

松辽盆地古龙地区页岩矿物成分与孔隙智能识别方法

李欣^{1,2,3}, 刘茜^{1,2}, 朱如凯^{1,2,3}, 刘畅^{1,2,3}, 蔡瑶⁴, 岳可心⁴, 任义丽^{1,2,3}

[1. 中国石油勘探开发研究院, 北京 100083; 2. 中国石油勘探开发人工智能技术研发中心, 北京 100083; 3. 多资源协同陆相页岩油绿色开采全国重点实验室, 黑龙江 大庆 163712; 4. 中国石油大学(北京), 北京 102249]

摘要: 中国陆相页岩油勘探开发不断深入, 传统储层评价方法在微观尺度表征方面面临诸多挑战。在分析现有技术方法的优势与不足基础之上提出了一套融合多维度信息、智能化程度更高的页岩储层综合评价体系。该方法基于自适应金字塔上下文网络(APCNet)并结合团队前期研发的页岩孔-缝分割网络(ShaleSeger), 实现对矿物组分与孔隙结构的智能分割; 结合“图像处理”与“数理统计”技术, 对岩石脆性指数进行定量计算, 并对孔隙结构特征开展精细化表征。研究表明, 该方法能够为页岩油气勘探开发及“甜点”识别提供更加具体、全面且量化的分析数据, 有助于油气藏资源潜力的量化评估以及开发技术难度与经济效益的综合判断。基于此技术形成的系统性解决方案, 可为陆相页岩油气高效勘探提供可靠的智能决策依据。同时, 该文还深入剖析了当前陆相页岩储层智能分析技术面临的挑战, 并指明了下一步研究重点。

关键词: 智能岩心技术; 深度学习; 语义分割; 微观储层评价; 页岩油; 古龙地区; 松辽盆地

中图分类号: TE122.2

文献标识码: A

A method for intelligent identification of mineral composition and pores in shales of the Gulong area, Songliao Basin

LI Xin^{1,2,3}, LIU Xi^{1,2}, ZHU Rukai^{1,2,3}, LIU Chang^{1,2,3}, CAI Yao⁴, YUE Kexin⁴, REN Yili^{1,2,3}

[1. Research Institute of Petroleum Exploration & Development, PetroChina, Beijing 100083, China; 2. Artificial Intelligence Technology R&D Center for Exploration and Development, CNPC, Beijing 100083, China; 3. State Key Laboratory of Continental Shale Oil, Daqing, Heilongjiang 163712, China; 4. China University of Petroleum (Beijing), Beijing 102249, China]

Abstract: With the continuous advancement in lacustrine shale oil exploration and development in China, traditional reservoir evaluation methods are facing a series of challenges in microscale characterization. In this study, we analyze the advantages and limitations of existing reservoir evaluation techniques and methods. Accordingly, a more intelligent, comprehensive shale reservoir evaluation method that integrates multidimensional data is proposed. Based on the Adaptive Pyramid Context Network (APCNet) for semantic segmentation, combined with the previously independently developed shale pore-fracture segmentation network (ShaleSeger), this method enables intelligent segmentation of minerals and pore structures within reservoirs. By further integrating image processing techniques with mathematical statistics, the method allows for both the quantitative calculation of the shale brittleness index and the fine-scale characterization of pore structures. The analytical results indicate that this proposed method serves to provide more specific, comprehensive, and quantitative analytical data for shale oil and gas exploration and development, as well as sweet spot identification. These analytical data in turn facilitate the quantitative evaluation of resource potential in shale hydrocarbon reservoirs and assist in the comprehensive assessment of relevant technical difficulties and economic benefits. The systematic solution established based on the proposed method offers a reliable basis for intelligent decision-making in the efficient exploration of lacustrine shale oil and gas. Additionally, this study presents a thorough analysis of challenges associated with current intelligent analysis techniques for lacustrine shale reservoirs and points out focus for future research.

收稿日期: 2025-09-09; 修回日期: 2026-01-08。

第一作者简介: 李欣(1975—), 男, 教授、博士研究生导师, 沉积地质学和层序地层学。E-mail: yjy_lix@petrochina.com.cn。

通信作者简介: 刘茜(1996—), 女, 工程师, 深度学习和多模态大模型在储层评价中的应用。E-mail: liuxi3@petrochina.com.cn。

基金项目: 国家自然科学基金面上项目(42372175); 国家科技重大专项(2025ZD1401501); 中国石油天然气股份有限公司科技项目(2023DJ84)。

Key words: intelligent core analysis technology, deep learning, semantic segmentation, microscopic reservoir evaluation, shale oil, Gulong Region, Songliao Basin

引用格式:李欣,刘茜,朱如凯,等. 松辽盆地古龙地区页岩矿物成分与孔隙智能识别方法[J]. 石油与天然气地质, 2026, 47(3): 1049–1060. DOI: 10. 11743/ogg20260322.

LI Xin, LIU Xi, ZHU Rukai, et al. A method for intelligent identification of mineral composition and pores in shales of the Gulong area, Songliao Basin[J]. Oil & Gas Geology, 2026, 47(3): 1049–1060. DOI: 10. 11743/ogg20260322.

陆相页岩油是中国重要的非常规油气资源,正逐步成为保障国家能源安全、支撑原油稳产增产的关键力量^[1-2]。近年来,中国在陆相页岩油勘探开发领域取得重大突破,已在新疆吉木萨尔、大庆古龙和胜利济阳等地建成国家级示范区。2024年,新疆吉木萨尔国家级陆相页岩油示范区年产油量突破 100×10^4 t,成为中国首个百万吨级陆相页岩油示范区。然而,与传统储层相比,陆相页岩油储层具有地质年代较新、有机质成熟度偏低、矿物成分复杂、断裂发育以及高温-高压等特征^[3],其勘探开发难度已达世界级水平。这一特殊而复杂的储层条件,对高精度、高效率的微观储层表征技术提出了前所未有的迫切需求。

对页岩储层进行精准表征,其核心在于厘清两大关键要素:矿物成分与孔隙结构。矿物成分是页岩油气藏中孔隙结构形成和有机质演化的物质基础,不同矿物的类型、含量与空间分布直接影响岩石的渗流能力、电学响应及力学特性。而孔隙结构则直接控制了页岩中油气的赋存空间、运移通道与最终可采储量,尤其在陆相页岩油储层中,普遍发育多尺度、多类型的复杂纳米级孔-缝网络。因此,实现对矿物组分与孔隙结构的精细化、定量化表征,是科学评价储层品质、有效预测“甜点”区带及优化开发方案的科学前提。

然而,现有表征技术仍面临显著瓶颈。在矿物识别方面,尽管扫描电镜(SEM)等技术能够获得高分辨率的岩石微观图像,但后续分析多依赖阈值分割、边缘检测等传统图像处理方法,易受成像质量干扰,对灰度相近矿物的区分能力有限,难以适应页岩高度非均质、矿物颗粒细小的微观结构特征。在孔隙表征方面,传统图像处理方法普遍存在精度低、依赖经验且难以区分复杂孔隙结构等问题^[4-5],难以满足对海量图像数据中复杂孔隙结构的客观、批量分析需求。

针对上述挑战,亟需构建一种能够突破传统方法局限的智能化解决方案。近年来,以计算机视觉和深度学习为代表的人工智能技术迅猛发展,为岩石微观图像的自动、高精度解析提供了全新的技术路径^[6]。为此,本文首先系统梳理当前页岩储层在矿物识别与孔隙表征方面所面临的主要问题与技术瓶颈;其次,聚

焦大庆古龙地区陆相页岩储层,重点介绍笔者团队提出的一套页岩储层智能分析方法,该方法可同步实现该地区页岩矿物成分的精准识别与孔隙结构的精细分割;最后,为页岩储层的定量评价提供一套高效、客观、可推广的智能分析方案,并对页岩微观表征智能技术的未来发展方向进行展望。

1 矿物成分与孔隙智能识别国内外研究现状

1.1 矿物成分智能识别

随着人工智能技术的快速发展,深度学习通过构建深层神经网络,能够利用标注数据从SEM图像中自主学习矿物特征,建立像素级分类模型,为岩石矿物的高效识别与分割提供了新途径。以U-Net为代表的编码器-解码器架构在矿物分割领域表现突出^[7]。例如,Chen^[8]使用U-Net架构,并引入局部空间统计权重函数,有效区分了泥盆纪Duvernay页岩样品中基质矿物颗粒和有机物的土集料;陈宗铭等人^[9]对比了基于掩码的区域卷积神经网络(Mask-RCNN)、全卷积网络(FCN)和U型卷积神经网络(U-Net)3种深度学习模型在矿物、有机质及孔隙识别中的性能,结果表明U-Net模型性能最优;刘成等人^[10]基于改进的U-Net模型开发了Shale-Net模型,显著减少了过度分割和欠分割问题。

针对页岩储层中更为复杂的地质情景及小目标检测难题,Bihani等人^[11]提出基于DeepLab-v3+架构的MudrockNet模型,解决了因灰度重叠导致的误判问题;Zhang等人^[12]通过增加小目标检测层、引入SE注意力机制,构建了更加适应页岩强非均质性的目标检测模型;Alekseev等人^[13]结合EfficientNetB4主干的U-Net模型,通过多矿物合并策略解决了数据不平衡问题;Yasin等人^[14]提出的KIU-Net模型融合KI-Net边缘检测与U-Net分割能力,提升了纳米级矿物边缘和微小孔隙的识别能力。

当前,深度学习在页岩矿物识别中已展现出显著优势,包括自动化程度高、识别速度快以及对复杂结构

适应性强等。但仍存在若干技术瓶颈:①模型性能严重依赖标注质量,而专业标注成本高昂;②现有模型小目标及灰度相近矿物的分割精度不足,且模型泛化能力受限于训练数据的代表性与多样性;③多矿物共生条件下的边缘模糊问题、非均质性导致的特征提取困难等,仍是亟待突破的技术难点。

1.2 孔隙智能分割

为突破传统方法的瓶颈,人工智能语义分割技术逐步被引入孔隙分析领域。近年来,以FCN, U-Net, Mask-RCNN 和 FLU-Net 等为代表的深度学习模型已成为孔隙识别的基础框架。Yu 等人^[15]基于FCN模型实现了孔隙的自动识别和分割;陈雁等人^[16]利用FLU-Net并结合孔隙尺度分类统计方法,实现了页岩储层微观孔隙结构的自动化定量表征;王庆等人^[17]以Mask-RCNN为基础提出基于多尺度区域卷积神经网络孔洞检测方法;Wang 等人^[18]系统评估了多种U-Net变体在孔、缝分割任务中的性能,结果表明,Residual U-Net++在捕捉复杂的孔隙-骨架边界及微裂缝连通结构方面表现最优。此外,研究者们还基于U-Net探索多种改进方案:李天平等人^[19]在U-Net编码器中引入残差网络构建R-T-UNet模型,提升了孔隙特征提取和分割能力;汪南洋等人^[20]在模型中设计多尺度融合注意力模块,并使用GP-Bneck模块替换部分普通卷积,增强网络特征提取和聚合不同尺度信息的能力;Tian 等人^[21]提出一种结合对比学习与U-Net的深度学习模型Geo-SegNet,该模型通过引入对比学习增强特征表征,有效解决了地质图像中因灰度重叠导致的孔隙分割困难;Wang 等人^[22]提出的TSD-Unet则针对岩石裂隙的细长、不连续特征进行优化,提升了其在复杂基质与背景噪声干扰下的识别鲁棒性。

针对页岩孔隙的复杂性和微观异质性,研究者不断探索更高效的网络架构。Xi 等人^[23]首次将高分辨率HR-Net网络模型应用于页岩孔隙识别,该模型在特征处理阶段持续进行重复的多尺度融合,实验结果表明HR-Net准确率优于U-Net;Zhang 等人^[24]提出一种多轴频域残差语义分割网络MaFR2U-Net,优化了Res2-Net的多尺度分支,集成多轴频域残差块(MaFR)以增强特征提取能力,有效捕捉页岩SEM图像中的纹理和细节;Chen 等人^[25]以川南龙马溪组页岩的氩离子抛光SEM图像为数据集,通过Pore-Net网络模型实现页岩SEM图像中孔隙的智能识别和定量表征。

然而,现有分割模型在识别页岩孔隙结构时仍面临两大挑战:①页岩孔隙呈“密集小目标分布”,易导致

漏检,影响孔隙数量与尺寸的统计准确性;②分割模型受固有结构限制,倾向于输出平滑边界,难以捕捉真实孔隙边缘的不规则与锐利特征,导致后续形态学参数与结构属性分析出现偏差。

2 融合深度学习与图像分析的页岩储层智能分析整体技术路线

本研究从矿物组成和孔隙结构两方面提出一套页岩储层智能分析方法。首先,利用扫描电子显微镜(SEM)技术和基于SEM与能谱分析(EDS)联用的自动化矿物定量分析(QEMSCAN)技术获取大视域和高分辨率的SEM图像及其对应的矿物分布图,并以此为基础构建矿物识别标签数据集。其次,构建矿物智能识别模型,并将前期研究中获得的适用于页岩孔-缝分割的网络ShaleSeger^[26]迁移应用至当前数据中,实现矿物成分和储集空间信息的同步提取。最后,本文综合运用“图像处理”与“数理统计”方法,依据《岩石孔隙结构特征的测定 图像分析法》标准,实现孔隙结构参数的定量表征。同时,参考前人研究^[27,31-34],建立基于矿物含量的脆性指数自动计算方法(图1)。

3 基于语义分割的矿物成分智能识别

3.1 矿物识别标签数据集构建

本文选取50组来自中国松辽盆地古龙地区白垩系青山口组的SEM图像及其相应的QEMSCAN图像,




图1 整体技术路线图

Fig. 1 Overall technology roadmap of the proposed intelligent analysis method for shale reservoirs

用于模型的训练、验证和测试。QEMSCAN 是一种融合扫描电子显微镜(SEM)与 X 射线能谱分析(EDS)的自动化矿物分析技术,能够快速识别矿物种类并测定元素含量。该技术所输出的高分辨率彩色矿物图像,可作为高质量的语义分割训练标签。

研究中,笔者团队首先通过颜色识别、溶蚀和膨胀等图像处理方法,将彩色矿物图像转换为单通道索引图。该图像以像素级整数值对应不同矿物类别,作为后续语义分割任务的初始 mask 标签。考虑到 QEMSCAN 在大视域扫描中易因边界混合效应、样品微观不均一性、能谱穿透性及荷电效应等产生类似“噪点”的伪色点(如电子束在矿物边界激发混合谱导致误判、穿透效应引起亚表层信号干扰、矿物内部的成分环带与微细包裹体被误识为独立物相,以及荷电效应干扰信号采集导致谱图失真)。为消除此类干扰,本研究通过综合研判背散射电子图像的灰度信息与矿物分布图的噪点特征,采用连通区域分析法将像素数少于设定阈值(如 10 像素)的孤立区域归并至其邻近的主要矿物类别中,从而在保持标注完整性的同时有效提升数据质量。

针对部分 SEM 扫描图像中因明-暗差异弱导致的矿物灰度不明显问题,笔者团队使用对比度限制自适应直方图均衡(CLAHE)技术对原始图像施加额外的预处理步骤,以提高图像的视觉质量及其分析潜力。CLAHE 处理显著提升了裁剪图像的对比度,增强了图像的可视性,使图像中的结构特征更易于辨识。图 2 清晰对比了处理前后的效果,如图 2b 所示,经 CLAHE 处理后图像对比度明显增强,孔隙和矿物等细节特征更加突出,为后续的精确定识与分析奠定了基础。

在数据预处理阶段,针对原始 SEM 图像数量有限且多为大视域与大尺度狭长图像的特点,为提升模型

训练效果与数据处理效率,采用滑动窗口法对原始图像进行子图裁剪。具体将每张图像划分为多个 224×224 像素的子图像,设定长、宽方向重叠率为 25%。该策略既保持了相邻子图之间的空间连续性,又确保不同子图间的视觉内容差异度超过 50%,从而有效扩充了样本多样性。此外,使用视域较小的子图进行训练,有助于增强模型对局部特征的辨识能力,使其更聚焦于关键区域并提取与任务相关的细节特征,同时也显著降低了计算与存储开销。

在数据集构建过程中,本研究严格遵循“先划分后采样”的原则,即首先划定训练、验证与测试集所对应的原始大图区域,再分别从各区域中独立生成子图。这一做法保障了不同数据集之间的严格独立性,从根本上避免了因随机划分子图可能导致的信息泄漏,确保了模型评估结果的可靠性。最终,通过上述流程共生成 2 030 张子图像,并划分为 1 762 个训练样本、134 个验证样本和 134 个测试样本。

通过对裁剪后数据集的统计分析,获得了如图 3 所示的矿物标签含量分布情况。该数据集共包含 32 种矿物成分,且矿物分布存在高度不均衡性和长尾分布特征:其中,石英和伊利石等主矿物含量高,二者合计高达 55%;此外,白云石、方解石、钠长石和黑云母等矿物也有相对较高的含量。相比之下,锆石、钛铁矿、锰白云石、重晶石、黝帘石和透辉石等稀有矿物(含量少的前 18 类)的总含量不足 0.5%,使得深度学习模型难以充分学习其鉴别其特征。为应对矿物种类的复杂性,本文依据 QEMSCAN 图像中提供的矿物成分分布信息,对部分矿物进行了合并处理(表 1)。例如,将石英和钠长石归为一类,主要原因在于二者平均原子序数极为接近(石英约为 10.8,钠长石约为 11.2),导致其在背散射电子(BSE)图像中呈现几乎一致的灰度响应,




图2 原始(a)和经对比度限制自适应直方图均衡化处理后的局部SEM图像(b)对比

Fig. 2 Portion of an SEM image before (a) and after enhancement using contrast limited adaptive histogram equalization (CLAHE) (b)




图3 矿物标签组分含量分布柱状图

Fig. 3 Bar chart showing the statistics of mineral label distributions

表1 训练集矿物合并后的含量和标签编号

Table 1 Contents and label values of minerals of main minerals in the training set

矿物大类	矿物组分	QEMSCAN 分析 矿物含量/%	矿物 标签
石英 + 钠长石	石英、钠长石	32.31	1
其他长石	钾长石、钙长石	0.75	2
云母	黑云母、白云母、钠云母	0.52	3
黏土矿物	伊利石、绿泥石、叶蜡石、蒙脱石、高岭石、海绿石	42.12	4
碳酸盐矿物	白云石、方解石、锰白云石、菱铁矿	21.04	5
重矿物	金红石、磷灰石、角闪石、透辉石、绿帘石、黝帘石、榍石、锆石、氧化铝、钛铁矿	0.56	6
黄铁矿	黄铁矿	1.54	7
自生硫酸盐矿物	石膏/硬石膏、重晶石	0.11	8

注:QEMSCAN是一种集成自动化扫描电子显微镜(SEM)与能谱分析(EDS)技术的矿物学分析系统。

难以通过灰度阈值进行有效区分。此外,在标准抛光样品中,两者的结晶学形态因表面被磨平而无法显现,进一步削弱了基于矿物形貌区分的可能性。基于上述分析与合并策略,最终构建了训练所需的标签数据集。

3.2 模型选型与训练

页岩储层精细表征的核心挑战之一在于实现矿物种类及其分布区域和形态的精准识别,其目的是准确计算各类矿物的含量,本质上属于典型的语义分割任务。然而,页岩矿物颗粒普遍细小,发育大量纳米级孔隙,且矿物分布呈现高度不均衡性,不同矿物微观特征间又存在显著相似性。这些因素使得基于传统图像分析方法或基于机器学习的矿物组分分割与识别面临巨大困难,亟需更强大、更智能的解决方案。

基于现有深度学习模型及本次研究数据集的特点,本文选用在语义分割任务中性能出色的自适应金字塔上下文网络(APCNet)^[28]构建矿物成分智能识别模型。该网络针对多尺度上下文信息融合问题,设计了自适

应上下文模块(ACM),该模块通过全局引导局部关联(GLA)分支自适应地计算每一局部位位置的上下文向量,并将其加权融合至特征图中,从而有效聚合上下文信息并构建多尺度的上下文表示(APCNet 流程框架)(图4)。其中, $X \in \mathbb{R}^{(h \times w \times c)}$ 表示由CNN提取的特征图, h, w 和 c 分别对应特征的高度、宽度和通道数。GLA分支主要用于计算亲和张量,其具体流程为:首先通过 1×1 卷积将特征 X 降维,变成大小为 $h \times w \times 512$ 的特征矩阵 x ;同时利用全局平均池化提取大小为 $1 \times 1 \times 512$ 的全局信息向量 $g(X)$;随后,将 $g(X)$ 与 x 融合并划分为 $s \times s$ 的网格,通过计算各子区域的亲和度系数,构建出维度为 $h \times w \times s^2$ 的亲和张量。下方分支则在将 X 划分为 $s \times s$ 的网格的基础上,利用自适应平均池化和 1×1 卷积将其转化为 $s \times s \times 512$ 的子区域特征表示,并重塑为 $s^2 \times 512$ 的特征向量。该向量与GLA分支的输出相乘,以实现基于亲和度的子区域特征加权。加权后的特征 Z' 与 x 进行残差融合,从而获得 $s \times s$ 尺度下的特征表示。最后,将所有不同尺度的特征表示与




图4 APCNet网络流程框架图

Fig. 4 Framework of the APCNet

(s 表示划分分子区域时网格的大小; CONV代表卷积; X 表示CNN提取的特征, $X \in R^{(h \times w \times c)}$; h, w 和 c 分别表示特征的高度、宽度和通道数; Z^s 表示在尺度 $s \times s$ 下经过加权融合后得到的上下文增强特征表示。)

CNN提取的特征拼接,即可得到融合多尺度上下文信息的最终特征。通过这一设计,APCNet能够在一定程度上缓解页岩电镜图像中矿物颗粒尺寸差异大、局部特征相似性高等问题对模型性能带来的影响。

在矿物成分智能识别模型训练时采用有监督的策略。鉴于标签数据集的规模有限,采用迁移学习的方式,加载在大规模数据集上预训练的APCNet模型权重作为网络初始化参数,并解锁全部网络层进行端到端的微调。训练使用带动量的随机梯度下降(SGD)优化器,其初始学习率设为0.001,动量系数为0.9,权重衰减设置为0.0005。该优化配置通过OptimWrapper统一管理,在每次迭代中执行前向计算、损失求解、梯度反向传播及参数更新。动量项的引入有助于加速收敛并平抑优化震荡,权重衰减则提供正则化作用以抑制过拟合。

3.3 实验结果分析

本研究从定性比较与定量分析两个维度,对电镜矿物成分识别任务的模型性能进行了综合评估,具体结果如图5所示。图中,样本1的原图、标签图及模型识别结果图分别对应子图5a—c;样本2的对应结果见子图5d—f;样本3的对应结果见子图5g—i;样本4的对应结果见子图5j—l。图5中样本1和样本2所示的

定性实验结果表明,APCNet对特征清晰、分辨率较高的图像具有较好的分割准确率;然而,在分辨率较低、灰度衬度差异不显著的图像中(如图5样本3和样本4中细小的石英与长石因颗粒尺寸微小、图像分辨率不足,与周围黏土矿物在灰度上区分度有限)模型的分割效果变差。这表明,在输入图像分辨率不足的情况下,模型所提取的特征分辨率相应受限,从而导致对矿物类别的判别能力减弱。

在定量模型评估中,本文选取交/并比(IoU)作为核心评价指标,该指标为预测分割与真实分割区域的重叠面积与二者联合面积的比值。 IoU 可直接反映预测区域与真实标注的重合程度,与人类视觉判断具有较高一致性,且对类别分布不平衡不敏感。为进一步适应矿物含量差异显著的实际情况,本文不仅计算各类别 IoU 的平均值,还引入整体像素准确率($aAcc$)、平均F1分数($mFscore$)、平均精确率($mPrecision$)与平均召回率($mRecall$)作为辅助评价指标。

表2汇总了不同模型的对比实验结果,其中,“APCNet*”表示未采用对比度限制自适应直方图均衡化(CLAHE)进行数据处理的模型训练结果。通过对比APCNet与APCNet*的实验结果可知,基于CLAHE预处理图像训练的模型在性能上表现出相对优势,验证了本文所采用的数据处理技术的有效性。进一步将




图5 松辽盆地4个样本的定性实验结果对比

Fig. 5 Comparison of qualitative experimental results of four samples in the Songliao Basin

表2 不同模型评价指标对比

Table 2 Comparison of various models

模型名称	评价指标/%					
	aAcc	mIoU	mFscore	wFscore	mPrecision	mRecall
CCNet	75.00	37.13	48.68	73.40	55.03	46.84
Deeplabv3	75.25	37.23	48.66	73.35	56.06	46.89
FCN	75.13	36.71	48.20	73.29	56.16	46.04
PIDNet	75.04	37.36	48.57	73.10	56.89	45.59
APCNet	75.05	37.64	49.27	73.16	59.13	46.93
APCNet*	74.77	36.88	48.18	72.71	54.94	46.25

注:aAcc为整体像素准确率;mIoU为平均交/并比;mFscore为平均F1分数;wFscore为加权平均的F1分数;mPrecision为平均精确率;mRecall为平均召回率。

APCNet与当前性能优异的语义分割模型(如PID-Net, CC-Net和FCN等)进行对比,本文模型在平均交/并比(*mIoU*)和*mFScore*指标上均取得更优结果,证明了本文算法的有效性。表3展示了本文模型对不同矿物类别的识别性能。其中,黏土矿物、碳酸盐矿物和黄铁矿

的识别效果较优,F1分数(*Fscore*)分别达到74.35%, 89.87%和72.06%,整体识别准确率为75.05%。

4 基于ShaleSeger网络的孔-缝智能分割

本文在当前构建的数据集上对前期研究中提出的ShaleSeger网络^[26]进行了测试与验证。ShaleSeger网络以经典的Transformer架构语义分割模型SegFormer为基础,引入了一个边缘特征提取模块,通过融合边缘信息对分割特征进行精细化调整,从而有效提升模型对细节区域的分割精度,并引入半监督训练提升模型的识别能力。该方法在本文数据集上的实验结果如图6所示。

从图6可见,该模型能够较为准确地识别视域中的裂缝及较大尺度的无机孔隙,但对于尺寸过小的无机孔隙,其识别效果仍有待提升。分析其原因,可能在于本文所用数据集的图像空间分辨率有限——每个像

表3 矿物类型合并后的分割结果

Table 3 Segmentation results of minerals after type merging

模型	面积占比/%	评价指标/%			
		<i>IoU</i>	<i>Fscore</i>	<i>Precision</i>	<i>Recall</i>
背景	1.09	52.14	68.54	67.24	69.90
石英	26.45	35.03	51.88	76.79	39.18
长石	0.67	31.05	47.38	57.28	40.41
云母	0.38	2.14	4.20	28.91	2.26
黏土矿物	32.23	59.17	74.35	64.31	88.10
碳酸盐矿物	36.08	81.60	89.87	87.08	92.85
重矿物	0.65	21.32	35.14	71.84	23.26
黄铁矿	2.41	56.32	72.06	78.76	66.40
硫酸盐矿物	0.04	0	0	0	0

注:*IoU*为交/并比;*Fscore*为F1分数;*Precision*为精确率;*Recall*为召回率。




图6 ShaleSeger网络在本文SEM图像中的应用效果
Fig. 6 Application of ShaleSeger in the model proposed in this study

素所代表的实际物理尺度较大,从而限制了模型对微细结构的特征表达能力,导致难以有效识别纳米级或亚像素级的微小孔隙。

5 智能分析技术在页岩储层评价中的应用

页岩储层评价的核心在于对“甜点”区带的精准识别与精细表征。页岩储层“甜点”是指分布于大面积页岩层系中、具有优良地质特性及丰富油气资源、并能通过储层改造技术实现经济开采的有利区带^[29-30]。与传统储层不同,页岩油主要赋存于纳米级孔隙与微裂缝之中,基质渗透率极低,通常不具备自然产能。因此,“甜点”的识别不仅关乎油气是否富集,更关键的是要找到储集性能与工程性能协同最优的靶区。

本文基于矿物与孔隙的智能识别模型,提出了一套综合储层脆性与孔隙结构特征的综合评价方法。该方法一方面通过定量表征矿物组成及其与岩石力学参数的关联,评估储层的脆性与可压裂性,助力锁定工程改造“甜点”;另一方面,通过精细刻画纳米级孔隙结构,定量表征储集空间发育程度与流体赋存能力,从而

助力圈定优质储层“甜点”。

5.1 岩石脆性指数计算

岩石脆性是指其在受外力作用下几乎不发生塑性变形便直接破裂的力学特性。主要受矿物成分与内部结构的控制。脆性矿物(如石英、长石和方解石等)硬度高、滑移系少,受力后不易发生塑性变形,易于积累弹性应变能,最终以脆性方式破裂;而黏土矿物和云母等塑性矿物硬度低、具有层状晶体结构,受力时易通过滑移或弯曲消耗能量,表现出明显的塑性行为,从而抑制脆性破裂的发生。因此,脆性矿物的相对含量是影响岩石脆性强弱的物质基础。

在页岩脆性评价中,基于矿物组成的计算方法被广泛采用。其中,石英含量常被视为关键指标^[31]。李钜源等强调在碳酸盐矿物含量高的地区需重视其贡献^[32];陈吉和肖贤明提出应考虑石英、长石、方解石和白云石等多种脆性矿物的共同影响^[33]。近期微观力学测试结果表明,黄铁矿具有最高的杨氏模量,其次为石英与长石^[34],显示出其显著的刚性特征。为更合理地评价页岩脆性,本文在综合前人研究成果的基础上,将石英、长石、黄铁矿及碳酸盐矿物统一归为脆性矿物组分。尽管不同矿物对岩石力学行为的实际贡献存在差异,理论上应为其分配相应的权重,但受限于当前实验数据的精度和覆盖范围,尚难以构建一个可靠且普适的矿物学力学贡献权重体系。因此,本文暂采用等权重求和的方式(即各类矿物权值均设为1)计算脆性指数,以初步反映脆性矿物总含量对岩石破裂能力的贡献。该方法可作为现阶段有效的分析手段,未来需结合岩石力学测试,构建更精细化的矿物力学贡献权重模型。

基于此,笔者团队结合图像处理与数理统计

方法,提出了一套自动计算脆性指数的方法,具体计算步骤为:①将页岩电镜扫描成像输入至页岩矿物智能识别模型生成各类矿物的掩膜(mask);②利用OpenCV算法库中的算法模型——包括连通区域分析(connectedComponentsWithStats)、轮廓查找(findContours)以及轮廓面积计算(contourArea)等——对各类矿物进行精准的面积量化;③根据下述公式(1)计算出脆性指数。

$$\text{脆性指数} = \frac{(\text{石英} + \text{长石} + \text{黄铁矿} + \text{碳酸盐矿物}) \text{含量}}{\text{矿物总量}} \quad (1)$$

理想的优质页岩储层工程甜点应具备高含量的脆性矿物,同时黏土矿物含量需保持在较低水平。其内在逻辑在于储层的可改造性:高脆性矿物含量预示着岩石在水力压裂过程中易于破裂并形成复杂裂缝,支撑剂能有效支撑裂缝;反之,若黏土矿物含量过高则预示着难以被有效压开,更会导致压裂时泵入的支撑剂(石英砂或陶粒)嵌入软弱的储层基质中,无法起到支撑裂缝的关键作用。

图7展示了松辽盆地3个页岩样本在本文所提出的矿物成分智能识别模型上的识别效果。①样本1的原图和模型识别结果图分别对应子图7a,b:脆性指数最高(达0.8668),得益于其极高的石英+钠长石含量(53.90%)和碳酸盐矿物含量(32.15%),同时黏土矿物含量较低(12.08%),有效抑制了压裂过程中的塑性变形,有利于形成复杂裂缝网络;其矿物组成上表现出高脆性特征,符合优质工程甜点的矿物学条件,指示该层段具备优良的可压裂性,有望通过水力压裂实现有效储层改造。②样本2的原图和模型识别结果图分别对应子图7c,d:脆性指数为0.6890,表现出较高的脆性特征,碳酸盐矿物、石英及长石含量较高,共同构成脆性矿物的主体,且黄铁矿作为高杨氏模量矿物进一步增强了岩石脆性;但较高的黏土矿物含量(30.97%)可能在一定程度上削弱了脆性表现,致使整体脆性水平低于样本1。③样本3的原图和模型识别结果图分别对应子图7e,f:脆性指数最低(0.2857),尽管黄铁矿含量高(16.61%),但石英与碳酸盐矿物含量相对偏低,同时黏土矿物含量高(71.29%),导致脆性矿物总体占比低,塑性较强;该位置可能存在的为相对劣质的储层,压裂改造难度较样本1和样本2对应的储层高。

5.2 孔隙结构评价

储层“甜点区”的本质在于优越的孔隙结构组合:

以宏孔(孔径>50 nm)和中孔(孔径2~50 nm)为主导,提供丰富的游离烃储集空间;微孔(孔径<2 nm)和有机质孔则主要贡献于吸附烃的储集能力。孔隙的总体积和比表面积共同决定了储层的油气赋存容量,而天然微裂缝系统则可为油气渗流提供高效通道。因此,系统量化表征孔隙结构参数成为预测储层甜点区的核心手段。

笔者团队对前期研究中形成的孔隙结构特征参数计算方法^[26]进行了回顾(面积占比、孔隙直径、视孔隙比表面积、孔隙周长和孔隙形状因子)和进一步的分析(计算了样本的特征参数如平均孔隙直径、平均视孔隙比表面积和平均孔隙形状因子)。同时,新增了多项几何与结构特征参数的提取方法,包括孔隙纵/横比、孔隙取向,以及一系列裂缝结构特征参数。具体而言,孔隙纵/横比指孔隙长轴与短轴长度的比值,长轴和短轴是在孔隙实例边缘提取(findContours)的基础上,采用OpenCV库中的minAreaRect函数获取最小外包矩形,并以其矩形的长边与短边分别作为长轴和短轴进行计算。孔隙取向则定义为孔隙长轴与参考坐标系之间的夹角;本文采用以图像左下角为原点、水平向右为 x 正方向的直角坐标系,取长轴与此 x 轴的夹角作为取向角;对于裂缝结构,团队采用skimage库中的skeletonize函数获得裂缝骨架,从而精确获取裂缝长度;在此基础上,通过面积除以裂缝长度计算裂缝宽度,参考《SY/T 6103 岩石孔隙结构特征的测定:图像分析法》标准实现裂缝特征参数的计算。本文提出的孔隙结构评价方法有效克服了传统实验法和目估法在复杂孔隙结构表征方面的局限,所提取的孔隙几何参数能够为关键储量指标计算提供可靠且直接的依据。

表4展示了古龙地区某页岩样本应用本文所提出的孔-缝智能分析算法获得的分析报告。报告显示:该位置有机质含量偏低(0.24%),制约了其生烃潜力;但有机孔具有较高的均质系数(0.78)和较大的平均孔径(158 nm),反映出一种相对均质且有利于气体赋存的孔隙结构。同时,无机孔与裂缝系统高度发育,显著增强了储层的渗流能力。综合来看,该位置虽然生烃潜力有限,但其良好的孔隙结构和发达的裂缝网络可能形成有效的储-渗体系。

6 总结与展望

本文提出的页岩矿物成分与孔隙结构智能识别方法,为页岩储层精细评价提供了新途径。基于该方法,




图 7 松辽盆地 3 个页岩样本矿物成分智能识别模型分析结果
Fig. 7 Mineral composition analysis results of three shale samples from Songliao Basin

研究不仅实现了脆性指数的定量计算,还拓展和丰富了孔隙结构量化评价的参数,形成了一套融合矿物与孔隙特征的页岩储层评价方法。这一技术体系可直接服务于页岩油气智能勘探解决方案,为陆相页岩油气的勘探决策提供可靠支持。

展望未来,该技术体系仍需在深度与广度上持续完善与拓展。在矿物组分识别方面,应进一步优化智能算法对复杂共生矿物组合及细分矿物类型的识别精度与效率,构建更具鲁棒性和泛化能力的矿物组分智

能识别模型。此外,矿物脆性系数的量化与各类矿物的权重分析也具有进一步研究的价值。在孔隙结构表征方面,当前技术需从静态结构描述向动态渗流特征评价延伸。重点发展方向包括孔隙网络模型(PNM)构建、孔隙渗透率预测、流体赋存与渗流行为之间的智能耦合等。

通过在上述关键方向上持续攻关,本智能分析技术将实现对页岩储层更精细、更全面的数字化与智能化刻画,显著提升储层评价精度与勘探开发效益预测

表 4 古龙地区某页岩样本孔-缝智能分析结果

Table 4 Intelligent analysis results of pores and fractures within a representative shale sample

孔-缝类型			面孔率/%		孔隙面积占比/%	
有机孔-缝	有机孔		0.012 1		0.336 7	
	有机缝		0		0	
无机孔-缝	无机孔		1.337 6		37.233 4	
	无机缝		2.242 8		62.429 9	
面孔率/%			1.349 7			
面缝率/%			2.242 8			
孔隙度/%			3.592 5			
有机质孔隙度/%			4.791 6			
有机质含量 /%			0.240 4			
计算单元总面积/mm ²			0.000 8			
孔隙类型	平均孔隙直径 /nm	孔隙均质系数	孔隙直径分选系数	平均孔隙形状因子	平均视孔隙比表面积/(nm ⁻¹)	平均纵/横比
有机孔	158.454 5	0.780 1	53.993 5	0.472 3	0.170 5	0.49 22
无机孔	140.074 5	0.313 7	82.843 5	0.493 8	0.165 4	0.541 1
总孔	140.239 3	0.314 0	82.647 8	0.493 7	0.165 4	0.540 8
孔隙类型	平均裂缝宽度/nm		平均裂缝等效圆直径/nm		裂缝面长度/(mm/mm ²)	
有机缝	0		0		0	
无机缝	272.516 5		1 981.409 5		154.300 3	
总缝	272.516 5		1 981.409 5		154.300 3	

的可靠性,为陆相页岩油气的规模效益开发提供更强有力的技术支撑。

参 考 文 献

[1] 窦立荣,李大伟,温志新,等. 全球油气资源评价历程及展望[J]. 石油学报, 2022, 43(8): 1035-1048.

DOU Lirong, LI Dawei, WEN Zhixin, et al. History and outlook of global oil and gas resources evaluation [J]. Acta Petrolei Sinica, 2022, 43(8): 1035-1048.

[2] 贾承造,郑民,张永峰. 中国非常规油气资源与勘探开发前景[J]. 石油勘探与开发, 2012, 39(2): 129-136.

JIA Chengzao, ZHENG Min, ZHANG Yongfeng. Unconventional hydrocarbon resources in China and the prospect of exploration and development [J]. Petroleum Exploration and Development, 2012, 39(2): 129-136.

[3] 董大忠,邹才能,杨桦,等. 中国页岩气勘探开发进展与发展前景[J]. 石油学报, 2012, 33(增刊1): 107-114.

DONG Dazhong, ZOU Caineng, YANG Hua, et al. Progress and prospects of shale gas exploration and development in China [J]. Acta Petrolei Sinica, 2012, 33(S1): 107-114.

[4] SAXENA N, HOFMANN R, ALPAK F O, et al. Effect of image segmentation & voxel size on micro-CT computed effective transport & elastic properties[J]. Marine and Petroleum Geology, 2017, 86: 972-990.

[5] IASSONOV P, GEBRENEGUS T, TULLER M. Segmentation of X-ray computed tomography images of porous materials: A crucial step for characterization and quantitative analysis of pore structures [J]. Water Resources Research, 2009, 45(9): W09415.

[6] 刘合,任义丽,李欣,等. 岩心智能识别技术内涵与展望[J]. 石油学报, 2024, 45(8): 1296-1308.

LIU He, REN Yili, LI Xin, et al. Connotation and prospect of intelligent recognition technology for cores [J]. Acta Petrolei

Sinica, 2024, 45(8): 1296-1308.

[7] LIANG Jiabin, SUN Yongyang, LEBEDEV M, et al. Multi-mineral segmentation of micro-tomographic images using a convolutional neural network [J]. Computers & Geosciences, 2022, 168: 105217.

[8] CHEN Zhuoheng, LIU Xiaojun, YANG Jinin, et al. Deep learning-based method for SEM image segmentation in mineral characterization, an example from Duvernay Shale samples in Western Canada Sedimentary Basin [J]. Computers & Geosciences, 2020, 138: 104450.

[9] 陈宗铭,唐玄,梁国栋,等. 基于深度学习的页岩扫描电镜图像有机质孔隙识别与比较[J]. 地学前缘, 2023, 30(3): 208-220.

CHEN Zongming, TANG Xuan, LIANG Guodong, et al. Identification and comparison of organic matter-hosted pores in shale by SEM image analysis—a deep learning-based approach [J]. Earth Science Frontiers, 2023, 30(3): 208-220.

[10] 刘成,万欢,马立涛,等. 基于深度学习的页岩微观结构智能分割与定量表征方法—以北部湾盆地流沙港组二段为例[J]. 中国海上油气, 2024, 36(6): 232-243.

LIU Cheng, WAN Huan, MA Litao, et al. Intelligent segmentation and quantitative characterization of shale microstructure based on deep learning: A case study of second member of Liushagang Formation in Beibu Gulf Basin [J]. China Offshore Oil and Gas, 2024, 36(6): 232-243.

[11] BIHANI A, DAIGLE H, SANTOS J E, et al. MudrockNet: Semantic segmentation of mudrock SEM images through deep learning[J]. Computers & Geosciences, 2022, 158: 104952.

[12] ZHANG Ruigang, CHEN Xiangru, TANG Xin, et al. Research on intelligent identification of microscopic substances in shale scanning electron microscope images based on deep learning theory [J]. Scientific Reports, 2025, 15(1): 11772.

[13] ALEKSEEV V V, ORLOV D M, KOROTEEV D A. Multi-

- mineral segmentation of SEM images using deep learning techniques [C]//SPE Russian Petroleum Technology Conference, Virtual, 2021. Richardson: Society of Petroleum Engineers, 2021: SPE-206526-MS.
- [14] YASIN Q, LIU Bo, SUN Mengdi, et al. Digital core modeling for multimaterial segmentation of lacustrine shale oil using FE-SEM and KiU-Net[J]. Fuel, 2025, 398: 135474.
- [15] YU Qingyang, XIONG Ziwei, DU Chao, et al. Identification of rock pore structures and permeabilities using electron microscopy experiments and deep learning interpretations[J]. Fuel, 2020, 268: 117416.
- [16] 陈雁, 李祉呈, 程超, 等. FLU-net: 用于表征页岩储层微观孔隙的深度全卷积网络[J]. 海洋地质前沿, 2021, 37(8): 34-43. CHEN Yan, LI Zhicheng, CHENG Chao, et al. FLU-net: A deep fully convolutional neural network for shale reservoir micro-pore characterization[J]. Marine Geology Frontiers, 2021, 37(8): 34-43.
- [17] 王庆, 曾齐红, 张友炎, 等. 基于多尺度区域卷积神经网络的露头孔洞自动提取[J]. 现代地质, 2021, 35(4): 1147-1154. WANG Qing, ZENG Qihong, ZHANG Youyan, et al. Automatic extraction of outcrop cavity based on multi-scale regional convolution neural network[J]. Geoscience, 2021, 35(4): 1147-1154.
- [18] WANG Hongsheng, GUO Ruichang, DALTON L E, et al. Comparative assessment of U-Net-based deep learning models for segmenting microfractures and pore spaces in digital rocks [J]. SPE Journal, 2024, 29(11): 5779-5791.
- [19] 李天平, 李功权. 融合多种深度学习模型的岩石铸体薄片孔隙自动分割方法[J]. 科学技术与工程, 2023, 23(21): 9168-9175. LI Tianping, LI Gongquan. Automatic pore segmentation method for rock cast thin section based on multiple deep learning models [J]. Science Technology and Engineering, 2023, 23(21): 9168-9175.
- [20] 汪南洋, 沈疆海. 基于MSHAM-UNet的岩心孔洞图像分割方法[J]. 科学技术与工程, 2024, 24(24): 10362-10369. WANG Nanyang, SHEN Jianghai. Image segmentation method of rock core hole based on MSHAM-UNet[J]. Science Technology and Engineering, 2024, 24(24): 10362-10369.
- [21] TIAN Qinyi, GOODHUE S, XIONG Hou, et al. Geo-SegNet: A contrastive learning enhanced U-net for geomaterial segmentation [J]. Tomography of Materials and Structures, 2025, 7: 100049.
- [22] HU Mangu, FU Tianyu, YANG Xiaobin, et al. Fracture identification in hot dry rock using TSD-Unet: From feature extraction to quantitative analysis of geometric parameters [J]. Geothermics, 2026, 136: 103569.
- [23] XI Zhaodong, TANG Shuheng, ZHANG Songhang, et al. Evaluation of mechanical properties of porous media materials based on deep learning: Insights from pore structure [J]. Fuel, 2024, 371(Part A): 131923.
- [24] ZHANG Xingpeng, LI Zheng, XIAO Bin, et al. Multi-axis frequency domain residual UNet for pore identification in deep shale scanning electron microscopy images [C]//2024 International Joint Conference on Neural Networks (IJCNN), Yokohama, 2024. Piscataway, NJ: IEEE Press, 2024: 1-8.
- [25] CHEN Xiangru, XIN Tang, XIONG Junjie, et al. Pore characterization was achieved based on the improved U-net deep learning network model and scanning electron microscope images [J]. Petroleum Science and Technology, 2025, 43(7): 715-729.
- [26] 刘茜, 任义丽, 汪文洁, 等. 基于语义分割的页岩孔隙结构智能表征方法 [J/OL]. 北京航空航天大学学报, 1-15 [2026-03-20]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0018>. LIU Xi, REN Yili, WANG Wenjie, et al. Intelligent representation method of shale pore structure based on semantic segmentation [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-15 [2026-03-20]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0018>.
- [27] 王晓东, 王一航, 王永田, 等. 利用矿物含量计算砂岩脆性指数——以鄂尔多斯盆地合水地区长6段致密砂岩储层为例[J]. 成都理工大学学报(自然科学版), 2018, 45(3): 367-373. WANG Xiaodong, WANG Yihang, WANG Yongtian, et al. A method of computing brittleness index of sandstone by mineral content: A case study of Chang-6 tight sandstone reservoir in Heshui, Ordos Basin, China [J]. Journal of Chengdu University of Technology (Science & Technology Edition), 2018, 45(3): 367-373.
- [28] HE Junjun, DENG Zhongying, ZHOU Lei, et al. Adaptive pyramid context network for semantic segmentation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, 2019. Los Alamitos, CA: IEEE Computer Society, 2019: 7511-7520.
- [29] HUANG Ruoxin, LI Yifan, GAO Zhiqian, et al. Machine learning-based sweet spot prediction for lacustrine shale oil in the Weixinan Sag, Beibu Gulf Basin, China [J]. Marine and Petroleum Geology, 2025, 179: 107436.
- [30] 杨智, 侯连华, 陶士振, 等. 致密油与页岩油形成条件与“甜点区”评价[J]. 石油勘探与开发, 2015, 42(5): 555-565. YANG Zhi, HOU Lianhua, TAO Shizhen, et al. Formation conditions and “sweet spot” evaluation of tight oil and shale oil [J]. Petroleum Exploration and Development, 2015, 42(5): 555-565.
- [31] 才博, 丁云宏, 卢拥军, 等. 非常规储层体积改造中岩石脆性特征的判别方法[J]. 重庆科技学院学报(自然科学版), 2012, 14(5): 86-88. CAI Bo, DING Yunhong, LU Yongjun, et al. Study of rock brittleness for stimulated reservoir volume fracturing technology [J]. Journal of Chongqing University of Science and Technology (Natural Science Edition), 2012, 14(5): 86-88.
- [32] 李钜源. 东营凹陷泥页岩矿物组成及脆度分析[J]. 沉积学报, 2013, 31(4): 616-620. LI Juyuan. Analysis on mineral components and frangibility of shales in Dongying Depression [J]. Acta Sedimentologica Sinica, 2013, 31(4): 616-620.
- [33] 陈吉, 肖贤明. 南方古生界3套富有机质页岩矿物组成与脆性分析[J]. 煤炭学报, 2013, 38(5): 822-826. CHEN Ji, XIAO Xianming. Mineral composition and brittleness of three sets of Paleozoic organic-rich shales in China South area [J]. Journal of China Coal Society, 2013, 38(5): 822-826.
- [34] XU Shang, WEN Jie, LIU Kouqi, et al. Brittle minerals, mechanical properties and fracability evaluation of shales [J]. Advances in Geo-Energy Research, 2024, 14(1): 8-11.