

基于显式视觉提示的煤岩 CT 图像裂隙分割模型及应用

靳子越¹, 李海涛^{1,2,3}, 杨冠宇^{1,2,3}, 陈宇龙^{1,2,3}, 张海宽^{1,2,3}

(1. 煤炭科学研究总院 深部开采与冲击地压防治研究院, 北京 100013; 2. 煤炭智能开采与岩层控制全国重点实验室, 北京 100013; 3. 天地科技股份有限公司 北京技术研究分公司, 北京 100013)

摘要: 针对目前煤岩识别算法模型难以准确识别 CT 扫描图像中细小裂隙等问题, 提出一种基于显式视觉提示的煤岩 CT 图像裂隙分割模型 (EViP-CTCrack), 并在自建的煤岩 CT 扫描图像数据集 CTRock 上进行了算法验证。EViP-CTCrack 主要由残差混合连接卷积模块、交叉注意力上采样模块、多代表性向量分类器和显式视觉提示生成器等模块组成。实验证明, EViP-CTCrack 在 CTRock 数据集上的平均交并比和精确率分别达到了 88.1% 和 94.4%, 取得了良好的裂隙分割效果。最后, 将该模型应用于矿井钻孔岩心裂隙识别, 建立了孔隙度-抗压强度方程, 可以快速推算其单轴抗压强度。

关键词: 视觉提示; 裂隙识别; 煤岩 CT 图像; 数字化

中图分类号: TD712

A Crack Segmentation Model for Coal-Rock CT Images Based on Explicit Visual Prompting and Its Applications

JIN Ziyue¹, LI Haitao^{1,2,3}, YANG Guanyu^{1,2,3}, CHEN Yulong^{1,2,3}, ZHANG Haikuan^{1,2,3}

(1. China Coal Research Institute, Deep Mining and Rockburst Institute, Beijing 100013, China; 2. State Key Laboratory of Intelligent Coal Mining and Strata Control, Beijing 100013, China; 3. Beijing Technology Research Branch, Tiandi Science & Technology Co., Ltd., Beijing 100013, China)

Abstract: There are various defect structures, including cracks and pores, in coal and rock masses, which have a decisive impact on the occurrence and migration of coalbed methane. At the same time, the instability and destruction of coal rock structures are closely related to the changes and expansion of coal rock pore and crack structures, leading to mining dynamic disasters. Therefore, conducting relevant analysis on coal rock crack identification is of great practical significance for studying the migration law of coal seam gas and the stability of surrounding rock. The models proposed in latest studies for improving the identification accuracy of internal cracks in coal and rock masses still have the following shortcomings: (1) the impact of noise interference in CT images on model performance is often overlooked. (2) The potential loss of small crack features during downsampling and the insufficient fusion of multi-layer features during upsampling have not received sufficient attention. (3) The rich differences within the crack categories have not been fully considered. To address the challenge of accurately identifying microcrack in CT scan images of coal and rock, this study proposes a crack segmentation model based on explicit visual prompting for coal and rock CT images (EViP-CTCrack) by reorganizing the convolution kernel, downsampling and upsampling processes, and classifier functions. This model effectively filters out noise interference and enhances its ability to capture key details of cracks by introducing an explicit visual cue generator. By improving the downsampling and upsampling strategies, preserving small crack features and enhancing multi-scale feature fusion capabilities, the segmentation accuracy of the model is improved. By using a multi representative vector classifier, the internal differences of crack categories can be fully described to improve the generalization ability of the model. The main results show that (1) the crack segmentation model EViP-CTCrack mainly consists of residual mixed connection convolution module, cross attention upsampling module, multi representative vector classifier, and explicit visual prompt generator module, which can effectively improve the shortcomings of existing models in noise interference, feature loss, and crack category difference description, significantly enhancing the robustness and generalization ability of the model. (2) This study proposes a high-quality coal and rock CT image dataset, CTRock, and conducts comparison and ablation study on CTRock to verify the effectiveness of the targeted design. The algorithm is validated by the proposed CTRock dataset. The average intersection to union ratio and accuracy of EViP-CTCrack on the CTRock dataset reaches 88.1% and 94.4%, respectively, achieving good crack segmentation results. (3) After CT scanning

基金项目: 国家自然科学基金资助项目 (52474174, 52374206, 52104090)

通信作者: 李海涛, 博士, 研究员, 从事数字岩石力学方面的研究; E-mail: lihaitao@mail.ccri.ccteg.cn

of the rock samples collected from Xinjie Coal Mine, EViP-CTCrack is used to identify cracks in all layers of the reconstructed data slices. A porosity compressive strength equation is established, which can quickly calculate its uniaxial compressive strength and provide new ideas for the study of coal rock physical and mechanical properties.

Key words: visual prompting; crack recognition; coal-rock CT images; digitization

1 引言

随着我国中东部煤矿逐渐进入深部开采，冲击地压等动力灾害日益加剧，严重制约深部矿井的安全高效开采^[1,2]。而煤岩体的稳定性主要受煤岩组分与裂隙分布的影响，裂隙的方向、大小对其扩展和贯通过程具有决定性影响^[3]。因此，开展煤岩裂隙识别的相关分析，快速准确地获取这些重要因素为防控煤岩失稳破坏提供了重要指导和设计依据。

随着计算机视觉技术和深度学习领域的不断进步，那些曾经让传统图像处理手段束手无策的煤岩裂隙识别难题，现已找到了新的破解之道。具体而言，煤岩裂隙的识别工作已被有效地纳入了图像语义分割的任务范畴之中。语义分割模型始于传统 CNN^[4]，随后引入 3D CNN^[5]，专注于三维数据处理，其发展历程如图 1 所示。随后，全卷积网络 FCN^[6]，首次实现像素级预测，奠定了深度学习在此领域的基础，而 U-Net^[7]通过编码器-解码器结构优化医学图像分割，强调特征保留。同时，ResNet^[8]引入残差连接，解决深层网络训练中的消失梯度问题，SegNet^[9]进一步优化 U-Net，采用对称结构保留细节。DeepLab^[10]系列结合空洞卷积和条件随机场改善分割精度，Deformable Convolution^[11]增强了模型对复杂形状的处理能力。Mask R-CNN^[12]扩展了 Faster R-CNN^[13]，实现物体检测与实例分割的结合。PSPNet^[14]通过金字塔池化模块提高了多尺度特征捕捉能力。Transformer^[15]在自然语言处理领域大放异彩，通过引入 Transformer 的自注意力机制，捕捉长距离依赖关系，推动语义分割的进一步发展。Vision Transformer^[16]和 Swin Transformer^[17]则通过创新的特征表示和注意力机制，进一步提升了分割性能。SegFormer^[18]则结合了 Transformer 和卷积网络的优点，实现高效的跨尺度特征学习，在处理不同大小物体时表现优异。近期的 Segment Anything^[19]又凭借其卓越的通用性、交互性和高效性，推动了图像及视频分割技术的发展，尤其在无监督和少监督分割任务中展现了巨大的潜力。




图 1 语义分割模型主要发展历程

Fig.1 Key Milestones in the Evolution of Semantic Segmentation Models

近年来，凭借卓越的特征提取与数据建模能力，这些算法模型已成为煤岩裂隙识别领域不可或缺的重要工具。与传统图像处理方法依赖人工提取特征工程不同，深度学习方法能够从大量数据中学习得多尺度的裂隙特征，尤其在处理高维度和复杂结构的数据时表现出明显优势。例如，王登科等^[20]通过改进 U-Net 模型提升了裂隙分割精度；冯雪健等^[21]通过对比几种分割模型，得出 ResNet-18 模型在图片样本为亮度 4，尺度为 3.5~21mm 时是适用于计算含裂隙的二维 CT 图像的分形维数的最优模型；吴承毅^[22]通过改进 DeepLabV3+实现了煤岩裂隙的精准分割；王登科等^[23]以 VGG16 作为主干提取网络，引入了 ResCBAM 注意力模块和 AC-ASPP 模块，设计并实现了 VRA-UNet 模型，有效解决了煤岩组合体中煤和裂隙颜色接近导致的识别问题；高亮等^[24]搭建了 AttentionU-net 神经网络，该网络在 U-net 基础上引入了注意门（Attention Gate），提高了对裂缝区域的关注权重；胡咤咤等^[25]通过预处理和数据增强技术提高图像质量并扩充样本数量，提出了一种基于 Trans-UNet 网络和 μ CT 图像的煤裂隙提取方法，大幅提高了分割精度和网络鲁棒性；Wang 等^[26]在 U-Net 网络架构基础上引入深度可分离扩张卷积和残差模块，提出

的裂隙分割模型 MCSN 在识别精度和鲁棒性方面有了大幅提升；Qian 等^[27]提出了一种改进 SOLOv2 框架的煤岩裂隙实例分割网络 FracSeg，通过引入 Swin Transformer 优化特征提取、使用 CARAFE 算子替代最近邻插值以减少计算开销，并加入 Shuffle Attention 模块提升裂隙特征检测能力，达到了理想的分割效果。

然而，尽管深度学习技术的最新进展极大地提升了煤岩体内部裂隙识别的精确度，但上述现有研究提出的模型（如改进 U-Net 系列、改进 ResNet 系列、改进 DeepLab 系列、改进 SOLO 系列与改进 Transformer 系列）仍存在以下不足：（1）CT 图像中的噪声干扰对模型性能的影响往往被忽视。噪声普遍存在于实际煤岩 CT 图像中，可导致模型误判裂隙，识别精度降低。而现有模型大多只在数据预处理阶段通过调整图像饱和度与对比度等方式简单处理噪声，难以有效分离高频裂隙特征与低频背景噪声。

（2）下采样过程中可能导致的细小裂隙特征丢失问题以及上采样过程中可能存在的多层特征融合不充分问题也未得到充分关注。细小裂隙在煤岩稳定性评估中具有重要意义，下采样与上采样策略不当可能导致这些关键特征的丢失，从而影响模型的分割效果。当前研究大多采用传统的下采样-上采样策略（如大核卷积与简单线性插值）以及单尺度分支设计的特征融合方式与注意力机制（如 CBAM 模块与注意力门），易导致特征定位偏差，影响细小裂隙分割精度。（3）裂隙类别内部丰富的差异性问题的也未得到充分考虑。不同类型的裂隙在形态、大小和方向上存在差异，这对模型的识别能力提出了更高要求。但现有研究往往采用简单的分类器，对裂隙进行单一分类向量表征，难以刻画裂隙类内形态多样性，导致模型在实际应用中的泛化能力受限。

鉴于此，本文通过重新梳理卷积核、下采样与上采样过程以及分类器的功能，提出了一种基于显式视觉提示的煤岩 CT 图像裂隙分割模型 EViP-CTCrack。该模型通过引入显式视觉提示生成器，有效过滤噪声干扰，增强模型对裂隙关键细节的捕捉能力；通过改进下采样与上采样策略，保留细小裂隙特征并增强多尺度特征融合能力，提高模型的分割精度；通过多代表性向量分类器，充分描述裂隙类别内部的差异性，提升模型的泛化能力。本文的主要贡献在于：（1）基于 4 个创新模块构建的裂隙分割模型 EViP-CTCrack 有效改善了现有模型在噪声干扰、特征丢失和裂隙类别差异描述方面的不足，显著提升了模型的鲁棒性和泛化能力；（2）自建高质量煤岩 CT 图像数据集 CTRock，并在 CTRock 上进行对比实验与消融实验，验证了针对性设计的有效性；（3）将新街煤矿所采岩样经 CT 扫描后，使用 EViP-CTCrack 对其重构数据所有层位的切片进行裂隙识别，建立了孔隙度-抗压强度方程，为煤岩物理力学性质研究提供了新思路。

2 煤岩 CT 图像裂隙分割模型

采用跳跃连接的编码器-解码器架构的 EViP-CTCrack 模型包含 4 个重要模块：残差混合连接卷积块（RMconv 块）、交叉注意力上采样（JAU）、多代表性向量分类器（MRV 分类器）和显式视觉提示生成器，具体架构设计如图 2 所示。

编码器部分，由注意力下采样和残差混合连接卷积块构建了四个阶段，每个阶段具有不同的块数。四个编码器阶段的通道被调整为 96、192、384 和 768。下采样操作在主干中通过步幅为 2 的 2×2 卷积进行，在三个下采样层中通过基于注意力的 LIP 池进行。随着网络深度的增加，编码器阶段 4 的特征图空间分辨率降至最低（高和宽均为原始图像的 $1/16$ ），导致细粒度裂隙特征（如微米级孔隙边界）因下采样过程中的信息压缩而显著丢失。此外，LIP 池化通过注意力权重筛选全局显著特征，但可能抑制局部高频细节（如细小裂隙），而深层大感受野（阶段 4）更偏向提取宏观裂隙的连续性形态，进一步加剧了微观特征的损失。

对于解码器，阶段 1 配备了交叉注意力上采样，其他阶段利用双线性插值进行上采样。由于裂隙和背景的重要特征在编码器阶段 4 中损失最大，解码器阶段 1 采用 JAU 模块，通过交叉注意力机制动态加权融合多层信息，重点恢复阶段 4 丢失的微观裂隙细节。考虑到对多层特征求和可能会覆盖一些细节，因此通过级联操作将相应阶段的编码器和解码器输出融合在一起。最后，采用多代表性向量分类器和双线性插值层为每个像素独立生成裂隙概率。




图2 基于显式视觉提示的煤岩 CT 图像裂隙分割模型设计架构

Fig.2 Architecture Design of an Explicit Visual Prompt-Based Model for Crack Segmentation in Coal-Rock CT Images

2.1 残差混合连接卷积块

残差混合连接卷积块 (RMconv) 的主要作用是增强模型下采样过程中的细粒度信息提取能力, 同时融合多尺度特征。煤岩体中矿物颗粒及宏、微观裂隙的尺寸多样性导致编码过程中的特征信息呈现多尺度状态, 而传统的卷积模块在处理多尺度信息时可能会丢失一些关键的细粒度细节。在煤岩 CT 图像裂隙识别任务中, 裂隙的细节信息对于准确识别至关重要, 因此, 设计了这种具有三个层残差混合连通分支的逆残差块。该块包括多分支深度 (DW) 卷积模块和两个逐点 (PW) 卷积层。不考虑偏差, 这两个卷积可以表示为:

$$DW(w, x)(i, j) = \sum_{u,v}^{k,k} x_{c,i+u,j+v} w_{u,v} \quad (1)$$

$$PW(w, x)(i, j) = \sum_c^C x_{i,j,c} w_c \quad (2)$$

式中, w 为卷积核权重, x 为输入, i, j 为输入特征的 2D 坐标, C 为输入特征的通道数量; c 为第 c 通道, k 为卷积核大小, 在 RMConv 中为 3。考虑到计算复杂度, 将 RMConv 的多分支卷积块上移, 如图 3 所示。通过逐渐增加通道并合理设计后续的非线性函数, 以提高倒置设计块的表现力。




图3 残差混合连接卷积块

Fig.3 RMConv Block

在 RMConv 的分支设计方面，仅设置了三个具有 3×3 卷积核的分支，以控制速度和接受域。值得注意的是，RMConv 先将每个分支的卷积结果连接起来，然后批量规范化（式（3））和 ReLU（式（4））处理。

$$BN = \frac{x - \mu_c}{\sqrt{\sigma_c^2 + \varepsilon}}, \quad \mu_c = \frac{1}{BHW} \sum_b \sum_i \sum_j x_{bcij} \quad (3)$$

$$\sigma_c^2 = \frac{1}{BHW} \sum_b \sum_i \sum_j (x_{bcij} - \mu_c)^2, \quad ReLU = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases} \quad (4)$$

式中， B 、 H 和 W 分别为输入特征的批量大小、高度和宽度， c 为特征通道索引（第 c 通道）， μ_c 和 σ_c 分别为第 c 通道的均值和方差， ε 是为了避免数值不稳定引入的小常数。通过式（1），RMConv 可以公式化为：

$$y(x) = \text{concat}(y_1(x_1), y_2(x_2), y_3(x_3)) \quad (5)$$

$$y_i(x_i) = \begin{cases} DW(w_i, x_i) & \text{for } i=1 \\ DW(w_i, \text{concat}(y_{i-1}(x_{i-1}), x_i)) & \text{for } i>1 \end{cases} \quad (6)$$

式中， x_i 、 y_i 和 w_i 分别为相应分支的输入特征、输出和核权重。

这种设计在保持计算效率的同时，可以更好地捕捉裂隙的细粒度信息。通过感受野等效方法将 Res2Net 和 RMConv 的多分支模块转换为类似混合深度卷积（MixConv）的结构，见图 4。混合深度卷积可以通过分割输入通道来融合多尺度信息。然而，在识别裂隙时，不同通道中的多尺度核引起的信息定位和特征提取之间的矛盾是不可避免的。由于区分细粒度信息对于裂隙检测很重要，考虑到计算效率和特征定位，小卷积核可能更好。RMConv 的结果可以看作是具有相同输入的两部分输出，一部分仅由 3×3 卷积核获得，而由较大感受野（ 5×5 和 7×7 ）处理的其他输出由堆叠的 3×3 卷积核生成，即通过三个分支的 3×3 卷积核堆叠等效 5×5 、 7×7 感受野，兼顾细粒度定位与多尺度特征融合。具体而言，小卷积核（ 3×3 ）优先捕捉颗粒边界和微裂隙的高频细节，而等效大感受野分支通过堆叠卷积捕获宏观裂隙的连续形态。因此 RMConv 为细粒度信息提取和多尺度信息融合提供了一种选择，而不影响特征定位。




图 4 混合深度卷积
Fig.4 MixConv Block

2.2 交叉注意力上采样

在具有编码器-解码器结构的裂隙检测网络中，上采样层的功能是对高/低分辨率特征图进行上采样，以匹配编码器策略的低/高分辨率输出特征。同时，上采样层还涉及在一些具有跳跃连接的解码器中融合多层特征。

对于编码器和解码器之间的跳跃连接结构，解码器中生成的信息主要是对解码器输出特性的补充。通过利用全局和多层特征，编码器的高分辨率输出可以指导解码器中低分辨率特征的上采样。由于像素自适应卷积不能直接应用于裂隙分割网络，因此提出了一种新的上采样方法，即交叉注意力上采样（JAU），旨在解决上采样过程中多层特征融合不充分的问题。其结构如图 5 所示。JAU 根据权重信息恢复下采样层中消失的裂隙特征。具体的，JAU 通过采用卷积并忽略批量大小，将第 i 个编码器策略的高分辨率输出特征作为查询进行处理，将解码器中第 j 级策略的低分辨率输出特性作为关键值进行处理。JAU 可以简单地表述为：

$$Y_{2H \times 2W, C} = JAU(E_{2H, 2W, C}, D_{H, W, 2C}) = \text{softmax}\left(\frac{Q_{2H \times 2W, C} K_{C, H \times W}}{\sqrt{C}}\right) V_{H \times W, C} \quad (7)$$

$$\text{softmax}(z_i) = \frac{\exp(z_i)}{\sum_{n=1}^N \exp(z_n)} \quad (8)$$




图 5 交叉注意力上采样

Fig.5 The diagram of Joint Attention Upsampling(JAU)

式中， $Y_{2H \times 2W, C}$ 为 $2H \times 2W$ 分辨率和 C 通道的上采样结果， N 为类别的总数， i 为的是第 i 类。由于 JAU 中的卷积投影可以对局部空间关系进行建模，因此 JAU 不需要位置嵌入。在 JAU 和第 i 个编码器策略输出的求和之后，有一个深度可分离（DS）卷积层，用于进一步从多层特征中捕获上采样信息和局部空间关系。这种设计使得模型能够更好地利用编码器阶段的高分辨率特征来指导解码器阶段的低分辨率特征上采样，从而提高裂隙分割的精度。

2.3 多代表性向量分类器

输入数据首先由深度网络处理成向量，然后使用基于 softmax 投影或像素查询的分类器分配到相应的类别。分类器可公式化为：

$$p(n|i) = \frac{\exp(-\langle i, g_n \rangle)}{\sum_{n=1}^N \exp(-\langle i, g_n \rangle)} \quad (9)$$

式中， $p(n|i) \in [0,1]$ 为像素 i 被分配给类 n 的概率， N 为类的数量， $\langle \cdot \rangle$ 为距离度量， g_n 为第 n 类的可学习投影向量或查询向量。

多代表性向量分类器（MRV）的设计是为了更好地描述裂隙类别的丰富类内方差。以往的裂隙分割模型可学习投影向量（即输出通道）的数量仅为 1 或 2，相应的分类器不足以描述裂隙的丰富类内方差。因此，提出一种针对每个类别具有多个代表向量的分类器，即 MRV。该方法的实现只需要基于传统分类器将每个类的输出通道数量从 1 个增加到 K 个。MRV 可表述为：

$$p(n|i) = \frac{\sum_{k=1}^K \exp(V_{n,k}^T i)}{\sum_{n=1}^N \sum_{k=1}^K \exp(V_{n,k}^T i)} \quad (10)$$

式中， n 为类别索引（ $n=1$ 表示裂隙， $n=2$ 表示背景）， k 为第 n 类中第 k 个代表向量（ $k=1,2,\dots,K$ ）， $V_{n,k}$ 为第 n 类第 k 个代表向量的可学习投影向量， K 为分类器中每个类的代表向量数量，本文中 K 设为

10. 这种设计使得模型能够更全面地把握不同形态、大小和方向的裂隙，从而提高模型的泛化能力。

2.4 显式视觉提示生成器

显式视觉提示生成器是 EViP-CTCrack 模型的重要结构，其设计通过过滤低频噪声并将包含细小裂隙特征的高频信息显式地注入网络，可显著提高裂隙识别的效果。煤岩 CT 图像中存在噪声和复杂的纹理特征，传统的分割网络在分割煤岩 CT 图像任务中往往因数据不平衡和噪声干扰表现出精度不足。而通过在煤岩 CT 图像上附加标注这种隐式的策略，又常导致深度神经网络出现过拟合现象。因此，设计一种显式视觉提示生成器，将煤岩 CT 图像中的高频特征作为显式提示信息嵌入到深度神经网络中，引导深度神经网络聚焦于裂隙的关键细节，增强深度神经网络在复杂纹理和噪声环境下的鲁棒性，进而显著提高岩石 CT 图像中裂隙的分割精度。

显式视觉提示生成器的输入为 CT 图像及其高频调优分量之和，由依次连接的 N 个卷积模块和 N 个提示信息组成，如图 6 所示。具体的，N 个卷积模块分别为卷积模块 1 至卷积模块 N，N 个提示信息分别为提示信息 1 至提示信息 N。第 n 个卷积模块后为第 n 个提示信息，卷积模块和提示信息成组出现，且卷积模块在前，每个卷积模块包括在前的卷积层和在后的激活层。另外，由 CT 图像获得其高频调优分量的过程为：为可输入图像的每个通道单独计算掩码；为可输入图像的每个通道单独做傅里叶变换（式 11）并中心化（式 12）；将最终掩码与中心化后的矩阵进行 Hadamard 乘积；逆中心化（式 13），逆傅里叶变换（式 14）并只保留所得结果的实部。

$$F(u, v) = \sum_{x=0}^{H-1} \sum_{y=0}^{W-1} f(x, y) \cdot e^{-j2\pi(\frac{ux}{H} + \frac{vy}{W})} \quad (11)$$

式中， $F(u, v)$ 是频率域上的复数值矩阵， u 和 v 分别表示在频率域中的横向和纵向频率， x 和 y 分别表示在空间域中的横向和纵向坐标， j 是虚数单位，满足 $j^2 = -1$ ；

$$F_c(u, v) = F(u, v) \cdot (-1)^{u+v} \quad (12)$$

式中， $F_c(u, v)$ 为中心化后的矩阵；

$$G_c(u, v) = G(u, v) \cdot (-1)^{u+v} \quad (13)$$

式中， $G(u, v)$ 为最终掩码与中心化后的矩阵进行 Hadamard 乘积结果， $G_c(u, v)$ 为逆中心化后的矩阵。

$$g_c(x, y) = \frac{1}{HW} \sum_{u=0}^{H-1} \sum_{v=0}^{W-1} G_c(u, v) \cdot e^{-j2\pi(\frac{ux}{H} + \frac{vy}{W})} \quad (14)$$




图 6 显式视觉提示生成器

Fig.6 Explicit Visual Prompt Generator

3 实验过程及结果

3.1 数据集

本文提出一种名为 CTRock 的高质量裂隙数据集，包含 1000 张精细注释的煤岩 CT 图像，其中训练集 600 张，验证集 200 张，测试集 200 张，原始图像分辨率为 512×512 像素。覆盖常见岩石，如煤、砂岩和花岗岩等。由于每个像素为微米级精度，大多数图像中的裂隙分布和背景基质比现有数据集更复杂。

CTRock 数据集制作过程如下：（1）取样和取芯；（2）煤岩试件的单轴压缩；（3）对有裂隙煤岩进行 CT 扫描并重建；（4）使用 Avizo 软件进行三维重构并导出 CT 切片。按照上述程序，采集 1 万张分辨率 1000×1000 像素的 CT 图像，每个图像被分割成几个 512×512 像素的图像块，然后去除重复或相似的裂隙分布并调整具有学习困难的数据数量，最终选择 1000 个图像块并使用 Labelme 进行精细标注形成 CT 图像裂隙分割数据集 CTRock，如图 7 所示。




图 7 数据集展示.(a) 原图; (b) 标签图

Fig.7 CTRock Examples:(a) source image;(b) label image

3.2 实验环境与参数设置

实验在 PyTorch 1.10.2+CUDA 11.3 上以 FP32 精度实现，使用单个 RTX A6000 GPU。在 CTRock 数据集上对模型进行训练，本文选择 AdamW 优化器，其动量为 0.9。AdamW 优化器是 Adam 优化器的改进版本，能够有效结合动量和自适应学习率的优点，同时避免权重衰减对参数更新的不良影响。批量大小设置为 16，这一选择一方面是基于硬件资源和模型内存需求的平衡，**另一方面也通过平衡 GPU 内存与多尺度特征学习需求确定：较大批量可覆盖不同矿物成分（如煤、砂岩）不同尺度的分布差异，缓解因矿物与裂隙的尺度差异导致的特征偏移。**总迭代次数为 100，这一设置是基于对模型收敛速度的观察和验证集上的性能评估，能够使模型在验证集上达到较好的性能，同时避免了过长的训练时间。线性预热次数设置为 5 次，这是基于对模型训练初期稳定性的需求，通过在训练初期逐渐增加学习率，有助于模型更稳定地进入收敛状态。初始学习率设置为 10^{-4} ，这是基于初步实验中表现出的较好收敛性能，同时避免了过高的学习率可能导致的训练不稳定。**权重衰减系数设置为 4×10^{-5} ，该值是通过在验证集上的实验结果确定的，旨在平衡模型对多尺度特征的泛化能力与过拟合风险。学习率乘以 $(1 - \text{iter}/\text{max_iter})^{0.9}$ ，这是一种常用的学习率动态衰减策略，能够根据迭代次数动态调整学习率，在训练初期保持较高学习率以快速拟合宏观裂隙，后期降低学习率以细化微裂隙定位。**

对于数据增强，随机旋转、随机颜色抖动、模糊以及随机水平和垂直翻转的可能性分别设置为 0.5、0.5、0.2、0.5 和 0.5。**最大随机旋转度为 30° ，目的是模拟钻孔岩心多方向切片的矿物分布特性，增强模型对裂隙方向变化的鲁棒性。随机颜色抖动的亮度、对比度、饱和度和色调分别为 32、0.5、0.5 和 0.1，旨在针对煤岩中不同矿物（如煤的暗色基质与方解石脉的亮色区域）的反射率差异，强制模型关注裂隙形态而非颜色偏差。高斯模糊的半径设置为 5，旨在抑制 CT 图像中矿物颗粒噪声（如石英晶粒的细观纹理），突出裂隙边缘的高频信号，减少细观干扰对特征提取的影响。**这些数据增强策略的选择是为了增加模型对不同数据变化的适应能力，同时避免模型对训练数据的过拟合。此外，受限于模型的输入要求和计算资源的限制，随机裁剪用于生成 448^2 像素的输入图像，以保证模型能够捕捉到足够细节的同时，避免过大的输入尺寸导致的计算资源浪费。交叉熵（CE）损失函数用于评估预测和标签之间的差异，这是分类任务中常用的损失函数，能够有效地衡量模型预测值与真实标签之间的差异。所有模型的权重都按照无限制正态分布进行初始化，这一初始化方法能够为模型提供一个合理的初始参数分布，有助于模型更快地进入收敛状态。

3.3 评价指标

本文基于混淆矩阵评价图像分割的准确性和性能。混淆矩阵以四个不同的分类结果为基础，包括真

阳性（TP）、真阴性（TN）、假阳性（FP）和假阴性（FN）。计算图像分割的评价指标为召回率（Recall）、精确率（Precision）、交并比（IoU）和平均交并比（mIoU），具体计算公式如下：

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

$$Recall = \frac{TP}{TP + FN} \quad (16)$$

$$IoU = \frac{TP}{FN + FP + TP} \quad (17)$$

$$mIoU = \frac{1}{N} \left(\sum_n^N \frac{TP}{FN + FP + TP} \right) \quad (18)$$

式中，TP、FP 和 FN 为真阳性、假阳性和假阴性的样本数量，N 为类别的数量，裂隙识别取值为 2。

3.4 裂隙识别结果

本文将基于显式视觉提示的岩石 CT 图像裂隙识别模型（EViP-CTCrack）与经典模型进行比较，包括基于 ResNet-101 的 CrackNet、CrackSeg、DeepCrack1、DeepCrack2、基于 ResNet-1001 的 DeepLabv3plus+SN+MSFFM（DSM）、FLANet、HRVit、U-HRNet、UNet2022 和改进的 CarNet。这些模型均为近年来在图像分割领域表现优异的模型，涵盖了不同的网络架构和特征提取方法，具有较高的代表性和广泛的应用前景。选择这些模型进行比较，旨在全面评估 EViP-CTCrack 模型在裂隙识别任务中的性能优势。此外，还将关键模块与 Res2Net、MixConv 和基于不可学习原型的分类器进行比较。

3.4.1 网络比较结果

图 8 通过比较不同裂隙识别模型对 CTRock 数据集中代表性示例的裂隙识别效果，展示出不同模型在处理复杂裂隙分布时的细节识别能力和背景抑制效果，直观地反映了各模型在实际应用中的优劣。从图 8 中可以看出，EViP-CTCrack 模型在识别细小裂隙和复杂背景下的裂隙时表现出色，能够更准确地提取裂隙的边界和形状，而其他模型在某些情况下会出现误判或漏判的情况。表 1 通过定量指标全面展示了各模型的性能差异，为模型性能的评估提供了客观依据。从表 1 中可以看出，EViP-CTCrack 模型在 mIoU 和裂隙 IoU 等关键指标上均优于其他模型，表明其在裂隙分割任务中具有更高的准确性和鲁棒性。具体而言，EViP-CTCrack 模型的 mIoU 达到了 88.1%，比之前的最优模型 U-HRNet 提高了 1.7%，裂隙 IoU 也达到了 77.4%，显示出其在裂隙识别任务中的显著优势。这些结果表明，EViP-CTCrack 模型在处理复杂裂隙分布时能够更有效地提取裂隙特征。与 CrackNet、CrackSeg、DeepCrack1、DeepCrack2、DSM、FLANet、HRVit、U-HRNet、UNet2022 和改进的 CarNet 相比，EViP-CTCrack 优于其他十种模型，得益于其 4 个关键创新模块在细粒度信息捕捉、多尺度特征融合、交叉注意力上采样以及高频信息显式注入等多方面优势的共同作用，EViP-CTCrack 以其独特的设计架构与强大的特征提取能力在煤岩 CT 图像裂隙分割任务中取得了显著优势。




图 8 不同裂隙识别模型对 CTRock 数据集中的代表性示例的裂隙识别效果（白色：真阳性，红色：假阴性，绿色：假阳性）

Fig.8 Qualitative results of different methods. White: True Positive; Red: False Negative; Green: False Positive.

表 1 CTRock 数据集的不同模型的定量评估

Table1 Quantitative evaluation of different methods on CTRock

Models	mIoU	IoU _{crack}	Precision	Recall
CrackSeg	78.4	59.1	85.4	74.9
CrackNet	81.4	64.8	88.1	76.5
DeepCrack2	82.0	66.9	87.3	78.2
DeepCrack1	83.7	69.1	92.0	80.5
DSM	84.4	70.4	91.2	82.1
HRVit	84.7	70.9	91.3	82.4
CarNet	85.2	71.9	92.1	83.2
FLANet	85.7	72.9	93.4	84.0
UNet2022	86.0	73.6	93.7	84.5
U-HRNet	86.4	74.2	94.0	85.2
EViP-CTCrack	88.1	77.4	94.4	88.5

图 9 为精确率-召回率曲线，并给出了平均精确率（AP）。图 9 通过展示不同模型在精确率和召回率之间的权衡关系，进一步说明了 EViP-CTCrack 模型在性能上的平衡性和优越性。从图 9 可以看出，EViP-CTCrack 模型在不同召回率水平下均保持了较高的精确率，其 AP 值达到了 94.4%，显著高于其他模型。这表明 EViP-CTCrack 模型在裂隙识别任务中不仅能够高召回率地识别裂隙，同时还能保持较高的精确率，减少了误判的可能性。这种性能平衡使得 EViP-CTCrack 模型在实际应用中更具优势。图 10 为基于不同裂隙识别模型的 CT 图像三维重构图。从图 10 中可以看出，EViP-CTCrack 模型在三维重构中能够更准确地还原裂隙的分布和形态，为后续的物理力学性质分析提供了更可靠的数据支持。其他模型则在某些情况下会出现裂隙分布的偏差或形态的不准确，这可能会影响对岩石物理力学性质的准确评估。因此，EViP-CTCrack 模型在三维重构中的表现进一步证明了其在裂隙识别任务中的优越性。得益于关键模块和网络结构的改进，本文提出的 EViP-CTCrack 模型表现出最佳效果，这更有助于精准地研究岩石的物理力学性质。




图 9 不同模型的精确率-召回率曲线

Fig.9 Precision-Recall curves of different models




图 10 基于不同裂隙识别模型的 CT 图像三维重构图像（白色：真阳性，红色：假阴性，绿色：假阳性）

Fig.10 Comparison of different methods for 3D reconstructed crack results based on 209 CT images of the coal rock. White: True Positive; Red: False Negative; Green: False Positive.

3.4.2 模块比较和消融研究

如表 2 所示，用 Res2Net（图 11）和深度卷积（DWConv）块替换 RMConv 块会导致不同数据集的性能下降。ERMConv 是 RMConv 模块的感受野等效结构（图 12）。ERMConv 的结果再次表明，尽管存在用于特征定位的小卷积分支，但大卷积核在用于裂隙识别的空间信息提取中无法表现出其优越性。

对于下采样和上采样方法，表 2 显示，基于注意力的采样操作在实现最佳效果方面发挥着重要作用。

表 2 各模块和消融研究的定量评估

Table 2 Quantitative evaluation of different methods on CTRock

	Methods	mIoU	IoU _{crack}
Modules	Res2Net	87.5	76.2
	DWConv	86.8	75.0
	ERMConv	87.5	76.3
	RMConv	88.1	77.4
Downsample	no attention	86.5	74.4
Upsample	no JAU	86.2	74.1
	K=1	87.1	75.4
Classifier	prototype(K=10)	86.1	73.6
	MRV(K=10)	88.1	77.4
Prompt	no prompt	83.2	67.9

与传统分类器（K=1）和基于不可学习原型的分类器（K=10）相比，多代表性向量分类器 MRV(K=10)有明显的性能提升，这是因为它可以更好地描述类内方差。而基于不可学习原型的分类器没有显示出其在裂隙识别方面的优势，这可能是因为在一些裂隙的颜色和形态与背景相似，导致较难识别。

对于显式视觉提示生成器，由于其过滤了低频噪声并将包含细小裂隙特征的高频信息注入网络，显著提高裂隙识别效果。值得注意的是，提示生成器对整体性能提升的贡献最大。




图 11 Res2net 模块（分支数为 4）

Fig.11 Res2net Block(branch number=4)




图 12 RMConv 感受野的等效结构 ERMConv

Fig.12 receptive field equivalent structures of RMConv

4 工程实例

4.1 钻孔岩心裂隙识别

本文对鄂尔多斯新街煤矿开展关键层位钻孔岩心的全维度数据采集工作，明确煤岩心内部裂隙分布，为精细建模提供高质量数据。CT 扫描设备为天津三英精密仪器股份有限公司第二代全岩心设备 Geoscan200，扫描精度约 100 微米。

本文在新街煤矿共扫描岩心 62.25 米，考虑到图像数量众多，以其中一个砂岩岩心重构结果为例进行展示。利用 Avizo 软件对 CT 扫描的岩心图像进行重构，得图 13 所示的岩心图像。利用本文提出的 EViP-CTCrack 裂隙识别模型对该岩心的裂隙进行识别并输出裂隙占比（图 14），再对识别到的孔裂隙的体积和面积进行统计（图 15）。该砂岩较为致密，未发育有大裂隙，均为小尺寸的孔隙。体积 $2 \times 10^7 \text{nm}^3$ 和表面积 $2 \times 10^5 \text{nm}^2$ 的孔隙占 77%，更大尺寸的孔隙的占比快速减小。




图 13 岩心 CT 扫描重构图像.(a) 横截面;(b) 纵截面

Fig.13 CT scan reconstructed images of the core: (a) Cross-section; (b) Longitudinal section.





图 14 裂隙识别结果.(a) 横截面;(b) 纵截面

Fig.14 Crack Identification Results: (a) Cross-section; (b) Longitudinal section.






图 15 孔裂隙的(a)体积和(b)表面积分布
Fig.15 Pore-crack (a) Volume; (b) Superficial area.

4.2 孔隙度与力学参数的相关性

将钻孔岩心加工成 $\Phi 50 \times H100\text{mm}$ 的标准圆柱体试件，再对加工后的试件进行 CT 扫描，获得 CT 图像，利用本文提出的 EViP-CTCrack 裂隙识别模型计算孔隙度。孔隙度在岩石力学中具有极其重要的意义，它不仅是描述岩石内部孔隙空间占比的物理参数，还直接影响岩石的力学性质、流体渗透性以及工程中的应用。

本文对试件进行单轴压缩实验，获得抗压强度和弹性模量。图 16 展示了其中一试件的孔隙面积占比沿试件高度的分布，孔隙度主要分布在 1-4% 之间，计算出该试件的孔隙度为 2.352%。将孔隙度与抗压强度和弹性模量进行关联，如图 17 所示。可以看出，试件的孔隙度与其抗压强度和弹性模量成负相关，即孔隙度越大，其抗压强度和弹性模量越小。随着孔隙度增大，其抗压强度和弹性模量的变化会逐渐趋于平缓。当孔隙度小于 2% 时，抗压强度和弹性模量变化幅度较大。而当孔隙度大于 2% 时，抗压强度和弹性模量的变化幅度明显减小。

对抗压强度进行拟合，得到了砂岩孔隙度与单轴抗压强度呈指数关系(式 19)，该结果与李杰林等^[28]中所得出的孔隙率与单轴抗压强度关系满足指数分布结论基本一致，表明采用 CT 图像技术开展岩石孔隙特征与其力学性能研究是可行的，根据所建立的孔隙度-抗压强度方程可以快速推算其单轴抗压强度。

$$\sigma_c = 4.682 + 6.878e^{-\phi^{0.0183}} \quad (19)$$

式中， σ_c 为单轴抗压强度， ϕ 为孔隙度。




图 16 孔隙面积占比沿试件高度分布

Fig.16 Distribution of pore-crack area proportion along the height of the specimen.




图 17 孔隙度与抗压强度和弹性模量的相关性

Fig.17 Correlation between porosity, uniaxial compressive strength, and elastic modulus

5 结论

(1) 本文提出一种基于显式视觉提示的煤岩 CT 图像裂隙识别模型 (EViP-CTCrack)。该模型包含 4 种新的裂隙网络模块：残差混合连接卷积块、交叉注意力上采样、多代表性向量分类器和显式视觉提示生成器。残差混合连接卷积块具有三个层次的残差混合连接分支，通过多尺度卷积核的信息提取和特征定位，能有效提取细粒度信息并融合多尺度特征。交叉注意力上采样模块可以同时执行上采样和多层特征的融合和指导解码器中低分辨率特征的上采样。多代表性向量分类器用于描述裂隙的丰富类内方差。显式视觉提示生成器用于提取和过滤图像高频信息，与编码器各阶段特征融合，帮助模型精确识别裂隙特征。

(2) 本文建立了一种用于煤岩 CT 图像裂隙检测的数据集 CTRock，其数据具有足够的数量和注释质量。EViP-CTCrack 模型对裂隙的识别效果优于其他经典模型。EViP-CTCrack 模型在 CTRock 数据集上平均交并比和精确率分别达到了 88.1% 和 94.4%，取得了较好的裂隙分割和提取效果。

(3) 将该模型应用于矿井钻孔岩心裂隙识别, 建立了孔隙度-抗压强度方程, 可以快速推算其单轴抗压强度, 为煤岩物理力学性质研究提供了新思路。

参考文献

- [1] 王恩元, 张国锐, 张超林, 等. 我国煤与瓦斯突出防治理论技术研究进展与展望 [J]. 煤炭学报, 2022, 47(01): 297-322. WANG Enyuan, ZHANG Guorui, ZHANG Chaolin, et al. Research progress and prospect on theory and technology for coal and gas outburst control and protection in China[J]. Journal of China Coal Society, 2022, 47(1): 297-322. (in Chinese)
- [2] 袁亮, 王恩元, 马衍坤, 等. 我国煤岩动力灾害研究进展及面临的科技难题 [J]. 煤炭学报, 2023, 48(05): 1825-1845. YUAN Liang, WANG Enyuan, MA Yankun, et al. Research progress of coal and rock dynamic disasters and scientific and technological problems in China[J]. Journal of China Coal Society, 2023, 48(5): 1825-1845. (in Chinese)
- [3] 谢和平, 高峰, 鞠杨. 深部岩体力学研究探索 [J]. 岩石力学与工程学报, 2015, 34(11): 2161-2178. XIE Heping, GAO Feng, JU Yang. Research and development of rock mechanics in deep ground engineering[J]. Chinese Journal of Rock Mechanics and Engineering, 2015, 34(11): 2161 - 2178. (in Chinese)
- [4] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in neural information processing systems, 2012, 25.
- [5] JI S, XU W, YANG M, et al. 3D convolutional neural networks for human action recognition [J]. IEEE transactions on pattern analysis and machine intelligence, 2012, 35(1): 221-231.
- [6] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation; proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, F, 2015 [C].
- [7] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation; proceedings of the Medical image computing and computer-assisted intervention - MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18, F, 2015 [C]. Springer.
- [8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition; proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, F, 2016 [C].
- [9] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(12): 2481-2495.
- [10] CHEN L-C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 40(4): 834-848.
- [11] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks; proceedings of the Proceedings of the IEEE international conference on computer vision, F, 2017 [C].
- [12] HE K, GKIOXARI G, DOLLÁR P, et al. Mask r-cnn; proceedings of the Proceedings of the IEEE international conference on computer vision, F, 2017 [C].
- [13] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [J]. Ieee Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [14] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network; proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, F, 2017 [C].
- [15] VASWANI A. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017.
- [16] DOSOVITSKIY A. An image is worth 16x16 words: Transformers for image recognition at scale [J]. arXiv preprint arXiv:2010.11929, 2020.
- [17] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows; proceedings of the Proceedings of the IEEE/CVF international conference on computer vision, F, 2021 [C].
- [18] XIE E, WANG W, YU Z, et al. SegFormer: Simple and efficient design for semantic segmentation with transformers [J]. Advances in neural information processing systems, 2021, 34: 12077-12090.
- [19] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything; proceedings of the Proceedings of the IEEE/CVF International Conference on Computer Vision, F, 2023 [C].
- [20] 王登科, 房禹, 魏建平, 等. 基于深度学习的煤岩 Micro-CT 裂隙智能提取与应用[J]. 煤炭学报, 2024, 49(08): 3439-3452. WANG Dengke, FANG Yu, WEI Jianping, et al. Intelligent extraction of Micro-CT fissures in coal based on deep learning and its application[J]. Journal of China Coal Society, 2024, 49(8): 3439-3452. (in Chinese)
- [21] 冯雪健, 沈永星, 周动, 等. 基于 CT 数字岩心深度学习的煤裂隙分布识别研究[J]. 煤炭科学技术, 2023, 51(08): 97-104. FENG Xuejian, SHEN Yongxing, ZHOU Dong, et al. Multi-scale distribution of coal fractures based on CT digital core deep learning[J]. Coal Science and Technology, 2023, 51 (8) : 97-104. (in Chinese)
- [22] 吴承毅. 基于深度学习的煤岩体 CT 图像裂隙分割方法研究[D]. 河南理工大学, 2023. Wu Chengyi. Research on coal crack segmentation method of CT images based on deep learning [D]. Henan Polytechnic University, 2023. (in Chinese)

- [23] 王登科,王龙航,秦亚光,等.基于 VRA-UNet 网络的煤岩组合体裂隙识别与三维重构[J/OL]. 煤炭科学技术, 2025. Wang Dengke, Wang Longhang, Qin Yaguang. Fracture identification and 3D reconstruction of coal-rock combinations based on VRA-UNet network [J]. Coal Science and Technology,2025. (in Chinese)
- [24] 高亮,饶法强,杨忠民,等.基于语义分割的公路路面裂缝智能识别技术研究[J].中外公路,2024,44(05):241-247. GAO Liang, RAO Faqiang, YANG Zhongmin. Intelligent Recognition Technology of Highway Cracks Based on Semantic Segmentation [J]. Journal of China & Foreign Highway,2024,44(05):241-247. (in Chinese)
- [25] 胡咤咤,张寻,金毅,等. 基于 μ CT 和深度学习的煤裂隙智能提取方法[J]. 煤田地质与勘探, 2025, 53(2):1-12. HU Zhazha,ZHANG Xun,JIN Yi,et al. Intelligent coal fracture extraction method using μ CT and deep learning[J]. Coal Geology & Exploration, 2025,53(2):1-12.(in Chinese)
- [26] Wang D, Li L, Zhang H, et al. Intelligent identification of coal fractures using an improved U-shaped network[J]. Advances in Geo-Energy Research, 2025, 15(2): 129-142.
- [27] Qian L, Wan Z, Cheng J, et al. Advanced Fracture Segmentation Techniques for Enhancing Intelligent Detection of Coal Roadway Roof Strata[J]. IEEE Access, 2024.
- [28] 李杰林, 周科平, 柯波. 冻融后花岗岩孔隙发育特征与单轴抗压强度的关联分析[J]. 煤炭学报, 2015, 40(8) : 1783 — 1789. Li Jielin,Zhou Keping,Ke Bo. Association analysis of pore development characteristics and uniaxial compressive strength property of granite under freezing-thawing cycles[J]. Journal of China Coal Society, 2015, 40(8) : 1783-1789.(in Chinese)