

• 试验研究 Experimental Research •
DOI:10.16410/j.issn1000-8365.2024.4176

特邀论文

基于机器学习方法的 GH4175 高温合金 高温塑性与成分关联研究

刘宜瑞¹, 刘有云², 赵佳军¹, 虎小兵¹, 陈一鸣¹, 赵张龙¹, 李俊杰¹, 王志军¹, 王锦程¹
(1. 西北工业大学凝固技术国家重点实验室, 陕西 西安 710072; 2. 中国人民解放军 93147 部队)

摘要: GH4175 合金是新型难变形高温合金的典型代表, 通过成分优化提升其高温单相区变形能力, 是避免该合金铸锭开坯过程中开裂的重要前提。综合利用相图热力学计算、高温拉伸实验及机器学习方法, 通过成分设计空间逐层筛选优化以及自适应学习策略, 获得了影响该合金 800 °C γ' 相体积分数、 γ' 相完全溶解温度和合金初始液化温度的关键元素, 建立了上述元素含量与高温伸长率之间的关系模型, 明确了在保证一定热加工温度窗口和 800 °C γ' 相体积分数的前提下, 同时具备优异高温塑性的合金成分范围及微观组织特征。

关键词: GH4175; 机器学习; 高温塑性; 成分优化

中图分类号: TG131

文献标识码: A

文章编号: 1000-8365(2024)11-1049-12

Relationship Between High-temperature Plasticity and the Composition of the GH4175 Superalloy Discovered via Machine Learning

LIU Yirui¹, LIU Youyun², ZHAO Jiajun¹, HU Xiaobing¹, CHEN Yiming¹, ZHAO Zhanglong¹,
LI Junjie¹, WANG Zhijun¹, WANG Jincheng¹

(1. State Key Laboratory of Solidification Processing, Northwestern Polytechnical University, Xi'an 710072, China; 2. 93147 Troops of the Chinese People's Liberation Army)

Abstract: The GH4175 alloy is a typical new difficult-to-deform superalloy. Optimizing its composition to enhance its deformation capability in the high-temperature single-phase region is a crucial prerequisite for preventing cracking during the cogging process of this alloy. By combining thermodynamic calculations, high-temperature tensile experiments, and machine learning methods, the composition of GH4175 was optimized. The key compositional elements that influence the γ' phase volume fraction at 800 °C, the γ' phase dissolution temperature, and the alloy melting temperature are identified via design space screening and adaptive learning strategies. A relationship model between the content of these elements and high-temperature elongation is established, clarifying the compositional range that ensures excellent high-temperature ductility while maintaining a reasonable processing window and γ' phase volume fraction at 800 °C.

Key words: GH4175; machine learning; high-temperature ductility; component optimization

GH4175 是我国近年来开发的可在 800 °C 长期服役的新型涡轮盘用变形高温合金^[1-4]。相较于传统变形高温合金, 该合金的合金化程度更高, 时效状态下 γ' 相体积分数超过 58%, 展现出卓越的高温力学性能。但该合金铸锭开坯过程极易开裂, 原因在

于其初始熔化温度较低, 而 γ' 相的完全溶解温度较高, 导致其 γ 单相区的温度范围(也称热加工温度窗口)较小, 开坯过程中局部温度极易降至 $\gamma+\gamma'$ 两相区, 此时粗大 γ 基体相中大量析出弥散细小的 γ' 相, 使得坯料塑性极具下降, 从而引起变形开裂。为

收稿日期: 2024-09-14

基金项目: 国家重点研发计划(2023YFB4606502)

作者简介: 刘宜瑞, 1999 年生, 硕士生。研究方向为高温合金和机器学习。Email: lyr261165@mail.nwpu.edu.cn

通讯作者: 赵张龙, 1981 年生, 博士, 副教授。研究方向为高温合金、钛合金塑性加工。Email: zlzhaol@nwpu.edu.cn

李俊杰, 1982 年生, 博士, 副教授。研究方向为凝固理论。Email: lijunjie@nwpu.edu.cn

引用格式: 刘宜瑞, 刘有云, 赵佳军, 虎小兵, 陈一鸣, 赵张龙, 李俊杰, 王志军, 王锦程. 基于机器学习方法的 GH4175 高温合金高温塑性与成分关联研究[J]. 铸造技术, 2024, 45(11): 1049-1060.

LIU Y R, LIU Y Y, ZHAO J J, HU X B, CHEN Y M, ZHAO Z L, LI J J, WANG Z J, WANG J C. Relationship between high-temperature plasticity and the composition of the GH4175 superalloy discovered via machine learning[J]. Foundry Technology, 2024, 45(11): 1049-1060.

提升 GH4175 在开坯过程中的变形能力,一方面要控制 γ' 析出相的形态,使 γ' 析出相尺寸增大到微米尺度^[5-6];另一方面应使材料在高温单相区发生尽可能大的变形,从而促进再结晶发生,细化 γ 基体相晶粒。因此,提升合金 GH4175 在高温单相区的塑性变形能力,是避免其开坯开裂的重要前提。

成分调控是改善镍基高温合金性能的重要手段。目前,国内外学者已在此方面开展了大量研究。如杜金辉等^[7]通过提高 Al、降低 Nb,并加入 W 来改善 GH4169 合金的高温拉伸强度及持久、蠕变性能。Zhang 等^[8]发现 P 元素的添加能够显著提高 GH4169 合金的高温持久寿命和塑性。Theska 等^[9]系统地研究了 B 和 C 元素添加对 René 41 变形高温合金性能的影响,发现高碳含量情况下晶界处会出现碳的偏析和溶质的富集,可防止晶界开裂,从而使合金展现出优异的塑性。Kontis 等^[10]在 750 °C 对含硼和不含硼的镍基高温合金进行了拉伸测试,并使用扫描电子显微镜(SEM)进行了进一步的原位观测,发现无硼合金断裂敏感性受晶界形貌影响更强,而含硼合金则展现出显著的塑性增强现象。Ou 等^[11]研究了 Ti 含量为 2.4%和 3.0%(质量分数)的镍基高温合金在不同温度下的拉伸性能,发现 Ti 升高可使室温和高温下的屈服强度和极限抗拉强度都显著提高。姚志浩等^[12]利用 Thermo-Calc 和 JMatPro 软件研究了 GH4738 合金 C、Al、Ti 和 Cr 元素含量对该合金相析出含量及回溶温度的影响,结果表明,Al 和 Ti 含量的增加可以明显提高合金相的完全溶解温度及其析出量,并有利于提高合金的抗拉强度,而 Cr 含量的增加则可以提高 γ' 相的完全溶解温度,但对其析出量的影响不大。目前,关于成分对高温合金力学性能影响的研究大多关注于一到两个元素的调控,热力学计算手段虽可方便地考察 γ' 相体积分数和溶解温度之类相平衡信息随多个组元含量的变化,但对多个组元含量与塑性、蠕变、持久等力学性能的评估仍需依靠实验,面临庞大的实验量挑战。

近年来,机器学习方法在合金成分及加工工艺设计方面获得了成功应用^[13]。如在高温合金领域,Yu 等^[14]利用 458 个钴基高温合金实验数据样本,以元素含量、时效温度、时效时间为特征,使用分类模型预测合金中 γ' 相是否存在,随后以元素含量作为特征,建立了 γ' 相的回溶温度预测模型,获得了一种具有高 γ' 相体积分数及高回溶温度的新型钴基高温合金。Liu 等^[15]利用机器学习算法对具有不同蠕变机制的 266 组镍基单晶高温合金进行自动聚类,并对每一类合金分别建立成分及热处理工艺与蠕

变寿命的关系预测模型,实现了镍基单晶高温合金蠕变寿命的快速预测。Qin 等^[16]利用材料高通量实验和微区 X 射线荧光光谱仪自动采集高温合金成分和显微组织信息,快速获取了 8371 个镍基高温合金成分和相结构的数据样本,并通过特征变量筛选,建立了关于拓扑密排相和几何密排相的预测模型。上述利用机器学习建立的高精度回归模型依赖于相对高质量的数据库。目前,高温性能数据的获取主要依赖热力学计算^[17]、文献收集或高通量实验^[18]。然而,对于某些合金体系的某些高温性能(如本文关注的 GH4175 高温塑性),如果无法通过上述途径获取数据,则只能通过传统实验方法进行测量,而高昂的成本将制约实验的大规模开展。此外,数据样本数量稀少成为制约机器学习模型预测效果的主要瓶颈。

自适应学习^[19]和基于领域知识的逐层筛选方法^[20]能够有效应对小数据集在建立准确预测模型时所面临的挑战。其中,自适应学习同时考虑不断优化数据分布的“探索(exploration)”与搜索最优性能的“开发(exploiting)”这两方面因素,推荐最具有价值的候选合金来进行下一步实验,通过不断迭代可优化模型,并最终发现具有最优目标性能的新合金。Xue 等^[21]利用自适应学习策略,以 3 个与化学键、原子半径相关的特征作为输入,利用初始的 53 个数据样本建立了 Ni-Ti 基形状记忆合金相转变温度预测模型,并经过 6 次自适应学习迭代反馈后,从 80 万种候选合金中找到了具有目标相转变温度的新型合金。Hu 等^[22]通过自适应学习策略辅助超强耐热钢设计,采用有效全局优化算法(efficient global optimization, EGO),经过 3 次迭代找到最佳候选合金成分,发现其硬度远超已知数据的超强耐热钢。通过领域知识对设计空间进行筛选,是减少实验数据需求的另一种有效方法,并且往往可以与自适应学习联用,提高机器学习模型的预测精度并加速最优性能合金的发现,有效解决“小样本数据”和“大设计空间”所带来的挑战。Li 等^[20]依据使用价电子浓度与塑性之间关系的领域知识,将 AlCoCrFeNi 高熵合金设计空间中低塑性成分筛除,而后在缩小的设计空间中通过 6 次自适应学习迭代,最终获得了同时具有高强度和高塑性的高熵合金。Liu 等^[23]依据抗氧化性领域知识、基于热力学计算的相组成分类模型以及基于实验数据的性能回归模型,对 Co-Al-W-Ni-Ti-Ta-Cr 多元合金的成分设计空间进行逐次筛选,将最初包含 210 792 种合金组成的成分空间缩小到小于 6 000 种,而后以 γ' 溶解温度为目标进行自适应学习,最

终成功获得承温能力达 1 266 °C 的新型钴基高温合金。上述文献表明,采用领域知识筛选与自适应学习方法可以有效实现小样本数据下的建模预测,这为通过少量的实验样本训练 GH4175 合金高温塑性与成分的关系模型提供了解决思路。

本文以优化 GH4175 合金成分,提升其高温塑性为出发点,通过领域知识筛选与自适应学习方法,构建 GH4175 合金高温塑性与 5 种合金元素含量之间的关系模型,在合金成分设计空间中寻找既能保证一定的热加工温度窗口和 800 °C 的 γ' 相体积分,又具有优异高温塑性的成分区间;并通过实验观测,分析此成分区间中合金高温塑性优异的根源,可为 GH4175 合金的成分调控提供依据。

1 实验材料与方法

1.1 样品制备

表 1 列出了 GH4175 合金元素的名义成分及其变化范围。由于该合金为仿制俄罗斯牌号 ВЖ175-ИД, 还尚不成熟,目前仅有名义成分^[1, 24-25], 缺乏详细的合金成分范围数据,此处成分范围为依据工程经验及参考其他同类型合金确定。在上述成分范围内,设定 C 元素的浓度变化步长为 0.02,其余元素浓度变化步长均为 0.2,由此形成的成分组合数量超过 6×10^7 。

通过对上述成分设计空间进行优化筛选后,选取若干成分合金进行熔炼,使用的单质原料纯度均在 99.99% 以上,熔炼设备为实验室自制“WK-II”型非自耗真空电弧炉,待合金完全熔化后浇注到铜模中,形成铸锭。随后,样品经历了 3 个阶段的均匀化热处理:首先在 1 140 °C 保温 5 h,以促使合金低熔点相回溶;接着在 1 180 °C 保温 10 h,消除合金中的枝晶组织并降低元素偏析;最后在 1 100 °C 保温 10 h。合金微观组织通过 TESCAN MIRA- III 型扫描电镜、OLYMPUS OLS4000 型光学显微镜进行表征。所有样品采用 240~2 500# 砂纸进行机械研磨,并使用 1 μm 金刚石膏体抛光至镜面。随后,样品在体积分数为 10% 的高氯酸(HClO_4)中进行电解抛光,电压为 30 V,时间为 10 s。高温拉伸试验由具有 CNAS 认证的第三方检测机构依据 GB/T 228.2-2015 标准进行(CX-DS-03),测试温度为 1 170 °C,拉伸速率为 $10^{-3}/\text{s}$ 。

1.2 机器学习策略

为了在“小样本数据”和“大设计空间”中建立高温塑性与合金成分之间的关系模型,采用图 1 所示的机器学习策略。首先通过基于热力学计算的特征工程分析和领域知识筛选,降低成分组合复杂度,优化设计空间;随后在优化后的设计空间中均匀抽取 20 组合进行高温拉伸试验,以构建初始数据集;

表1 GH4175合金各元素的名义成分与变化范围

Tab. 1 Nominal composition and variation range of the GH4175 alloy

	(mass fraction/%)									
Element	C	Cr	Co	W	Mo	Al	Ti	Nb	V	Ni
Nominal Comp.	0.06	10.0	15.5	3.0	4.5	4.0	2.5	4.5	0.6	Bal.
Lower limit	0.04	9.0	14.0	2.4	3.6	3.0	2.0	3.8	0.2	Bal.
Upper limit	0.12	11.4	16.4	3.8	5.0	4.4	3.0	5.0	1.0	Bal.

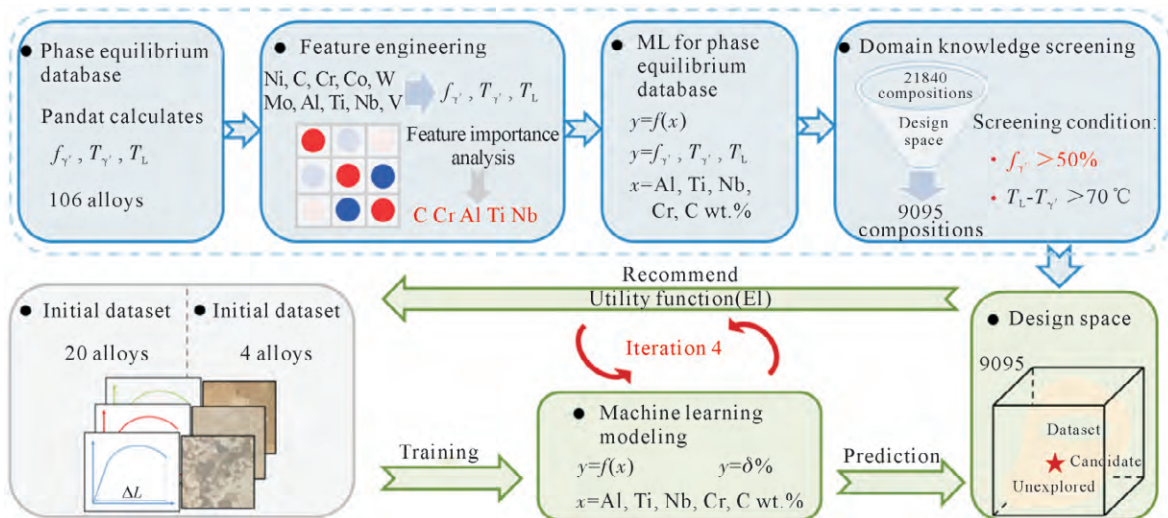


图 1 GH4175 合金成分优化的机器学习策略流程图

Fig.1 Flowchart of the machine learning strategy for the composition optimization of the GH4175 alloy

最后,采用自适应学习策略,通过机器学习模型训练与推荐实验的4轮次迭代,建立并优化合金成分与高温塑性之间的关系模型。主要有以下步骤。

(1)相平衡特征计算 在GH4175合金中, γ' 相是主要的强化相,800℃时的 γ' 相含量($f_{\gamma'}^{800}$)是决定其高温性能的重要指标。此外,由 γ' 相完全溶解温度(T_{γ})和合金初始液化温度(T_L)决定的热加工窗口 T_D ($T_D=T_L-T_{\gamma}$)是决定实际开坯过程控制难度的关键指标。因此,本文将依据 $f_{\gamma'}^{800}$ 和 T_D 进行成分空间筛选。在理论上,设计空间中所有成分组合对应的 $f_{\gamma'}^{800}$ 和 T_D 均可通过计算相图的方法获得,但计算量过于庞大,效率低下。因此,通过建立关于 $f_{\gamma'}^{800}$ 和 T_D 的机器学习预测模型的方法提升效率。为此,首先从初始设计空间中均匀抽取106组不同成分的合金,通过相图计算软件Pandata,计算各个合金的 $f_{\gamma'}^{800}$ 、 T_{γ} 、 T_L ,建立相平衡信息数据库。

(2)特征工程分析 采用皮尔逊相关系数和随机森林重要性排序方法,找到影响 $f_{\gamma'}^{800}$ 、 T_{γ} 、 T_L 的主要元素,其余元素的成分固定为名义成分,由此初步减小设计空间。

(3)相平衡特征预测模型建立 基于上述106种合金的相平衡特征作为初始训练集,采用高斯过程回归(Gaussian process regression, GPR)、随机森林回归(random forest, RF)、二次多项式回归(Poly-2)、极端梯度增强(extreme gradient boosting, XGBoost)和径向基核函数支持向量回归(support vector machine-radial basis function, SVR-rbf)5种回归模型进行训练,以均方根误差(RMSE)和决定系数(R^2)作为模型性能的评估指标,采用留出法交叉验证(hold-out cross validation, HOCV),对以上5种模型的预测性能进行评估。选取30组新的合金相图计算数据,组成验证集,对模型进行验证。

RMSE是衡量预测值与真实值之间偏差的公式之一,其表达式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (1)$$

式中, y_i 和 \hat{y}_i 分别表示真实值与预测值; N 为合金个数。决定系数 R^2 通过下式计算获得:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

式中, \bar{y} 为真实值的均值。

(4)依据领域知识的设计空间优化 以 $f_{\gamma'}^{800}$ 大于50%, ΔT_D 大于70℃为筛选条件,进一步缩小设计空间。

(5)高温塑性初始数据库建立 采用均匀抽样的方式,从优化后的设计空间中选择19种合金成分以及GH4175名义成分进行合金熔炼及均匀化热处理,随后进行1170℃高温拉伸实验,这些合金命名为T-1至T-20,具体成分如表2所示。除元素成分不同外,合金原料制备的其他工艺(包括合金制备、均匀化处理、高温拉伸)均保持一致。实验结果作为高温塑性机器学习预测模型的初始训练数据。

表2 20种合金编号及成分

Tab.2 Number and composition of the 20 kinds of alloy (mass fraction/%)

Alloy	C	Cr	Co	W	Mo	Al	Ti	Nb	V	Ni
T-1	0.04	9.0	15.5	3.0	4.5	3.2	2.8	4.8	0.6	Bal.
T-2	0.12	11.4	15.5	3.0	4.5	4.4	2.8	3.8	0.6	Bal.
T-3	0.12	9.0	15.5	3.0	4.5	4.4	2.8	3.8	0.6	Bal.
T-4	0.08	11.4	15.5	3.0	4.5	3.2	3.0	5.0	0.6	Bal.
T-5	0.04	10.4	15.5	3.0	4.5	3.8	3.0	3.8	0.6	Bal.
T-6	0.06	9.2	15.5	3.0	4.5	3.8	3.0	3.8	0.6	Bal.
T-7	0.06	9.0	15.5	3.0	4.5	4.2	2.0	4.8	0.6	Bal.
T-8	0.06	9.4	15.5	3.0	4.5	4.0	2.0	5.0	0.6	Bal.
T-9	0.06	9.6	15.5	3.0	4.5	4.2	2.0	5.0	0.6	Bal.
T-10	0.08	11.0	15.5	3.0	4.5	3.8	2.2	4.0	0.6	Bal.
T-11	0.08	9.0	15.5	3.0	4.5	3.2	3.0	5.0	0.6	Bal.
T-12	0.10	10.6	15.5	3.0	4.5	4.4	2.6	3.8	0.6	Bal.
T-13	0.06	11.4	15.5	3.0	4.5	3.8	2.6	3.8	0.6	Bal.
T-14	0.04	10.0	15.5	3.0	4.5	3.8	2.6	3.8	0.6	Bal.
T-15	0.06	10.0	15.5	3.0	4.5	4.0	2.8	4.0	0.6	Bal.
T-16	0.06	10.2	15.5	3.0	4.5	4.0	2.8	4.0	0.6	Bal.
T-17	0.12	11.0	15.5	3.0	4.5	4.0	2.0	3.8	0.6	Bal.
T-18	0.12	9.8	15.5	3.0	4.5	3.8	2.4	3.8	0.6	Bal.
T-19	0.12	11.2	15.5	3.0	4.5	3.6	2.6	3.8	0.6	Bal.
T-20	0.10	10.0	15.5	3.0	4.5	3.6	2.2	5.0	0.6	Bal.

(6)自适应学习建模 首先基于初始数据库,以合金成分作为输入特征,以高温拉伸伸长率作为输出性能,进行机器学习模型训练,依据本团队前期研究^[22],此处选用的机器学习模型为GPR模型。然后,用训练好的模型对设计空间中尚未探索的合金进行预测。再根据预测结果计算设计空间中各个合金的期望函数EI^[26]:

$$EI = \int_{\mu^*}^{\infty} (y - \mu^*) P(y|x') dy = \sigma [\phi(z) + z\Phi(z)] \quad (3)$$

$$z = \frac{(\mu - \mu^*)}{\sigma} \quad (4)$$

式中, μ 和 σ 分别表示通过机器学习模型获得的设计空间中各合金塑性的均值与不确定性; y 表示预测值; μ^* 表示数据库中合金性能的最大值; $\phi(z)$ 表示标准正态密度函数; $\Phi(z)$ 表示标准正态分布函数。随后,推荐EI值最高的合金开展新的实验,并将实验结果反馈至数据库。重复上述步骤

以实现多次迭代反馈,不断完善合金成分与高温塑性之间的关系模型。

2 实验结果

2.1 设计空间优化

对相图计算获得的 106 种合金相平衡信息数据库的特征分析结果如图 2 所示。其中图 2a 是各合金元素成分之间的皮尔逊相关系数(ρ)热图,图中红色代表正相关($\rho>0$),蓝色代表负相关($\rho<0$),各元素成分之间的相关性大小由颜色的深浅表示,颜色越深表示相关性越大。可以看出不同元素之间的皮尔逊相关系数均处于 $-0.1\sim 0.3$ 之间,说明元素成分之间并不具备强相关性。这表明相平衡信息数据库中数据点分布均匀,不存在冗余数据。图 2b~d 为各合金元素成分与 f_{γ}^{800} 、 T_{γ} 、 T_L 之间的皮尔逊相关系数。从图 2b 看出,Al、Ti 和 Nb 元素对于 f_{γ}^{800} 影响最大。图 2c 看出,Al、Ti 元素对 T_{γ} 影响最大,而其他元素则未表现出较强的相关性。从图 2d 看出,Nb、Cr 和 Ti 是对于 T_L 影响最大的元素。综上,Al、Ti、Nb、Cr 元素是影响 f_{γ}^{800} 、 T_{γ} 、 T_L 的关键元素。由于皮尔逊相关系数仅能表示两个变量之间的线性相关性,为了更进一步分析合金元素对 f_{γ}^{800} 、 T_{γ} 、 T_L 的影响,采用随机森林重要性分析来对合金元素进行重要性排序。为提高排序结果的可靠性,共运行 50 次随机森林重要性分析,取各合金元素的平均重要性权重作为最终结果。各元素对 f_{γ}^{800} 、 T_{γ} 、 T_L 的重要性排序结果如图 2e~g。依据排序结果发现,Al、Ti 元素对 f_{γ}^{800} 、 T_{γ} 的重要性最高;对于 T_L 而言,Nb 元素影响最大,Cr、Ti、Mo 依次降低。以上结果与皮尔逊相关性分析结果基本一致。上述特征分析中,C 元素重要性均较

低,但 C 元素作为主要的晶界强化元素之一,对合金性能起到至关重要的作用^[27]。综上,本研究从 9 种合金元素中筛选出析出强化元素 Al、Ti、Nb,固溶强化元素 Cr 以及晶界强化元素 C 作为研究对象,其余 4 种元素按 GH4175 合金名义成分取值。据此,设计空间中合金数量从大于 6×10^7 缩小到 21 840。

为实现上述 21 840 种合金, f_{γ}^{800} 、 T_{γ} 和 T_L 的高效预测,训练了 5 种机器学习预测模型,结果如图 3 所示。其中图 3a 和 b 为 5 种模型在训练集上的均方根误差以及决定系数,从图中可以发现,XGboost、SVR-rbf 以及 RF 预测精度较低,GPR 预测对 γ' 含量的预测较好,Poly-2 模型对于 f_{γ}^{800} 、 T_{γ} 、 T_L 的预测均表现出最高的预测能力,其 R^2 超过了 0.98,而且 RMSE 也是 5 个模型中最低。图 3c 和 d 为 Poly-2 模型对 f_{γ}^{800} 、 T_{γ} 和 T_L 的预测结果,其中蓝色点为训练集数据,红色点为验证集数据。可以看出图中数据点基本分布在对角线上,表明预测结果与相图计算结果基本一致;即使在训练数据稀疏的地方,其预测结果仍与相图结果基本吻合。这说明,Poly-2 模型的预测能力及泛化能力均较高。因此,最终确定 Poly-2 模型作为 f_{γ}^{800} 、 T_{γ} 、 T_L 的预测模型。

进一步通过 Poly-2 模型计算了上述 21 840 种合金的 f_{γ}^{800} 、 T_{γ} 和 T_L 值,结果如图 4a 所示。图中横、纵坐标分别表示合金的 T_{γ} 和 T_L ,点的颜色表示合金的 f_{γ}^{800} 大小。从图中可以发现, f_{γ}^{800} 值较高的点主要分布在图的右下角,此区域 T_{γ} 值高、 T_L 低,对应热加工窗口($T_b=T_L-T_{\gamma}$)很小,这与文献报道的规律相符合^[3]。以 800°C 的 γ' 相体积分数 $f_{\gamma}^{800}>50\%$ 和热加工窗口温度 $T_b>70^{\circ}\text{C}$ 为条件进行合金筛选,结果如图 4b 所示,最终设计空间中合金数量降低到 9 095 个。

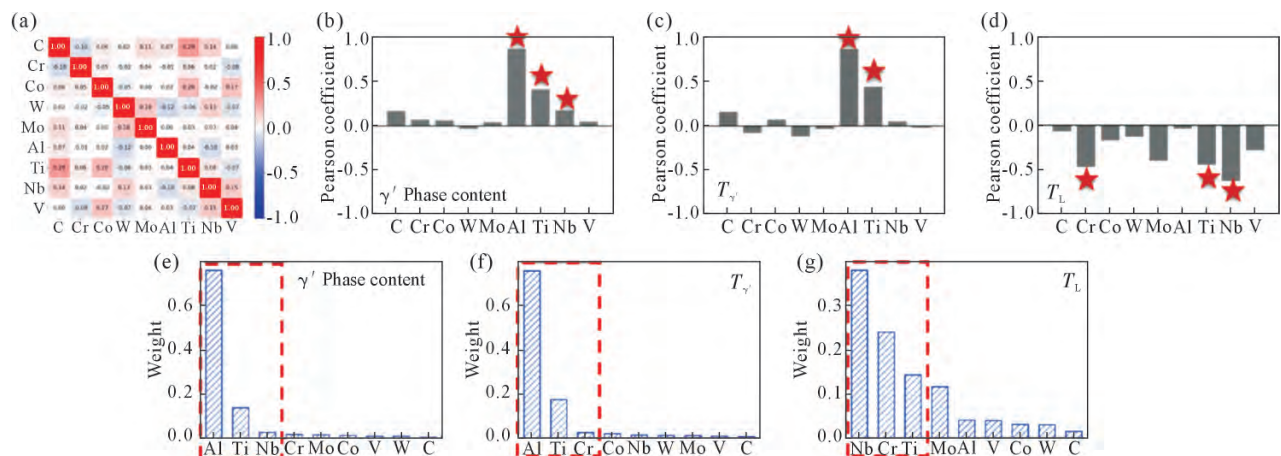


图2 基于特征工程筛选合金元素:(a)合金元素成分之间皮尔逊相关系数;(b~d)合金元素与 f_{γ}^{800} 、 T_{γ} 、 T_L 之间的皮尔逊相关系数;(e~g)合金元素对 f_{γ}^{800} 、 T_{γ} 、 T_L 的随机森林重要性排序结果

Fig.2 Element screening based on feature engineering: (a) Pearson's correlation coefficient between the elements; (b~d) Pearson's correlation coefficient between the elements and f_{γ}^{800} , T_{γ} , T_L respectively; (e~g) random forest importance analysis of elements for f_{γ}^{800} , T_{γ} , T_L

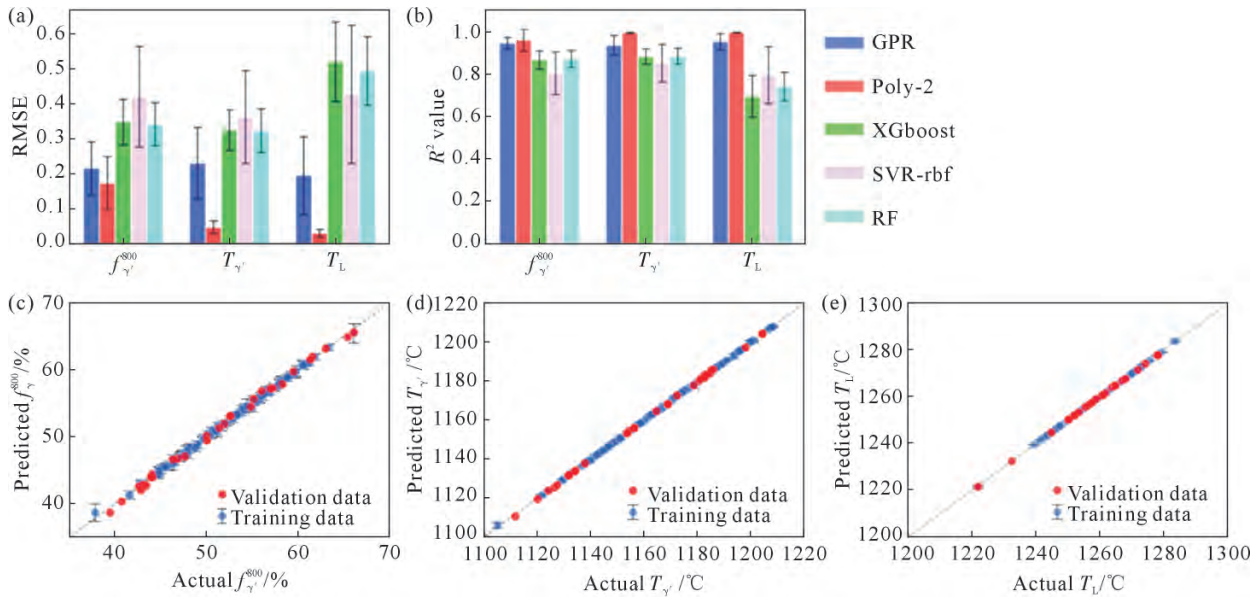


图3 5种模型对 f_{γ}^{800} 、 T_{γ} 、 T_L 的预测性能比较: (a) RMSE; (b) R^2 ; (c) f_{γ}^{800} ; (d) T_{γ} ; (e) T_L

Fig.3 Performances of the 5 trained ML models in predicting f_{γ}^{800} , T_{γ} , T_L : (a) RMSE; (b) R^2 ; (c) f_{γ}^{800} ; (d) T_{γ} ; (e) T_L

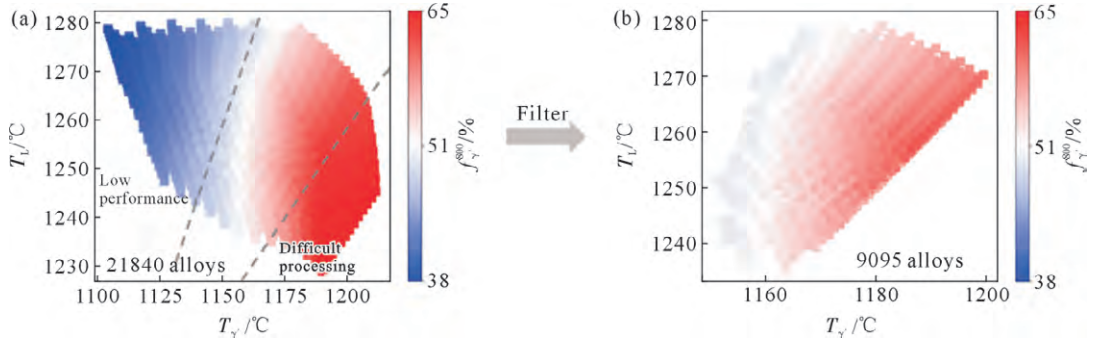


图4 Poly-2模型预测的各个合金的 f_{γ}^{800} 、 T_{γ} 、 T_L :(a)设计空间中21840种合金的结果;(b)依据 $f_{\gamma}^{800}>50\%$ 且 $T_D>70^{\circ}\text{C}$ 进行筛选后的剩余合金结果

Fig.4 Predictions of f_{γ}^{800} , T_{γ} and T_L via the trained Poly-2 model: (a) results for 21840 alloys in the design space; (b) results for alloys satisfying $f_{\gamma}^{800}>50\%$ and $T_D>70^{\circ}\text{C}$

2.2 高温性能测试

本文从筛选后的设计空间中选择了19种合金和名义成分合金进行1170℃高温拉伸性能测试,进而建立合金高温塑性数据库。图5a和b为上述20组合金的高温拉伸曲线,从图中可以发现,20种合金的高温拉伸曲线存在较大差异,屈服强度最大值(试样T-3)与最小值(试样T-10)相差近92%,伸长率最大值(试样T-17)与最小值(试样T-2)相差近75%。这些结果表明,通过在设计空间内改变合金的成分,可以在很大范围内改变合金的高温塑性,并且有希望寻找具有更好性能的合金。

2.3 成分-高温塑性建模及迭代优化

基于上述20组高温拉伸数据训练的GPR模型预测结果如图6a所示,可以看出模型预测精度不高,特别是对高伸长率范围的预测存在较大不确定性(图中黄色圈内数据点误差棒范围大)。这主要是由于初始数据样本分布不均匀,高伸长率区域的数据较少所致。为优化模型预测精度,使用EGO方

法,结合模型预测的设计空间中合金伸长率的均值与不确定性,计算合金的优化期望EI值来推荐合金进行实验并反馈到数据集中。4轮迭代所推荐的4个合金命名为E-1至E-4,其伸长率预测结果及实验结果如图6b所示。4轮迭代推荐合金的伸长率预测值均超过50%,这表明自适应学习策略主要针对高伸长率区域进行了模型优化。从图6b中可以看出,合金E-1的伸长率实际值与预测值接近,而合金E-2和E-3的实际值与预测值存在较大差异。这些预测误差较大的合金为模型修正高伸长率区域的预测提供了机会,有助于提高整体模型的精度。合金E-4的实际值与预测值基本相同,且预测的方差相比第一轮迭代结果明显降低,表明随着迭代次数的增加,模型对高伸长率区域的预测精度得到提升。

为进一步定量观测上述训练模型对设计空间中的9095种合金高温塑性的预测均值和方差,采用主成分分析(principal component analysis, PCA)方法对5种元素(Al、Ti、Nb、Cr和C)浓度形成的高维数据

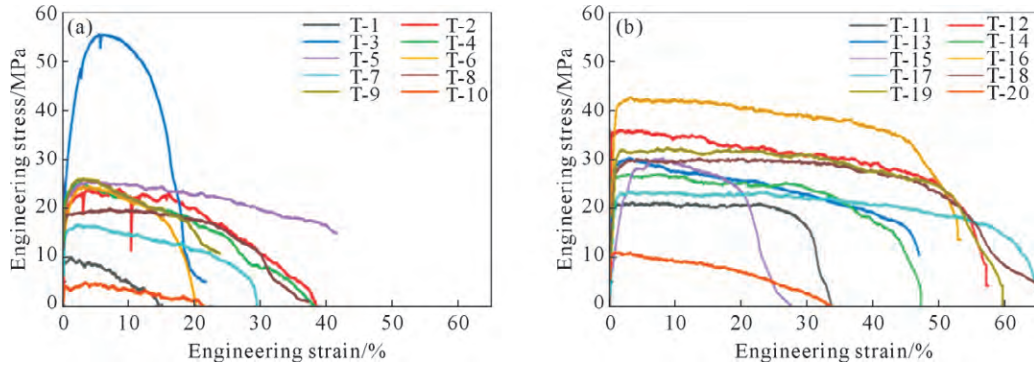


图5 GH4175 合金 1170 °C 拉伸曲线:(a) T1-T10 合金;(b) T11-T20

Fig.5 Tensile curves of the GH4175 alloys at 1170 °C: (a) T1-T10 alloys; (b) T11-T20 alloys

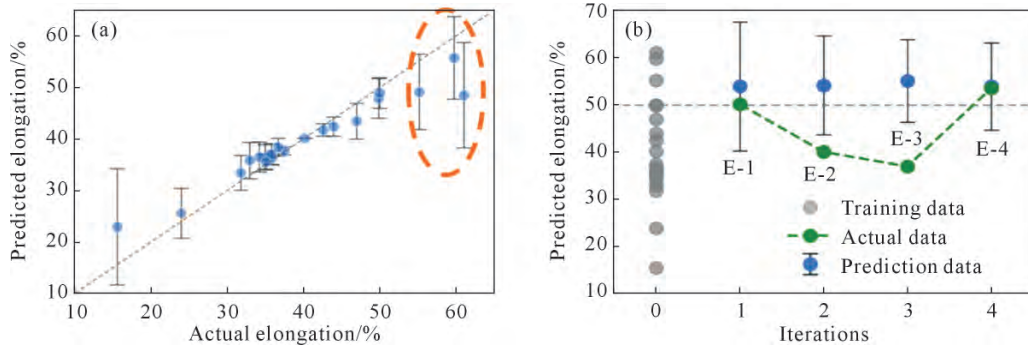


图6 自适应学习策略预测及实验结果:(a) 基于初始数据库的高温伸长率预测值与实测值;(b) 迭代过程中推荐合金的预测值与实测值

Fig.6 Results of the adaptive learning strategy: (a) the predicted high-temperature elongation based on the initial database and the experimental value; (b) prediction and experimental results for the recommended alloys during iteration

进行降维处理,在降维后前2个主成分变量(PC1和PC2)构成的二维平面内可清晰展示9095种合金高温塑性预测均值或方差,结果如图7所示。图中的每1个点代表设计空间中的1个合金,点的颜色表示该合金的伸长率预测均值或预测方差。图7a和b分别为基于初始数据库的训练模型的预测均值和方差,可以看到除了高伸长率的部分区域(灰色圆圈范围内)预测方差相对较小,初始模型对大部分合金的预测方差普遍较高,说明初始训练的GPR模型整体预测精度较低。图7c和d展示了经过4次迭代后训练模型对设计空间中合金伸长率的预测均值和方差。对比图7b和d发现设计空间中绝大多数合金的预测方差都有所下降,特别是图中灰色圆圈所对应的高伸长率合金的方差显著降低,说明经过4次迭代,模型对高伸长率合金具备了较好的预测能力。

如要进一步提高预测模型的精度,可以考虑增加迭代次数。但本文通过4轮迭代后推荐合金E-4的高温伸长率达到53.5%,已显著高于名义成分合金(试样T15)35.5%的高温伸长率;且本文的主要目的是分析高塑性合金的成分选择范围,而非找到一个具有最高伸长率的合金成分,因此未再进行更多轮次的迭代。

3 讨论

3.1 高温塑性与合金成分的关联

通过上述高温塑性预测模型,可以获得设计空间中9095种合金在1170 °C的伸长率,进而分析具有高塑性特点的合金中Al、Ti、Nb、C和Cr元素的成分范围。从设计空间中进一步选择满足 $f_{\gamma}^{800} > 55\%$ 的合金进行分析,从而保证候选合金同时具备服役温度下的高强度以及良好的高温塑性。满足 $f_{\gamma}^{800} > 55\%$ 设定的合金数量从9095下降到2724。图8展示了这2724种合金在1170 °C下的伸长率、800 °C下的 γ' 相含量 f_{γ}^{800} 及热加工窗口温度 T_D 随各种元素浓度的变化情况。图中的每个数据点代表设计空间中的一个合金,红色点对应伸长率大于50%的合金。由于一些合金的结果相似,因此部分数据点重叠。

对Al元素而言,从图8a可以看出,高伸长率的合金中Al含量均在上限(4.4%,质量分数,下同);从图8b和c可以看出,这些高伸长率的合金中存在 f_{γ}^{800} 含量较高、 T_D 较宽的情况,因此Al元素可选择浓度上限(4.4%)。从图8d-f可看出,高伸长率合金中Ti元素含量在中下限(2.0%~2.6%),且高伸长率合金的 f_{γ}^{800} 随Ti元素含量增加呈现上升趋势, T_D 随Ti元素含

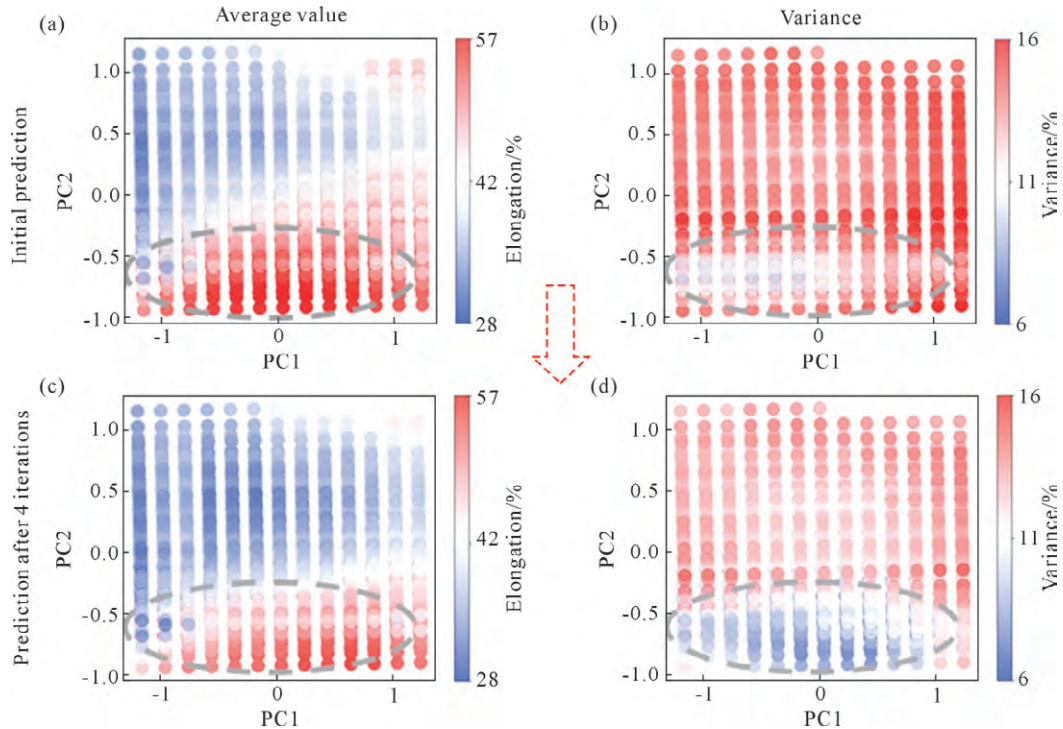


图7 GPR模型对高温延伸率的预测结果:(a, b)基于初始数据库训练模型的预测均值和方差;(c, d)经过4次迭代训练后的模型预测均值和方差

Fig.7 Prediction of high-temperature elongation via the GPR model: (a, b) average value and variance via the prediction model trained with the initial database; (c, d) average value and variance via the prediction model trained after 4 iterations

量增加呈现下降趋势,综合考虑,Ti元素取值宜在2.2%~2.6%。从图8g~i可以看出,高伸长率合金中Nb元素含量在下限附近(3.8%~4.0%),且此成分范围的高伸长率合金中也存在高 f_{γ}^{800} 和宽的 T_D 情况,因此Nb元素含量宜在3.8%~4.0%。从图8j~l可发现,高伸长率的合金中C元素含量在中高浓度(0.08%~0.12%),该成分范围合金中也存在高 f_{γ}^{800} 和宽 T_D 的情况,因此,C元素含量宜在0.08%~0.12%;这一结果与Theska等^[9]对René 41变形高温合金研究结论相一致,他们研究发现高碳含量合金晶界处会发生碳的偏析和溶质的富集,这种特性有效地防止了晶界开裂,从而使合金展现出优异的延展性。图8m~o表明,相比其它元素,高伸长率合金中Cr元素可以在更大的浓度范围内变化,在此范围内,Cr含量过低时, f_{γ}^{800} 低,Cr含量高时, T_D 降低,所以Cr宜选择中间浓度9.4%~10.6%。进一步分析Al元素与Ti元素含量比值与合金性能的关联,结果如图8p~r所示,可以发现高伸长率合金的Al/Ti含量比值靠近中上限(1.6~2.2),高伸长率合金的 f_{γ}^{800} 随Al/Ti含量比值升高呈下降趋势,而 T_D 呈上升趋势,综合考虑后,Al/Ti含量比值宜在1.6~2.0之间。

24组高温拉伸试验中高伸长率合金的实际成分与上述规律相符合,如试样E-4和T-12的伸长率分别为53.5%和59.8%,二者中Al、Ti、Nb、Cr和C元素

含量分别为:4.4%Al-2.2%Ti-3.8%Nb-0.1%C-10.2%Cr以及4.4%Al-2.6%Ti-3.8%Nb-0.1%C-10.6%Cr,处于上述高塑性合金推荐成分范围之内。而GH4175名义成分合金试样(试样T-15)中C(0.06%)、Al(4.0%)、Nb(4.5%)含量均在上述推荐范围之外,其伸长率仅35.1%。

3.2 高温塑性与微观组织的关联

为分析合金在1170℃具有良好伸长率的原因,选择2种满足上述推荐成分范围的合金(试样E-4和T-12)进行微观组织观测,并将其与名义成分合金(试样T-15)进行对比。

图9a~c为上述3种合金在均匀化热处理后的通过SEM观测的 γ' 相组织,可以发现此时3种合金中均存在粗大的一次 γ' 相,其平均尺寸接近1 μm 。将上述均匀化热处理的合金按照高温拉伸的升温速率在热处理炉中再次加热到1170℃,短暂保温后(时间与高温拉伸实验中试样温度均匀化设定的保温时间相同)快速水冷淬火,此状态下3种合金试样的SEM观测组织分别如图9d~f所示,这些组织对应于高温拉伸实验中合金的初始组织。可以看到3种合金中粗大的一次 γ' 相完全溶解,仅剩下水冷过程中形成的细小的二次 γ' 相,平均尺寸均小于50nm。这表明上述合金在1170℃拉伸时, γ' 相已完全溶解,合金处于 γ 单相状态, γ 相组织状态是决定其高温

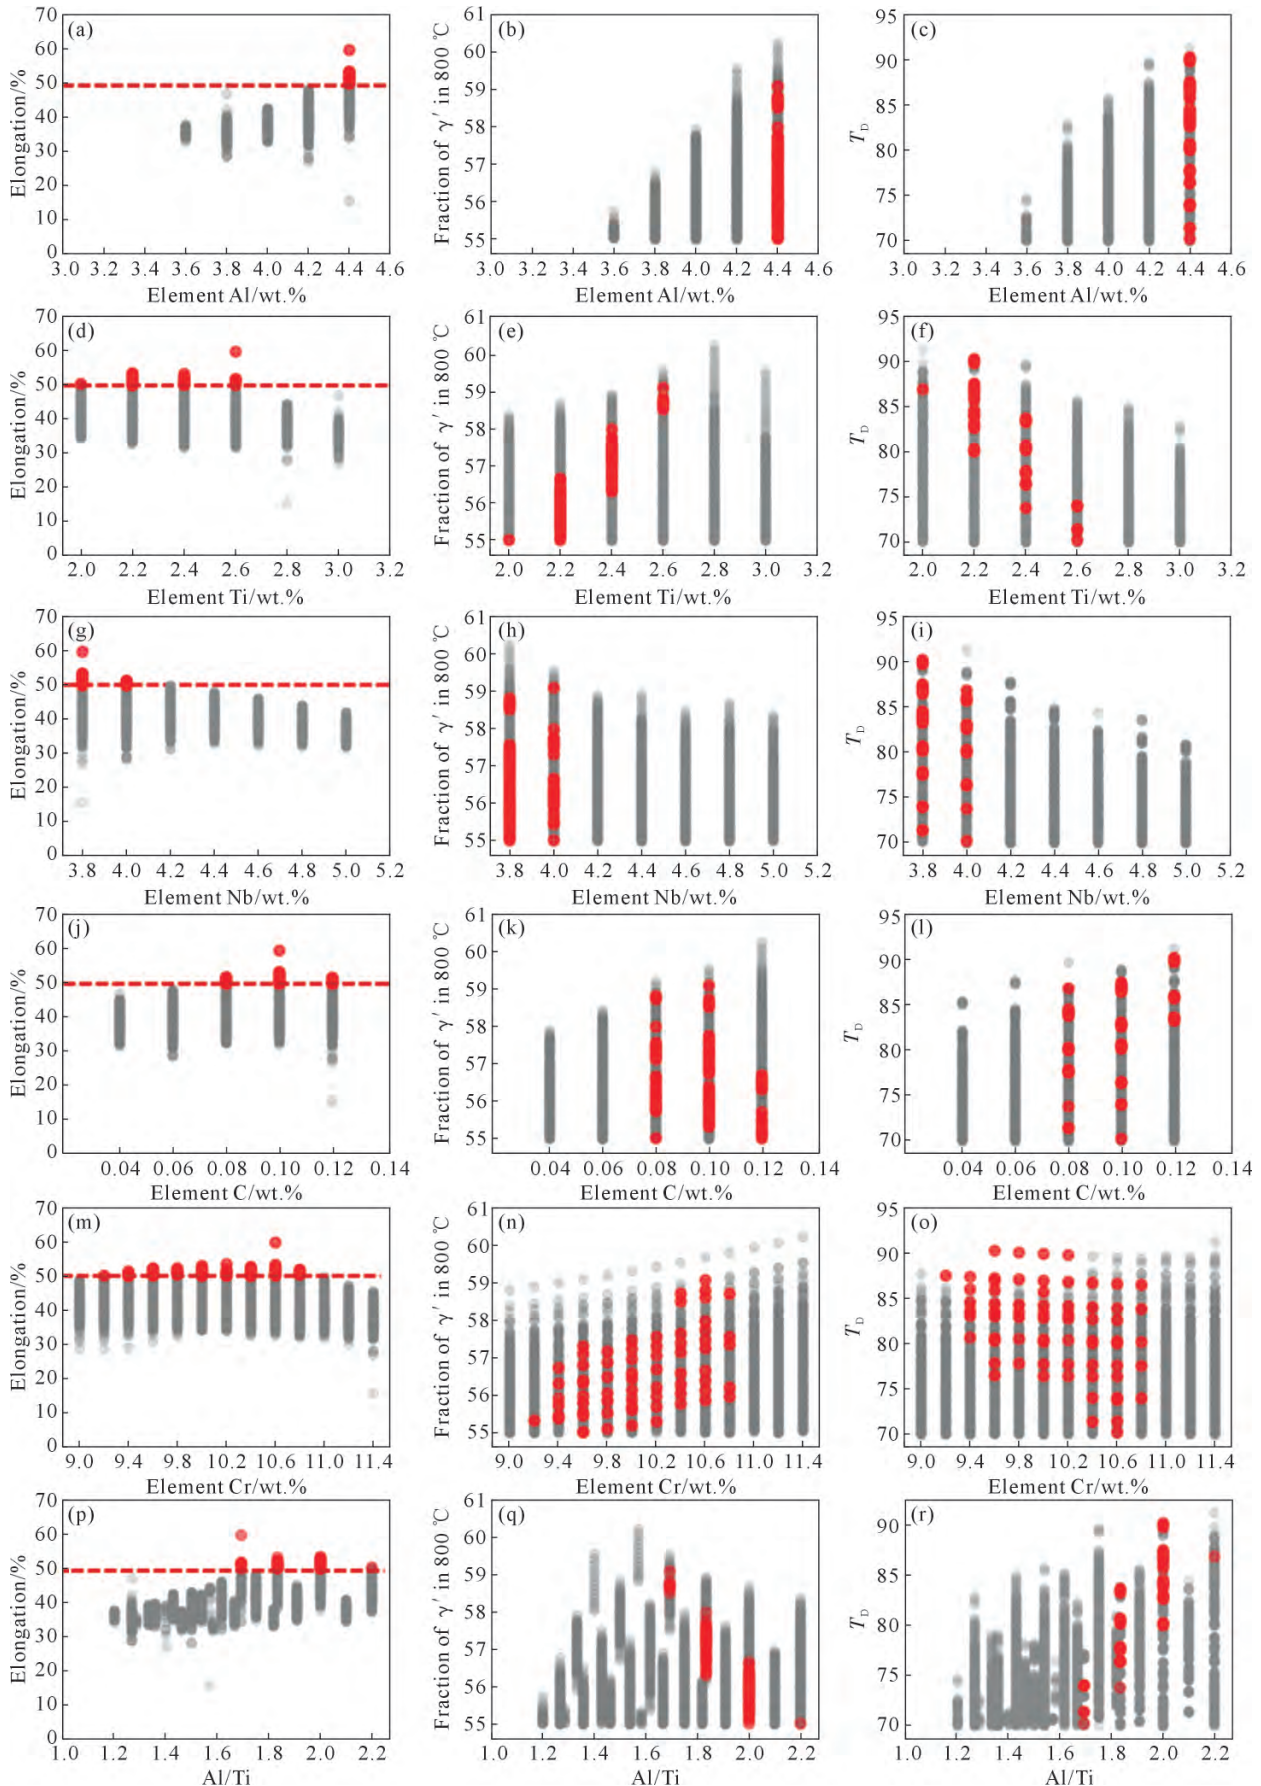


图8 合金 δ 、 $f_{\gamma'}$ 、 T_b 随各元素浓度的变化:(a~c) Al 元素;(d~f) Ti 元素;(g~i) Nb 元素;(j~l) C 元素;(m~o) Cr 元素;(p~r) Al/Ti 含量比值

Fig.8 Distribution of δ , $f_{\gamma'}$ and T_b corresponding to different element contents: (a~c) Al; (d~f) Ti; (g~i) Nb; (j~l) C; (m~o) Cr; (p~r) ratio of Al to Ti




图9 名义成分合金(试样 T15)与高塑性合金(试样 T12 和 E4)中的 γ' 相组织:(a~c) 均匀化热处理后的组织;(d~f) 1 170 °C 淬火组织

Fig.9 γ' phase in the alloy with a nominal composition (sample T15) and those with high elongation (samples T12 and E4): (a~c) microstructures after homogenization treatment; (d~f) microstructures quenched from 1 170 °C

塑性的主要因素。

图 10 展示了 3 种合金在 1 170 °C 短暂保温后水冷试样的 γ 晶粒组织形态, 左下角标注了平均晶粒尺寸。可以看出, 与名义成分合金(图 10a)相比, E-4 和 T-12 合金(图 10b 和 c)的晶粒尺寸明显细小, 其中 T-12 合金的晶粒尺寸最小, 约为 165 μm 。已有大量研究^[28]表明, 对变形高温合金而言, 较大的晶粒尺寸通常会导致较差的高温塑性, 而细小晶粒可以使变形更均匀并减少应力集中, 同时细小晶粒引起的晶界的曲折度增加也对裂纹扩展形成更大阻碍, 从而减少开裂机会。上述分析表明, E-4 和 T-12 合金优异的高温伸长率主要与其细小的晶粒尺寸相关。

4 结论

通过热力学相图计算和特征工程分析, 筛选出

影响 GH4175 合金 800 °C 下 γ' 相含量 $f_{\gamma'}^{800}$ 、 γ' 相完全溶解温度 T_{γ} 和合金初始液化温度 T_L 的主要元素, 并进一步通过针对上述相平衡特征的机器学习模型预测结果, 筛选出的满足 $f_{\gamma'}^{800} > 50\%$ 且热加工窗口 $T_D = T_L - T_{\gamma} > 70$ °C 的成分组合。在此优化后的成分空间中, 通过 1 170 °C 高温拉伸实验及自适应学习方法, 构建了 GH4175 合金高温塑性与 5 种合金元素含量之间的关系模型, 获得了高温塑性优异的合金中 Al、Ti、Nb、C 和 Cr 元素的浓度范围及微观组织特征。以下是得到的主要结论。

(1) Al、Ti 和 Nb 是影响 γ' 相体积分数的关键元素, Al、Ti 是影响 γ' 相完全溶解温度的关键元素, 而 Nb、Cr、Ti 是影响初始液化温度的关键元素。

(2) 在保证 $T_D > 70$ °C 和 $f_{\gamma'}^{800} > 55\%$ 的前提下, 为了提高 GH4175 合金高温塑性, 建议 Al 元素取成分范




图 10 合金 1 170 °C 淬火后的 γ 晶粒组织: (a) 名义成分合金(试样 T15); (b) 高塑性合金(试样 T12); (c) 高塑性合金(试样 E4)
Fig.10 Microstructure of the γ phase for alloys quenched at 1 170 °C: (a) the alloy with nominal composition (sample T15); (b) the alloy with high elongation (sample T12); (c) the alloy with high elongation (sample E4)

围上限(4.4%),Ti元素取成分范围中下限(2.2%~2.6%),Nb含量取成分范围下限附近(3.8%~4.0%),C元素取成分范围中上限(0.08%~0.12%),Cr元素取成分中间范围(9.4%~10.6%),Al/Ti含量比值维持在1.6~2.0。

(3)成分为4.4%Al-2.2%Ti-3.8%Nb-0.1%C-10.2%Cr以及4.4%Al-2.6%Ti-3.8%Nb-0.1%C-10.6%Cr的2种合金在170℃伸长率分别达到53.5%和59.8%,显著高于GH4175名义成分合金,原因在于前面二者在高温单相区的 γ 晶粒更为细小。

参考文献:

- [1] ZHANG W Y, HUANG S, TIAN Q, QING H Y, XU G H, ZHAO G P, ZHANG B J. Microstructure control and mechanical properties of new developed C&W superalloy GH4175 at 800 °C[J]. IOP Conference Series: Materials Science and Engineering, 2018, 452(2): 022123.
- [2] 张勇,李鑫旭,韦康,万志鹏,贾崇林,王涛,李钊,孙宇,梁红艳. 850℃涡轮盘用新型变形高温合金GH4975挤压棒材热变形规律研究[J]. 金属学报, 2020, 56(10): 1401-1410.
ZHANG Y, LI X X, WEI K, WAN Z P, JIA C L, WANG T, LI Z, SUN Y, LIANG H Y. Hot deformation characteristics of novel wrought superalloy GH4975 extruded rod used for 850 °C turbine disc[J]. Acta Metallurgica Sinica, 2020, 56(10): 1401-1410.
- [3] 江河,董建新,张麦仓,姚志浩. 800℃以上服役涡轮盘用难变形镍基高温合金研究进展[J]. 航空制造技术, 2021, 64(1): 62-73.
JIANG H, DONG J X, ZHANG M C, YAO Z H. Development of typical hard-to-deform nickel-base superalloy for turbine disk served above 800 °C[J]. Aeronautical Manufacturing Technology, 2021, 64(1): 62-73.
- [4] 张北江,黄烁,张文云,田强,陈石富. 变形高温合金盘材及其制备技术研究进展[J]. 金属学报, 2019, 55(9): 1095-1114.
ZHANG B J, HUANG S, ZHANG W Y, TIAN Q, CHEN S F. Recent development of nickel-based disc alloys and corresponding cast-wrought processing techniques [J]. Acta Metallurgica Sinica, 2019, 55(9): 1095-1114.
- [5] ZHANG B J, ZHAO G P, ZHANG W Y, XU G H, QIN H Y. Deformation mechanisms and microstructural evolution of $\gamma+\gamma'$ duplex aggregates generated during thermomechanical processing of nickel-base superalloys[M]// HARDY M, HURON E, GLATZEL U, GRIFFIN B, LEWIS B, RAE C, SEETHARAMAN V, TIN S. Superalloys 2016: Proceedings of the 13th International Symposium of Superalloys. New York: John Wiley & Sons, 2016: 487-496.
- [6] YANG Z S, LIU X, ZHAO J J, ZENG Q H, XU K F, LI Y, WANG C Y, WANG L, LI J J, WANG J C, KIM H S, WANG Z J, HE F. Discontinuous coarsening leads to unchanged tensile properties in high-entropy alloys with different recrystallization volume fractions[J]. International Journal of Plasticity, 2024, 176: 103963.
- [7] 杜金辉,吕旭东,邓群,庄景云. GH4169合金研制进展[J]. 中国材料进展, 2012, 31(12): 12-20, 11.
DU J H, LYU X D, DENG Q, ZHUANG J Y. Progress in GH4169 alloy development[J]. Materials China, 2012: 12-20, 11.
- [8] ZHANG A W, ZHANG S, LIU F, QI F, YAO X Y, TAN Y G, JIA D, SUN W R. Effect of cooling rate on phosphorus segregation behavior and the corresponding precipitation of γ'' and γ' phases in IN718 alloy [J]. Journal of Materials Science and Technology, 2019, 35(7): 1485-1490.
- [9] THESKA F, STREET S R, LISON-PICK M, PRIMIG S. Grain boundary microstructure-property relationships in the cast & wrought Ni-based superalloy René 41 with boron and carbon additions[J]. Acta Materialia, 2023, 258: 119235.
- [10] KONTIS P, ALABORT E, BARBA D, COLLINS D M, WILKINSON A J, REED R C. On the role of boron on improving ductility in a new polycrystalline superalloy[J]. Acta Materialia, 2017, 124: 489-500.
- [11] OU M Q, MA Y C, GE H L, XING W W, ZHOU Y T, ZHENG S J, LIU K. Microstructure evolution and mechanical properties of a new cast Ni-base superalloy with various Ti contents[J]. Journal of Alloys and Compounds, 2018, 735: 193-201.
- [12] 姚志浩,董建新,张麦仓,张玉峰,谢伟,李蓬川. 高强GH4738合金成分设计计算与验证[J]. 稀有金属材料与工程, 2017, 46(11): 3382-3387.
YAO Z H, DONG J X, ZHANG M C, ZHANG Y F, XIE W, LI P C. Composition optimization design and verification for nickel based high strength superalloy GH4738 [J]. Rare Metal Materials and Engineering, 2017, 46(11): 3382-3387.
- [13] 谢建新,宿彦京,薛德祯,姜雪,付华栋,黄海友. 机器学习在材料研发中的应用[J]. 金属学报, 2021, 57(11): 1343-1361.
XIE J X, SU Y J, XUE D Z, JIANG X, FU H D, HUANG H Y. Machine learning for materials research and development[J]. Acta Metallurgica Sinica, 2021, 57(11): 1343-1361.
- [14] YU J X, WANG C L, CHEN Y C, WANG C P, LIU X J. Accelerated design of L12-strengthened Co-base superalloys based on machine learning of experimental data[J]. Materials & Design, 2020, 195: 108996.
- [15] LIU Y, WU J M, WANG Z C, LU X G, AVDEEV M, SHI S Q, WANG C Y, YU T. Predicting creep rupture life of Ni-based single crystal superalloys using divide-and-conquer approach based machine learning[J]. Acta Materialia, 2020, 195: 454-467.
- [16] QIN Z J, WANG Z, WANG Y Q, ZHANG L N, LI W F, LIU J, WANG Z X, LI Z H, PAN J, ZHAO L, LIU F, TAN L M, WANG J X, HAN H, JIANG L, LIU Y. Phase prediction of Ni-base superalloys via high-throughput experiments and machine learning[J]. Materials Research Letters, 2021, 9(1): 32-40.
- [17] 邓钥丹,胡旺,连利仙,巩秀芳,刘颖,章语,王誉程. 数据驱动的镍基高温合金多目标优化设计与开发[J]. 铸造技术, 2022, 43(5): 351-356.
DENG Y D, HU W, LIAN L X, GONG X F, LIU Y, ZHANG Y, WANG Y C. Data-driven multi-objective optimization design and development of Ni-base superalloy[J]. Foundry Technology, 2022, 43(5): 351-356.
- [18] 张国栋,苏宝龙,廖玮杰,王晓峰,邹金文,袁睿豪,李金山. 机器学习在高温合金粉末盘构件疲劳寿命预测中的应用[J]. 铸造技术, 2022, 43(7): 519-524.
ZHANG G D, SU B L, LIAO W J, WANG X F, ZOU J W, YUAN R H, LI J S. Prediction of fatigue life of powder metallurgy super-

- alloy disk via machine learning[J]. Foundry Technology, 2022, 43 (7): 519-524.
- [19] XUE D Z, BALACHANDRAN P V, HOGDEN J, THEILER J, XUE D Q, LOOKMAN T. Accelerated search for materials with targeted properties by adaptive design[J]. Nature Communications, 2016, 7: 11241.
- [20] LI H C, YUAN R H, LIANG H, WANG W Y, LI J S, WANG J. Towards high entropy alloy with enhanced strength and ductility using domain knowledge constrained active learning[J]. Materials & Design, 2022, 223: 111186.
- [21] XUE D Z, XUE D Q, YUAN R H, ZHOU Y M, BALACHANDRAN P V, DING X D, SUN J, LOOKMAN T. An informatics approach to transformation temperatures of NiTi-based shape memory alloys[J]. Acta Materialia, 2017, 125: 532-541.
- [22] HU X B, ZHAO J J, LI J J, WANG Z J, CHEN Y M, WANG J C. Global-oriented strategy for searching ultrastrength martensitic stainless steels[J]. Advanced Theory and Simulations, 2022, 5(3): 2100411.
- [23] LIU P, HUANG H Y, ANTONOV S, WEN C, XUE D Z, CHEN H W, LI L F, FENG Q, OMORI T, SU Y J. Machine learning assisted design of γ' -strengthened Co-base superalloys with multi-performance optimization[J]. npj Computational Materials, 2020, 6: 62.
- [24] 林莺莺, 于秋颖, 贺晓勇, 东赟鹏, 方爽, 陈由红, 张敏聪. 难变形高温合金 GH4175 铸态组织及均匀化工艺[J]. 材料热处理学报, 2021, 42(8): 54-60.
- LIN Y Y, YU Q Y, HE X Y, DONG Y P, FANG S, CHEN Y H, ZHANG M C. As-cast microstructure and homogenization process of difficult-to-deform GH4175 superalloy[J]. Transactions of Materials and Heat Treatment, 2021, 42(8): 54-60.
- [25] 林莺莺, 东赟鹏, 于秋颖, 方爽. 铸态 GH4175 合金高温变形行为及热加工图研究[J]. 精密成形工程, 2022, 14(1): 133-140.
- LIN Y Y, DONG Y P, YU Q Y, FANG S. High temperature deformation behavior and hot processing map of as-cast GH4175 alloy [J]. Journal of Netshape Forming Engineering, 2022, 14(1):133-140.
- [26] BALACHANDRAN P V, XUE D Z, THEILER J, HOGDEN J, LOOKMAN T. Adaptive strategies for materials design using uncertainties[J]. Scientific Reports, 2016, 6: 19660.
- [27] ZHAO G D, ZANG X M, JING Y, LU N, WU J J. Role of carbides on hot deformation behavior and dynamic recrystallization of hard-deformed superalloy U720Li[J]. Materials Science and Engineering: A, 2021, 815: 141293.
- [28] 徐志超, 屈波, 谢锡善, 程秀峰. 晶粒大小及 Mg 对 GH169 合金持久与缺口周期持久性能的影响 [J]. 北京钢铁学院学报, 1987 (4): 38-44.
- XU Z C, QU B, XIE X S, CHENG X F. The effects of grain size and magnesium addition on stress rupture and notched cyclic stress rupture properties of GH169 superalloy[J]. Journal of Beijing University of Iron and Steel Technology, 1987(4): 38-44.