

考虑晶粒不均匀度的神经网络晶粒长大模型构建及应用

王 赞¹ 周智敏¹ 童逸杰¹ 吕航鹰²

(1 杭州职业技术学院友嘉智能制造学院, 杭州 310018)

(2 浙江广厦建设职业技术大学智能制造学院, 东阳 322100)

文 摘 为了深入研究 Inconel X-750 高温合金的晶粒长大行为,使用人工神经网络对其进行了表征和预测。通过晶粒长大试验获得了 Inconel X-750 高温合金在不同保温时间和温度下的晶粒尺寸分布,研究了保温时间和温度对晶粒尺寸及其不均匀度的影响。通过将保温时间和温度作为输入,将平均晶粒尺寸和晶粒尺寸变异系数作为输出,构建了基于人工神经网络的包含晶粒不均匀度的晶粒长大模型。采用构建的晶粒长大模型对宽泛的工艺参数范围内的晶粒尺寸和晶粒不均匀度进行预测,建立了等温条件下晶粒尺寸、晶粒不均匀度、保温温度和保温时间之间的响应关系。结果表明,该晶粒长大神经网络模型具有较高的精度。

关键词 晶粒长大, Inconel X-750 高温合金, 晶粒尺寸, 不均匀度, 人工神经网络

中图分类号: TG146.1

DOI: 10.12044/j.issn.1007-2330.2025.02.006

Construction and Application of Artificial Neural Network Based Grain Growth Model Considering Non-uniformity of Grains

WANG Yun¹ ZHOU Zhimin¹ TONG Yijie¹ LV Hangying²

(1 Fair Friend Institute of Intelligent Manufacturing, Hangzhou Vocational & Technical College, Hangzhou, Zhejiang 310018)

(2 School of Intelligent Manufacturing, Zhejiang Guangsha Vocational and Technical University of Construction, Dongyang, Zhejiang 322100)

Abstract To further investigate the grain growth behavior of Inconel X-750 superalloy, artificial neural networks were employed in this work. The grain growth tests of Inconel X-750 superalloy were carried out to obtain the grain distributions under different holding temperatures and holding times, and the influences of the holding temperature and holding time on the size and non-uniformity of grains were investigated. The artificial neural network based grain growth model involving grain non-uniformity was constructed with the holding temperature and holding time as inputs, and average grain size and coefficient variation of grain size as outputs. The relationships between the grain size, grain non-uniformity, holding temperature and holding time under isothermal condition were established by predicting the grain sizes and grain non-uniformities in wide process parameter range using the constructed grain growth model. The results show that the neural network model for grain growth possesses high precision.

Key words Grain growth, Inconel X-750 superalloy, Grain size, Non-uniformity, Artificial neural network

0 引言

Inconel X-750 高温合金是一种常见的镍基高温合金,它不仅具有优异的加工性和焊接性,在 980℃ 以下还具有出色的抗氧化性和耐腐蚀性,在 800℃ 以下强度较高^[1];在常温条件下难加工^[2-3],通常进行热

加工成型^[4]。但在高温状态下,高温合金会发生晶粒长大,引起晶粒尺寸和晶粒均匀度的改变^[5],从而影响合金的微观组织和力学性能。因此,为了有效优化和控制其力学性能,对其高温晶粒长大行为的研究具有非常重要的意义^[6]。

收稿日期: 2023-11-14

基金项目: 杭州市农业与社会发展科研一般项目 (20201203B135); 浙江省教育厅一般科研项目 (Y202148060)

第一作者简介: 王赞, 1985 年出生, 高级技师, 研究方向为机械工程材料。E-mail: 2019010012@hzvtc.edu.cn

通信作者: 童逸杰, 1989 年出生, 副教授, 研究方向为航空航天先进材料。Email: tyj175194234@yeah.net

高温合金在高温条件下的晶粒长大是一种典型的微观组织演变方式。目前对于晶粒长大模型的研究主要集中于将晶粒尺寸作为研究目标的晶粒长大模型的研究。常见的晶粒长大模型主要有Sellar晶粒长大模型^[7]和Anelli晶粒长大模型^[8]。这些模型具有特定的物理意义和表达形式,通常通过试验数据和数学解析方法进行计算。但由于不同材料具有不同的晶粒长大特性,特定形式的晶粒长大模型往往精度较低,甚至不能客观表征材料的晶粒长大规律。目前,人工神经网络(简称“神经网络”)由于其对于非线性数据优秀的学习能力和泛化能力被广泛应用于材料表征^[9]。例如,马斌^[10]等基于BP神经网络构建了HNi55-7-4-2高温合金的本构模型并与JC模型进行了对比,司家勇^[11]使用BP神经网络预测了钛合金的动态再结晶体积分数和动态再结晶晶粒尺寸。通过这些研究结果可知,神经网络由于其杰出的学习和泛化能力,相对于常用的数学模型具有较为明显的精度优势。另一方面,微观组织方面影响材料最终性能的主要因素是晶粒尺寸大小和晶粒尺寸均匀性^[12]。细小的晶粒能够带来材料强度和韧性的同时提升,而晶粒尺寸越均匀则能降低材料的内部应力,减少晶间裂纹的产生和扩展^[13]。但目前对于晶粒均匀性的研究较少。而神经网络可进行多个变量的输出工作,因此可同时完成晶粒均匀性的研究。

本文通过建立以保温时间和保温温度为输入变量,以平均晶粒尺寸、晶粒尺寸不均匀度为输出变量,构建了Inconel X-750高温合金晶粒长大规律的人工神经网络模型。初始数据来源于在较宽的保温温度和保温时间范围内进行一系列晶粒长大试验获得的Inconel X-750合金的微观组织形貌和晶粒尺寸数据。应用构建的神经网络模型构建了考虑晶粒均匀度的Inconel X-750高温合金晶粒长大响应关系。该响应关系的构建能够进一步揭示Inconel X-750合金在各种条件下的晶粒长大规律,同时能够为Inconel X-750合金晶粒长大行为的其他研究提供丰富且有效的基础数据。本研究提供了一种构建晶粒长大模型的新方法,对容易被忽视但影响材料性能的重要因素晶粒均匀性进行了定量分析,为材料晶粒均匀性的研究和预测提供了一种新思路。

1 试验材料及方法

Inconel X-750高温合金的化学成分如表1所示。其原始微观组织见图1,初始组织为均匀的等轴晶和孪晶,平均晶粒尺寸31.5 μm。晶粒长大所用试样是从坯料上切割下的φ8 mm×12 mm的圆柱形试样若干组。试验时,将每组试样置于熔金炉中,按10 K/min的加热速度分别升温至1 123、1 223、1 273、1 323或

1 423 K,并保温0、100、200或300 min,保温至指定时间后立即对试样进行水冷。具体试验步骤如图2所示。

Tab. 1 Chemical compositions of the experimental material wt%

Cr	Fe	Ti	Co	Nb	Mn	Si	C	H	Ni
15.94	6.27	2.42	1.02	0.92	0.72	0.24	0.05	0.02	余量




图1 试验材料原始微观组织

Fig. 1 Original microstructure of the experimental material




图2 晶粒长大试验流程

Fig. 2 Procedures of the grain growth tests

2 晶粒长大规律

晶粒长大试验中不同保温温度和不同保温时间下的Inconel X-750合金微观组织及晶粒尺寸分布如图3~图7所示。可知,在1 123~1 273 K下,大部分晶粒长大试样晶界呈现为平直晶界,晶界夹角接近120°,晶粒尺寸较为均匀,微观形貌表现为与原始组织类似的孪晶和等轴晶。从晶界形貌及晶粒尺寸均匀性可以判断,在1 123~1 273 K下,晶粒未出现晶粒异常长大现象。在1 323~1 423 K下,部分晶界发生运动并与周边晶界融合,晶界融合后部分小尺寸晶粒消失融合成尺寸较大且多边的晶粒。这种尺寸不均匀形状不规则的微观组织表明试验材料在1 323~1 423 K下出现了晶粒异常长大。

晶粒长大试样在不同保温时间和保温温度下的平均晶粒尺寸统计结果如表2所示。由文献[14]可知,Inconel X-750合金的晶粒尺寸随保温温度的升




图3 保温温度1123 K及不同保温时间下的
微观组织及晶粒尺寸分布

Fig. 3 The microstructures and grain size distributions at the
holding temperature of 1123 K and holding times




图4 保温温度1223 K及不同保温时间下的
微观组织及晶粒尺寸分布

Fig. 4 Microstructures and grain size distributions at the
holding temperature of 1223 K and holding times

高和保温时间的延长而增大。晶粒长大速率随保温时间的迁移和温度的降低而降低。在1123~1273 K内,晶粒低幅长大,在1323~1423 K内,晶粒长大程度显著增加。

本文中,晶粒尺寸的不均匀度用如式(1)式(2)所示的标准差(σ)和变异系数(C_v)来表征^[15]。不同试验条件下的晶粒尺寸变异系数统计结果如表3所示。

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (d_i - d_A)^2} \quad (1)$$




图5 保温温度1273 K及不同保温时间下的
微观组织及晶粒尺寸分布

Fig. 5 Microstructures and grain size distributions at the
holding temperature of 1273 K and holding times




图6 保温温度1323 K及不同保温时间下的
微观组织及晶粒尺寸分布

Fig. 6 Microstructures and grain size distributions at the
holding temperature of 1323 K and holding times

$$C_v = \frac{\sigma}{d_A} \times 100\% \quad (2)$$

式中, N 为试样观察视野范围内的晶粒总数, d_i 和 d_A 分别代表每个晶粒的晶粒尺寸和在一定试验条件下的平均晶粒尺寸。

图8为晶粒尺寸的变异系数与保温时间的关系。可以看出,试样晶粒尺寸的变异系数随保温时间的增加而增大,说明随着保温的进行,试样晶粒尺寸在高温环境下增大的同时晶粒尺寸的不均匀度增加。但随着保温时间的延长,晶粒尺寸的不均匀度的增长速度逐渐减缓。由此说明,在高温环境下,晶粒会发生长大,但不同晶粒的长大驱动力(界面能)不同,




图7 保温温度1 423 K及不同保温时间条件下的微观组织及晶粒尺寸分布

Fig. 7 Microstructures and grain size distributions at the holding temperature of 1 423 K and holding times

表2 试验条件下的平均晶粒尺寸

Tab. 2 Average grain sizes at the experimental conditions

保温时间 /min	平均晶粒尺寸/ μm				
	1 123 K	1 223 K	1 273 K	1 323 K	1 423 K
0	31.7	34.6	38.9	48.2	65.3
100	33.5	38.7	48.8	62.6	90.7
200	33.6	40.5	55.7	73.8	110.6
300	35.3	42.1	57.5	80.3	116.2

表3 不同温度和保温时间下的晶粒尺寸变异系数

Tab. 3 Variability coefficients of average grain sizes at different temperatures and holding times

保温时间 /min	变异系数/%				
	1 123 K	1 223 K	1 273 K	1 323 K	1 423 K
0	2.52	2.72	3.05	3.27	3.84
100	2.53	3.04	3.29	3.91	5.89
200	2.59	3.09	3.49	4.84	7.24
300	2.76	3.13	3.55	5.30	7.46

会导致晶粒长大速度不一样,最终导致晶粒尺寸大小不一,从而晶粒尺寸的不均匀度增加。但在某一特定温度下,环境能够提供的能量是有限的,晶粒不可能无限长大,因此,晶粒尺寸的不均匀度增长的速度逐渐降低。

晶粒尺寸的变异系数与保温温度的关系如图9所示。可以看出,保温温度提高可导致试样晶粒尺寸的变异系数增大。且晶粒尺寸变异系数以1 273 K为分界点,低于1 273 K时缓慢增长,而在高于1 273 K时快速增长,表明 Inconel X-750 合金的晶粒尺寸不均匀度随温度升高而急速增加。从图6、图7的晶

粒尺寸分布可以看出,在1 323和1 423 K条件下, Inconel X-750 合金由于晶粒异常长大导致大尺寸晶粒增多,在分布图上形成了局部的小高峰。




图8 晶粒尺寸变异系数与保温时间的关系

Fig. 8 Relationships between the variation coefficient of grain sizes and holding time




图9 晶粒尺寸变异系数与保温温度的关系

Fig. 9 Relationships between the variation coefficient of grain sizes and holding temperature

3 神经网络模型构建与评价

3.1 神经网络构建

本次研究采用基于误差反向传播算法的BP神经网络来构建 Inconel X-750 合金的晶粒长大模型,描述和预测 Inconel X-750 合金工艺参数及晶粒尺寸、晶粒不均匀度的映射关系。

BP神经网络将保温温度(T)和保温时间(t)作为输入,将平均晶粒尺寸(d_A)和变异系数(C_V)作为输出。两种输入变量和两种输出变量间具有不同的单位且数值差距较大,为了提升网络学习性能,实现网络的快速收敛,采用式(3)所示的归一化公式^[16]对数据进行归一化处理以缩小数据间数值梯度。通过式(3),能够将输入及输出数据转化至(0.2,0.7)区间,并在神经网络中传递和反馈。神经网络训练结果证实,使用该区间的归一化数据能够使神经网络发挥较强的性能并获得较高的精度。输出数据时,通过式(4)所示的反归一化公式将数据还原至原单位数

量级。神经网络将 `learnbd` 函数和 `trainbr` 函数分别作为学习函数和训练函数,将 `purelin` 函数和 `tansig` 函数分别作为输出层和隐含层的传递函数。神经网络通过将数据进行正向传播和逆向反馈,对权值进行不断修正以降低训练误差。为提高网络稳定性,防止其获得局部最优解,将网络学习速率定义为 0.01^[17]。

$$A' = 0.2 + 0.5 \cdot \frac{A - 0.95A_{\min}}{1.05A_{\max} - 0.95A_{\min}} \quad (3)$$

$$A = 2.1A_{\max}A' - 1.9A_{\min}A' - 0.42A_{\max} + 1.71A_{\min} \quad (4)$$

式中, A 表示数据的输入值, A' 表示归一化后的值, $A_{\max}$ 和 $A_{\min}$ 为输入值中的最大和最小值。

相比于单隐含层的人工神经网络,双隐含层的人工神经网络具有更高的精度,且能够极大程度地避免获得局部最优解,因此本研究采用双隐含层的人工神经网络。以设置的神经网络基本参数为基础,将式(5)所示的平均相对误差(MRE)作为目标,

进行第一、第二隐含层神经元数量 3~12 的神经网络结构寻优,寻优结果如图 10 所示。经寻优,第一隐含层数量为 6,第二隐含层数量为 9 时,平均晶粒尺寸平均相对误差最低,为 1.50%,此时晶粒尺寸变异系数平均相对误差为 8.45%;第一隐含层数量为 7,第二隐含层数量为 8 时,晶粒尺寸变异系数平均相对误差最低,为 2.16%,此时晶粒尺寸平均相对误差为 2.14%。综合来看,第一隐含层神经元数量为 7,第二隐含层神经元数量为 8 时,平均晶粒尺寸平均相对误差和晶粒尺寸变异系数平均相对误差均较小,神经网络性能更优,因此确定神经网络第一隐含层数量为 7,第二隐含层数量为 8。

$$MRE = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{Y_i - S_i}{S_i} \right| \times 100\% \quad (5)$$

式中, S 和 Y 分别表示试验值和预测值, N 表示试验值和预测值对象的总数。




图 10 隐含层神经元数量与平均晶粒尺寸及晶粒尺寸变异系数的平均相对误差的关系

Fig. 10 Relationships between the neuron numbers of the hidden layers and the mean relative errors of average grain size and variation coefficients of grain size

3.2 神经网络评价

本次研究采用构建的神经网络晶粒长大模型对不同条件下的晶粒尺寸及其不均匀度进行了预测,并使用平均相对误差(MRE)和相关系数(R)^[18]作为神经网络精度的考核指标。

图 11 为预测的原试验保温温度、保温时间下的平均晶粒尺寸和晶粒尺寸变异系数与试验数据的对比。可知,试验实测的和神经网络模型预测的平均晶粒尺寸和晶粒尺寸变异系数数据吻合度较高,说明神经网络能够较好地学习和再现 Inconel X-750 合金的晶粒长大规律。经计算,平均晶粒尺寸和晶粒尺寸变异系数的 MRE 值分别为 2.14% 和 2.16%。式(6)中的相关系数(R)表示数据的相关性,其值越接近 1 表明数据具有越高的相关性。神经网络预测的

平均晶粒尺寸和晶粒尺寸变异系数数据与试验数据的线性相关性如图 12 所示。可以看出,以实测值为横轴,以预测值为纵轴的数据点距离理想结果非常接近。平均晶粒尺寸数据相关系数为 0.998,晶粒尺寸变异系数的相关系数为 0.997 1,表现出非常高的数据相关性。根据数据可知,通过神经网络对训练数据的学习,平均晶粒尺寸和晶粒尺寸变异系数数据的预测精度都较高,进一步说明该神经网络晶粒长大模型具有较强的学习能力。

$$R = \frac{\sum_{i=1}^N (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (S_i - \bar{S})^2 \cdot \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (6)$$

式中, $\bar{S}$ 和 $\bar{Y}$ 分别为试验值和预测值的平均值。




图 11 神经网络预测的 Inconel X-750 合金平均晶粒尺寸及晶粒尺寸变异系数与试验值的比较
Fig. 11 Comparisons between the predicted average grain sizes and variation coefficients of grain size by the neural network and the experimental values of Inconel X-750 alloy




图 12 预测的 Inconel X-750 合金平均晶粒尺寸及晶粒尺寸变异系数结果与试验结果的相关性
Fig. 12 Correlation relationships between the predicted and experimental average grain size and variation coefficient of grain size of Inconel X-750 alloy

为了验证神经网络的泛化能力,在 1 250 K 下进行验证试验,保温时间分别为 0、133.3、266.7 min。获得试验条件下金相组织如图 13 所示,对试样的晶粒尺寸进行统计,将获得的平均晶粒尺寸和晶粒尺寸变异系数与神经网络预测数据进行对比,结果如

表 4 所示,平均晶粒尺寸相对误差最大为-4.51%,晶粒尺寸变异系数相对误差最大为-5.45%。较低的相对误差水平说明神经网络预测的平均晶粒尺寸和晶粒尺寸变异系数具有较高的精度,通过训练数据以外的测试数据验证了神经网络优秀的泛化能力。




图 13 保温温度 1 250 K 及不同保温时间下的微观组织及晶粒尺寸分布
Fig. 13 Microstructures and grain size distributions at the holding temperature of 1 250 K and different holding times

表4 验证试验数据对比
Tab. 4 Comparison of validation test data

保温温度/K	保温时间/min	平均晶粒尺寸			尺寸变异系数		
		神经网络预测/ μm	实测/ μm	相对误差/%	神经网络预测/%	实测/%	相对误差/%
1 250	0	36.2	37.91	-4.51	1.04	1.10	-5.45
	133.3	45.08	46.23	-2.49	1.46	1.42	2.82
	266.7	48.59	50.41	-3.61	1.64	1.58	3.79

4 晶粒长大响应关系构建

神经网络的优势在于具有非常强的泛化能力。本次研究采用构建的神经网络晶粒长大模型对 Inconel X-750 合金在 1 123~1 423 K 保温温度和 0~300 min 保温时间内的晶粒尺寸进行预测,建立了等温条件下平均晶粒尺寸、晶粒不均匀度、保温温度和保温时间之间的响应关系,如图 14 所示。图中将晶粒尺寸的标准差(σ)作为晶粒不均匀度的表征量,用于表征在某一保温温度和保温时间下晶粒尺寸的绝对离散程度。该响应关系的构建能够进一步揭示 Inconel X-750 合金在各种条件下的晶粒长大规律,同时能够为 Inconel X-750 合金晶粒长大行为的其他研究提供丰富且有效的基础数据。




图 14 神经网络模型预测的晶粒尺寸及晶粒不均匀度对保温温度和保温时间的响应关系
Fig. 14 Response relationships of grain size, non-uniformity of grains to holding temperature and holding time predicted by the neural network model

5 结论

- (1) Inconel X-750 合金晶粒在 1 323~1 423 K 温度范围内发生了异常生长,引起了晶粒尺寸不均匀度的显著增加。
 - (2) 在保温温度一定时,保温时间的增加会导致晶粒尺寸的不均匀度增加,但晶粒尺寸的不均匀度增加速度逐渐降低;保温时间一定时,保温温度的升高也会引起晶粒尺寸的不均匀度增加,且晶粒的异常长大会导致晶粒尺寸的不均匀度激增。
 - (3) 通过将保温温度和保温时间作为输入,将平
- 宇航材料工艺 <http://www.yhclgy.com> 2025 年 第2期

均晶粒尺寸和晶粒尺寸变异系数作为输出,构建了第一隐含层神经元数量为 7,第二隐含层神经元数量为 8 的神经网络晶粒长大模型。构建的神经网络模型能够精确地表征和预测 Inconel X-750 合金的晶粒长大规律。

(4) 通过神经网络晶粒长大模型构建了 Inconel X-750 合金等温条件下晶粒尺寸、晶粒尺寸不均匀度与保温温度和保温时间之间的响应关系。

参考文献

[1] HUA Peitao, ZHANG WeiHong, HUANG Linjie, et al. Investigation of work hardening behavior of inconel X-750 alloy [J]. Acta Metallurgica Sinica (English Letters), 2017, 30(09): 869-877.

[2] MILLS W J, MASTEL. Room temperature and elevated temperature deformation characteristics of inconel X-750 (room temperature to 816℃)[J]. Society & Natural Resources, 1979, 20(20):177-185.

[3] PU E, ZHENG W, SONG Z, et al. Hot deformation characterization of nickel-based superalloy uns10276 through processing map and microstructural studies[J]. Journal of Alloys and Compounds, 2017, 694: 617-631.

[4] YU Q Y, YAO Z H, DONG J X. Deformation and recrystallization behavior of a coarse-grain, nickel-base superalloy udimet720li ingot material [J]. Materials Characterization, 2015:398-410.

[5] TIAN G, JIA C, LIU J, et al. Experimental and simulation on the grain growth of p/m nickel-base superalloy during the heat treatment process[J]. Materials & Design, 2009, 30(3):433-439.

[6] COLLINS D M, CONDUIT B D, STONE H J, et al. Grain growth behaviour during near- γ' solvus thermal exposures in a polycrystalline nickel-base superalloy [J]. Acta Materialia, 2013, 61(9): 3378-3391

[7] SELLARS C M, WHITEMAN J A. Recrystallization and grain growth in hot rolling[J]. Metal Science Journal, 1978, 13(3-4):187-194.

[8] LAN Y J, LI D Z, LI Y Y. A mesoscale cellular automaton model for curvature-driven grain growth [J]. Metallurgical & Materials Transactions B, 2006, 37 (1) : 119-129.

[9] LIN Y C, LIANG Y J, CHEN M S, et al. A comparative study on phenomenon and deep belief network models for hot

deformation behavior of an Al-Zn-Mg-Cu alloy [J]. Applied Physics A, 2017, 123(1): 68.

[10] 马斌,李平,梁强. 基于修正JC模型和BP-ANN算法预测 HNi55-7-4-2 合金高温流变行为的对比[J]. 机械工程材料,2021,45(01):92-99.

MA B, LI P, LIANG Q. Comparison on high-temperature flow behavior of HNi55-7-4-2 alloy predicted by modified jc model and BP-ANN algorithm [J]. Materials for Mechanical Engineering, 2021,45(01):92-99.

[11] 司家勇,韩鹏彪,付明杰,等. 用BP人工神经网络模型预测 Ti-46. 5Al-2. 5V-1. 0Cr-0. 3Ni 合金的高温变形组织[J]. 机械工程材料,2010,34(06):92-96.

SI J Y, HAN P B, FU M J, et al. Microstructure of Ti-46. 5Al-2. 5V-1. 0Cr-0. 3Ni alloy at elevated temperatures predicted by BP artificial neural network model[J]. Materials for Mechanical Engineering, 2010,34(06):92-96.

[12] 向小琴. 大型齿圈锻件晶粒和组织均匀性的改善[J]. 金属热处理,2019,44(10):122-124.

XIANG X Q. Improvement in grain size and microstructure uniformity of heavy ring gear forgings [J]. Heat Treatment of Metals, 2019,44(10):122-124.

[13] 张劲,蒋震,虞大联,等. 6082 铝合金锻造组织不均匀性及其对锻件性能的影响[J]. 锻压技术,2020,45(09):8-15.

ZHANG Jin, JIANG Zhen, YU Dalian, et al. Forging microstructure inhomogeneity of 6082 aluminum alloy and its effect on properties of forgings [J]. Forging & Stamping Technology, 2020,45(09):8-15.

[14] 吕航鹰,潘巧玉,黄庆华,等. Inconel X-750 高温合

金晶粒粗化行为研究[J]. 特种铸造及有色合金,2023,43(03):363-369.

LV Hangying, PAN Qiaoyu, HUANG Qinghua, et al. Grain coarsening behavior study of inconel X-750 superalloy [J]. Special-cast and Non-ferrous Alloys, 2023, 43 (03) : 363-369.

[15] 胡晓航,徐建新,杨凯,等. 基于变异系数的顶吹搅拌槽温度场均匀性分析[J]. 昆明理工大学学报(自然科学版),2022,47(01):54-61.

HU Xiaohang, XU Jianxin, YANG Kai, et al. Analysis of temperature field uniformity of top-blown agitator based on variation coefficient [J]. Journal of Kunming University of Science and Technology (Natural Science Edition), 2022, 47 (01):54-61.

[16] ZHU Y C, ZENG W D, SUN Y, et al. Artificial neural network approach to predict the flow stress in the isothermal compression of as-cast TC21 titanium alloy [J]. Computational Materials Science, 2011, 50 (5): 1785-1790.

[17] LIN Y C, CHEN X M, WEN D X, et al. A physically-based constitutive model for a typical nickel-based superalloy [J]. Computational Materials Science, 2014, 83: 282-289.

[18] 叶青,陈博,倪恒,等. 基于神经网络的 Haynes282 合金高温流动行为表征及其有限元应用[J]. 宇航材料工艺, 2022,52(2):052.

YE Qing, CHEN Bo, NI Heng, et al. Hot flow behavior characterization of Haynes 282 alloy based on artificial neural network and its finite element application [J]. Aerospace Materials and Technology, 2022,52(2):052.