

基于BP神经网络的熔模铸件收缩率预测研究

田国良, 卜 昆, 邱 飞, 张现东, 张雅丽, 任帅军

(西北工业大学现代设计与集成制造技术教育部重点实验室, 西安 710072)

[摘要] 针对熔模铸件模具型腔设计中存在收缩率赋值不准确导致多次修模的问题, 作为初期研究, 提出一种典型结构在凝固过程中收缩率的预测方法, 为铸件收缩率预测提供一种思路。由于BP神经网络具有强大的容错性和鲁棒性, 故基于BP神经网络构建依附于铸件结构的几何参数和收缩率之间的映射模型。由于BP神经网络隐含层神经元尚无针对不同案例的设计准则, 因此, 在映射模型建立时研究隐含层神经元个数对建模准确度的影响。结果表明, 针对此典型结构铸件, 当隐含层神经元个数为3时, 映射模型的预测误差最小, 此时, 测试样本的预测和实测值收缩率平均偏差为0.09%, 可较好地实现凝固过程收缩率预测。

关键词: 收缩率; BP神经网络; 预测方法; 结构; 铸件

DOI: 10.16080/j.issn1671-833x.2018.09.047



田国良

博士研究生, 主要研究方向为熔模铸造过程的精确控形。

熔模铸造被广泛应用于航空、航天、水力发电、轨道交通等高端装备制造领域。在熔模铸造过程中,

普遍存在着铸造尺寸精度偏低的问题, 容易造成铸件报废。例如, 空心涡轮叶片作为航空发动机中重要的热端部件, 其恶劣的服役环境及高精度的装配需求对叶片本身尺寸精度有着严格的要求, 其批量生产通常采用精密熔模铸造方法。然而, 截止目前, 国内生产的空心涡轮叶片普遍存在着尺寸超差, 各批次之间稳定性差的问题。国外某发动机厂商生产的空心涡轮叶片合格率在70%左右。据国内某叶片生产单位统计分析, 国内采用国产模具陶芯进行生产时, 叶片的精铸成品率不超过40%^[1]。由尺寸超差所造成的单晶空心叶片失效约占一半左右^[2]。模具作为熔模铸件的重要工装, 合理的模具设计对铸件成型尺寸精度起着关键性作用。在模具设计过程中, 依据收缩率进行放形是模具型腔设计的重要环节。然而在工厂实际生产实践过程中, 由于无法对铸

件收缩率进行准确预测, 模具型腔设计仍然采用均匀线性的材料收缩率进行放形。由于依据材料收缩率的赋值并不足以完全补偿叶片的收缩变形, 为了成功制造出符合尺寸精度要求的空心涡轮叶片, 需要反复修模才能实现, 因此, 存在生产周期长, 花费成本高的问题。针对此问题, Ferreira等^[3]提出了在3个方向分别赋予不同的线性值进行放形, 这种做法在一定程度上减小了反复修模的次数, 由于和铸造凝固过程中收缩率分布并不一致, 因此, 未从根源完全解决此问题。郑岩^[4]研究了压铸工艺参数对铸件局部收缩的影响。Luca等^[5]研究了浇铸温度、模具预热温度对铸件收缩率的影响。Geiger^[6]发现浇铸系统的尺寸和位置对铸件尺寸有着较大的影响, 改变浇铸系统的充型位置对铸件收缩产生影响。Nawrocki^[7]等针对713C型镍基高温合金铸造工

艺参数对铸件尺寸影响,采用数值模拟方法进行仿真,并采用统计方法分析结果,其发现工艺参数中冷却速率对铸件尺寸有着显著影响。Rezavand 等^[8]以空心涡轮叶片为例,研究了浇铸液温度和模壳保温时间对其收缩的影响,发现模壳保温时间对收缩影响的作用大于浇铸液温度。然而,铸件在凝固过程中,随着温度的降低,会产生收缩现象,这种收缩不仅与工艺和浇铸系统布局有关,还与铸件本身的结构密切相关。由于铸件凝固过程的收缩和结构密切相关,在工艺参数和浇铸系统排布确定的情况下,如何根据依附于铸件结构的几何参数实现收缩率预测就十分重要,这可为模具型腔设计过程中的放形提供依据。作为初期研究,本文提取空心涡轮叶片叶身前缘处的典型结构,如图1所示,为类圆环形结构。针对此典型结构,建立几何参数和收缩率之间的映射模型,为后续研究基于铸件结构的几何参数和收缩率映射关系建模提供一种思想方法。




图1 叶身截面部分典型结构示意图
Fig.1 Typical structure of blade body section part




图2 类圆形结构铸件浇铸系统示意图
Fig.2 Casting system of the ring like structure casting

试验

由于典型结构为类圆环形结构,本文设计其浇铸系统如图2所示。类圆环形结构铸件及其连接浇道的几何参数示意图如图3所示。其中,编码为1~5号类圆环结构铸件为研究对象。1~5号类圆环结构铸件及其连接浇道的尺寸如表1所示。

本文重点关注于铸件内径 r 的收缩,如图3所示。采用试验方法获取研究对象的收缩分布。铸造工艺参数如表2所示。采用此工艺参数进行铸造,并冷却至室温,然后去除模壳,取出浇铸系统。

ZL101A 的材料成分如表3所示。对去除模壳后的浇铸系统进行切割,获取本次研究所需的1~5号类圆环结构铸件,如图4所示。

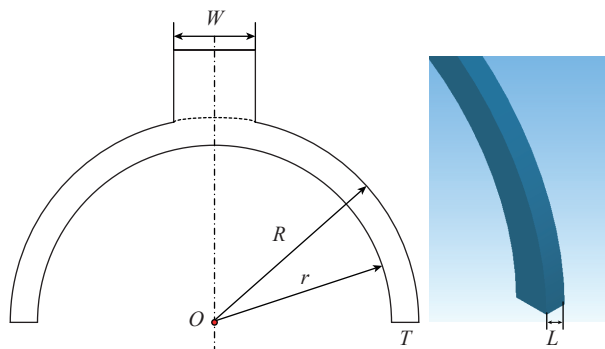


图3 类圆环结构铸件及其连接浇道的几何参数标识图
Fig.3 Geometric parameters of the ring like structure casting and its connecting sprue

表1 类圆环结构铸件及其连接浇道的几何参数表 mm

编号	外径 R	内径 r	壁厚 T	长度 L	宽度 W
1	75	72	3	8	30
2	75	70	5	8	30
3	75	68	7	8	30
4	75	66	9	8	30
5	75	64	11	8	30

表2 铸造工艺参数表

铸造材料	浇铸温度	模壳预热温度	铸造方式	冷却方式	模壳粘沙
ZL101A	740℃	260℃	熔模铸造	空冷	8层

图5为收缩率计算示意图。本文重点关注铸件自身的收缩,由于弧HC属于内浇道部分,因此对其不予研究。实线弧BC为铸件内径的CAD轮廓。虚线弧AD为铸造后铸件内径的轮廓。沿着弧BC的方向,设从B到C以等参数方式离散成n个点。同理,沿着弧AD的方向,设从A到D以等参数方式离散成n个点。设G点为弧BC的第i个离散点,E点为弧AD的第i个离散点。则线段EG的长度为内径BC上第i个点的收缩。

内径BC上第i个点的收缩率为:

$$k = \frac{l_{OG} - l_{OE}}{l_{OG}} \quad (1)$$

式中, l_{OG} 为线段OG的长度, l_{OE} 为线段OE的长度。

沿着弧BC的方向离散成20个点,根据研究点所处区域的收缩率计算公式,进行收缩率计算。

图6为类圆环结构铸件内径收缩率分布情况。由图6可知,随着内径的减小,总体来说,平均收缩率有先下降后上升的趋势,收缩率与内径之间并非简单的线性关系,在内径为66mm时,平均收缩率最小为0.88%。在内径为70mm和72mm时,收缩率分布非线性较为明显。由于浇道在凝固过程中,自身随着温度下降也有收缩趋势,浇道收缩趋势产生的牵拉作用使得铸件与浇道连接部位不能自由收缩,产生局部变形。这说明内径为70mm和72mm时,这种局部变形作用使得内径收缩率受到的影响较大。

数学建模

在收缩率与铸件结构相关的几何参数建模过程中,由于冒口、浇道、铸件之间在凝固过程中各自存在的收缩趋势使得其存在着互相约束作用,这相当于建模过程的“干扰项”。因此,寻找一种具有较好容错性的数学建模方法用于收缩率与几

何参数之间的建模就很有必要。而BP神经网络方法以其强大的非线性映射能力以及较好的容错性、鲁棒

性被广泛用于传统数学建模方法不易建模的多因素耦合及非线性关系建模中^[9-11]。因此,本文选取BP神

表3 ZL101A的材料成分表(质量分数) %

Si	Mg	Ti	Al	杂质不大于
6.5~7.5	0.25~0.45	0.08~0.2	余量	0.7




图4 类圆环结构铸件图

Fig.4 Ring like structure casting




图5 收缩率计算示意图

Fig.5 Sketch of shrinkage rate calculation




图6 类圆环结构铸件内圆弧收缩率分布

Fig.6 Shrinkage rate of inner radius of the ring like casting

神经网络进行数学建模。然而, BP神经网络在建模时仍然存在一些不足之处。这就是神经网络中隐含层神经元个数的确定仍未存在针对特定案例的设计规则, 多采用经验计算方法。因此, 在对收缩率和几何参数进行建模的过程中, 需同时研究神经网络隐含层神经元个数对建模精度的影响。

BP神经网络结构如图7所示, 包含输入层、隐含层和输出层。设第*i*个隐含层神经元的输出值为 y_i , 其对应的激活函数为 f , 则:

$$y_i = f\left(\sum_{j=1}^m v_{ji}x_j - \theta_i\right) \quad (2)$$

式中, v_{ji} 为输入层第*j*个神经元到隐含层第*i*个神经元的权值, x_j 为输入层第*j*个神经元的值, θ_i 为隐含层第*i*个神经元的阈值, m 为输入层神经元的个数。

设第*i*个输出层神经元的输出值为 z_i , 其对应的激活函数为 g , 则:

$$z_i = g\left(\sum_{j=1}^n w_{ji}y_j - q_i\right) \quad (3)$$

式中, w_{ji} 为隐含层第*j*个神经元到输出层第*i*个神经元的权值, y_j 为隐含层第*j*个神经元的值, q_i 为隐含层第*i*个神经元的阈值, n 为隐含层神经元的个数。

BP神经网络通过误差梯度下降法进行训练, 其输出误差为:

$$E = \frac{1}{2} \sum_{i=1}^p (d_i - z_i)^2 \quad (4)$$

式中, d_i 为第*i*个输出层神经元的期望值, z_i 为第*i*个输出层神经元的计算值, p 为输出层神经元个数。

隐含层与输出层神经元连接权值调整量为:

$$w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad (5)$$

式中, η 为学习率。

输入层和隐含层神经元连接权值调整量为:

$$v_{ji} = -\eta \frac{\partial E}{\partial v_{ji}} \quad (6)$$

由于采用BP神经网络方法构建收缩率与结构相关几何参数的映射模型, 在建模过程需要大部分数据作为学习样本, 其他数据需对此模型进行准确度验证。因此, 拟采用第1、2、4、5号铸件的 20×4 个研究点作为学习样本, 采用第3号铸件的20个研究点作为验证样本。图6表明, 收缩率不仅和几何参数相关, 也与研究点的位置相关。类圆环结构铸件和与其连接浇道的几何参数如表1所示。研究点的位置可用研究点和O点线段与X轴的夹角表示, 如图5所示。因此, 几何参数为外径 R , 内径 r , 壁厚 T , 长度 L , 宽度 W , 研究点和O点连线与X轴的夹角 θ 。因此, 神经网络输入层神经元个数为6。输出层神经元个数为1, 其表示研究点处的收缩率。由于隐含层神经元个数的确定未存在成熟的设计规则。因此, 先按照经验公式(7)计算出隐含层神经元的个数, 然后在计算数值左右寻找最佳隐含层神经元个数。

$$n_H = \sqrt{n_i \times n_o} + 1 \quad (7)$$

式中, n_H 表示隐含层神经元个数, 若为小数则进位取整, n_i 表示输入层神经元个数, n_o 表示输出层神经元个数。按式(7)得出神经网络隐含层神经元的经验设计个数为4, 在计算值附近找出最优BP神经网络隐含层神经元个数。

为了保证BP神经网络具有较好的映射精度, 对其建模过程中的学习参数进行设置, 参数的设置如表4所示。

由于式(8)可以表示神经网络在特定隐含层神经元个数时, 预测和实测值的偏差, 因此, 采用其评价不同个数隐含层神经元建模的准确度。

$$S = \sum_{i=1}^n \sqrt{(z_i - y_i)^2} \quad (8)$$

式中, S 表示测试样本的预测误差, n 表示测试样本的数量, z_i 表示第*i*个测试样本的预测值, y_i 表示第*i*个测试样本的实际值。S值与神经网络预测误差成正比, S值与神经网络预测准确度成反比。不同隐含层神经元个数的BP神经网络预测误差如表5所示。

从表5中可以看出, 在隐含层神




图7 BP神经网络结构图

Fig.7 Structure of BP neural network

表4 BP神经网络学习参数表

激活函数		神经元数量		学习算法	误差精度
隐含层	输出层	隐含层	输出层		
tan-sigmoid	tan-sigmoid	2~6个/1层	1	Levenberg-Marquardt	10^{-6}

表5 不同隐含层神经元个数的BP神经网络预测误差表

隐含层神经元数量	2	3	4	5	6
S值	0.0614	0.0171	0.0478	0.0352	0.0235

经元经验公式计算值附近,当隐含层神经元个数为2时,此时 S 值最大,构建的BP神经网络数学模型预测误差最大。当隐含层神经元个数为3时, S 值最小,构建的BP神经网络数学模型预测误差最小,预测准确度最高。由于隐含层神经元经验计算公式计算值为4,这说明隐含层神经元经验计算公式在本文案例中依然存在一定偏差。

图8为隐含层神经元个数为3时,测试样本收缩率预测和实测值的对比。从图8中可以看到,预测值和实测值分布趋势相同,预测值和实测值的平均偏差为0.09%,预测精度较高。这说明本文构建的BP神经网络预测模型可以根据几何参数较好地实现类圆环结构铸件收缩率预测。

结论

提取了空心涡轮叶片叶身截面的典型结构,以典型结构铸件内径在凝固过程中的收缩率为研究对象,发现随着内径的减小,其收缩率先下降后上升。在内径为66mm时,平均收缩率最小,内径为70mm和72mm时,收缩率非线性分布趋势明显。

采用BP神经网络方法,建立了几何参数和收缩率之间的映射模型,研究了隐含层神经元个数对BP神

经网络预测误差的影响。发现当隐含层神经元个数为3时,此映射模型的预测误差最小。

依据本文数学建模方法对典型结构铸件在凝固过程的收缩率进行预测。结果表明,对于测试样本,预测和实测值的平均偏差仅为0.09%,预测精度较高。

参考文献

- [1] 董一巍. 净成形空心涡轮叶片精铸模具型腔优化设计方法研究[D]. 西安: 西北工业大学, 2012.
- [2] DONG Yiwei. Optimization design method of investment casting die profile for net-shaped hollow turbine blade[D]. Xi'an: Northwestern Polytechnical University, 2012.
- [3] 蒋睿嵩, 汪文虎, 王增强, 等. 航空发动机涡轮叶片精密成形技术及其发展趋势[J]. 航空制造技术, 2016, 59(21): 57-62.
- [4] JIANG Ruisong, WANG Wenhui, WANG Zengqiang, et al. Precision forming technology and its development trend of aeroengine turbine blade[J]. Aeronautical Manufacturing Technology, 2016, 59(21): 57-62.
- [5] FERREIRA J C, MATEUS A. A numerical and experimental study of fracture in RP stereolithography patterns and ceramic shells for investment casting[J]. Journal of Materials Processing Technology, 2003, 134(1): 135-144.
- [6] 郑岩. 压铸工艺参数对铝合金压铸件局部收缩裂纹的影响及研究[C]// 2014中国铸造活动周论文集. 沈阳: 中国机械工程学会铸造分会, 2014: 1-4.

ZHENG Yan. Influence of die-casting parameters on local shrinkage crack of aluminum alloy castings[C]// 2014 Chinese foundry week literature collection. Shenyang: Foundry Institution of Chinese Mechanical Engineering Society, 2014: 1-4.

[5] LUCA A, BALC N, DRSTVENSEK I, et al. Analysis of aluminum parts for accuracy improvement in vacuum casting process[J]. Academic Journal of Manufacturing Engineering, 2011, 9(3): 74-79.

[6] GEIGER E J, MAIR D A, SVEC F, et al. Development of an injection molding tool for complex microfluidic geometries[J]. Microsystem Technologies, 2011, 17(9): 1537-1540.

[7] NAWROCKI J, SZELIGA D, KUBIAK K, et al. Influence of process parameters on cooling conditions in nickel base superalloy investment casting[J]. Key Engineering Materials, 2015, 641(13): 124-131.

[8] REZAVAND S A M, BEHRAVESH A H. An experimental investigation on dimensional stability of injected wax patterns of gas turbine blades[J]. Journal of Materials Processing Technology, 2007, 182(1-3): 580-587.

[9] CHENG G, LIU H, XIA W S. Application of BP neural network on the temperature prediction of injection mold cavity[J]. China Foundry Machinery & Technology, 2012, 31(9): 683-693.

[10] 李振, 陈香香, 杨文府. BP神经网络算法的探究及其应用[J]. 数字技术与应用, 2016(2): 132.

LI Zhen, CHEN Xiangxiang, YANG Wenfu. Research and application of BP artificial neural network algorithm[J]. Digital Technology and Application, 2016(2): 132.

[11] 崔晓斌, 黄放, 孟伟娜, 等. 基于人工神经网络的铸钢合金成分与流动性关系的研究[J]. 铸造技术, 2016(9): 1835-1837.

CUI Xiaobin, HUANG Fang, MENG Weina, et al. Study on relationship between composition and fluidity of steel castings based on artificial neural network[J]. Foundry Technology, 2016(9): 1835-1837.

通讯作者: 卜昆, 教授、博士生导师, 主要研究方向为熔模铸造过程的精确控形, E-mail: pukun89@nwpu.edu.cn.

(下转第70页)




图8 隐含层神经元个数为3时, 预测和实测收缩率对比图

Fig.8 Comparison between shrinkage rate prediction and measurement when the number of neurons in the hidden layer is three

[ABSTRACT] In this paper, the current manufacturing status of aero-engine blades is taken as the research object. We made a brief overview of ECM, CNC machining, precision forging, the key technologies and measurement methods used in manufacturing of aero-engine blades. The implementation of coordinate positioning, measurement trajectory planning and noise reduction of coordinate measurement is also considered. And then we analyze the influence of laser probe installation accuracy, laser projection angle, depth of field on laser scanning measurement, which has certain guiding significance to the development of precision manufacturing and efficient testing technology of aero-engine blades.

Keywords: Aero-engine blade; Manufacturing process; Coordinate measurement; Laser scanning; Data acquisition

(责编 大漠)

(上接第51页)

Research on Shrinkage Rate Prediction Method of Casting Based on BP Neural Network

TIAN Guoliang, BU Kun, QIU Fei, ZHANG Xiandong, ZHANG Yali, REN Shuaijun

(The Key Laboratory of Contemporary Design and Integrated Manufacturing Technology, Ministry of Education, Northwestern Polytechnical University, Xi'an 710072, China)

[ABSTRACT] In the design process of die cavity of investment casting, the inaccurate enlarged die cavity that based on shrinkage rate can lead the die need mold-repair for many times. As an initial study, a shrinkage rate prediction method of typical structure casting in the solidification process is proposed in this article. The method can provide a way of thinking for shrinkage rate prediction of casting. As BP neural network has strong fault tolerance and robustness function. Thus, the mapping model between geometric parameters that attach to the structure and shrinkage rate is built based on BP neural network. As there is no determination criterion for the number of the hidden layer neurons of the BP neural network in different cases, thus, the influence of the number of neurons in the hidden layer on the accuracy of modeling is researched. The result is that for the typical structure casting, when the number of neurons in the hidden layer is three, the mapping model has the least prediction error. In this case, the shrinkage rate average deviation of the predicted and measured values is 0.09%. The mapping model can better realize shrinkage rate prediction of the casting in solidification process.

Keywords: Shrinkage rate; BP neural network; Prediction method; Structure; Casting

(责编 大漠)

(上接第63页)

[ABSTRACT] Scanning electron microscopy was employed to investigate the aging precipitation behavior of beta process TC17 titanium alloy. Tensile properties and fracture toughness were used to characterize the effect of different aging treatment on mechanical property. The results show that the secondary α phase was nucleated, precipitated and grew on the β phase matrix. The fraction of secondary α phase and tensile strength decreased, secondary α phase did not diffuse and fracture toughness increased with the increase of aging temperature after solution in two phase region. The tensile strength linearly decreased, plasticity reduced and fracture toughness linearly increased. The secondary α phase was acicular after aging in a short time at 630°C. The thickness of secondary α phase (d) was coarsened from 42nm to 138nm and fraction (ω_a) decreased from 12.6% to 4.5% which can increase the tensile strength, reduce the plasticity and fracture toughness. The relationship between the tensile strength R_m and the thickness and fraction of secondary α phase was $R_m = 1.01\omega_a - 0.95d + 1274.1$.

Keywords: TC17 titanium alloy; Aging temperature; Aging time; Secondary α phase; Mechanical property

(责编 大漠)