引用格式:何星星,王瑶祺,张岳,等.基于可解释性机器学习的铝合金 GTAW 质量在线监测[J].热加工工艺,2026,55(5):205-210+215.
HE Xingxing, WANG Yaoqi, ZHANG Yue, et al. Online Quality Monitoring of Aluminum Alloy GTAW Based on Explainable Machine Learning [J]. Hot Working Technology, 2026, 55(5): 205-210+215.
DOI: 10.14158/j.cnki.1001-3814.20240065

基于可解释性机器学习的铝合金 GTAW 质量在线监测

何星星[1], 王瑶祺[1], 张 岳[1], 洪宇翔[1,2]

(1. 中国计量大学 机电工程学院, 浙江 杭州 310018; 2. 浙江省智能制造质量大数据溯源与应用重点实验室, 浙江 杭州 310018)

摘 要:焊接过程及质量在线监测对铝合金钨极气体保护电弧焊(GTAW)的质量保障具有重要意义。提出一种基于熔池视觉传感和可解释性机器学习的焊接状态在线监测方法。首先,采用被动视觉传感系统获取正面熔池图像;其次,提出一种图像多区域特征同步提取算法,实时提取熔池前端区域几何特征和熔池后端区域直线度特征,并分析了所提取视觉特征与焊接状态的相关性;最后,建立 CatBoost 模型识别典型焊接状态,并引入 SHAP 方法分析解释模型。实验结果表明,相较于现有方法重点关注的熔池前端区域几何特征,熔池后端区域直线度特征更能显著地表征 GTAW 熔池状态。所提出的方法能准确识别三种典型焊接状态,分类准确率达到 96.15%,且能定量分析各特征变量对识别结果的影响程度。

关键词:钨极气体保护电弧焊;焊接状态识别;熔池图像;特征提取;可解释性机器学习

中图分类号:TG409 **文献标识码**:A **文章编号**:1001-3814(2026)05-0205-06

Online Quality Monitoring of Aluminum Alloy GTAW Based on Explainable Machine Learning

HE Xingxing[1], WANG Yaoqi[1], ZHANG Yue[1], HONG Yuxiang[1,2]

(1. College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou 310018, China; 2. Key Laboratory of Intelligent Manufacturing Quality Big Data Tracing and Application of Zhejiang Province, Hangzhou 310018, China)

Abstract: Online monitoring of welding process and quality is of great significance for the quality assurance of aluminum alloy gas tungsten arc welding (GTAW). An online welding status monitoring method based on molten pool visual sensing and explainable machine learning was proposed. Firstly, a passive visual sensing system was used to acquire frontal molten pool images. Secondly, a image multi-region processing algorithm was proposed to extract geometric features of the molten pool's front-end area and straightness feature of the back-end area in real time, and the correlation between the extracted visual features and the welding status was analyzed. Finally, a CatBoost model was established to identify typical welding status, and SHAP (Shapley Additive exPlanations) method was introduced to explain the model. The experimental results show that compared with the geometric features of the molten pool's front-end area which are the focus of the existing methods, the straightness feature of the molten pool's back-end area is more effective in characterizing the molten pool state during the GTAW process. The proposed method can accurately identify the three typical welding status with an average accuracy of 96.15%, and can quantitatively analyze the influence of each feature variable on the recognition results.

Key words: gas tungsten arc welding (GTAW); welding status recognition; molten pool image; feature extraction; explainable machine learning

收稿日期:2024-01-08 **修回日期**:2025-10-11

基金项目:国家自然科学基金资助项目(51605251);浙江省自然科学基金项目(LY22E050009);浙江省教育厅科研资助项目(Y202249427);浙江省教育厅科研资助项目(Y202147838);浙江省属高校基本科研业务费专项资金资助(2023YW41)

作者简介:何星星,男,硕士,主要研究方向:机器人与智能化焊接;E-mail:s21010802003@cjlu.edu.cn

通讯作者:洪宇翔,男,博士,副教授,主要研究方向:智能化焊接与增材制造;E-mail:hongyuxiang@cjlu.edu.cn

随着人工智能的快速发展,智能制造已成为未来制造业的主流发展趋势。机器人智能化焊接作为智能制造的关键组成部分,致力于实现焊接质量、适应性和生产效率的全面提升[1]。焊接过程及质量在线监测是实现高效、高质量焊接的有力保证,也是智

能化焊接的关键技术之一。然而，基于传感器技术实现精准、可靠的焊接状态在线监测仍是智能焊接制造的瓶颈和难点[2]。

焊接过程中熔池形态与焊缝成形质量密切相关。与热成像[3]、声发射[4]、光谱仪[5]等其他类型传感技术相比，视觉传感器可以提供更直观和丰富的信息。其中，基于主动视觉的方法具有抗干扰能力强、图像结构化信息丰富等优点。例如，Li 等[6]利用激光视觉法建立了振荡熔池表面反射激光图像与不同熔透状态的映射关系。Peng 等[7]采用标准的激光三角测量装置获取焊缝熔池图像，提出了一种新的焊缝面特征“熔池凹陷度”。然而，这些研究通常需要借助辅助光源系统来观察熔池行为，增加了视觉系统光路结构的复杂性。相比之下，基于被动视觉的方法可以利用熔池自身辐射或弧光反射来获取熔池信息，具有成本低、可达性良好和更具工业实用性等优点。洪宇翔等[8]基于 CMOS 相机采集的氦弧焊熔池图像提取熔池特征参数，在线检测熔池失稳状态。基于阈值分割和形态学算法，肖宏等[9]高效地获得了 2219 铝合金氦弧焊熔池尺寸特征参数。

传统的机器学习方法如人工神经网络（artificial neural network，ANN）、支持向量机（support vector machine，SVM）和随机森林（random forest，RF）等被广泛应用于焊接质量监测。这些方法通过图像预处理步骤提取和选择特征，然后将其输入训练好的机器学习模型以获得预测结果，具有训练效率高、对数据量要求低等优点[10]。例如，刘亮等[11]以熔池宽度等焊接动态过程的多元信息作为输入，基于改进的 SVM 算法成功实现了未熔透、全熔透和过熔透的在线识别。Chen 等[12]基于主动外观轮廓提取的熔池视觉特征和 RF 算法实现了 GTAW 过程中熔透状态和焊缝宽度的评估。其中，集成学习方法通过整合多个基学习器、利用群体学习器的输出来补偿误差，可以有效提高整个学习系统的泛化能力和鲁棒性[13]。然而，缺乏可解释性仍然是阻碍机器学习模型（特别是集成学习和深度学习模型）在工业自动化生产领域进一步发展的主要原因之一，这尤其限制了其在航空航天、能源动力等安全敏感任务中的实际应用。

本文以 2219 铝合金 GTAW 过程为研究对象，提出了一种基于可解释性机器学习的过程监测与状态识别方法。首先，采用一种新颖的图像多区域特征同步提取算法提取熔池几何形态特征，并分析了各熔池特征变量与焊接状态变化的相关性；然后采用 CatBoost 模型在线识别多种典型焊接状态，引入 SHAP（shapley additive explanations，机器学习、深度学习解释库）方法[14]明确各熔池特征变量对分类模型贡献的相对重要性。

1 试验系统与方法

1.1 试验系统与参数

焊接试验系统主要包括视觉传感系统和机器人焊接设备，如图 1 所示。机器人焊接设备主要由焊接电源、机械臂、焊枪、控制柜、工控机、保护气体（He）和水冷箱组成。试验材料是 300 mm×150 mm×9.5 mm 的 2219 铝合金板。焊接电源的工作模式为直流正接（DCEN）。焊接试验为铝合金 GTAW，焊接工艺为钨极氦弧焊，氦气流量设置为 12 L/min。具体焊接试验参数见表 1。视觉传感系统由一台高速工业相机和中心波长为 660 nm 的窄带滤光片组成。窄带滤光片置于镜头前方以抑制强烈弧光干扰。焊接过程中，相机固定在焊枪上，调整相机光路轴线与焊枪成 45°角，从后上方监测熔池。

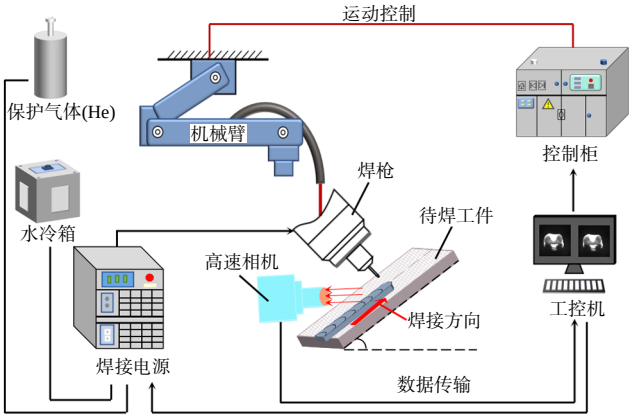


图 1 GTAW 试验系统示意图

Fig.1 Schematic diagram of GTAW experiment system

表 1 焊接试验参数

Tab.1 Welding experiment parameters

焊接速度 /(mm·min^{-1})	焊接电流 /A	焊接电压 /V	钨极直径 /mm
200	285~305	24.5	5.0

为了诱导真实焊接应用场景下可能出现的缺陷情况，在焊件倾斜一定角度的情况下，改变焊接电流进行了一系列焊接试验。根据焊缝外观，将焊接状态分为咬边、成形不良和良好焊缝三种。不同焊接状态的焊缝正面和背面形貌如图 2 所示。在整个焊接过程中，从工件后上方连续捕获序列熔池图像，采样帧

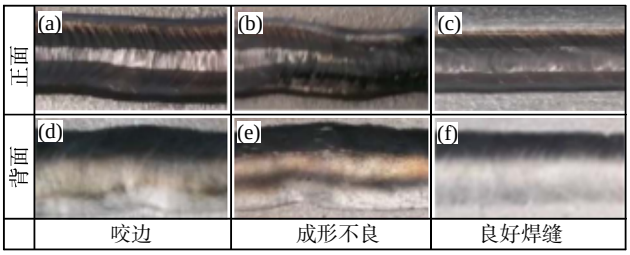


图 2 不同焊接状态下的焊缝成形
Fig.2 Weld forming under different welding status

率为 250 帧 /s。试验共采集熔池图像 4200 张，数据集细节如表 2 所示。

表 2 数据集细节
Tab.2 Dataset details

焊接状态	训练样本	测试样本	总和
咬边	1280	320	1600
成形不良	1280	320	1600
良好焊缝	800	200	1000
总和	3360	840	4200

1.2 熔池特征参数定义与提取

在本研究中，提取了 6 个特征来描述熔池区域的形态变化，特征参数定义如图 3 所示。具体来说，在熔池前端区域提取了 5 个特征，包括熔池面积 A、熔池质心(C_x,C_y)、熔池长度 L 和熔池宽度 W。在熔池后端区域提取直线度特征δ来描述熔池后端区域的形变程度。具体的量化公式如表 3 所示。

本文提出的特征提取算法主要包括熔池前端区域几何特征提取和熔池后端区域直线度特征提取两个部分。熔池前端区域几何特征提取时，首先通过高斯滤波、灰度切割、形态学算法等方法粗略提取熔池边界参数；然后，根据提取的边界参数自动从熔池图像中分离出感兴趣的熔池区域；最后，利用 ROI 分离熔池前端区域进行 Otsu 阈值分割，以获取熔池前端区域几何特征参数。熔池后端区域直线度特征提取时，首先为了准确提取熔池轮廓以量化直线度特征，采用自适应直方图均衡化和显著性检测方法对感兴趣熔池区域图像进行增强；然后，采用 Otsu 算法对增强后的感兴趣熔池图像进行二值化；最后，将二值化后的感兴趣熔池图像与二值化后的掩模图像进行逻辑或运算，以获取清晰的熔池轮廓边缘。图 4 给出了熔池特征提取算法的具体流程。

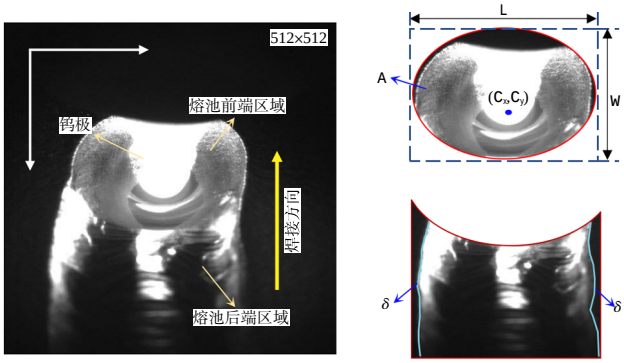


图 3 熔池特征量化示意图
Fig.3 Illustration view of molten pool features quantification

表 3 熔池特征量化公式
Tab.3 Quantitative formulas for molten pool features

特征	量化公式	参数描述
C_x	$C_x=\sum_{i=1}^{n}\sum_{j=1}^{m} g(i,j)\cdot i/\sum_{i=1}^{n}\sum_{j=1}^{m} g(i,j)$	g(i,j)为位置(i,j)处图像像素的灰度值
C_y	$C_y=\sum_{i=1}^{n}\sum_{j=1}^{m} g(i,j)\cdot j/\sum_{i=1}^{n}\sum_{j=1}^{m} g(i,j)$	同上
W	$W=\max u-\min u \quad (u,v)\in S$	S 是熔池前端区域像素坐标集合
L	$L=\max v-\min v \quad (u,v)\in S$	同上
A	$A=\sum_{i=1}^{n}\sum_{j=1}^{m} \mathrm{binary}(i,j)$	binary(i,j)是位置(i,j)处图像像素的二值化值
δ	$\delta_i=\sum_{n=1}^{N_i}\frac{\lvert\Delta L_{in}\rvert}{L_{in}}, i=l,r$ $\Delta L_l=\sum_{i=1}^{N_l}(L_{li}-\min u) \quad (u,v)\in S_l$ $\Delta L_r=\sum_{i=1}^{N_r}(\max u-L_{ri}) \quad (u,v)\in S_r$ $\delta=\beta\times\delta_l+(1-\beta)\times\delta_r, 0\leqslant\beta\leqslant 1$ $\beta=\max L_l/(\max L_l+\max L_r)$	δ_i是熔池后端区域单侧轮廓直线度；ΔL_{in} 是熔池后端区域在 u 轴方向的像素坐标值；$\lvert\Delta L_{in}\rvert$ 是熔池后端区域轮廓边界与 ΔL_{in} 距离的绝对值；N_i 是熔池后端区域在 v 轴方向上的像素集合；l 表示熔池后端区域沿 v 轴方向的左侧部分；r 表示熔池后端区域沿 v 轴方向的右侧部分；S_i 是熔池后端区域像素坐标值集合；β 为直线度因子

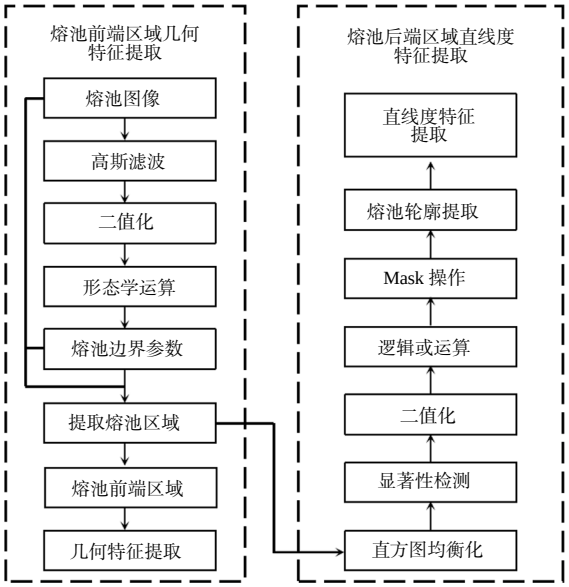


图 4 熔池特征提取流程图

Fig.4 Flowchart of molten pool feature extraction

2 CatBoost-SHAP 焊接质量预测模型

2.1 CatBoost 概述

分类梯度提升（categorical gradient boosting，CatBoost）是俄罗斯互联网公司 Yandex 在 2018 年提出的一种基于梯度提升决策树（gradient boost decision tree，GBDT）改进的高效集成学习算法。CatBoost 被提出用来有效地处理分类特征，它通过融合多个遗忘决策树作为弱学习器来建立强分类器，在防止过拟合的同时提高了模型的整体鲁棒性和准确性。通常，GBDT 算法使用贪婪目标统计将标签 y 的均值$\hat{x}_k^j$替换成第 k 个数据的第维特征$\hat{x}_k^j$，如下所示：

$$\hat{x}_k^j=\frac{\sum_{j=1}^{n}[x_j^i=x_k^i]\cdot y_j}{\sum_{j=1}^{n}[x_j^i=x_k^i]} \tag{1}$$

CatBoost 在此基础上增加了先验 p 以减少数据噪声对分类的影响，如式(2)所示：

$$\hat{x}_k^i=\frac{\sum_{j=1}^{n}[x_j^i=x_k^i]\cdot y_j+cp}{\sum_{j=1}^{n}[x_j^i=x_k^i]+c} \tag{2}$$

式中：x_k^i为第个 k 数据的第个 i 类别特征；$\hat{x}_k^i$为 x_k^i的无偏梯度估计；x_j^i为每次采样第 j 个数据的第 i 个类别特征；p 为先验项；c 为权重系数，$c>0$。

CatBoost 采用排序提升方法来有效对抗训练集中的噪声点，从而解决梯度估计误差和预测偏差问题。此外，该算法具有快速和可扩展的 GPU 实现，使模型的计算速度更快。因此，本文采用 CatBoost 算法建立焊接质量预测模型，并通过网格搜索算法对模型参数进行优化，来提高识别精度和效率。

2.2 SHAP 分析概述

在焊接状态识别任务中，理解模型为什么会做出某种预测与预测的准确率一样重要。作为最新的可解释的人工智能(XAI)，SHAP 可以打开黑盒模型如 XGboost、CatBoost、ANN 等，并解释模型对相应预测的决策，这一定程度上降低了人工智能模型的复杂性，从而有助于焊接操作人员分析焊接缺陷成形的具体原因并优化焊接工艺。因此，本文采用 SHAP 来增强基于 CatBoost 的焊接质量预测模型的可解释性。

SHAP 是一种量化单个特征的边际效应和两个特征的联合效应的博弈论方法。SHAP 可以通过计算每个特征对输出的贡献来解释任何机器学习模型的输出。它通过对每个特征分配一个分数来表明该特征在输出中的重要性，这个分数被称为 SHAP 值。SHAP 解释模型应该与原始模型相匹配，并且数据集中缺失的特征不被赋予重要属性。此外，即使我们修改模型以增加特征对模型的影响，赋予特征的属性也永远不会减少。SHAP 将模型的输出定义如下：

$$f(x)=g(z')=\phi_0+\sum_{i=1}^{M}\phi_i z_i' \tag{3}$$

式中：g（z'）为 SHAP 解释模型；ϕ_i 为 SHAP 值；$z_i'\in\{0,1\}$为二元变量。可以认为，SHAP 将预测任务分解为一个由二元变量组成的线性函数。通常可以使用 Kernel SHAP 和 Tree SHAP 两种方法来近似 SHAP 值。本文采用 Tree SHAP 近似 SHAP 值，因为它比 Kernel SHAP 快得多，并且可以与 CatBoost 等基于树的方法结合使用。

3 试验验证与分析

3.1 熔池特征参数与焊接状态相关性分析

不同焊接状态下熔池特征参数曲线随时间的变化规律如图 5 所示。可以看出，随着焊接电流的变化，焊件依次出现咬边、成形不良和良好焊缝等不同焊接状态。不同焊接状态下的熔池特征参数变化各异，熔池前端区域几何特征中熔池面积大致可以反映出焊接状态的变化趋势，但其他特征与焊接状态变化程度的相关性不高。此外，熔池后端区域直线度

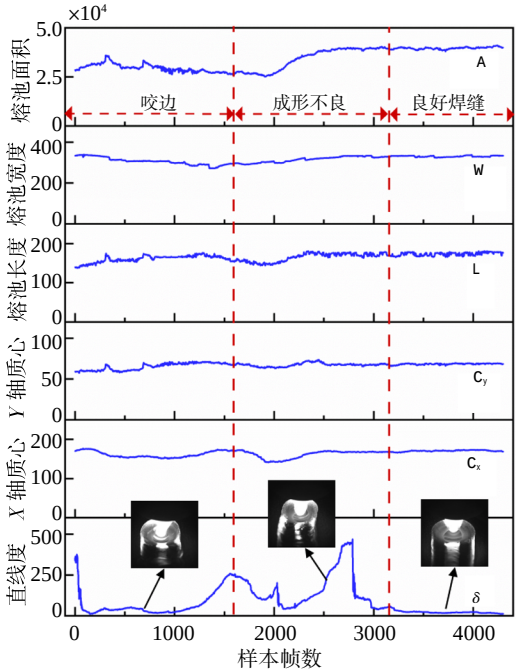


图 5 不同焊接状态下熔池特征曲线随时间的变化
Fig.5 Variation of molten pool features versus time under different welding status

特征的变化幅度远大于熔池前端区域几何特征的变化幅度。熔池后端区域直线度特征在三种焊接状态下呈现不同程度的波动,且变化幅度较大。因此,该特征能有效表征铝合金 GTAW 过程中出现的三种典型焊接状态。

3.2 试验结果与模型性能对比

本研究通过建立 CatBoost 模型对铝合金 GTAW 过程中出现的三种典型焊接状态进行实时检测。为减少特征参数维度和大小对模型训练的影响,将所有特征参数归一化到 0～1 范围内。建模过程中,将 5 折交叉验证整合到模型中,并采用网格搜索进行参数寻优。将 4200 个数据样本按 8:2 的比例划分为训练集和测试集,并按顺序依次输入 CatBoost 模型训练和测试。为了综合评价所提出的焊接状态预测模型的分类性能,在测试中应用了四个评价指标,包括准确率(Ac)、精度(Pr)、召回率(Re)和 F_1 分数(F_1)。

首先计算了单个特征作为输入的 CatBoost 模型分类准确率和 F_1 分数,如表 4 所示。可以看出,将熔池后端区域直线度特征作为输入获得了最高的分类准确率,分类结果显著优于基于熔池前端区域单个几何特征作为输入的分类结果。将所有熔池特征集合作为输入,表 5 阐述了所提出的焊接状态识别模型在测试集上的试验结果。CatBoost 模型的 Re、Pr、F_1 和 Ac 分别为 96.34%、96.24%、96.22% 和 96.15%,表明所建立的 CatBoost 模型具有良好的泛化能力和鲁棒性。此外,单个特征的最高分类准确率只有 90.94%(表 4),这表明单个特征难以准确预测三种典型焊接状态。而熔池前端区域几何特征与熔池后端区域直线度特征的组合特征可以更加准确地描述铝合金 GTAW 过程中的熔池状态。

表 4 CatBoost 模型的单个特征测试结果(%)
Tab.4 Single feature test results of the CatBoost model (%)

编号	特征	F_1		Ac	
		训练集	测试集	训练集	测试集
1	δ	92.14	91.68	91.70	90.94
2	A	88.68	86.53	87.41	86.39
3	C_x	79.02	76.26	75.43	76.19
4	C_y	73.24	58.92	61.87	62.42
5	W	82.87	85.96	81.94	86.90
6	L	79.85	77.77	74.71	77.45

表 5 基于熔池特征集输入的 CatBoost 模型测试结果(%)
Tab.5 Test results of CatBoost model based on the molten pool feature set inputs (%)

指标	咬边	成形不良	良好焊缝	平均值
Re	95.71	93.33	100	96.34
Pr	100	96.14	92.59	96.24
F_1	97.81	94.71	96.15	96.22
Ac	–	–	–	96.15

为了证明所提出的 CatBoost 模型的优越性和稳定性,本文将其与最新的 GBDT 模型和传统的机器学习模型进行了比较。为了公平比较,使用网格搜索对所有模型的参数进行了优化,并结合 5 倍交叉验证在相同的测试集上进行了 10 次测试。图 6 显示了不同算法的对比结果。可以看出,与 BPNN、KNN 和 SVM 等传统机器学习模型相比,基于树的模型

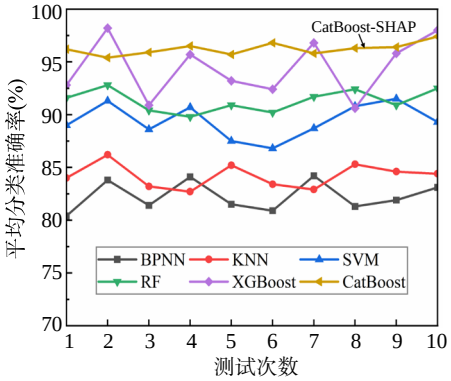


图 6 不同模型的分类准确率
Fig.6 Classification accuracy of different models

由于泛化能力强、处理非线性关系且对异常值鲁棒，在焊接状态分类任务中表现更佳。XGBoost模型虽然在第2、7、10次测试获得了最高的准确率，但并不稳定。基于相同的数据集，CatBoost在焊接状态分类的准确性和稳定性方面取得了最高的性能，这主要是由于其可以动态调整特征权重并充分考虑特征间的依赖关系。

3.3 模型可解释性分析

CatBoost、神经网络等被认为是典型的黑箱模型，难以解释模型如何为特定的预测做出决定。在本研究中，采用Tree SHAP算法计算的SHAP值解释CatBoost模型，以增强焊接状态识别结果的可靠性。图7显示了焊接状态识别任务中各熔池特征变量的SHAP重要性排序。由图7可知，直线度和熔池面积是影响识别结果的关键特征，这与现有的研究成果相符。其中，直线度特征SHAP值最高，是最重要的预测因子，表明了熔池后端区域形态特征对于焊接状态识别任务的重要性。

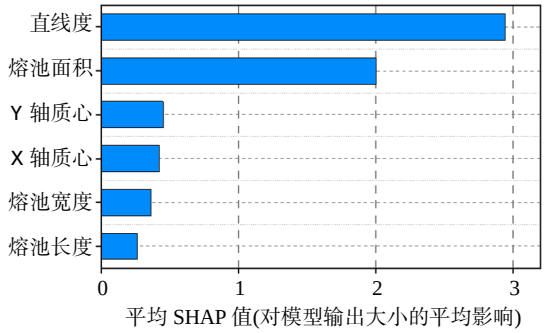


图7 基于SHAP理论的特征重要性排序

Fig.7 Importance ranking of features based on SHAP

虽然图7显示了各熔池特征的总体显著性，但并不能显示出该特征与输出是正相关还是负相关。因此，绘制了特征重要性散点图来表示各熔池特征变量与焊接状态识别结果的正负相关性，如图8所示。特征值按重要性从上到下排列。图上的每个点对应数据集中的一行，红色或蓝色分别代表较高或较低的输入值。所有特征点的两侧都涂有颜色，表示该特征对模型的负面(左侧)或正面(右侧)影响程度。可以看出，直线度特征在预测不同焊接状态时具有很高的重要性。大多数直线度特征值较高时具有正的SHAP值，因此对模型结果产生的正面影响，随着SHAP值的增大，其影响程度更为显著。当熔池面积的特征值增大时，其SHAP值小于0并不断减小，对模型有负面影响；当其特征值减小时SHAP值大于0并不断增大，对模型有正面影响，并且该特征的正面影响与负面影响程度相当。此外，有些特征对模型输出贡献很少或没有贡献，如熔池宽度和熔池长度。因此，在后续的工作中有必要重新评估模型的性能，以决定是否排除这些低贡献或无贡献的特征。

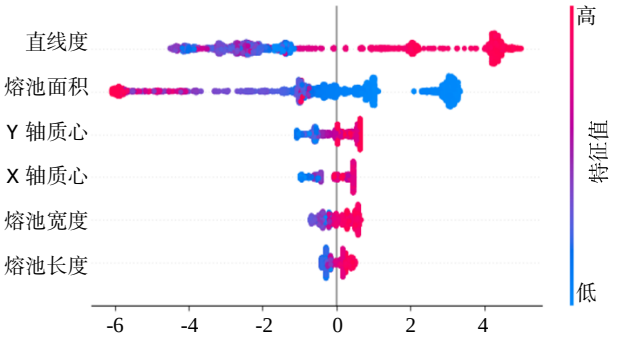


图8 特征重要性散点图

Fig.8 Scatter plot of feature importance

4 结论

(1) 提出一种新颖的图像多区域特征同步提取算法，实现了熔池前端区域几何特征和熔池后端区域直线度特征的实时提取。相对于现有方法重点关注熔池前端区域的几何特征，熔池后端区域直线度特征与焊接状态的相关性更强，更能有效表征铝合金GTAW过程中的熔池状态。

(2) 将熔池特征集合作为输入，所建立的CatBoost-SHAP模型能高效、鲁棒地识别咬边、成形不良和良好焊缝等多种典型中厚板铝合金焊接状态。与XGBoost、RF和传统机器学习模型相比，CatBoost具有更高的分类准确率和稳定性。

(3) 基于可解释人工智能方法SHAP量化了各熔池特征的贡献度和影响程度，明确熔池后端区域直线度特征是影响模型分类性能的最关键因素。此外，SHAP理论还揭示了各输入熔池特征变量与焊接状态识别结果的正负相关趋势。所提出的过程监测方法为铝合金GTAW焊缝成形缺陷的在线智能识别与焊接工艺优化提供了依据。

参考文献:

[1] Ren W, Wen G, Xu B, et al. A novel convolutional neural network based on time-frequency spectrogram of arc sound and its application on GTAW penetration classification [J]. IEEE Transactions on Industrial Informatics, 2020, 17(2): 809-819.

(下转第215页)

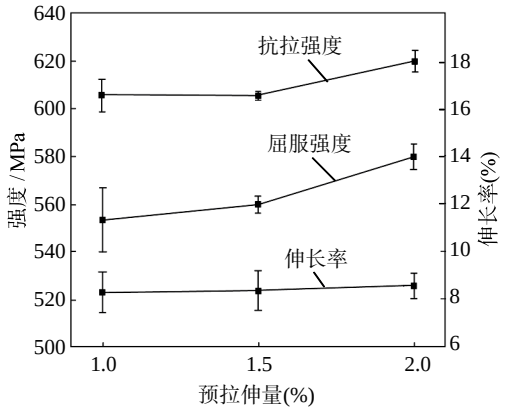


图 8 不同预拉伸量下试件的力学性能
Fig.8 Mechanical properties of specimen under different pre-stretching amounts

2 结论

（1）材料表面的黑色斑块及条纹类缺陷主要为后期形成的浅表层缺陷，热处理前进行表面处理，如碱腐蚀除油或三酸清洗，可以有效消除和预防该类缺陷。

（2）热处理生产过程中产生的外形损伤缺陷后期难以修复，单层排列式倾斜绑扎方式在缺陷预防上最优，不宜采用点夹方式及多件捆扎。

（3）过烧缺陷大幅度增加后续冷加工过程中裂纹的产生概率，热处理前材料表面应确保无可燃性污染物。裂纹对冷校形也较为敏感，应控制其成形时间在固溶处理后 60 min 以内，反向成形严禁用于铝锂合金零件的加工。

（4）在固溶处理后 60 min 内进行一定的预拉伸校直，拉伸量控制在 1%～2%，材料性能大幅度提高，可以有效预防力学性能不合格问题的产生。

参考文献：

[1] Gao C, Luan Y, Yu J C, et al. Effect of thermo- mechanical treatment process on microstructure and mechanical properties of 2A97 Al-Li alloy [J]. Transactions of Nonferrous Metals Society of China, 2014, 24: 2196-2202.

[2] 林毅，郑子樵，韩烨，等. 热处理工艺对2A97铝锂合金拉伸性能和腐蚀性能的影响 [J]. 中国有色金属学报，2012，22(8)：2181-2186.

[3] 朱宏斌，韩艳彬，同博. 2A97 铝锂合金薄板热处理与蒙皮零件成形研究[J]. 军民两用技术与产品，2018(4)：59-61.

[4] 高文理，闫豪，冯朝辉，等. 时效制度对2A97铝锂合金组织和力学性能的影响 [J]. 中国有色金属学报，2014，24(5)：1206-1211.

[5] 于娟，陆政，李国爱，等. 预拉伸处理对 2A97 薄板组织和性能的影响[J]. 航空材料学报，2016，36(5)：21-25.

[6] 姚春臣，佐齐生，易绯雄，等. 2A12铝合金托盘开裂失效分析[J]. 精密成形工程，2013，5(4)：57-59.

[7] 杨有才，柯美武，孙志刚. 7A04 铝合金热处理开裂失效分析[J]. 金属热处理，2015，40(4)：204-206.

[8] 于建民，张治民，王强. 高强铝合金轮辋失效分析[J]. 机械强度，2018，40(1)：55-60.

[9] 陈再良，吕东显，曹明宇，等. 金属热处理残余应力与开裂失效关系的探讨[J]. 金属热处理，2007，32(S1)：40-44.

[10] 徐永礼，黄双健，庞祖高，等. 圆管铝型材挤压模具失效分析及其热处理工艺优化[J]. 锻压技术，2015，40(2)：116-122.

(上接第 210 页)

[2] Zhao Z, Lv N, Xiao R, et al. Recognition of penetration states based on arc sound of interest using VGG-SE network during pulsed GTAW process [J]. Journal of Manufacturing Processes, 2023, 87: 81-96.

[3] Sreedhar U, Krishnamurthy C V, Balasubramaniam K, et al. Automatic defect identification using thermal image analysis for online weld quality monitoring [J]. Journal of Materials Processing Technology, 2012, 212(7): 1557-1566.

[4] 王齐胜，高延峰，龚岩峰，等. 基于声发射信号短时能量的 TIG 焊熔透状态识别[J]. 热加工工艺，2020，49 (21)：107-110.

[5] Chen Y, Chen B, Yao Y, et al. A spectroscopic method based on support vector machine and artificial neural network for fiber laser welding defects detection and classification [J]. NDT & E International, 2019, 108: 102176.

[6] Li C, Wang Q, Jiao W, et al. Deep learning-based detection of penetration from weld pool reflection images [J]. Weld J, 2020, 99(9): 239S-245S.

[7] Peng G, Chang B, Xue B, et al. Closed-loop control of medium-thickness plate arc welding based on weld-face vision sensing [J]. Journal of Manufacturing Processes, 2021, 68: 371-382.

[8] 洪宇翔，杨明轩，都东，等. 铝合金爬坡 TIG 焊熔池失稳状态的视觉检测[J]. 焊接学报，2021，42 (10)：8-13.

[9] 肖宏，宋建岭，刘宪力，等. 基于形态学算法的 2219 铝合金钨极氦弧焊熔池图像特征提取[J]. 宇航材料工艺，2019，49 (1)：78-81.

[10] Hong Y, Yang M, Chang B, et al. Filter-PCA-based process monitoring and defect identification during climbing helium arc welding process using DE-SVM [J]. IEEE Transactions on Industrial Electronics, 2022, 70(7): 7353-7362.

[11] 刘亮，杨长祺，倪加明，等. 2219 铝合金变极性 TIG 焊熔透状态识别方法[J]. 上海交通大学学报，2016，50 (S1)：71-74.

[12] Chen C, Lv N, Chen S. Welding penetration monitoring for pulsed GTAW using visual sensor based on AAM and random forests [J]. Journal of Manufacturing Processes, 2021, 63: 152-162.

[13] 高向东，郑俏俏，王春草. 旋转磁场下焊接缺陷磁光成像检测与强分类研究 [J]. 机械工程学报，2019，55 (17)：61-67.

[14] Lundberg S M, Lee S I. A unified approach to interpreting model predictions [C]//Advances in Neural Information Processing Systems 30 (NIPS 2017), 2017.