

智能化电弧熔丝增材制造在线监控研究现状



李曾鹏, 菅晓霞*

武汉工程大学机电工程学院, 湖北武汉 430205

摘要: 电弧熔丝增材制造 (WAAM) 凭借沉积效率高、成本低及成形尺寸受限小等优势, 在大型复杂金属构件的快速制造领域展现出显著潜力。然而, 受逐层累积热循环影响, 成形精度控制难、内部微观缺陷 (如气孔、裂纹) 及力学性能各向异性等问题, 严重制约了该技术的产业化应用与可靠性。针对 WAAM 工艺参数间强耦合、非线性及随机扰动等特征, 智能化在线监控已成为提升制造质量的核心途径。本文首先梳理了 WAAM 过程信息监测的多元传感方案, 涵盖视觉 (可见光、激光、红外、X 射线)、声发射及电弧光谱传感, 对比分析了各技术在捕捉熔池形貌与内部质量特征方面的性能边界; 继而探讨了机器学习 (ML) 在信号特征提取与状态判别中的研究进展, 重点剖析了深度神经网络与支持向量机在缺陷识别及工艺预测中的鲁棒性表现。在此基础上, 归纳了基于数据驱动模型与强化学习算法的智能控制策略, 探讨了其在实现熔滴过渡、送丝速率等关键参数自适应控制中的应用价值。最后, 针对当前多源数据融合困难、高质量样本集匮乏及多变量协同控制薄弱等瓶颈问题, 对 WAAM 智能化制造的发展趋势进行了展望

关键词: 电弧增材制造; 在线监控; 视觉传感; 机器学习; 智能控制

DOI: [10.57237/j.cst.2026.02.004](https://doi.org/10.57237/j.cst.2026.02.004)

Research Status of Intelligent Online Monitoring for Wire Arc Additive Manufacturing

Li Zengpeng, Jian Xiaoxia*

School of Mechanical and Electrical Engineering, Wuhan Institute of Technology, Wuhan 430205, China

Abstract: Wire arc additive manufacturing (WAAM), owing to its advantages of high deposition efficiency, low cost, and low limitations on part dimensions, exhibits significant potential in the rapid fabrication of large and complex metal components. However, issues such as difficulties in geometrical accuracy control, internal micro-defects (e.g., porosity, cracks), and anisotropy of mechanical properties caused by the cyclic thermal history during layer-by-layer deposition severely restrict the industrial application and reliability of this technology. In response to the strongly coupled, nonlinear, and randomly disturbed characteristics of WAAM process parameters, intelligent online monitoring has become a key approach to improving manufacturing quality. This paper first reviews the diverse sensing schemes for WAAM process information monitoring, covering vision-based (visible light, laser, infrared, X-ray), acoustic emission, and arc spectroscopy methods, and comparatively analyzes the performance boundaries of each technique in capturing melt pool morphology and internal quality features. Subsequently, the research progress of machine learning (ML) in signal feature

*通信作者: 菅晓霞, 179947304@qq.com

extraction and state classification is discussed, with emphasis on the robustness of deep neural networks and support vector machines in defect identification and process prediction. On this basis, intelligent control strategies based on data-driven models and reinforcement learning algorithms are summarized, and their application value in achieving adaptive control of key parameters such as droplet transfer and wire feed speed is explored. Finally, in view of current bottlenecks including difficulties in multi-source data fusion, scarcity of high-quality sample datasets, and weaknesses in multivariable cooperative control, the development trends of intelligent WAAM manufacturing are prospected.

Keywords: WAAM; Online Monitoring; Vision Sensing; Machine Learning; Intelligent Control

1 引言

增材制造（又称 3D 打印）通过逐层累积材料，将数字化模型直接加工为三维实体，具有柔性化、数字化、材料利用率高、加工周期短等优点，已应用于医疗、航空航天、交通等领域。电弧熔丝增材制造技术（Wire Arc Additive Manufacturing, WAAM）是金属增材制造的主要技术之一，利用焊接电弧熔化填充的金属丝材，通过堆焊的方式实现三维制造。相比激光及电子束的金属增材制造技术具有沉积效率高，成本低，对产品尺寸几乎没有限制等优点[1]，是大型复杂装备重点发展的制造技术。

WAAM 工艺过程是金属在焊接电弧作用下不断熔化形成熔池，随后凝固，后续沉积层在前一层的形貌及热、力状态下继续堆积最终形成三维实体。在上述熔池形成、凝固及逐层累积过程中易产生多种制造问题，如图 1 所示。首先是成形精度较低，熔池边缘处于弱拘束状态，在多种力的作用下易产生波动并在凝固后保留下来从而造成表面粗糙度高。当热输入过大，熔池边缘易发生塌陷，造成沉积层的几何形状误差，且该误差在后续沉积层不断被继承并累积造成宏观偏差。后续沉积层对前一沉积层具有加热效果，在循环加热和冷却中易产生热变形。上述三种原因导致 WAAM 成形的几何与尺寸精度较低[2]。其次，WAAM 制造的微观缺陷，在材料污染、工艺不当等多种原因下易产生气孔、裂纹、偏析等微观缺陷。最后，WAAM 制造力学性弱。在逐层沉积过程中，由于热积累效应各层的凝固热环境不同，造成凝固组织形态不同；而且由于存在重熔现象，最终沉积金属的层层间组织不均。综上，成形精度、微观缺陷、力学性能三方面问题严重影响 WAAM 制造的可重复性及交付产品的可靠性，是 WAAM 工艺推广应用亟需解决的问题。




图 1 WAAM 成形主要问题

目前研究人员已经从工艺参数调整，数值分析等方面做了大量研究，解决上述关键问题。如应用于 AM 过程的数学和统计模型可避免缺陷，提高零件质量。这些研究都依赖于复杂的模拟和基于物理的有限元分析，因此伴随着巨大的计算负担。而且 WAAM 工艺是动态过程，每个沉积层面对不同的初始形貌及热、力条件。目前的工艺优化系统及模型还不能为每一层预测最优工艺参数。面对 WAAM 的多参数、高耦合、非线性、随机性等特征，闭环控制成为保障制造质量的一种有效方式[2, 3]。闭环控制的原理为实时检测与制造质量密切相关的工艺过程参量并触发控制命令，主动将制造偏差最小化。传统的增材制造闭环控制使用手工编程，需要大量的人工设置，而且控制策略的适用范围有限，适应性和可扩展性差。随着传感技术、物联网、数据传输技术及人工智能的迅速发展，WAAM 实现工艺过程的在线“感知-决策-反馈-执行”成为可能，促使 WAAM 的闭环控制从自动化向智能化转变。

智能化闭环控制的主要环节包括信息感知、信息诊断及控制策略。WAAM 工艺中包含丰富的能够反应成形特征及成形缺陷的声、光、电等信号，为在线工艺检测提供大量数据信息。机器学习（ML）是人工智能的一种，具有强大的数据处理和预测能力，可以分析历史数据和实时数据，在信息诊断及策略优化方面具有优势。综上，本文首先对 WAAM 工艺信息获取的主流

传感技术进行了综述，其次本文论述了 ML 在 WAAM 闭环控制中的信息诊断及控制系统环节的应用现状。

2 WAAM 工艺信息检测

2.1 视觉传感

目前 WAAM 中特征信息获取的一种重要方法为视觉传感，主要基于可见光、激光、红外及 X 射线等方式获取工艺进程中的图像或视频。基于可见光的光学相机可以捕获工艺过程中高分辨率和色彩精度的沉积层外观形貌及尺寸。尤其是利用高速相机可以开展工艺的实时检测。Ma 等人[4]在旁路耦合双脉冲 WAMM 中使用高速相机观察熔滴的过度路径、捕获到阳极与旁路丝材间发生的飞溅及桥接现象，为熔滴过渡稳定性提供实时信息。除上述高速相机监测熔滴过渡过程外，可见光视觉传感也被广泛用于沉积层表面形貌缺

陷的检测。在焊缝形貌与缺陷的实时检测方面，激光视觉传感展现了强大的能力。余鹏飞等人[5]针对不锈钢平板对接焊中的微间隙焊缝，搭建了基于激光视觉传感器的检测系统。该系统通过细化算法和中值滤波提取焊缝轮廓线，利用坡口运动算法确定焊缝区域，实现了对最小宽度仅为 0.048mm 的微间隙焊缝的准确识别，焊缝位置检测精度达到 $\pm 0.039\text{mm}$ 。此外，通过欧式空间向量法检测焊缝两侧拐点，该系统能精确测量错边量，检测误差精度在 $\pm 0.15\text{mm}$ 以内。在焊缝跟踪过程中，视觉算法还能有效克服钢板表面粗糙度不一、局部反光等造成的干扰，保证特征提取的稳定性。李冰等人[6]针对薄板对接焊，提出了一种基于主动视觉的焊缝检测方法。通过颜色分割与亮度分割消除环境光干扰，利用灰度重心法提取激光条纹中心线，并采用一阶差分方法实现了焊缝左右边界及中心的精确检测。该方法还能有效处理激光条纹因表面脏污或遮挡产生的分断缺陷，提高了检测的鲁棒性。




图 2 基于激光视觉的接焊缝边界与中心检测结果[6]

基于激光的视觉传感技术使用激光作为光源，激光器通过镜头组生成线结构光，投射到被检测物体上发生漫反射，再通过接收镜头组，在 CMOS/CCD 传感器上成像。这些图像信息经过特殊的处理，可以生成被检测物体的位置、形状等信息。激光在相干性、单色性方面胜过传统光源，可以实现高对比度、低噪声成像，在精密尺寸和细微表面缺陷的检测方面具有突出优势。Garmendia 等人[7]将激光轮廓仪集成于 WAAM 沉积头，在逐层沉积间隙对已沉积焊道表面形貌进行三维扫描重建，实现了沉积层高度偏差和表面凹陷等几何缺陷的在线检测，为后续层间补偿策略提供数据支撑。此外，Wang 等人[8]设计了一种基于激光视觉的原位检测系统，将三维形貌重建、缺陷检测与粗糙度测量三项功能集成于统一的实时扫描任务中，在单次扫描即可同步获取多维度的表面质量信息，实现了 WAAM 表面质量的高效在线评估。西南交通大学 Xiong 等人[9]设计的单 CCD 虚拟双目立体激光视觉系统，突破了传统激光视觉测量方法在 WAAM 沉积层表面粗糙度在线检测中难以兼顾检测精度与系统复杂度之间的瓶颈——传统结构光法依赖精密运动平台实现沿焊道方向扫描，布置复杂且扫描效率低；Xiong 等[9]通过虚拟双目设计仅用单个 CCD 传感器同时获取两个方向的激光条纹图像，在简化系统结构的同时实现了焊道表面粗糙度的快速在线检测，检测结果与接触式表面粗糙度仪测量值吻合良好。

相机内部传感器不仅能够捕获可见光还可捕获红外光，在不可见的中、远红外光谱中工作的热像仪根据物体的热量或热辐射捕获图像，具有高动态的热像仪能够捕捉到材料表面的细微温度变化。在 WAAM 中，利用红外传感可实检测温度变化，记录熔池形成与熔化过程中的温度峰值，加热与冷却速率，层间温度变化等信息。例如，Yu 等人[10]利用红外热像仪构建了 WAAM 焊件温度场测量系统，优化了 HOG 算法提取焊件侧壁 ROI 区域的温度分布特征，并将其输入 CNN 模型用于识别熔覆层偏移。实验结果表明该方法对熔覆层偏移的识别准确率超过 99%，有效解决了视觉感知方法中电弧光干扰导致熔覆层偏移识别困难的问题。此外，Chen 等人[11]提出了基于温度场的多特征数据融合无损检测方法，使用热像仪实时采集沉积层温度数据，通过温度堆叠算法和宽度提取算法提取沉积层轮廓图像和宽度曲线，结合残差神经网络实现了驼峰、沉积塌陷、偏移、内部气孔及表面夹渣等常见缺陷的在

线检测与分类，对单层和多层 WAAM 试样均获得了良好的检测效果。

上述视觉更适用于监测表面缺陷和测量几何偏差，但是对于内部的裂纹、气孔等缺陷不能识别。X 射线能量大于可见光，可穿透物体表面与内部物质发生复杂的物理化学反应，利用不同物质对能量吸收率不同的特性，实现构建物体内部结构的图像。而且，通过从多个角度拍摄可以精确重建物体内部三维结构，即断层成像。如 Nablusi 等人[12]使用 X 射线断层摄像获取的碳钢 WAAM 沉积层内部结构，如图所示。图中灰色代表主相物质钢，红色、蓝色和绿色代表层间区域，不连续黄色代表空洞缺陷。目前 X 射线数字成像检测已应用于制造工艺动态过程研究。Cunningha 等[1]利用超高速同步加速器 x 射线成像技术量化了激光增材过程中小孔的形成。他们发现加工参数和小孔形状密切相关，可以通过调整参数达到控制小孔形态的目的。除了内部结构 X 射线视觉还能够反应其他成形特征。如 Brown 等人[13]使用 71 keV x 射线对 304L 不锈钢衬底上沉积单层 308L 不锈钢过程中的温度、相演变和残余应力开展检测，观察了液/固相变和固相相变。该方法还可用于绘制熔池的范围，识别热梯度，并测量沉积过程中材料的残余应力。




图3 基于 X 射线的 WAAM 制造碳钢内部三维结构[12]

2.2 声音传感

声学传感具有成本低的优势，并且作为一种原位监测系统，在识别外部和内部缺陷方面显示出极大的潜力，在多种实时快速检测 WAAM 工艺过程变化及缺陷的技术中，基于声音传感的技术已被证明具有良好

的稳定性和适应性[14]。在 WAAM 材料凝固过程中, 材料会发出高频声波, 这些声波由传感器收集, 可以用来识别空洞、裂纹和分层等缺陷, 并提供早期预警信号[15]。例如, Zhang 等人[16]提出了一种基于声学信号小波时频图的 DED-arc 缺陷识别方法——通过连续小波变换将制造过程中采集的一维声学信号转换为二维时频图, 利用 CNN 模型 (AlexNet、ResNet-18、VGG-16、MobileNetV3) 进行训练和测试, 分别获得了 96.35%、97.92%、97.01% 和 98.31% 的分类准确率。研究还发现正常和异常声学信号的能量分布在时域和频域均存在显著差异, 验证了声学信号可用于 WAAM 工艺中缺陷的有效识别。此外, Alcaraz 等人[17]开发了一套多模态高分辨率传感系统, 集成了声学 (麦克风)、电信号和光学模态, 实现了 2 MHz 采样率下的高保真瞬态事件采集 (包含飞溅和气泡爆裂等), 发现 500 Hz–10 kHz 频段的麦克风信号即可为缺陷分类提供最丰富的信息, 并基于稀疏小波网络 (SWaN) 建立了可解释的缺陷检测框架, 同时保证了实时监测可行性。Hauser 等人[18]证明 WAAM 中当沉积层表面轮廓发生波动, 电弧路径偏差、气流量变化及丝尖端距金属距离变化时亦引起声波变化, 基于检测的声波信号能够准确预测上述工艺异常现象。上述检测机理是, 电弧等离子体是 WAAM 中的主要声源之一。电弧等离子体体积变化导致气压变化, 从而引发声波发射。当沉积层形貌波动、路径发生偏差及保护气流量发生变化时导致丝材尖端至沉积金属表面间电离气体体积发生变化, 导致声发射数据发生波动。如图所示, 电弧路径偏差后, 被电离气体体积增大, 引发更大面积的空气波动, 从而导致声发射强度的上升。




图 4 WAAM 正常过程和具有轨迹偏差的过程声发射的示意图 [19]

2.3 光谱

基于焊接工艺的 WAAM 在沉积金属过程中产生包含丰富信息的光谱, 包括金属蒸汽、保护气和电弧等离子体, 他们与成形特征密切相关, 因此成为 WAAM 在线检测的一种重要手段。光谱传感通过采集和分析 WAAM 过程中电弧等离子体发射的特征谱线实现工艺在线监测, 具有响应速度快、灵敏度高、非接触和无损等突出优点。在 WAAM 电弧放电过程中, 保护气分子、金属蒸气原子及离子在高温下跃迁至高能态, 随后以光辐射的形式释放能量, 产生带有状态信息的特征光谱。所以, 当出现气孔、裂纹等缺陷时, 电弧状态和元素浓度会发生改变, 进而导致光谱强度和谱线形态产生异常波动, 从而为缺陷检测提供依据。

Zhang 等人[19]首次将发射光谱技术应用于 WAAM 铝合金的电弧特征探测和结构特征检测。研究发现, 铝合金 WAAM 中的气孔主要由污染物氢引起, 且气孔率与氢原子特征谱线的强度之间呈近似线性关系。基于此, 他们通过分析相关特征谱线强度变化实现了气孔缺陷的在线检测, 并建立了电弧光谱特征与沉积层成形宽度、气孔等结构特征之间的定量关联。研究结果验证了光谱诊断在 WAAM 成形尺寸和气孔缺陷检测中的适用性。Zhuang 等[20]提出了基于光谱与视觉协同感知的 WAAM 质量监测方法, 在峰值电流时采集光谱, 基值电流时拍摄熔池图像, 再结合轮廓曲线特征的 KNN 和局部保持投影的 KNN 分类算法, 实现对工艺参数异常状态和质量缺陷的同步监测, 他们的实验验证了该方法在多种焊丝材料冷金属过渡 (CMT) 焊接中的准确性和稳定性均优于单一传感方法。

2.4 小结

视觉检测包含丰富信息, 检测准确性高, 但容易被遮挡。光谱和声学传感器适用于检测内部缺陷, 如孔隙和裂纹。光谱传感器具有灵敏度高、信息丰富等优点。但其局限性在于获取的信息不直观, 预测结果高度依赖于数据处理和分析算法。声波传感器也可以用来监测电弧的稳定性和液滴的过渡模式。但是, 它容易受到外界的干扰, 如环境噪声, 并且大多数声信息与焊接电信号相关, 可以很容易地从焊接机上采集到焊接电信号。

3 WAAM 工艺信息诊断

机器学习是人工智能的一个分支, 专注于从数据中学习并进行预测, 具有高精度、高可靠性和稳定性。一种机器学习辅助的 WAAM 闭环控制如图 2 所示。在该系统中, ML 应用 1 为前期工艺优化。在该阶段用户基于 ML 的优化算法提出满足目标的工艺参数最佳范围, 在该参数范围内, 可以避免缺陷和异常的发生。这些算法通常在工艺开始之前应用, 即离线应用[21]。该环节常用 ML 算法有[22, 23]: 神经网络(ANN), 主成分分析(PCA), 强化学习算法 Q-learning 等。ML 应用 2 为在线工艺诊断: 基于采集的在线工艺信息, 使用 ML 相关算法诊断工艺状态, 如, 正常、缺陷、异常或错误, 为工艺预警及控制系统提供信息。通常这些算法在线运行。常用算法包括[24]: ANN, K-近邻算法(KNN), 卷积神经网络(CNN), 深度神经网络(DNN), 随机森林(RF)、支持向量机(SVM), 线性回归(LR)、朴素贝叶斯(NB), 等。ML 应用 3 为在线控制: 基于传感器采集到的沉积层当前的和过去的状态来控制执行器动作。通过避免、减轻或修复缺陷或异常, 实现过程偏差最小化, 从而确保最终制造产品满足性能要求。机器学习基于数据来进行预测, 并从数据中学习并生成控制策略, 随着大量有效数据的积累, 训练模型的能力持续进化。机器学习中的 ANN, 高斯回归(GPR), 深度学习(Deep-Learning)等算法已应用于传统 PID 或模糊控制策略中。

机器学习在增材制造工艺模型、预测及控制种有广泛的应用, 但所示在粉末床或者基于激光的增材工艺种。在 WAAM 工艺种的应用报道较少。在 Web of Science 网页上以“Wire arc additive manufacturing, machine learning”为关键词进行搜索只有 56 篇报道。这些报道大多集中于机器学习在工艺质量预测及工艺参数优化方面, 关于机器学习在线信息分析与诊断及在线控制方面报道较少。

4 工艺检测中的机器学习算法

由第 3 节可知在工艺检测环节, 对传感器捕获的单一源或多源信息进行诊断常用的 ML 算法中主要代表为人工神经网络算法及其衍生算法和支持向量机。本节研究以上两种代表算法的应用现状

4.1 人工神经网络算法的应用

ANN 是一种模拟生物神经网络工作方式的计算模型。它由多个神经元(或节点)组成, 这些神经元通过权重和偏置相互连接, 可以接收输入信号并进行处理, 然后产生输出信号。神经网络在处理复杂和非线性问题时表现良好, 在电弧熔丝增材制造中有广泛的应用。深度学习(deep learning, DL)是 ANN 的一种, 网络由多个隐藏层组成, 数据特征以多层抽象的方式学习, 允许计算机从相对简单的概念中学习复杂的概念, 被认为是一种从 WAAM 过程中收集的图像数据中检测和分类缺陷的有效方法。基于深度学习的神经网络算法还可以实现缺陷的分类与定位, 在 WAAM 的缺陷检测中根据提取的特征信息, 将缺陷分为不同的类型(如气孔、裂纹等), 并确定缺陷在部件中的具体位置。这为后续的缺陷修复和处理提供了重要的信息支持。但需要大量的数据和计算资源来训练模型。DL 的体系结构包括循环神经网络(RNN)、卷积神经网络(CNN)和深度神经网络(DNN)。

CNN 在基于图像的分类中表现出了最好的性能, 常用于检测焊接驼峰、飞溅等表面形貌现象。如 Lee 等人[25]使用高动态相机收集 WAAM 过程信息, 并使用 CNN 算法在线诊断工艺状态, 研究了 5 种不同架构下 CNN 对异常和缺陷的预测精度。Pan 等人[26]针对图像数据不足的缺陷, 采用了迁移学习技术, 以检测小数据集下焊接缺陷问题。除了表面形貌, Nomura 等人[27]使用 CNN 的分类功能在获取的图像中来预测熔深。

RNN 及其变体长短期记忆网络(LSTM)擅长处理 WAAM 过程中的时序信号数据(如声学信号、电弧电信号和温度序列), 可捕捉缺陷演化的时间依赖性特征。Qin 等人[28]采集了不同熔滴过渡模式下 WAAM 电弧信号(电压、电流)的时间序列, 利用基于 LSTM 的深度网络成功实现了熔滴过渡模式的在线分类与控制, 显著提升了电弧稳定性。

DNN 通过多层非线性变换从原始信号中自动提取高维抽象特征, 可用于 WAAM 中多源信号融合与工艺状态诊断。Huang 等[29]提出了一种基于深度神经网络的多源传感器数据融合与缺陷预测方法, 用于气体金属电弧增材制造(GMA-AM)过程监测。该方法采集 WAAM 过程中的电流、电压和声音三种多源信号, 首先通过鲸鱼优化算法(WOA)自适应地优化变分模态分解(VMD)参数, 对多源原始信号进行自适应分解, 并以分解分量的能量熵构建特征向量; 在此基础上, 构

建一维卷积神经网络 (1D-CNN) 模型, 通过其多层卷积与池化操作实现非线性特征变换, 从原始信号特征中自动提取高维抽象特征, 完成对轨迹偏移、气孔、夹渣、热变形和表面不平整五种典型缺陷状态的分类与判别。实验验证表明, WOA-VMD 能够根据信号特性自适应选取最优分解层数, 有效提取信号在不同频带中的能量熵特征, 所构建的 1D-CNN 模型在五种缺陷模式识别中表现出良好的分类精度和泛化性能, 证明了利用 DNN 实现多源信号融合与 WAAM 工艺状态诊断的可行性。

4.2 支持向量机算法的应用

支持向量机 (Support Vector Machine, SVM) 是一种基于统计学习理论和结构风险最小化原则的有监督学习算法, 通过寻找特征空间中的最优分类超平面实现对不同类别样本的区分。在处理 WAAM 工艺中小样本、高维度、非线性等特征数据时, SVM 相比深度学习方法具有训练数据需求量小、泛化能力强等优势, 因此在工艺状态诊断与缺陷识别中应用。SVM 对特征空间划分的最优超平面通常依赖于核函数的选择及相关超参数的设定, 常用的核函数包括线性核、多项式核、径向基函数 (RBF) 核及 Sigmoid 核等。

在 WAAM 及相近的弧焊工艺缺陷诊断中, SVM 主要用于对工艺状态、和多种缺陷类型的分类识别。针对焊缝表面缺陷的检测与分类, Hu 等人[30]提出了一种基于激光视觉传感与方向梯度直方图 (HOG) 特征提取的 HOG-SVM 焊缝表面缺陷智能检测方法, 通过激光视觉传感器采集焊缝图像并进行预处理和轮廓提取, 利用 HOG 提取焊缝激光条纹轮廓图像的特征向量, 并基于五折交叉验证与网格搜索法优化 SVM 模型参数, 最终建立 SVM 分类模型以实现对气孔、凹陷、咬边及无缺陷等不同状态的识别与分类, 识别率达 97.86%, 优于同等条件下的随机森林、K 近邻和朴素贝叶斯分类器。该方法利用激光视觉对焊缝表面形貌的高灵敏度, 有效弥补了单一传感手段在表面缺陷分类识别方面的不足。

在工艺参数与成形质量的预测建模方面, 支持向量回归 (Support Vector Regression, SVR) 作为 SVM 的回归扩展也得到了应用。Zhang 等[31]人建立了基于 SVR 的 WAAM 焊道成形尺寸与工艺参数预测模型, 以焊接电流、焊接电压、送丝速度和扫描速度等为输入特征, 预测焊道的宽度和高度等几何尺寸, 并通过

粒子群优化 (PSO) 算法对 SVR 的超参数进行自动寻优。对比实验表明, PSO-SVR 模型在工艺参数预测中取得了最高的预测精度。在此基础上, 该研究进一步综合考虑能耗与效率的平衡, 优选了最佳工艺参数组合, 为 WAAM 低能耗工艺参数的前馈控制提供了有效的数据驱动模型。

针对 WAAM 过程中传感信号的多源、异构特性, 部分研究将 SVM 与信号处理及特征降维方法相结合。主成分分析 (PCA) 常被用于对高维传感数据进行降维, 提取对缺陷敏感的主成分特征后再输入 SVM 进行分类, 以降低模型复杂度并提高分类效率。此外, 将 SVM 与遗传算法 (GA)、粒子群优化 (PSO) 等智能优化算法结合, 自动搜索最优超参数组合, 已成为提升 SVM 诊断性能的常用策略。

5 展望

针对当前电弧熔丝增材制造 (WAAM) 面临的挑战, 未来研究应重点聚焦于多源信息深度融合机制与异构数据协同感知体系的构建。由于单一传感手段在复杂制造环境下存在信息盲区或易受干扰, 亟需开发能够集成视觉、声学、电信号及光谱特征的复合传感网络, 通过研究跨模态特征映射与自适应加权融合算法, 解决多源数据在时空维度上的对齐与误差补偿难题, 以实现熔池演变及内部缺陷 (如微气孔、残余应力) 的全维度原位监测。同时, 建立涵盖多材料、多工艺参数的标准化高质量开源数据集, 利用迁移学习和自监督学习技术缓解工业样本匮乏带来的模型泛化性不足问题, 是推动 WAAM 智能化检测向通用化发展的关键。

在控制策略方面, 未来将由单一几何特征的闭环调节向多变量协同自适应智能控制转变。针对 WAAM 工艺参数间强耦合、非线性的动态特征, 应进一步探索强化学习与物理信息神经网络 (PINN) 在成形质量预测中的应用, 构建深度融合物理演化规律与数据驱动特征的数字孪生模型。通过开发具备实时演进能力的智能决策控制器, 实现对送丝速率、扫描路径及层间温度等关键变量的动态解耦协同控制, 从而消除层间热积累导致的形貌波动与组织不均, 提升复杂构件制造的可重复性与整体力学性能, 最终实现 WAAM 从“自动化堆积”向“全流程自主智能化制造”的跨越。

参考文献

- [1] Cunningham C R, Flynn J M, Shokrani A, et al. Invited review article: strategies and processes for high quality wire arc additive manufacturing [J]. *Additive Manufacturing*, 2018, 22: 672-686. <https://doi.org/10.1016/j.addma.2018.06.020>
- [2] Jin Z, Zhang Z, Gu G X. Automated real-time detection and prediction of interlayer imperfections in additive manufacturing processes using artificial intelligence [J]. *Advanced Intelligent Systems*, 2020, 2(1): 1900130. <https://doi.org/10.1002/aisy.201900130>
- [3] McCann R, et al. In-situ sensing, process monitoring and machine control in laser powder bed fusion: a review [J]. *Additive Manufacturing*, 2021, 45: 102058. <https://doi.org/10.1016/j.addma.2021.102058>
- [4] Ma C, Yan Y H, Yan Z Z, et al. Investigation of bypass-coupled double-pulsed directed energy deposition of Al-Mg alloys [J]. *Additive Manufacturing*, 2022, 58: 103058. <https://doi.org/10.1016/j.addma.2022.103058>
- [5] 余鹏飞. 基于激光视觉传感的焊缝检测与焊接过程控制研究 [D]. 长春: 长春工业大学, 2024.
- [6] 李冰, 白云山, 赵宽, 等. 基于视觉传感的薄板对接焊缝检测方法研究 [J]. *热加工工艺*, 2024, 53(17): 13-19. <https://doi.org/10.14158/j.cnki.1001-3814.20221431>
- [7] Garmendia I, Leunda J, Pujana J, et al. In-process height control during laser metal deposition based on structured light 3D scanning [C] // *Procedia CIRP*, 2018, 74: 87-91. <https://doi.org/10.1016/j.procir.2017.12.098>
- [8] Wang H, Qi S N, Zang T J, et al. In-situ surface inspection for wire-arc directed energy deposition integrating 3D topography reconstruction, defect detection and roughness measurement [J]. *Optics & Laser Technology*, 2025, 187: 112871. <https://doi.org/10.1016/j.optlastec.2025.112871>
- [9] Xiong J, Li Y J, Yin Z Q, et al. Determination of surface roughness in wire and arc additive manufacturing based on laser vision sensing [J]. *Chinese Journal of Mechanical Engineering*, 2018, 31: 74. <https://doi.org/10.1186/s10033-018-0276-8>
- [10] Yu R, He S, Yang D, et al. Identification of cladding layer offset using infrared temperature measurement and deep learning for WAAM [J]. *Optics and Lasers*, 2024, 170: 110243. <https://doi.org/10.1016/j.optlastec.2023.110243>
- [11] Chen, X, Fu Y H, Kong F R, et al. An in-process multi-feature data fusion nondestructive testing approach for wire arc additive manufacturing [J]. *Rapid Prototyping Journal*, 2021, 28(3): 573-584. <https://doi.org/10.1108/rpj-02-2021-0034>
- [12] Al-Nabulsi Z, Mottram J T, Gillie M, et al. Mechanical and X-ray computed tomography characterisation of a WAAM 3D printed steel plate for structural engineering applications [J]. *Construction and Building Materials*, 2021, 274: 121700. <https://doi.org/10.1016/j.conbuildmat.2020.121700>
- [13] Brown D W, Losko A, Carpenter J S, et al. In-situ high-energy X-ray diffraction during a linear deposition of 308 stainless steel via wire arc additive manufacture [J]. *Metallurgical and Materials Transactions A*, 2020, 51: 1379-1394. <https://doi.org/10.1007/s11661-019-05605-2>
- [14] Bigelow T A, Schneider B, Taheri H. Detection of pores in additive manufactured parts by near field response of laser induced ultrasound [C] *AIP Conference Proceedings*, 2019, 2102(1): 70002. <https://doi.org/10.1063/1.5099802>
- [15] Rozin E H, Sultan T, Taheri H, et al. Detecting selective laser melting beam power from ultrasonic temporal and spectral responses of phononic crystal artifacts toward in-situ real-time quality monitoring [J]. *3D Printing and Additive Manufacturing*, 2024, 11(6): 1982-1995. <https://doi.org/10.1089/3dp.2023.0063>
- [16] Zhang H, Qian R W, Tang W L, et al. Acoustic signal-based defect identification for directed energy deposition-arc using wavelet time-frequency diagrams [J]. *Sensors*, 2024, 24(13): 4397. <https://doi.org/10.3390/s24134397>
- [17] Alcaraz J. Developing process monitoring and real-time defect detection for wire-arc additive manufacturing [D]. Leuven, Belgium: KU Leuven, 2025.
- [18] Hauser T, Reisch R T, Kamps T, et al. Acoustic emissions in directed energy deposition processes [J]. *The International Journal of Advanced Manufacturing Technology*, 2022, 119: 3517-3532. <https://doi.org/10.1007/s00170-021-08598-8>
- [19] Zhang C, Chen C, Zeng X Y, et al. Spectral diagnosis of wire arc additive manufacturing of Al alloys [J]. *Additive Manufacturing*, 2019, 30: 100869. <https://doi.org/10.1016/j.addma.2019.100869>
- [20] Zhuang Z, Guo Y T, Jing H, et al. Quality monitoring in wire-arc additive manufacturing based on cooperative awareness of spectrum and vision [J]. *Optik*, 2019, 181: 351-360. <https://doi.org/10.1016/j.ijleo.2018.12.071>
- [21] Hamoud M, Sobhi A. A new algorithm for optimal process parameters based on minimum building time in additive manufacturing [J]. *Beni-Suef University Journal of Basic and Applied Sciences*, 2022, 11(1): 80. <https://doi.org/10.1186/s43088-022-00260-w>
- [22] Cheng J, De Waele W. Prediction and optimization of surface waviness of WAAM components using a hybrid Rank-Gaussian PSO algorithm and ANN [J]. *Structures*, 2024, 69: 107247. <https://doi.org/10.1016/j.istruc.2024.107247>

- [23] Guizani A, Hammadi M, Yousfi L, et al. Predictive modeling of part quality in the WAAM process using PCA model reduction and machine learning [C]. *Design and Modeling of Mechanical Systems - VI*. 2023: 410-419.
https://doi.org/10.1007/978-3-031-65007-9_43
- [24] Paturi U M R, Palakurthy S, Reddy A, et al. Role of Machine Learning in Additive Manufacturing of Titanium Alloys—A Review [J]. *Archives of Computational Methods in Engineering*, 2023, 30(6): 3867-3895.
<https://doi.org/10.1007/s11831-023-09969-y>
- [25] Lee C, Seo G, Kim D B, et al. Development of defect detection AI model for wire + arc additive manufacturing using high dynamic range images [J]. *Applied Sciences*, 2021, 11: 7541.
<https://doi.org/10.3390/app11167541>
- [26] Pan H, Pang Z, Wang Y, et al. A new image recognition and classification method combining transfer learning algorithm and mobilenet model for welding defects [J]. *IEEE Access*, 2020, 8: 119951-119960.
<https://doi.org/10.1109/access.2020.3005450>
- [27] Nomura K, Fukushima K, Matsumura T, et al. Burnthrough prediction and weld depth estimation by deep learning model monitoring the molten pool in gas metal arc welding with gap fluctuation [J]. *Journal of Manufacturing Processes*, 2021, 61: 590-600. <https://doi.org/10.1016/j.jmapro.2020.10.019>
- [28] Qin J, Wang Y P, Ding J L, et al. Optimal droplet transfer mode maintenance for wire + arc additive manufacturing (WAAM) based on deep learning [J]. *Journal of Intelligent Manufacturing*, 2023, 34: 3173-3189.
<https://doi.org/10.1007/s10845-022-01986-1>
- [29] Huang Y, Yue C, Tan X, et al. Quality prediction for wire arc additive manufacturing based on multi-source signals, whale optimization algorithm—variational modal decomposition, and one-dimensional convolutional neural network [J]. *Journal of Materials Engineering and Performance*, 2024, 33(5): 2331-2346. <https://doi.org/10.1007/s11665-023-08768-7>
- [30] Hu D, Lyu B, Wang J J, et al. Study on HOG-SVM detection method of weld surface defects using laser visual sensing [J]. *Transactions of the China Welding Institution*, 2023, 44(1): 57-62, 70. <https://doi.org/10.12073/j.hjxb.20211231001>
- [31] Zhang H, Bai X, Dong H, et al. Modelling and prediction of process parameters with low energy consumption in wire arc additive manufacturing based on machine learning [J]. *Metals*, 2024, 14(5): 567. <https://doi.org/10.3390/met14050567>