

基于 KNN 和 GRNN 的挤压铸造温度参数设计方法

邓建新^{1, 2}, 谢彬^{1, 2}, 曾向明^{1, 2}

(1. 广西大学 广西制造系统与先进制造技术重点实验室, 广西南宁 530003; 2. 广西大学 机械工程学院, 广西南宁 530003)

摘要: 针对现有的挤压铸造工艺参数研究方法效率低下、局限性较大的现状, 利用已有挤压铸造工艺数据采用机器学习方法实现了对挤压铸造温度工艺参数的快速设计。首先基于 K 最近邻 (K Nearest Neighbors, KNN) 算法参考相近材料铸件的温度工艺参数, 从材料成分层面对浇注温度和模具预热温度进行初始设计, 然后结合铸型参数和广义回归神经网络 (Generalized Regression Neural Network, GRNN) 对设计误差较大的模具预热温度进行修正, 建立了误差修正模型; 基于数据和实例铸件进行应用, 并结合 Procast 进行实例铸件仿真试验, 验证了提出的温度工艺参数设计方法的有效性。

关键词: 挤压铸造; 工艺参数设计; 数据驱动; KNN; GRNN

作者简介:

邓建新 (1979-), 男, 博士, 副教授, 研究方向为制造系统与信息学、挤压铸造技术、产品公理化设计、制造服务技术。电话: 13707889023, E-mail: dengjxin@163.com

中图分类号: TG248

文献标识码: A

文章编号: 1001-4977(2022)07-0898-08

基金项目:

国家自然科学基金 (51965006); 广西自然科学基金 (2018GXNSFAA050111); 国家金属材料近净成形工程技术研究中心、金属材料高效近净成形技术与装备教育部重点实验室 (B类) 开放基金 (2019001); 中国—东盟信息港鲲鹏生态创新中心 2021 年第一批补贴项目 (38)。

收稿日期:

2022-01-01。

挤压铸造结合了铸造和锻造的工艺特点, 是对浇入型腔内的定量液态金属施加较高机械压力, 使其凝固成形的近净成形制造工艺, 已广泛应用于高性能材料制备和汽车、家电、航空领域的高质量零件生产^[1]。

合理的工艺参数是挤压铸造生产高质量铸件的前提。挤压铸造的工艺参数主要包括浇注温度、模具预热温度、挤压压力、保压时间、浇注速度等。其中温度参数 (浇注温度和模具预热温度) 是最重要的参数之一, 合理温度下铸件才能顺利凝固^[2], 产出成形完整的高质量铸件。不合适的温度会造成金属液流动性不足, 导致浇不足或过早凝固, 凝固区域分布不均匀, 产生缩孔、缩松等缺陷, 影响挤压铸件的力学性能^[3]。为此, 不少研究者研究了温度参数对挤压铸造的影响, 并获得最佳的温度参数, 其中对浇注温度的研究更多。ZHAO 等^[4]通过单因素试验, 研究了浇注温度对挤压铸造 AZ91D 合金铸件的晶粒大小、抗拉强度和伸长率的影响规律, 以此确定该铸件的最佳浇注温度; 文献[5]和[6]通过正交试验分别研究了浇注温度和模具预热温度对挤压铸件性能的影响, 从而确定了最佳的浇注温度和模具预热温度; YANG 等^[7]通过控制变量法研究了浇注温度、挤压压力对挤压铸造 AZ91-Ca 铸件力学性能的影响规律, 通过分析铸件性能确定了铸件的最优浇注温度和挤压压力。文献[8]基于试验所得数据, 利用遗传算法建立了工艺参数对挤压铸件力学性能的预测模型, 进一步优化了铸件浇注温度和模具预热温度等工艺参数; 文献[9]基于正交试验所得数据, 通过灰色关联分析法建立数学模型进一步优化了铸件浇注温度、模具预热温度和挤压压力。但目前研究和获取挤压铸造温度工艺参数的方法主要以试验为主, 效率低下, 且大多研究并非为了直接设计或获得挤压铸造的温度参数, 更多是从材料制备角度分析温度参数对其铸造质量和铸件性能的影响, 最终通过试验结果或对试验数据的分析可间接地获取较优工艺参数。这制约了挤压铸造在生产中的应用。因此急需研究温度参数等的高效设计方法。

当前, 随着大数据技术的成熟, 基于数据来构建工艺参数的设计方法逐渐成为趋势和手段, 如文献[10]以现有数据样本为基础, 建立随机森林预测模型, 通过材料成分预测材料的屈服强度和伸长率, 得到了对应材料的热处理工艺条件; 文献[11]基

于100组热固性推进剂数据样本,采用极限学习机和支持向量机建立了固体火箭热固性推进剂装药浇注过程的关键参数的预测模型,实现浇注速度和浇注量的设计。但在挤压铸造领域还未见基于大数据构建工艺参数的应用,尤其是数据驱动范式的应用,而只有少量学者基于少量的实验数据,通过构建实验数据的回归等模型来优化工艺参数^[8-9]。

为此,本文收集了已有文献的挤压铸造工艺数据,通过分析挤压铸造温度参数的影响因素,构建了基于数据和机器学习的挤压铸造温度参数快速设计方法。该方法以新(材料)铸件的温度参数为设计目标,首先考虑材料成分对温度参数的影响,应用KNN算法从已有数据集中找到与所求铸件最相近的材料工艺参数的加权和作为初始工艺参数,然后考虑铸件形状对温度参数的影响,应用GRNN进行修正,实现挤压铸造温度参数较准确且快速的设计。为挤压铸造及其他领域的工艺参数设计提供新的思路。

1 挤压铸造温度参数设计方法

挤压铸造的温度参数主要包括浇注温度和模具预热温度,二者相互影响,通过共同作用使金属液具有良好的流动充型能力并实现高质量高效的凝固成形。本文将并行设计。

现有研究表明,材料成分和几何特征是影响挤压铸件工艺参数的基本因素,而材料成分影响更为显著,尤其是浇注温度与材料成分密切相关,因为材料成分的组成决定了金属的熔点^[12]。理论上材料成分相近,其需要的浇注温度条件等也相近,因此可借鉴相近材料的温度工艺参数来设计新(材料)挤压铸件的温度工艺参数。为此,构建已有铸件的工艺参数数据库,并应用KNN算法从中找到相近材料铸件,基于材料成分来设计挤压铸造温度工艺参数,在此基础上,根据其误差大小结合铸型参数使用GRNN对其进行修正的工艺参数设计方法。

1.1 挤压铸造工艺参数数据库

现有的挤压铸造研究积累了大量特定材料铸件的工艺参数数据。为利用这些数据设计挤压铸造的温度工艺参数,从相关文献中收集了挤压铸造工艺参数数据样本,形成了挤压铸造工艺参数数据库。数据库中样本数据主要包含挤压铸造的工艺参数(挤压压力、浇注温度、模具预热温度等)、材料成分(如铝)和形状特征(如形状复杂度)等相关属性数据。为便于应用,将挤压铸造工艺参数样本数据按性质划分为工艺影响因素 X_k ($k=1, 2, \dots, t$, t 表示工艺影响因素个数,其中材料成分为前 θ 个)和工艺参数 Y_j ($j=1,$

$2, \dots, n$, n 表示工艺参数个数),数据库中每个数据样本 S_i ($i=1, 2, \dots, m$, m 为数据样本的个数)的对应属性数据分别记为 x_{ik} 和 y_{ij} ,表示为 $S_i=(x_{ik}, y_{ij})$ 。其结构如表1所示。

表1 挤压铸造工艺参数数据结构
Table 1 Structure of the process parameters data of the squeeze casting

样本编号	X_1	...	X_t	Y_1	...	Y_n
S_i	x_{i1}	...	x_{it}	y_{i1}	...	y_{in}
...
S_m	x_{m1}	...	x_{mt}	y_{m1}	...	y_{mn}

1.2 基于KNN算法的温度参数初始设计

将数据库中的已有数据样本作为参考对象,利用KNN算法^[13]找出与设计铸件材料成分最相近的 K 个最近邻样本,并根据 K 个最近邻样本与设计铸件的材料成分的距离来确定其影响权重,然后将 K 个最近邻样本的对应温度工艺参数加权回归值作为设计铸件的温度工艺参数的设计初值。为便于表述,设第 i 个样本的浇注温度和模具预热温度分别为 y_{i1} 、 y_{i2} ,设目标铸件为 O ,对应材料成分为 $\{o_1, o_2, \dots, o_\theta\}$,浇注温度和模具预热温度分别为 y_{o1} 、 y_{o2} 。具体方法如下:

(1)首先对 S_i 的 x_{ik} 中的材料成分数据按列进行预处理,消除材料成分数据大小差异过大的影响,公式如下:

$$x'_{ik} = \frac{x_{ik} - \min(k)}{\max(k) - \min(k)} \quad (k=1, 2, \dots, \theta) \quad (1)$$

式中: $\max(k)$ 和 $\min(k)$ 分别表示工艺参数数据库中第 k 列数据的最大值和最小值。

(2)采用欧氏距离(Euclidean)计算目标铸件的材料成分 $\{o_1, o_2, \dots, o_\theta\}$ 与数据库样本 S_i 的材料成分之间的距离 d_i :

$$d_i = d_i(O, S_i) = \sum_{k=1}^{\theta} \sqrt{\sum_{k=1}^{\theta} (o_k - x'_{ik})^2} \quad (k=1, 2, \dots, \theta) \quad (2)$$

(3)根据距离 d_i 的大小,按从小到大顺序,取 K 个与 O 材料成分距离最小的样本,即最近邻聚类样本集 CS , $CS=\{s_{i'}|i'=1, 2, \dots, K\}$,并根据距离关系确定各聚类样本的权重 $\omega_{i'}$,表征与 O 的相近程度。

$$\omega_{i'} = \frac{1/d_{i'}}{\sum_{i'} 1/d_{i'}} \quad (i'=1, 2, \dots, K) \quad (3)$$

(4)计算 CS 所有样本对应的浇注温度和模具预热温度的加权值,将加权值作为 O 的温度工艺参数,即:

$$\begin{aligned} y_{o1} &= \sum_{i'=1}^K (\omega_{i'} y_{i'1}) \\ y_{o2} &= \sum_{i'=1}^K (\omega_{i'} y_{i'2}) \end{aligned} \quad (4)$$

综上所述, K 值影响确定的最近邻的聚类样本数量, 进而影响设计的准确性。为此, 将 K 值作为优化的变量, 将数据库的已有样本 S_i 作为目标铸件, 通过检查在不同 K 值下基于以上方法的设计结果与数据库中样本的已有温度参数真值的误差, 取其总误差最小时的 K 值为最优 K 值。设计值与样本的已有温度参数真值误差采用平均相对误差 $error$ 和均方误差 MSE 来衡量, 计算方法如下:

$$error = \frac{1}{m} \sum_{i=1}^m |(y_{oj} - y_{ij}) / y_{ij}| (j=1, 2) \quad (5)$$

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_{oj} - y_{ij})^2 (j=1, 2) \quad (6)$$

1.3 基于 GRNN 的温度工艺参数修正

实验发现, 基于KNN算法预测的浇注温度误差较小, 可直接应用, 而模具预热温度预测值误差较大, 平均设计误差在13%左右。这是因为模具预热温度的选择与合金的凝固温度、铸件尺寸形状都有关^[14], 如当铸件(局部)薄至一定程度时要求较高的模具预热温度。以下只对模具预热温度进行修正。

虽然基于挤压铸造的工程知识和已有研究知模具预热温度与铸件形状有关, 但其定量影响关系尚不清楚, 无法构建准确的修正模型。为此引入GRNN来进行模糊修正。GRNN是径向基神经网络(RBF)的一种, 具有很强的非线性映射能力和学习速度, 即使在样本数据少时, 其预测效果也很好^[15], 且还可以处理不稳定数据。基于GRNN修正时, 将模具预热温度的误差影响因素作为输入变量, 模具预热温度的误差值(修正值)作为GRNN的输出量, 通过使用已有样本进行训练得到修正模型。

设 Δy_{o2} 为基于GRNN的模具预热温度的修正值; y'_{o2} 为修正后的模具预热温度值, 则最终有:

$$y'_{o2} = y_{o2} - \Delta y_{o2} \quad (7)$$

1.3.1 模具预热温度修正的影响因素识别

由于GRNN修正模型的输入变量为模具预热温度的影响因素, 其影响修正的准确性和复杂度, 为准确确定GRNN的修正模型的输入量, 首先设法基于数据库中的数据分析出除材料成分外的主要影响因素。方法如下: 对数据库中已有样本的零件复杂度等(除材料成分外的)相关属性进行分类, 然后按划分类别(等级), 统计数据库中已有样本属于各种类别的数量, 并计算各类铸件的模具预热温度算术平均值; 在此基础上, 采用最小二乘法(OLS)拟合对应相关属性与模具预热温度, 通过拟合优度结果判断其实际相关性, 取拟合优度超过80%的为最相关因素, 列入GRNN的输

入量。利用PyCharm平台实现最小二乘法(OLS)拟合。拟合优度计算如下:

$$R^2 = \frac{\sum (\hat{y}_i - \frac{1}{m} \sum y_{i2})^2}{\sum (y_{i2} - \frac{1}{m} \sum y_{i2})^2} \quad (8)$$

式中: \hat{y} 为最小二乘法拟合的模具预热温度值。

表2为参照文献[16]和基于已收集的数据(表5)得到的挤压铸造铸件形状复杂度及其对应的模具预热温度。由表2可知, 随着铸件复杂度提高, 模具预热温度逐渐提高, 复杂度2和3的铸件所对应的模具预热温度平均值间距最大。表明当铸件为具有加强筋或侧孔的复杂件时, 需要更高的模具预热温度。拟合发现其相关性为0.843, 即密切相关。

表2 划分的挤压铸造铸件形状复杂度等级及其统计关系
Table 2 Divided shape complexity of squeeze casting parts and its statistical relations with die preheating temperature

形状复杂度	类别	样本数量	模具预热温度平均值/℃
1	柱体、方锭等简单铸件	42	220
2	杯、盘等简单阶梯件	24	228
3	有加强筋、侧孔的复杂件	14	253
4	轮毂、壳体等复杂件	20	266

在大量文献统计中发现, 铸件的最小厚度也影响模具预热温度。同样地, 对铸件的最小厚度划分等级, 并统计衡量铸件最小厚度对模具预热温度的影响, 结果如表3所示。结果显示, 最小厚度等级为1时所对应的模具预热温度平均值远高于等级2和等级3, 这说明铸件最小厚度低于一定程度时, 需要增加模具预热温度来提高流动性, 而等级2、3不存在局部明显过薄的铸件, 对模具预热温度的要求不明显。其拟合优度为0.844。

表3 划分的挤压铸件最小厚度等级及其统计关系
Table 3 Divided minimum thickness of squeeze casting parts and its statistical relations with die preheating temperature

最小厚度等级	厚度/mm	样本数量	模具预热温度平均值/℃
1	≤5	10~20	≥20
2	18	33	49
3	271.7	244	228.5

同时, 考虑浇注温度对模具预热温度的交叉影响, 得到对应的拟合优度, 如表4所示。可见, 相比零件复杂度和铸件最小厚度, 浇注温度对模具预热温度的影响更为显著。

1.3.2 修正模型

基于以上分析, 得到基于GRNN的模具预热温度

表4 模具预热温度相关属性的相关性
Table 4 Correlation of related attributes of die preheating temperature

相关属性	拟合优度 R^2
零件复杂度	0.843
浇注温度	0.972
最小壁厚等级	0.844

的修正模型结构，如图1所示。模型由四层构成，即输入层、模式层、求和层和输出层，其为有导师型网络，通过样本训练可得到利用的修正模型。




图1 广义回归神经网络结构图
Fig. 1 Structure chart of GRNN

(1) 输入层，即影响因素变量，由于是在初始的模具预热温度基础上进行修正，因此将浇注温度、模具预热温度初值、最小壁厚等级和零件复杂度作为输入向量（即有四个神经元），表示为 D ，对应输出为模具预热温度误差值。

(2) 模式层。是训练GRNN的关键层，计算测试（目标）与训练样本输入向量的距离信息。该层的神经元数量与模型的训练样本数量相同，即每一个模式层神经元对应一个训练样本，其与输入层神经元为全连接，表示所有输入变量对模具预热温度误差都有影响，层内神经元采用无连接（即不同铸件其模具预热温度独立）。其传递函数为：

$$P_{\lambda} = \exp \left[\frac{(D_0 - D_{\lambda})^T (D_0 - D_{\lambda})}{2\sigma^2} \right], \lambda = 1, 2, \dots, q \quad (9)$$

式中： D_{λ} 为模式层的第 λ 个神经元对应的训练样本的输入向量； D_0 为目标铸件的输入向量； P_{λ} 为模式层的第 λ 个神经元的计算值； q 为训练样本的数量； σ 为超参数光滑因子。

(3) 求和层。使用两种类型神经元进行求和。

A类神经元：该类神经元只有一个。该神经元计算值为所有模式层神经元的输出算数和。

$$Q = \sum_{\lambda=1}^q P_{\lambda} \quad (10)$$

B类神经元：该类神经元数量与输出向量维数相同，需要对模式层所有神经元进行加权求和。例如：求和层第1个B类神经元与模式层第 λ 个神经元的连接权

值为该模式层神经元对应的学习样本的输出向量中第1个元素 $l_{\lambda 1}$ （模具预热温度误差值），其计算公式为：

$$Q_1 = \sum_{\lambda=1}^q l_{\lambda 1} \cdot P_{\lambda} \quad (11)$$

式中： $l_{\lambda 1}$ 为第 λ 个模式层神经元对应的学习样本对应的第1个输出值。

(4) 输出层。按以上模型得到的输出量即模具预热温度的修正值 Δy_{02} 计算为：

$$\Delta y_{02} = \frac{Q_1}{Q} \quad (12)$$

代入式(7)，即可得到最终的模具预热温度设计值。

根据式(8)，光滑因子 σ 对GRNN的预测性能影响较大，当其较小时可能导致模型无法收敛，较大时模型容易出现过拟合现象。为使模型预测效果达到最好，需对光滑因子 σ 进行寻优。采取前面优化 K 的方法，将数据库样本 S_i ——作为目标铸件（测试样本），其余样本作为GRNN训练样本，类似地利用GRNN预测测试样本的模具预热温度误差值大小，根据式(7)和式(5)计算修正后的模具温度平均误差作为评价指标来优化 σ 。令 σ 在 $[0.1, 1]$ 内以增量0.01递增，对GRNN模型进行反复训练和测试。

基于以上方法原理，得到整个温度工艺参数的设计方法的流程，如图2所示，图中虚线框选部分仅在建模和模型训练过程中执行，使用模型时不执行。

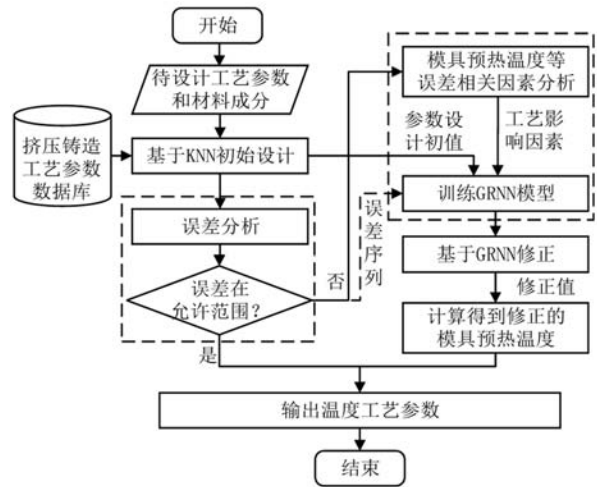


图2 挤压铸造工艺参数设计方法流程
Fig. 2 Method process of process parameters design of squeeze casting

2 应用验证

为验证以上方法的有效性，本节将从两方面进行测试实验：（1）基于收集的数据和以上方法构建模型，测试本文方法和构建的模型设计挤压铸造温度参数的准确性。（2）以实际铸件为对象，基于已经验证

准确的模型，进行铸件的温度参数设计，并利用数值模拟进行仿真验证，分析设计工艺参数的合理性和优劣性。


2.1 基本模型构建与测试

以铝合金材料为对象，从涉及挤压铸造工艺参数研究的文献中收集得到挤压铸造铝合金工艺参数数据库，其结构如表5所示。剔除缺失数据以及不可靠数据，共得到铝合金挤压铸造工艺数据样本100个。表中铝合金主要成分主要包括Al、Cu、Mn、Fe、Si、Mg、Zn、Ti、Cr、Ni等材料成分。

首先基于KNN算法求取最优K值，以构建最优聚类规模。如图3所示，当K=8时，浇注温度和模具预热温度设计初值的相对误差和均方误差均接近最低水平，

表5 挤压铸造工艺数据库
Table 5 Dataset case of the squeeze casting process

样本编号	浇注温度/℃	模具预热温度/℃	Al/%	...	零件复杂度
1	730	200	94.35	...	1
2	725	230	86.63	...	1
...
100	720	300	89	...	1



浇注温度相对误差和均方误差仅为2.37%和550；模具预热温度的相对误差和均方误差仅为13.29%和1205。此时KNN模型预测效果最精确和稳定。基于K=8得到的部分浇注温度和模具预热温度设计初值如表6所示。

其次，对光滑因子 σ 寻优，构建最优性能GRNN模型。根据1.3.2节方法得到 σ 的寻优结果。如图4所示，光滑因子 $\sigma=0.67$ 时，利用GRNN模型修正后的模具预热温度值 y'_{o2} 与其真值 y_{o2} 的平均相对误差最低，仅为6.38%，远低于修正前的误差13.29%，模具预热温度平均相对误差降低了51.2%。经过上述方法对模具预热温度进行修正后，最大误差都小于25℃，测试样本修正

表6 部分温度参数设计初值
Table 6 Initial designed values of temperature parameters

样本序号	浇注温度/℃		模具预热温度/℃	
	样本值	设计值	样本值	设计值
1	730	734.7	200	223.4
2	725	699.1	225	250.5
3	720	712.9	280	225.9
...
100	720	705.6	300	243.1




图3 温度工艺参数的相对误差和均方误差

Fig. 3 Relative error and MSE of temperature process parameters




图4 光滑因子寻优

Fig. 4 Optimization of the smoothing factor

模具预热温度与设计初值、真值的比较如图5所示。

2.2 实际铸件工艺参数设计

为进一步验证方法的有效性，选择连接座铸件^[17]（简称铸件）进行挤压铸造温度参数设计。改变其材料成分，基于2.1训练好的模型设计并修正铸件的挤压铸造温度参数，然后利用ProCAST进行挤压铸造工艺仿真，验证所得工艺参数的合理性。除浇注温度和模具预热温度外，其余工艺参数取自文献[17]。如图6所示，铸件属于较简单的多阶梯对称件，零件复杂度为2，最小厚度等级为2（6 mm）。由于已有数据库以铝合金为主，为了保证效果，测试了A356、AlCu3Si6两




图5 样本模具预热温度修正结果及其与设计初值、真值的比较
Fig. 5 Comparisons of die preheating temperature corrected with the true values and the initial design values




图6 连接座铸件图
Fig. 6 Schematic diagram of connecting seat casting

种铝合金铸件的工艺参数，设计得到的温度工艺参数如表7所示（其余材料成分为0）。

根据表6中浇注温度和模具预热温度修正前后的铸件充型过程仿真结果如图7所示。可见充型结果较好，两种材料铸件充型结束时温度均高于合金的液相线（A356和AlCu3Si6合金的固液相线温度分别为613 °C、611.8 °C），金属液流动性满足铸件的充型要求。表明设计的温度满足铸件成形需求。但充型结束时两种材料的铸件均有局部温度较低现象，这说明充型过程中可能存在金属液流动性不足和铸件过早凝固的情况，容易导致压力补缩困难从而产生缩松、缩孔。尤其体现在模具预热温度较低的A356合金铸件中（见图7a、8a）。

图8为铸件挤压铸造工艺缩松、缩孔仿真结果。由图8可知，铸件的缩松、缩孔较少，且主要产生在较容易产生缩松、缩孔的铸件最后凝固区域，符合工程先验知识。这说明应用本方法设计能满足要求。修正前缩松、缩孔率分别为5.24%、4.18%，修正后缩小到0.78%与1.23%，具体缩孔率见表7。修正后，铸件充型质量显著提高，缩松、缩孔明显减少。也反映了模具预热温度的重要性及其浇注温度对挤压铸件成形的协同影响，表明本文方法对模具预热温度的修正有效。

综上所述，本文提出的挤压铸造温度参数设计方法所设计的不同材料成分铸件的工艺参数（浇注温度和模具预热温度）均能获得较优的铸件质量，表明该方法结合材料成分和铸型参数设计的浇注温度和模具预热温度质量较优。该方法具有较大的应用价值和推广潜力。

表7 材料成分及工艺参数设计结果
Table 7 Material composition and the design result of process parameters

合金牌号	$w_B/\%$						浇注温度/°C	模具温度/°C		缩松缩孔率/%	
	Al	Cu	Mn	Si	Mg	Fe		修正前	修正后	修正前	修正后
A356	92.49	0.08	0.03	7	0.4	0	700.7	214.3	254.2	5.24	0.78
AlCu3Si6	91	3	0	6	0	0	705.3	231.7	241.6	4.18	1.23




图7 不同材料铸件充型过程的仿真结果
Fig. 7 Simulation results of filling process of castings with different materials

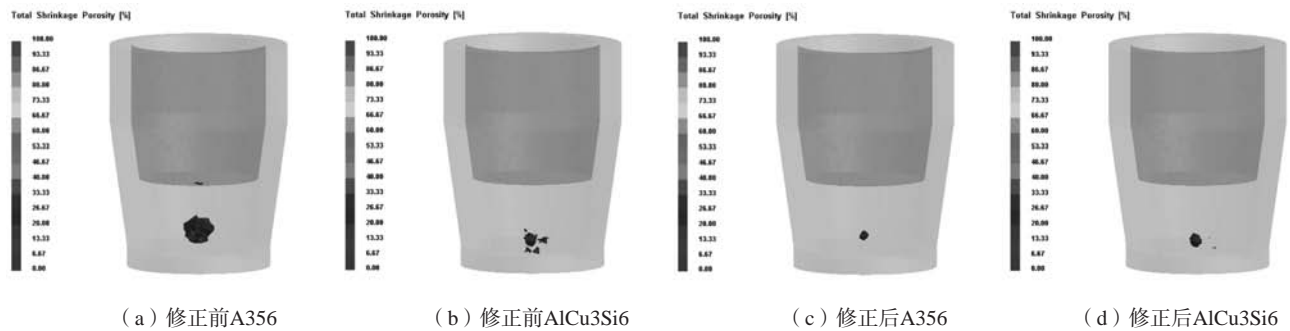


图8 不同材料铸件缩松缩孔仿真结果

Fig. 8 Simulation results of the shrinkage of the castings with different materials

3 结束语

本研究通过收集现有挤压铸造工艺数据, 考虑挤压铸造温度工艺参数与挤压铸件材料和形状特征的关系, 基于KNN与GRNN构建了基于数据直接设计挤压铸件的温度工艺参数的设计方法, 实例应用表明, 有较高的准确性。相比传统的基于物理实验的方法, 本方法直接利用已有文献的实验数据, 无需实验, 节约了成本, 提高了设计效率, 该方法突出了对现有研究数据的利用。方法有序地兼顾了材料成分和铸型参数

对挤压铸造温度参数的影响, 提高了温度参数设计的准确性, 实现挤压铸造浇注温度和模具预热温度的并行设计。为挤压铸造工艺参数数字化设计提供了一种方法, 具有较大应用潜力。理论上该方法也可用于挤压铸造的其他工艺参数的设计, 下一步我们将测试对挤压压力等其他工艺参数的设计效果, 并构建修正模型; 同时将开发对应系统进行物理实验, 进一步验证设计的合理性、优劣性, 并完善设计方法, 提高设计应用效率。

参考文献:

- [1] 张卫文, 齐丕骧, 朱德智, 等. 铸造技术路线图: 挤压铸造 [J]. 铸造, 2017, 66 (6): 535-540.
- [2] 戴护民, 金俊松. 液态模锻温度对镁合金汽车转向节臂性能的影响 [J]. 热加工工艺, 2020, 49 (7): 109-112, 115.
- [3] 王伟, 崔晓明, 石博, 等. 铝合金轮毂连接盘挤压铸造数值模拟 [J]. 铸造, 2021, 70 (3): 306-310.
- [4] ZHAO Chunfang, XU Hongyu, JI Zesheng, et al. Effect of near-liquidus squeeze casting temperature on microstructure and mechanical property of AZ91D alloy differential support [J]. Materials Letters, 2020, 270: 127681.
- [5] 周颖, 马晓录, 李尚辰. 浇注温度对AZ31液态模锻铸件组织及性能的影响 [J]. 河南科技, 2015 (6): 50-53.
- [6] CHEN Yushi, WU Guohua, LIU Wencai, et al. Effect of mold temperature on microstructure and mechanical properties of rheo-squeeze casting Mg-3Nd-0.2Zn-0.4Zr alloy [J]. Journal of Materials Research, 2017, 32 (22): 4206-4218.
- [7] YANG Zhang. Effects of processing parameters and Ca content on microstructure and mechanical properties of squeeze casting AZ91-Ca alloys [J]. Materials Science & Engineering A, 2014, 595: 109-117.
- [8] PATEL G C M, KRISHNA P, PARAPPAGODAR M B. Modelling of squeeze casting process using design of experiments and response surface methodology [J]. International Journal of Cast Metals Research, 2015, 28 (3): 167-180.
- [9] PATEL G C M, KRISHNA P, PARAPPAGODAR M B. Optimization of squeeze cast process parameters using taguchi and grey relational analysis [J]. Procedia Technology, 2014, 14: 157-164.
- [10] WANG Chenchong, SHEN Chunguang, CUI Qing, et al. Tensile property prediction by feature engineering guided machine learning in reduced activation ferritic/martensitic steels [J]. Journal of Nuclear Materials, 2020, 529: 151823.
- [11] 徐志刚, 张浩, 韩秀洁, 等. 数据驱动的装药浇注过程关键参数预测 [J]. 固体火箭技术, 2021, 44 (5): 662-669.
- [12] 范晓明. 金属凝固理论与技术 [M]. 武汉: 武汉理工大学出版社, 2019: 20-21.
- [13] ALTMAN N S. An introduction to kernel and nearest-neighbor nonparametric regression [J]. Taylor & Francis Group, 2012, 46 (3): 175-185.
- [14] 陈维平, 李元元. 特种铸造 [M]. 北京: 机械工业出版社, 2018: 221-221.
- [15] 黄鑫, 赵捍东. 基于广义回归神经网络的弹丸落点预报方法 [J]. 测试科学与仪器, 2016, 7 (1): 7-12.
- [16] 罗守靖, 齐丕骧, 陈晓光. 液态模锻与挤压铸造技术 [M]. 北京: 化学工业出版社, 2007.
- [17] 吕野楠, 丁韧. 压力对挤压铸造铝合金件性能的影响 [J]. 铸造技术, 2017, 38 (2): 466-468.

Design Method of Squeeze Casting Temperature Parameters Based on KNN and GRNN

DENG Jian-xin^{1,2}, XIE Bin^{1,2}, ZENG Xiang-ming^{1,2}

(1. Guangxi Key Lab of Manufacturing System & Advanced Manufacturing Technology, Guangxi University, Nanning 530003, Guangxi, China; 2. School of Mechanical Engineering, Guangxi University, Nanning 530003, Guangxi, China)

Abstract:

In view of the low efficiency and limitations of the existing research methods of squeeze casting process parameters, the rapid design of squeeze casting temperature process parameters was realized by using the existing squeeze casting process data and machine learning method. Firstly, based on KNN (K Nearest Neighbors) algorithm to referring to the temperature process parameters of similar material castings, the initial design of pouring temperature and die preheating temperature was carried out from the material composition level. Then, the die preheating temperature with large design error is corrected by combining casting parameters and generalized regression neural network (GRNN). The error correction model was established. The validity of the proposed temperature process parameter design method was verified by the application based on data and the example casting and the simulation experiment of the example casting with ProCAST.

Key words:

squeeze casting; process parameter design; data driven; KNN; GRNN
