, 在训练神经网络前一般需要对数据进行预处理, 即将所有的输入和输出变量归一化到同一区间内, 并在网络输出结果时进行反归一化。数据归一化的方法有多种, 本文采用剑桥大学 Bhadeshia 研究组的做法<sup>[8]</sup>。

#### 2.3.2 训练方式

通过对网络模型进行训练, 能够保证神经网络模型具有合理的输出, 得到准确可靠的预测性能。在众多训练方法中, 本文采用“舍一法”<sup>[9]</sup>来训练构建的神

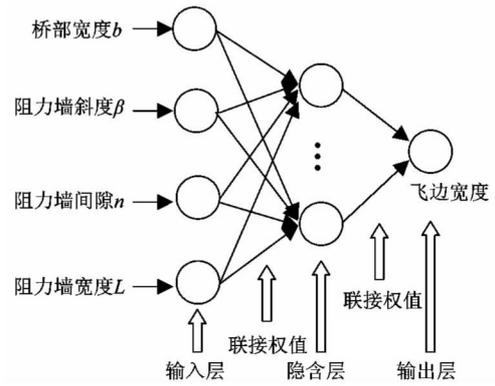


图4 GR神经网络结构示意图  
Figure 4 Structure of GRNN model

经网络模型, 使每个样本数据均进行一次网络的检验, 进而优化模型, 满足模型的预测精度要求。

### 3 网络训练及预测性能分析

#### 3.1 人工神经网络模型训练评价

对 GR 神经网络的训练来说, 其需要调整的参数相对于 BP 神经网络要少, 只有一个扩展系数 (spread) 参数。通过调整扩展系数进行多次训练, 得到较优的 spread 值为 0.15, 训练后的计算值与实测值构成的散点图如图 5 所示。其横坐标为飞边宽度实测值, 纵坐标为网络的计算值。从图中可以看出, 各点基本沿 45° 对角线分布, 训练结果与实际结果较接近。

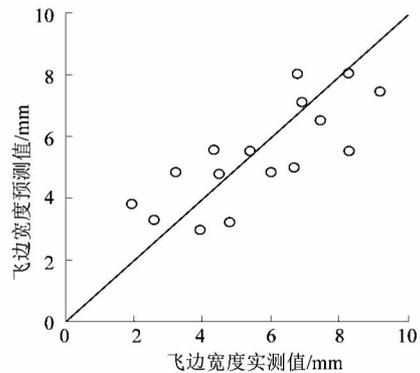


图5 训练样本散点图

Figure 5 Scatter plot of training sample

散点图虽可以直观反映预测性能, 但不能定量描述预测误差。为了定量地评价 GR 神经网络的预测性能, 笔者采用均方误差 ( $M_1$ )、相对均方误差 ( $M_2$ ) 和拟合分值 ( $V$ ) 3 个统计学指标来评价模型的预测性能<sup>[10]</sup>。

表 2 是样本经模型训练得到的 3 个评价指标, 从数据上看, 各项指标均较好, 计算值和实测值能够很好地拟合, 人工神经网络 (Artificial Neural Network, ANN) 模型得到较理想的训练。

表2 ANN模型对训练样本的计算误差

Table 2 Statistical errors of trained samples by ANN model

名称	$M_1$	$M_2/\%$	$V$
数值	1.229 0	0.625 0	1.589 8

### 3.2 人工神经网络模型预测性能检验

由上文可知,GR神经网络模型训练效果较好,可用来预测转向节长叉充填效果。从样本数据中随机抽取3个样本,输入到已训练好的网络模型中进行飞边宽度的预测,从而对模型的性能进行检验。得到的散点图和评价指标值,如图6和表3所示。

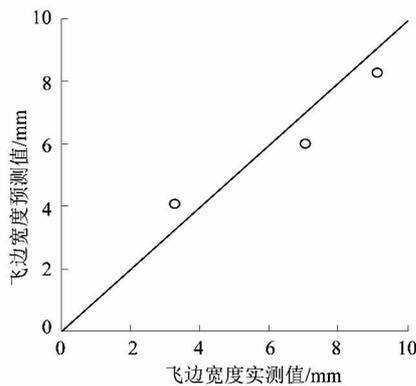


图6 预测样本散点图

Figure 6 Scatter plot of predicted sample

表3 ANN模型预测值的统计误差

Table 3 Statistical errors of predicted values by ANN model

误差	$M_1$	$M_2/\%$	$V$
数值	0.898 0	0.167 1	1.973 9

图6中预测样本各点沿45°线分布,且从表3可知,均方误差和相对均方误差均较小且接近于1,拟合分值也接近于2。该结果表明网络模型对样本的预测结果较好,预测性能令人满意,可应用于转向节锻模阻力墙参数对其充填效果定量影响的分析。

### 4 阻力墙参数对长叉充填的定量影响

研究各个阻力墙参数对转向节锻件长叉充填的影响,了解各工艺参数的作用,可以有针对性地采取措施来优化工艺,从而提高开发效率和产品性能。笔者用经过训练和检验的GR神经网络模型来分析各阻力墙参数对转向节锻件充填的定量影响。

通过分析表1中4种阻力墙参数的取值范围,确定了各阻力墙参数合适的基准值,如表4所示。分析某一参数的影响时,其它阻力墙参数不变,为基准值。

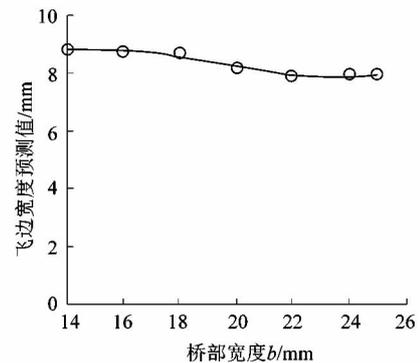
表4 阻力墙参数的基准值

Table 4 Basic values of resistance wall parameters

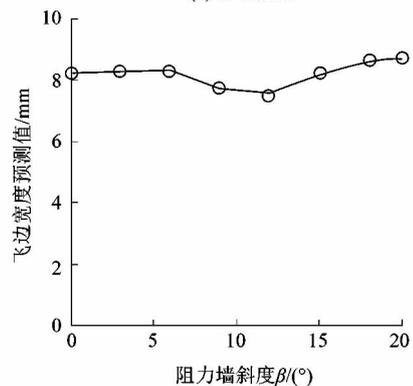
名称	$b/\text{mm}$	$\beta/(\text{°})$	$n/\text{mm}$	$L/\text{mm}$
基准值	20	15	2.5	45

图7是GR神经网络模型计算得到的4个阻力墙参数对转向节长叉处充填性的定量影响。

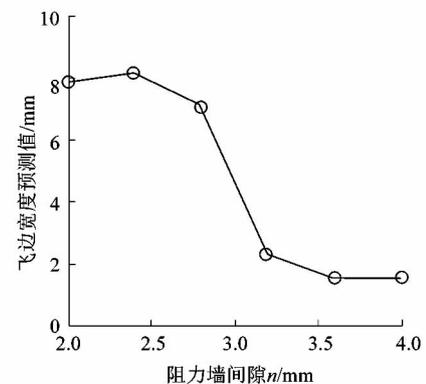
图7(a)为长叉侧边桥部宽度 $b$ 对长叉充填效果的影响,随着桥部宽度的增加,即阻力墙离长叉越远,长叉末端飞边宽度越小,充填效果越差,但飞边宽度减小幅度不大。这是因为当其他值固定时,阻力墙离长叉越远,阻力墙对长叉充填作用越弱,飞边依然过早的流向长叉外侧。



(a) 桥部宽度



(b) 阻力墙斜度



(c) 阻力墙间隙

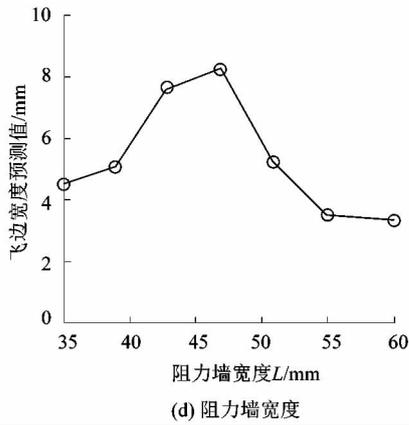


图7 阻力墙参数对锻件充填的影响  
Figure 7 Influence of resistance wall parameters on forging filling

图7(b)显示了阻力墙斜度 $\beta$ 对成形充填的影响。由图可知,阻力墙斜度的变化对长叉末端的充填影响不明显。随着阻力墙斜度的增加,长叉末端飞边宽度先有所降低,随后小幅增大。

图7(c)为阻力墙间隙 $n$ 与长叉充填的关系曲线,随着阻力墙间隙的增大,长叉末端飞边宽度减小,且幅度较大。当阻力墙间隙足够大时,阻力墙对充填的作用较弱。

由图7(d)可知,随着阻力墙宽度 $L$ 的增加,长叉末端飞边宽度先增大后减小。当阻力墙宽度较小时,其对外侧飞边阻碍作用较小,而阻力墙宽度过大时,整个外侧均为阻力墙,对长叉的充填效果不明显。

### 5 结语

1) 阻力墙各因素对转向节长叉充填具有交互性的影响,所以建立一种智能处理系统,处理该多元非线性问题。

2) 设计广义回归(GR)人工神经网络模型,并用“舍一法”训练神经网络模型,具有较高的预测精度。可较准确地反映各阻力墙参数对转向节锻件长叉充填

的定量影响。

3) 训练后的GR网络模型预测结果表明:长叉侧边桥部宽度和阻力墙斜度的增加对长叉充填作用不明显;阻力墙间隙的加大不利于长叉充填;阻力墙宽度对长叉充填的影响呈抛物线关系,先增大后减小,存在一个极大值。

4) 训练后的GR网络模型预测精度高,适合处理多变量多响应复杂的多元非线性问题,为解决复杂过程的建模问题提供新的思路和途径。

### 参考文献:

- [1] HECHT-NIELSEN R. Neurocomputing [M]. Massachussetes: Addison Wesley Publishing Company, 1991:59.
- [2] SCARSELLI F, TSOI A C. Universal approximation using feedforward neural networks; a survey of some existing methods, and some new results[J]. Neural networks, 1998, 11(1): 15-37.
- [3] 何文涛, 刘淑梅, 赵毅, 等. 基于正交试验的转向节锻模阻力墙结构参数优化[J]. 锻压技术, 2015, 40(12): 11-15.
- [4] 张渝, 安治国, 周杰. 曲轴锻模新型飞边结构的智能优化设计[J]. 重庆大学学报, 2010, 33(11): 70-76.
- [5] LIU Wei, YANG Yuying. Multi-objective optimization of sheet metal forming process using pareto based genetic algorithm [J]. Journal of materials processing technology, 2008, 208(1/2/3): 499-506.
- [6] 李朝将, 凡银生, 李强. 基于GRNN的电火花线切割加工工艺预测[J]. 华中科技大学学报(自然科学版), 2012, 40(增刊2): 1-4.
- [7] 丁硕, 常晓恒, 巫庆辉. GRNN与BPNN的函数逼近性能对比研究[J]. 现代电子技术, 2014, 37(7): 114-117.
- [8] 蒋鹏, 方刚, 曹世金, 等. 奔驰重卡转向节挤压锻造复合工艺的有限元分析[J]. 锻压技术, 2006, 31(1): 22-27.
- [9] ZHAO Deying, ZHANG Liandong, SUN Huixue. Research on closed die forging process of car steering knuckle[C]//中国机械工程学会, 郑州大学, 河南工业大学, 等. Proceedings of The Fifth International Conference on Physical and Numerical Simulation of Materials Processing. 郑州: 中国机械工程学会, 2007: 6.
- [10] SO Sung-Sau, KARPLUS M. Evolutionary optimization in quantitative structure-activity relationship; an application of genetic neural networks[J]. Journal of medicinal chemistry, 1996, 39(7): 1524-1530.