面向增材制造中自动孔洞检测与关键性评估的可解释计算机视觉框架

Akshansh Mishra[1,2], Rakesh Morisetty[3]

[1]米兰理工大学工业与信息工程学院，意大利米兰[2]AI Fab Lab 计算材料研究组，
印度北方邦[3] Fastweb S.p.A.，意大利米兰

摘要： 内部孔隙率仍是增材制造构件中的一种关键缺陷模式，会损害结构性能并限制工业应用。虽然已有自动缺陷检测方法，但其缺乏可解释性，工程师因此无法理解临界性预测的物理依据。本研究提出了一种用于三维断层体数据中孔洞检测与关键性评估的可解释计算机视觉框架。研究将连续灰度切片重建为体数据集，并结合基于强度的阈值分割与连通组件分析，识别出500个独立孔洞。研究采用几何描述符对每个孔洞进行表征，包括尺寸、长宽比、延展度，以及相对于试样边界的空间位置。研究使用基于百分位数的欧氏距离准则构建孔洞相互作用网络，得到24,950条孔洞间连接。机器学习模型根据提取的特征预测孔洞关键性评分，并通过SHAP分析量化各项特征的贡献。结果表明，归一化表面距离对模型预测的影响占主导地位，其重要性比所有其他描述符高出一个数量级以上。孔隙尺寸的影响极小，而几何参数的影响则微乎其微。表面邻近度与关键性之间的强反向关系揭示了边界驱动的失效机制。这一可解释框架能够实现透明的缺陷评估，并为增材制造中的工艺优化与质量控制提供切实可行的见解。

关键词： 增材制造、孔隙率检测、可解释人工智能、计算机断层扫描、SHAP分析

1. 引言

增材制造通过逐层材料沉积，能够实现传统方法无法制造的复杂几何形状，提升了航空航天、生物医学和汽车行业的生产能力 [1-5]。然而，带来设计自由度的这些工艺特性也会引入微观结构缺陷，尤其是内部孔隙率，从而损害机械完整性并缩短疲劳寿命 [6-9]。凝固过程中，受困气体、未完全熔合或粉末床不规则性会导致孔隙成核；孔隙的尺寸、形状和空间分布会直接影响工作载荷下裂纹的萌生与扩展。

当前的质量控制高度依赖计算机断层扫描来显示内部缺陷，但分析仍主要依靠人工或半自动化方式，且对于哪些孔隙风险最大，缺乏深入的物理洞见。传统机器学习模型可以根据孔隙特征预测失效模式，但这些模型如同黑箱，只提供预测结果，却缺少机理性解释 [10-15]。这种不透明性使工程师无法理解为何某些孔隙被判定为关键孔隙，降低了人们对自动评估系统的信心，并阻碍了工艺优化。

可解释人工智能通过量化各项特征对模型预测的贡献，为实现透明的缺陷分析提供了途径 [16-18]。近期，SHAP 值在材料科学中的应用已展现出其对特征重要性进行排序并揭示交互效应的能力，但其在增材制造三维孔隙网络中的应用尚未得到探索。了解哪些几何和空间描述符决定孔隙关键性，有助于制定扫描策略、选择工艺参数并作出后处理决策。

本研究旨在构建一个可解释框架，不仅能够检测断层成像体数据中的孔隙，还能阐明其预测临界性评分的物理依据，从而在保持机理透明度的同时，实现数据驱动的质量保证。

2. 方法

输入数据由一组三维断层成像图像堆栈构成，以连续的灰度 TIFF 切片形式存储。每个切片表示试样的一个横截面 [19], , 沿轴向堆叠后即可重建完整的体数据集 I（z、 y、 x）。所有图像均被载入并组装成一个三维数组，同时保留原始体素强度。后续分析仅考虑高强度体素，即断层成像图像中的明亮区域，以抑制无关背景信息并分离与孔洞相关的特征。通过基于强度的阈值分割识别孔洞候选区域，阈值根据公式 1 计算。

$$M(z,y,x) = 1\{I(z,y,x) \geq I_{thr}\} \tag{1}$$

其中，$I_{thr} = 250$ 被选定以捕获明亮的孔洞区域。对二值掩膜应用连通分量标记，以识别图 1 所示的各个明亮区域。最大的连通分量始终被判定为试样边界或成像伪影，因此在后续分析中予以排除。若其体素数量满足公式 2，则将剩余的连通分量归类为孔洞。

$$2 < A_k < 0.01A_{max} \tag{2}$$

其中，A_k 为孔隙体积，A_{max} 为最大连通分量的尺寸。

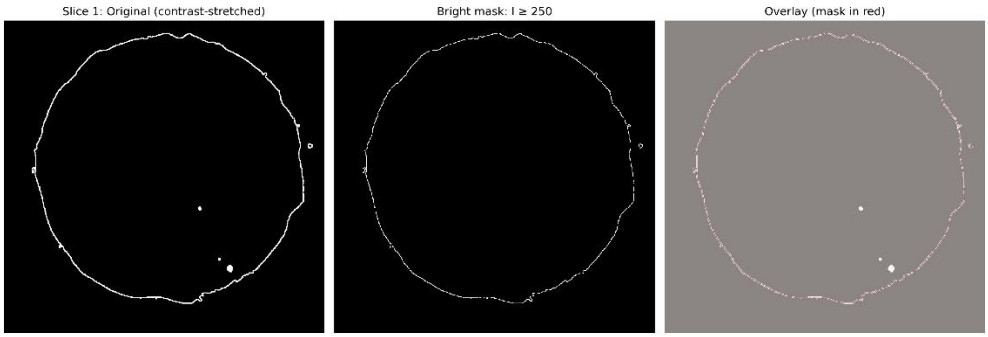

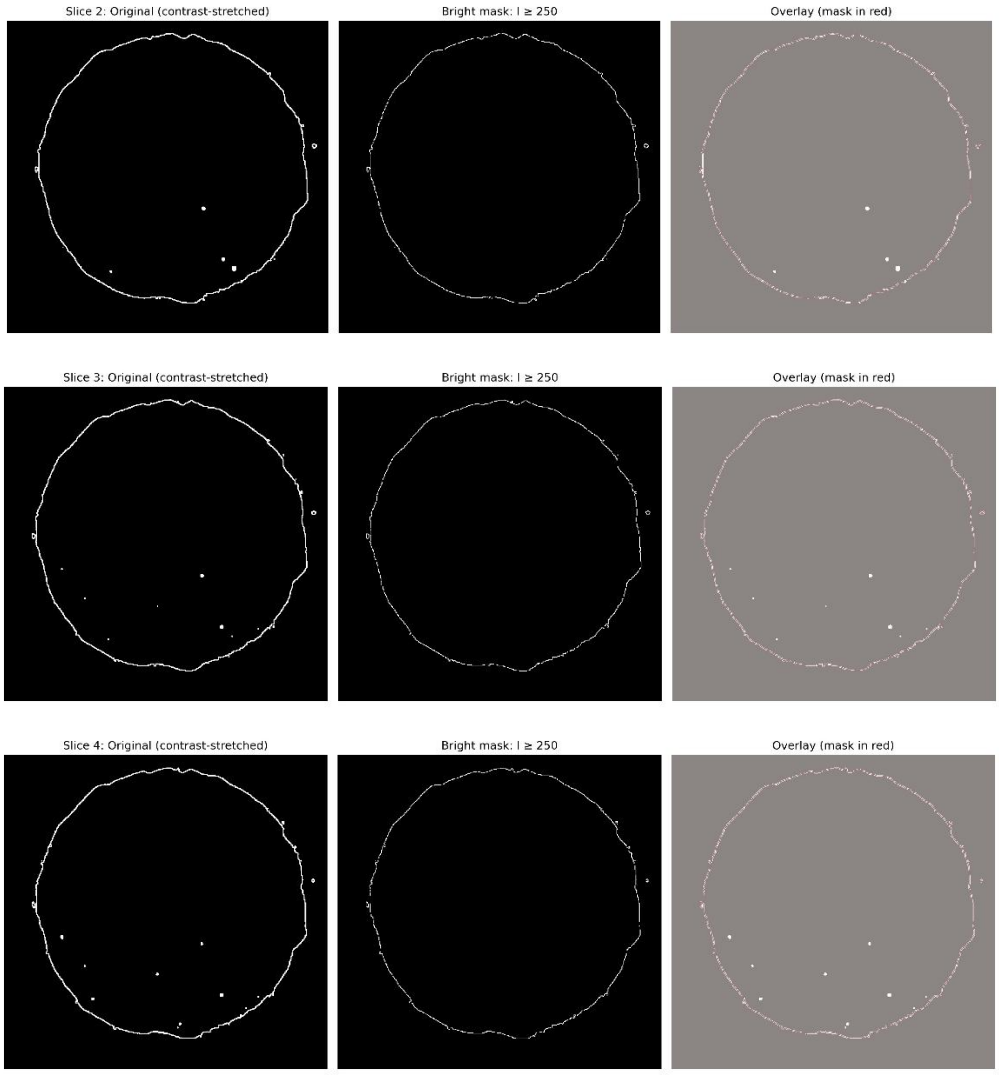

图1. 代表性断层切片上孔隙分割的可视化。对于每个切片，左侧面板显示经对比度拉伸的原始灰度图像，中间面板显示高强度掩膜（$I \geq 250$），突出主要亮边界，右侧面板显示亮掩膜叠加在原始图像上的效果（红色）。该图表明，高强度阈值主要捕获试样边界，而内部孔隙的强度较低，需要自适应阈值处理才能实现可靠检测。

分割过程完成后，使用一组几何和空间描述符对每个识别出的孔洞进行表征。计算每个孔洞的质心，以确定其在试样内的三维位置。孔隙尺寸以构成每个孔洞的体素总数进行量化。提取其他形状描述符，包括长宽比和延展度，以刻画孔隙形态。每个孔洞的轴向位置由其质心沿堆叠方向的坐标确定。计算每个孔洞质心到试样表面的最小距离，并根据试样尺寸进行归一化，以考虑边界效应。

通过将每个孔洞表示为一个位于其质心处的节点，构建了孔洞相互作用网络。计算孔隙之间的两两距离，并依据基于百分位数的距离准则建立连接，以确保网络密度保持一致。该方法无需设定任意的全局距离阈值，并可在不同数据集之间进行可重复的比较。所得网络编码了孔隙之间的空间邻近关系

，且不受孔隙尺寸或取向影响。为保证计算可行性，网络规模限制为仅包含最大的孔隙，同时不改变其底层空间结构。

我们训练了一个监督式机器学习模型，使用提取的描述符作为输入特征，预测各个孔洞的标量临界性评分。特征集既包括孔隙内在特征，也包括外在空间信息。模型训练和评估采用标准数据划分，以确保稳健性并防止过拟合。模型在孔隙层级进行预测，从而能够将局部结构特征与模型输出直接关联。我们采用基于SHAP解释方法的可解释人工智能技术来解释模型预测。通过 SHAP值绝对均值量化特征重要性，并利用蜂群图和依赖图分析特征贡献的方向性和变异性。此项分析无需依赖特定于模型的假设，即可识别主要控制特征并评估次要影响。

3. 结果与讨论

从分割后的断层扫描体中提取并重建的三维孔隙网络如图 2 所示。多个视口展示了该网络的空间组织和连通性，共识别出 500 个孔隙（节点）和 24950 条孔隙间连接（边）。孔隙被定义为面积小于主导圆形边界面积 1% 的连通亮区。每个孔隙的质心位置 k 根据公式 3 计算。

$$c_k = \frac{1}{|\Omega_k|}\sum_{(z,y,x)\epsilon\Omega_k}(z,y,x) \tag{3}$$

图 2a) 和 2c) 显示，孔隙沿试样的整个高度（Z 方向）分布，同时高度集中在外侧径向边界附近。图 2d) 显示出一种环状孔隙排列，其核心区域孔隙稀疏，表明孔隙形态以壳层为主，而非均匀多孔体积。

孔洞间连通性根据使用公式 4 计算的质心之间的欧几里得距离定义。

$$d_{ij} = \left\|c_i - c_j\right\|_2 \tag{4}$$

为所有满足公式 5 的孔洞对构建边。

$$d_{ij} < d_{thr}, d_{thr} = Percentile_{20\%}\left(\left\{d_{ij}: i \neq j\right\}\right) \tag{5}$$

$N = 500$ 个孔洞可能形成的连接总数使用公式 6 计算。

$$\binom{N}{2} = \frac{N(N-1)}{2} = 124750 \tag{6}$$

保留的最低 20% 距离产生 $0.2 \times 124750 = 24950$ 条边，这与图 2（a-d）所示的观测网络密度完全吻合。这证实连通性水平在数学上是一致且受控的。

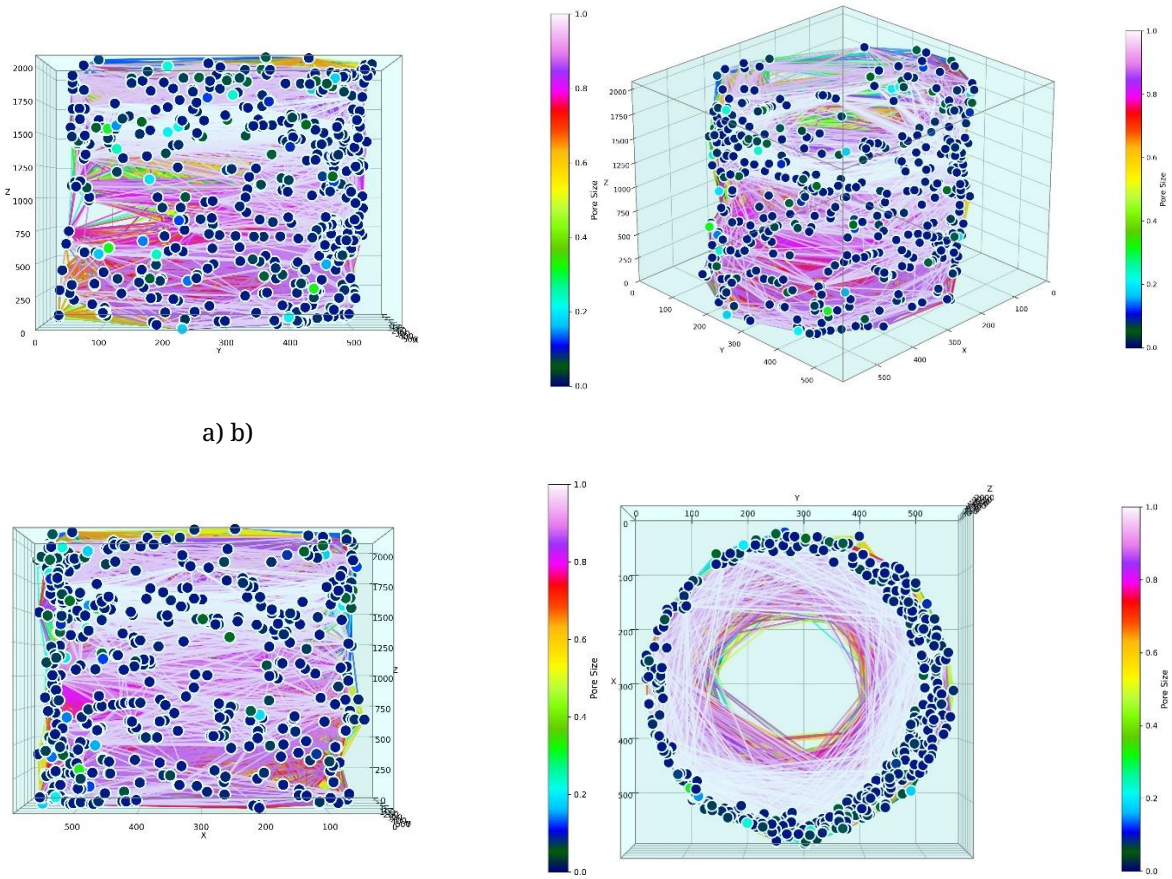

图 2。 根据分割后的断层扫描体重建的三维孔隙网络。该网络由 500 个孔隙（节点）和 24,950 个孔隙间连接（边）组成，这些连接根据基于百分位数的欧几里得距离准则定义。节点对应孔隙质心，并按归一化孔隙尺寸着色；边表示孔隙之间的空间邻近性，并展示了不同的观察方向：(a) 正视图，(b) 等轴测视图，(c) 侧视图和 (d) 俯视图。

图 3 所示的基于 SHAP 的特征重要性排序表明，表面距离在决定模型响应方面占主导地位。表面距离的平均绝对 SHAP 值比所有其他特征高出一个数量级以上，表明模型预测主要由孔洞与外部边界的接近程度所支配。可以观察到，孔隙尺寸的贡献仅属次要，而长宽比、延展度以及轴向（Z）位置等几何描述符对预测结果的影响可忽略不计。这一层级关系意味着，在学习到的关系中，空间位置的重要性超过了固有孔隙形态。模型输出 $f(x)$ 可用公式 7 进行近似。

$$f(x) \approx \Phi_{surface\ distance} + \epsilon \tag{7}$$

其中，Φ 表示 SHAP 贡献值，ϵ 汇总了所有其余特征。ϵ 的幅度较小，证实已知表面距离后，次要描述符不会显著改变预测。

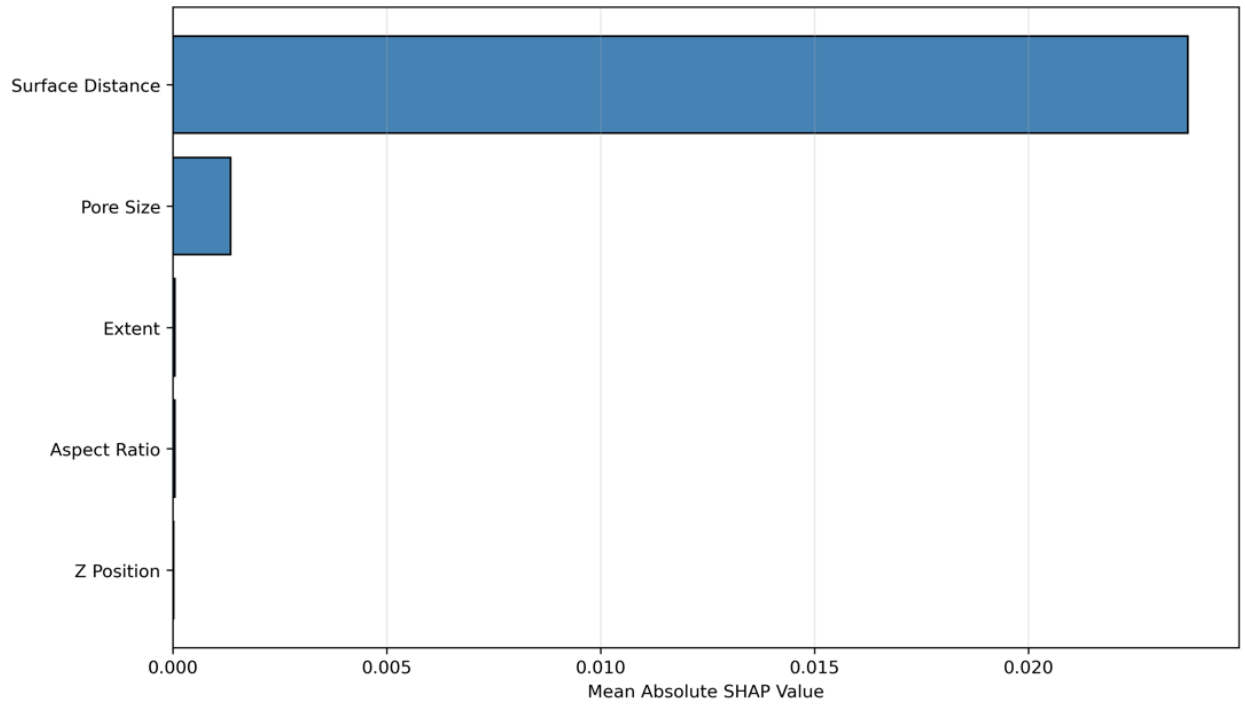

图 3. 基于 SHAP 的特征重要性排序显示了所有输入特征的SHAP值绝对均值。表面距离主导模型预测，其重要性比所有其他描述符高出一个数量级以上。

图4所示的 SHAP蜂群图揭示了各特征对模型输出的贡献大小和方向。表面距离的 SHAP值分布最宽，证实它是控制预测的主导特征。表面距离较高的值（红色点）与负SHAP值相关，而较低的表面距离值（蓝色点）则对模型输出产生正向贡献。这表明表面距离与预测响应之间存在很强的单调反向关系。孔隙尺寸的影响有限，但具有可解释性。较大的孔洞（红色）往往会使预测略微向正方向偏移，而较小的孔洞（蓝色）则产生微弱的负面影响或近乎为零的影响。SHAP值的分布范围较窄，表明孔隙尺寸是次要调节因素，而非主要驱动因素。延展度、长宽比和轴向（Z）位置的 SHAP值均紧密聚集在零附近，且没有明显的颜色分离。这意味着这些描述符既不会产生显著的非线性效应，也不会与主导特征显著交互。在其整个取值范围内，这些特征的贡献始终可以忽略不计。

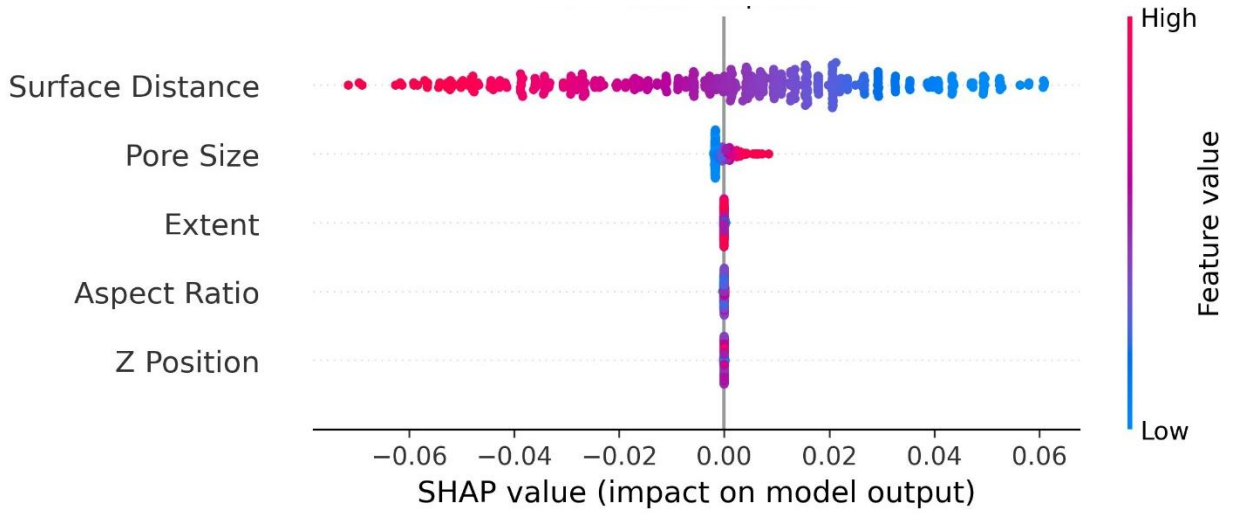

图4. SHAP蜂群图展示了各特征对模型输出的贡献分布、大小和方向。每个点代表一个样本，颜色表示特征值（蓝色：低，红色：高）。

图5所示的散点图呈现了孔隙尺寸与预测临界性评分之间的关系，点的颜色表示孔隙尺寸的 SHAP 贡献值。数据分布表明，在大多数数据中，孔隙尺寸与临界性之间不存在明显的单调依赖关系。小孔隙（≈3–8 个体素）的临界性值几乎覆盖了全部范围，这说明仅凭孔隙尺寸无法确定系统临界性。这一观察结果与此前发现的孔隙尺寸平均SHAP重要性较低相一致。较大的孔隙（≥15 个体素）表现出略小的临界性取值范围，且往往聚集在中等至较高的数值附近。相应的 SHAP 值变为正值（黄色至红色的点），这表明孔隙尺寸是较弱的正向修饰因素，而非模型输出的主要驱动因素。缺乏明显趋势或分岔点，意味着临界行为并非由孔径阈值决定。相反，孔隙尺寸以加和且有条件的方式发挥作用，可能与表面距离等空间特征相互作用。

图6所示的散点图描绘了归一化表面距离与预测临界性评分之间强烈且近乎线性的反向关系。距离表面更近的孔隙始终表现出更高的临界性，而位于材料内部更深位置的孔隙则显示出逐渐降低的临界性数值。平滑的单调趋势和狭窄的散点分布表明，表面邻近度是一个确定性的控制参数，而非弱统计相关因素。这一观察解释了此前识别出的表面距离在SHAP重要性中的主导地位，因为仅该特征的变化就足以解释模型预测中的大部分方差。颜色渐变进一步强化了这一解释。较高的SHAP值（黄–橙色）对应于较小的表面距离以及对临界性的正向贡献，而较大的距离则产生负向SHAP贡献（紫色），从而降低预测响应。这证实了在整个特征范围内影响方向性稳定且一致。从物理上看，这种行为表明临界性的主导机制是边界驱动的，邻近表面的孔隙发挥着不成比例的重要作用。这种行为可能源于增强的应力集中、传输可达性，或局部化于试样表面附近的边界条件效应。

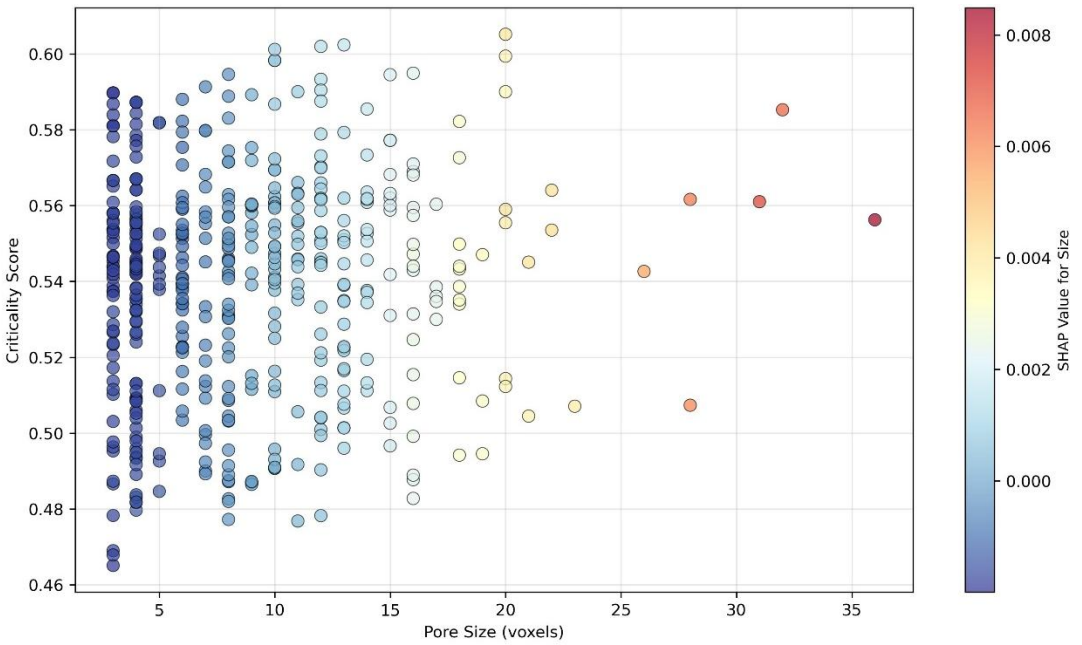

图5。孔隙尺寸与预测临界性评分之间的关系。每个点代表一个独立孔洞，颜色表示与孔隙尺寸相关的 SHAP 值。散点分布广泛且缺乏明显的单调趋势，表明孔隙尺寸本身并不能决定临界性。较大的孔洞对预测有较弱的正向贡献，起次要调节因素的作用，而非主要控制特征。

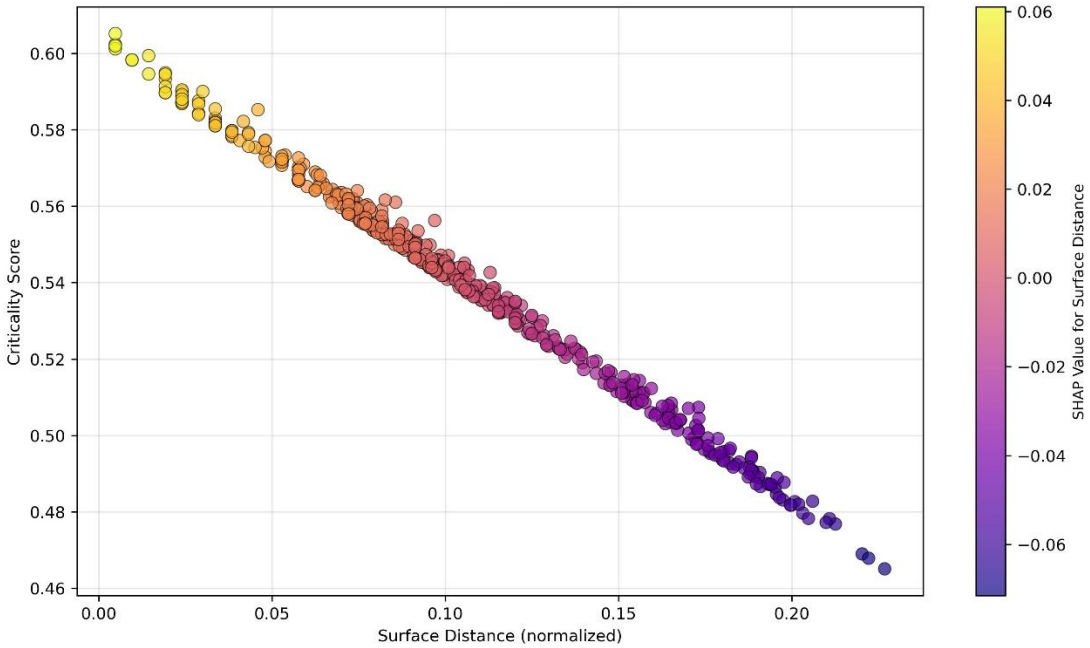

图6。 归一化表面距离与预测临界性评分之间的关系。每个点代表一个独立孔洞，颜色表示与表面距离相关的 SHAP 值。可以观察到明显的反向、近乎线性的趋势，表明越靠近表面的孔洞临界性越高。SHAP 颜色渐变的一致性证实，表面邻近度是模型预测中占主导地位且方向稳定的贡献因素。

4. 结论

本研究利用三维断层扫描数据，开发了一种用于增材制造部件自动孔洞检测与关键性评估的可解释计算机视觉框架。对500个分割孔隙和24,950个空间连接的分析表明，归一化表面距离是临界性预测的主导因素，其特征贡献比其他所有因素高出一个数量级以上。表面邻近度与预测临界性之间存在显著的反向关系，这表明与内部缺陷相比，近边界孔隙会带来不成比例的结构风险。

尽管孔隙尺寸通常被认为与失效模式相关，但其预测影响极小；而长宽比和延展度等几何描述符对模型输出的贡献也微乎其微。SHAP分析以透明的方式量化了这些关系，证实在所研究的试样中，决定临界性的因素是空间位置，而非孔隙本身的形态。这一机理层面的见解表明，扫描策略和过程控制应优先缓解近表面缺陷，而非降低体孔隙率。

这一可解释框架使质量保证决策能够以物理理解为依据，而非依赖不透明的算法预测。未来研究应将此方法拓展至不同的合金体系、制造工艺和载荷条件，以验证表面驱动临界性机制的普适性，并为增材制造质量控制制定自适应检测协议。

参考文献

1. Javaid, M. 和 Haleem, A.，2019年。增材制造在骨科中的应用：综述。临床骨科与创伤杂志，9(3)，第202–206页。

2. Bahnini, I.、Rivette, M.、Rechia, A.、Siadat, A. 和 Elmesbahi, A.，2019年。增材制造技术：现状、应用与前景。国际先进制造技术杂志，97(1)，第147–161页。

3. De Leon, A.C.、Chen, Q.、Palaganas, N.B.、Palaganas, J.O.、Manapat, J. 和 Advincula, R.C.，2019年。用于增材制造应用的高性能聚合物纳米复合材料。反应性与功能性聚合物，103，第141–155页。

4. Abdulhameed, O.、Al-Ahmari, A.、Ameen, W. 和 Mian, S.H.，2019年。增材制造：挑战、趋势与应用。机械工程进展，11(2)，第1687814018822880页。

5. Paul, A.A., Aladese, A.D. 和 Marks, R.S.，2024年。增材制造在生物传感器技术中的应用。《生物传感器》，14(2)，第60页。

6. Kim, F.H.， Kim, F.H. 和 Moylan, S.P.，2018年。金属增材制造缺陷文献综述 .

7. Chen, Y.、Peng, X.、Kong, L.、Dong, G.、Remani, A. 和 Leach, R.，2021。增材制造缺陷检测技术。《极端制造》，3(2)，第022002页。

8. Sanaei, N.、Fatemi, A. 和 Phan, N.，2019年。金属激光粉末床熔融增材制造中的缺陷特征及其变异性分析。《材料与设计》，182，第108091页。

9. Honarvar, F. 和 Varvani-Farahani, A.，2020年。超声检测在增材制造中的应用综述：缺陷评估、材料表征和过程控制。《超声学》，108，第106227页。

10. Gnanasambandam, R., Gotawala, N., Wu, X., Standfield, B., Dou, C., Yu, H.Z., Yu, J. 和 Kong, Z., 2025. 用于增材摩擦搅拌沉积多物理场建模的耦合物理信息神经网络。《IEEE自动化科学与工程汇刊》，23，pp.1631-1649。

11. Herzog, T., Brandt, M., Trinchi, A., Sola, A. 和 Molotnikov, A., 2024. 激光金属增材制造中的过程监测与机器学习缺陷检测。《智能制造杂志》，35(4)，pp.1407- 1437。 12. Li, R., Jin, M. 和 Paquit, V.C., 2021. 利用机器学习模型进行增材制造几何缺陷检测。《材料与设计》，206，p.109726。 13. Chen, Y., Peng, X., Kong, L., Dong, G., Remani, A. 和 Leach, R., 2021. 增材制造缺陷检测技术。《极端制造》，3(2)，p.022002。 14. Du, Y., Mukherjee, T. 和 DebRoy, T., 2021. 物理信息机器学习与机理建模在增材制造中的应用，以减少缺陷。《今日应用材料》，24，p.101123。 15. Salvati, E., Tognan, A., Laurenti, L., Pelegatti, M. 和 De Bona, F., 2022. 基于缺陷的物理信息机器学习框架，用于增材制造中的疲劳有限寿命预测。《材料与设计》，222，p.111089。 16. Lamens, A. 和 Bajorath, J., 2026. 可解释人工智能在药物研究分子设计中的应用。《化学科学》。 17. Kang, Y., Chen, J., Liu, L., Sharma, K., Mazzarello, M., Mora, S., Duarte, F. 和 Ratti, C., 2026. 利用眼动追踪系统、街景图像和可解释人工智能解读人类安全感知。《计算机、环境与城市系统》，123，p.102356。 18. Moraes, I.A., Arrighi, L., J unior, S.B., Cunha, R.L. 和 Barbin, D.F., 2026. 将可解释人工智能（XAI）应用于深度计算机视觉，以评估和分类不同油凝胶剂类型及浓度的油凝胶。《微化学杂志》，p.116821。 19. Ogoke, O.F., Johnson, K., Glinsky, M., Laursen, C., Kramer, S. 和 Farimani, A.B., 2022. 金属增材制造过程中产生的孔隙率分布的深度学习生成器。《增材制造》，60，p.103250。