



## 基于深度学习算法的致密储层薄片图像颗粒、孔隙智能表征方法研究

王金焕<sup>1</sup>, 许承武<sup>1</sup>, 乔宏亮<sup>2</sup>, 唐露<sup>1</sup>, 刘天勇<sup>1</sup>, 曲端刚<sup>1</sup>, 徐坚<sup>1</sup>, 孟英杰<sup>1</sup>, 李乙鸿<sup>3</sup>

1. 东北石油大学 非常规油气研究院, 黑龙江 大庆 163000;

2. 中国石油长庆油田分公司第二采油厂, 陕西 西安 710000;

3. 榆林学院 化学与化工学院, 陕西 榆林 719000

**摘要:** 在致密砂岩储层薄片图像分析中, 针对传统方法的准确率不足和任务繁重等问题, 采用结合了 Transformer 和卷积神经网络的 TransUnet 及 Unet 神经网络, 用于颗粒、孔隙特征的高效表征。Unet、TransUnet 在颗粒特征表征方面表现优异, 实验数据显示 Unet 的交并比达到 79.6%, 召回率为 87.3%, 精确率为 89.7%, TransUnet 的交并比达到 71.3%, 召回率为 86.1%, 精确率为 82.5%。实验图像显示, 在局部像素差异较大的情况, TransUnet 优于传统方法, 证明其在紧密复杂颗粒分割的有效性。Unet 在孔隙特征方面也表现出高效表征效果, 其交并比、召回率和精确率分别为 82.4%、84.3% 和 95.3%。实验还表明, 虽然面孔率影响交并比, 但模型整体仍保持高效率 and 准确性。这些结果充分说明深度学习方法, 在复杂致密储层薄片图像的精确分割中效果显著, 为非常规致密储层研究提供新思路, 展现了其在地质学领域应用的巨大潜力。

**关键词:** 深度学习; 薄片分析; 致密储层; 粒度分析; TransUnet

## Intelligent characterization of particles and pores in thin slice images of tight reservoirs based on deep learning algorithm

WANG Jin-huan<sup>1</sup>, XU Cheng-wu<sup>1</sup>, QIAO Hong-liang<sup>2</sup>, TANG Lu<sup>1</sup>, LIU Tian-yong<sup>1</sup>, QU Duan-gang<sup>1</sup>, XU Jian<sup>1</sup>, MENG Ying-jie<sup>1</sup>, LI Yi-hong<sup>3</sup>

1. Institute of Unconventional Oil and Gas, Northeast Petroleum University, Daqing 163000, Heilongjiang Province, China;

2. No. 2 Oil Production Plant of Changqing Oilfield Branch, PetroChina, Xi'an 710000, China;

3. School of Chemistry and Chemical Engineering, Yulin University, Yulin 719000, Shaanxi Province, China

**Abstract:** In the thin-section image analysis of tight sandstone reservoir, to solve the problems such as low accuracy and heavy work of traditional methods, TransUnet and Unet neural networks by combining Transformer with convolutional neural network (CNN) are used for efficient characterization of particles and pores. The TransUnet has excellent performance in particle characterization. The experiment shows that the intersection over union (IoU) reaches

收稿日期: 2023-11-13; 修回日期: 2023-11-29. 编辑: 张哲.

基金项目: 国家自然科学基金面上项目“原位加热下页岩储层孔-裂隙动态演化机制研究”(42172163).

作者简介: 王金焕(1998—), 男, 硕士, 从事薄片鉴定与分析、深度学习图像分割研究, 通信地址 黑龙江省大庆市发展路 199 号, E-mail//1311186348@qq.com

通信作者: 许承武(1978—), 男, 博士, 教授, 从事非常规油气地质学、构造沉积演化形成研究, 通信地址 黑龙江省大庆市发展路 199 号, E-mail//2868915@qq.com

引用格式: 王金焕, 许承武, 乔宏亮, 唐露, 刘天勇, 曲端刚, 徐坚, 孟英杰, 李乙鸿. 基于深度学习算法的致密储层薄片图像颗粒、孔隙智能表征方法研究[J]. 地质与资源, 2025, 34(1): 61-69.

Wang J H, Xu C W, Qiao H L, Tang L, Liu T Y, Qu D G, Xu J, Meng Y J, Li Y H. Intelligent characterization of particles and pores in thin slice images of tight reservoirs based on deep learning algorithm [J]. Geology and Resources, 2025, 34(1): 61-69.

0.86, with the recall rate of 0.824 and precision of 0.839, which is superior to traditional methods, proving its effectiveness in tight particle segmentation. The Unet shows efficient characterization of pores as well, with the IoU of 0.824, recall rate of 0.843 and precision of 0.953. Besides, experiment indicates that although porosity affects IoU, the model still maintains high efficiency and accuracy generally. These results fully demonstrate that deep learning method, especially TransUnet, is significantly effective in accurate segmentation of thin section images of complex tight reservoir, providing new ideas for the study of unconventional tight reservoir and showing its great potential in the field of geology.

**Key words:** deep learning; thin section analysis; tight reservoir; particle size analysis; TransUnet

## 0 前言

岩石薄片分析是在显微镜下观察统计岩石结构、构造、颜色、成分等岩石学特征<sup>[1]</sup>,从而推断岩石的形成环境和成因的分析方法.对砂岩储层的岩石薄片进行观测,可以表征孔隙大小、孔径分布,孔隙类型等储层特征,从而建立对储层的物理性质和流体流动特性的理解.在此基础上通过荧光观测,可以研究含油气赋存特征等.岩石薄片分析在油气储层特性评估中发挥有重要作用.但传统的岩石薄片分析存在着工作量大,且观测结论易受观察者主观因素影响等问题<sup>[2]</sup>.随着机器学习技术的快速发展,以深度学习为基础的人工智能技术愈发成熟,在此基础上,众多研究者开始利用人工智能结合图像分析技术,开展自动提取颗粒、孔隙特征的研究工作,以帮助地质工作人员从繁重的岩石薄片分析工作中解放出来,并且降低主观因素的干扰<sup>[3-11]</sup>.尽管针对岩石薄片图像分割已经进行了诸多研究,但却很少有人致密储层薄片图像紧密颗粒分割上进行过深入的研究.随着常规油气资源日趋衰竭以及深地、深海、深空国家战略的持续推进,致密储层具有重要的研究意义和迫切的技术需求<sup>[12-14]</sup>.然而,由于致密储层孔隙度低、渗透性差,传统的储层评价方法往往难以准确揭示其复杂的地质特性.致密储层薄片图像颗粒间、颗粒与孔隙之间紧密,分割难度大,对精确的定量分析造成了障碍.

引入 Unet<sup>[15]</sup>、TransUnet<sup>[16]</sup>模型并且结合形态学原理将其应用到致密砂岩储层薄片图像紧密颗粒分割上.实验结果表明,对具有紧密颗粒且语义信息较多的致密砂岩储层薄片图像进行颗粒、孔隙表征时,深度学习方法是一种非常科学有效的手段,采用 Unet、TransUnet 对紧密颗粒分割具有良好的效果,可为更复杂的非常规和深层储层研究提供一种新的研究路径和

方法.

## 1 数据准备

本研究选用新疆深层和大庆致密油储层的铸体薄片、荧光薄片进行颗粒、孔隙智能表征应用.通过 Leria Thunder DMi8 成像仪器以单张 20×20 像素大小范围的扫描区间获取无缝拼接的高分辨率大视域显微图像.

在基于深度学习的薄片颗粒、孔隙等特征识别中,获取到充足训练样本的难度和代价非常高.因此,数据增广成为一种常用的增加训练样本的手段.数据增广用于增加有限数据的数量和多样性,并从有限的数中提炼出诸如改善模型泛化能力、增强特征识别鲁棒性和缓解数据集类别不平衡问题等有用信息,从而产生等价于更多数据的价值<sup>[17]</sup>.本研究采用形状变换的增强处理(如图 1 所示)以及非形状变换的增强处理(如图 2 所示)两种方式.形状变换的增强处理包括图像的旋转、翻转等,这种处理方式增加了图像的几何多样性,帮助模型学习从不同角度和方向识别相同对象的能力.这样的增广不仅提升了模型对物体位置和方向变化的鲁棒性,还增强了模型在面对位置和方向差异时的识别准确性.非形状变换的增强处理包括图像的对比如度变换、锐化变换等,这种处理方式改变了图像的光学属性和纹理特征,增加了图像在光照、清晰度和纹理上的多样性.这种增广使得模型能够更好地处理不同光照条件和纹理变化,提高了模型在不同光照和纹理条件下识别对象的性能.

## 2 TransUnet 模型

TransUnet 是由苏黎世大学 (University of Zurich) 的研究员 Fabian Isensee 等人提出的.它是一个结合

了 Transformer<sup>[18]</sup> 和 Unet 的深度学习架构(如图 3 所示)。TransUnet 模型融合了卷积神经网络 (CNN) 和 Transformer 的优势<sup>[19]</sup>, 用于高效的图像分割任务。该模型首先利用 CNN 层提取图像的局部特征, 然后将这些特征转换成序列化格式以适应 Transformer 结构。在 Transformer 模块中, 自注意力机制被用来捕捉特征之

间的长距离依赖关系, 实现全局信息的整合。随后, 通过解码器对特征进行上采样和重建, 结合跳跃连接技术恢复细节信息。最终, 模型通过卷积层进行像素级分类, 完成精确的图像分割。这种结合局部和全局特征处理的方法使 TransUnet 在处理复杂图像分割任务时表现出色, 特别是在需要对图像内容进行精细理解

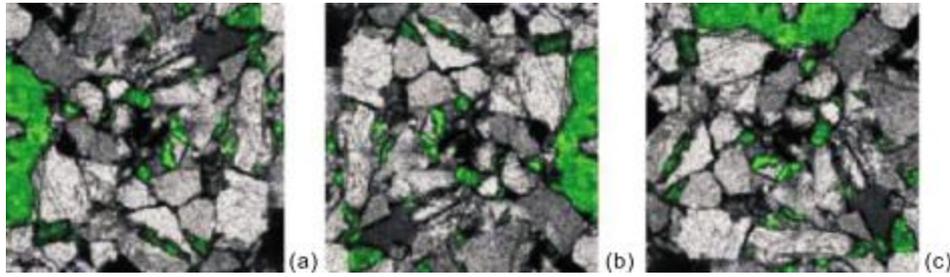


图 1 形状变换

Fig. 1 Shape transformation

a—原图(original image); b—垂直翻转(vertical turning); c—90°旋转(90° rotation)

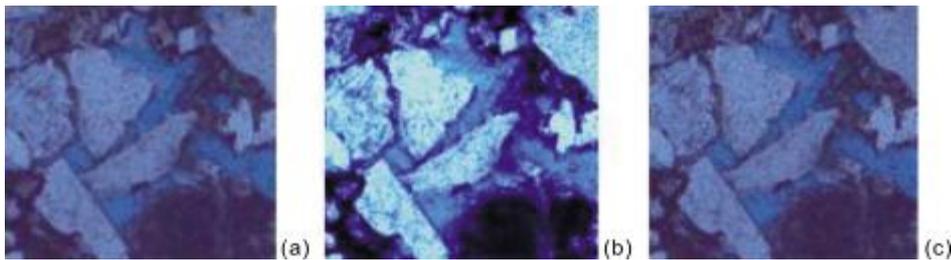


图 2 非形状变换

Fig. 2 Non-shape transformation

a—原图(original image); b—对比度变换图(contrast transformation); c—锐化变换图(sharpening transformation)

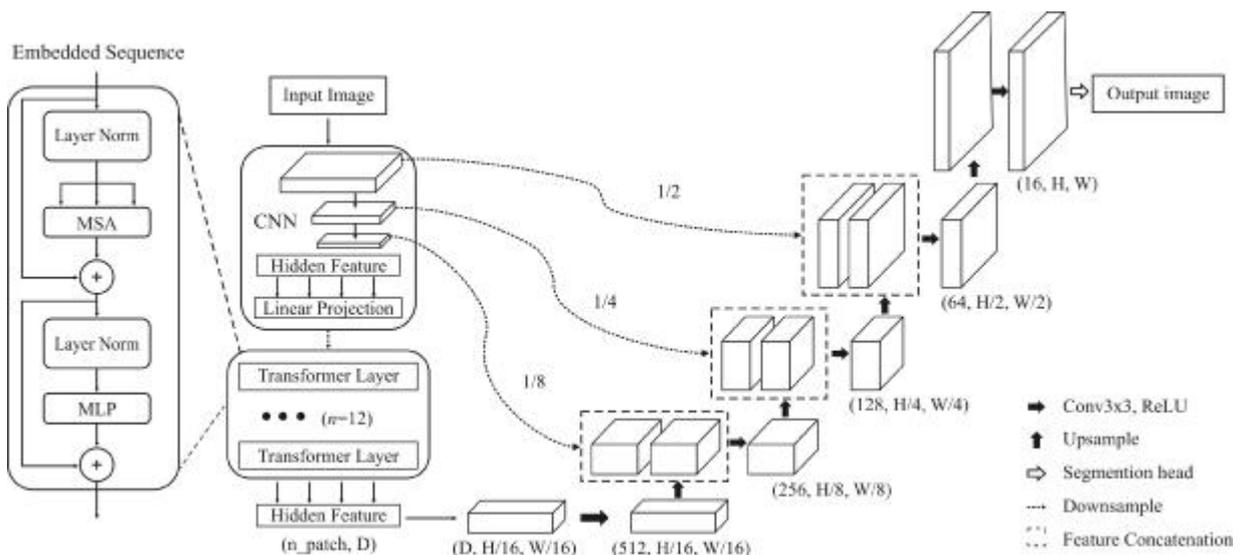


图 3 模型结构图

Fig. 3 Model structure diagram

的应用场景中. 因此该模型可以对致密储层薄片图像中紧密颗粒的情况相对分割得更为彻底.

### 3 图像颗粒、孔隙识别过程

在 TransUnet 编码器中, 通过卷积层和池化操作逐步下采样图像, 减小其空间维度同时增加特征的深度, 从而将图像的局部特征转换为一系列代表小区域的特征向量. 这些特征向量包含了颗粒和孔隙的关键信息, 如形状、大小和分布. 随后, 这些向量被输入到 Transformer 部分, 其中自注意力机制通过计算每个特征向量的查询(Q)、键(K)、值(V)三元组, 对全局上下文信息进行深入建模, 有效捕捉和整合图像中颗粒和孔隙的全局特征. 这样的处理不仅提取了局部信息, 还确保了对图像整体内容的深入理解.

在 TransUnet 中, 解码器通过上采样逐渐恢复图像的空间维度, 同时利用跳跃连接将编码器捕获的局部特征(如颗粒和孔隙的细节)与解码器的全局信息结合, 从而有效地恢复图像细节. 这种机制确保了在最终输出时, 每个像素位置不仅恢复了其原始空间维度, 还被赋予一个反映其岩石组成(如颗粒类型或孔隙)的类别标签. 这些类别标签的确定是通过网络的最后一个卷积层实现的, 它们将复合特征转换为具体类别的概率分布, 确保了对颗粒和孔隙等关键元素的精确识别和分类.

## 4 基于深度学习的致密砂岩储层薄片图像颗粒、孔隙表征

### 4.1 实验环境与评价指标

本研究所有实验均在操作系统 Ubuntu 22.04、GPU 为 RTX 3090 环境中运行(表 1), 使用 Python 3.9 编译环境, 版本为 2.0.1 的 PyTorch 框架.

表 1 实验环境参数表

Table 1 Experimental environment parameters

操作系统	Ubuntu 22.04
内存	10 核 32 GB
显存	1 卡 * 24 GB
硬盘	50 GB

在 Unet、TransUnet 中, 使用平均交并比(MIoU)、

查准率(Precision)、查全率(Recall)以及 F1 分数(F1-score)等指标来评估模型在岩石薄片图像分割任务中的性能, 特别是在颗粒和孔隙特征的识别方面. 这些指标衡量的是模型预测分割与真实分割之间的相似度和准确性. 例如, MIoU 衡量的是模型识别颗粒和孔隙区域与实际这些区域的重叠程度, 而 Precision 和 Recall 则分别评估了模型预测的颗粒和孔隙区域的准确性和完整性. F1 分数作为这两者的调和平均值, 提供了一个整体的性能评估.

$$MIoU = \left( \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i + FN_i} \right) \times 100\% \quad (1)$$

其中,  $N$  是类别的数量,  $TP_i$  是第  $i$  类的真阳性数量,  $FP_i$  是第  $i$  类的假阳性数量,  $FN_i$  是第  $i$  类的假阴性数量. 在具体的颗粒、孔隙识别任务中, 真阳性数量代表一个颗粒(孔隙)被正确地识别为颗粒(孔隙)的数量. 假阳性数量代表如果一个非颗粒(孔隙)元素被错误地识别为颗粒(孔隙)的数量. 假阴性数量代表如果一个颗粒(孔隙)没有被识别出来, 或者被错误地分类为非颗粒(孔隙)的数量. MIoU 的值范围在 0~1 之间, 值越接近 1, 表示预测结果越好. 在诸多图像分割任务中, MIoU 因为其代表性强而成为最常用的度量标准<sup>[20]</sup>.

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

其中,  $TP$  是真阳性数量,  $FN$  是假阴性数量. 查准率越高, 表示模型在预测正样本时的准确性越高; 查全率越高, 表示模型在捕捉到实际正样本时的准确性越高.

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

F1 分数综合了查准率和查全率, 因此可以在一定程度上反映模型的整体性能.

损失函数如交叉熵损失(Cross-Entropy Loss)和 Dice 损失(Dice Loss)等损失函数在优化过程中主要用于评估模型预测值与真实标签之间的匹配程度. 这些损失函数在训练过程中起到了指导优化方向的作用, 帮助模型更好地学习如何准确分割出薄片图像中的颗粒和孔隙特征. 通过观察损失值的收敛趋势, 可以判断模型的训练是否有效, 从而采取相应措施进一步优化模型性能, 确保其在实际应用中能准确地识别和表述岩石薄片图像中的关键特征.

#### 4.2 实验过程及应用效果

为了验证 Unet、TransUnet 对于致密砂岩储层薄片图像的颗粒分割效果,以 Unet、TransUnet 进行实验,从客观以及主观两个维度进行比较.此外,为了将薄片中的孔隙特征进行表征,采用交叉熵损失和 Dice 损失的 Unet 为主训练孔隙提取模型.实验过程如下.

考虑到岩石薄片图像的保密性质以及不同面孔率薄片图像的已有数量,为了能够用更多薄片图像进行模型训练,从已有的薄片图像中截取近 250 张作为颗粒数据集,154 张作为孔隙数据集.因 Unet、TransUnet 模型初次调试需要,将颗粒数据集图像截取为  $256 \times 256$  像素大小作为模型输入,而将孔隙数据集图像截取为  $512 \times 512$  像素大小作为模型输入.

颗粒数据集按照约 7:3 的比例划分为训练集和测试集,然后随机选取训练集中的部分图像进行数据增广,最终得到 395 张图像作为训练集.然后,设置 Unet、TransUnet 模型的超参数.学习率为 0.01,批次大小为 16,TransUnet 的损失函数为 Dice 函数、Unet 的损失函数为交叉熵函数.

孔隙数据集按照约 7:3 的比例划分为训练集和测试集,然后随机选取训练集中的部分图像进行数据增广,最终得到 410 张图像作为训练集.然后,设置不同损失函数 Unet 的超参数.学习率为 0.01,批次大小为

4,损失函数为 Dice 函数、交叉熵函数.

在具体的颗粒、孔隙识别任务中,学习率决定了颗粒、孔隙模型在训练过程中权重更新的速度,批次大小影响训练的稳定性及效率,而损失函数则用于量化颗粒、孔隙模型预测与实际标签之间的差异,指导模型优化.

待损失函数收敛且趋于平稳时,停止训练模型,保存最优模型.记录 Unet 以及 TransUnet 模型两者在颗粒、孔隙测试集上的模型指标,结果如表 2 所示.

表 2 颗粒、孔隙识别模型指标结果  
Table 2 Model index results of particle and pore identification

指标	颗粒识别		孔隙识别	
	Unet	TransUnet	Dice_Loss_Unet	CE_Loss_Unet
MIoU	79.6%	71.3%	77.4%	82.4%
Recall	87.3%	86.1%	77.3%	84.3%
Precision	89.7%	82.5%	95.7%	95.3%
F1-score	88.4%	84.0%	85.2%	89.3%

注:Dice\_Loss\_Unet 是以 Dice 为损失函数的 Unet; CE\_Loss\_Unet 是以交叉熵为损失函数的 Unet.

比较 Unet 模型、TransUnet 模以及人工颗粒识别图像三者的颗粒识别效果,结果如图 4 所示.

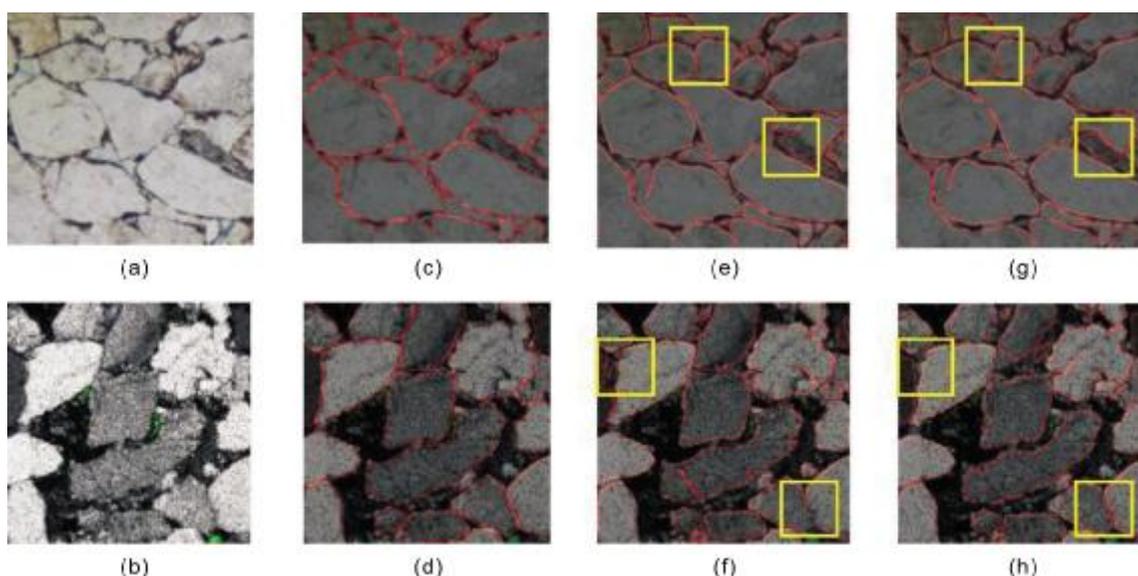


图 4 颗粒识别

Fig. 4 Particle recognition

a, b—原图(original image); c, d—人工识别图(manual recognized image); e, f— Unet 识别图(Unet recognized image); g, h— TransUnet 识别图(TransUnet recognized image); 黄框为颗粒边界处分割(Yellow box represents segmentation of particle boundary)

比较不同损失的 Unet 以及人工孔隙识别图像两者的孔隙识别效果,结果如图 5 所示.

用 TransUnet 以及 CE\_Loss\_Unet 对不同面孔率的致密砂岩储层薄片图像粒度、孔隙识别的部分结果,如图 6 所示.

在石油地质学领域,孔隙度直接影响岩石的渗透性,而致密砂岩储层会妨碍油气及地下水的迁移,进而直接作用于油气藏的生成与分布<sup>[21-23]</sup>. 为了进一步验证 TransUnet 模型的泛化能力以及对于不同面孔率的致密砂岩储层薄片图像的粒度识别效果,使用部分局

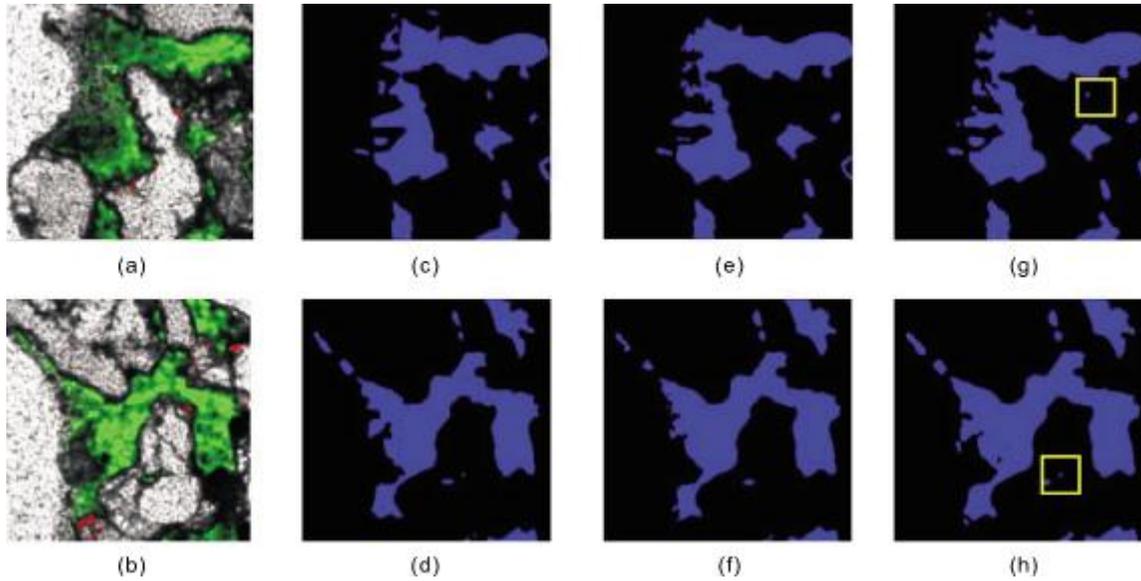


图 5 孔隙识别

Fig. 5 Pore recognition

a, b—原图(original image); c, d—人工识别图(manual recognized image); e, f— CE Loss Unet 识别图(CE-Loss Unet recognized image,); g, h— Dice Loss Unet 识别图(Dice Loss Unet recognized image); 黄框为细微目标处(Yellow box represents subtle target)

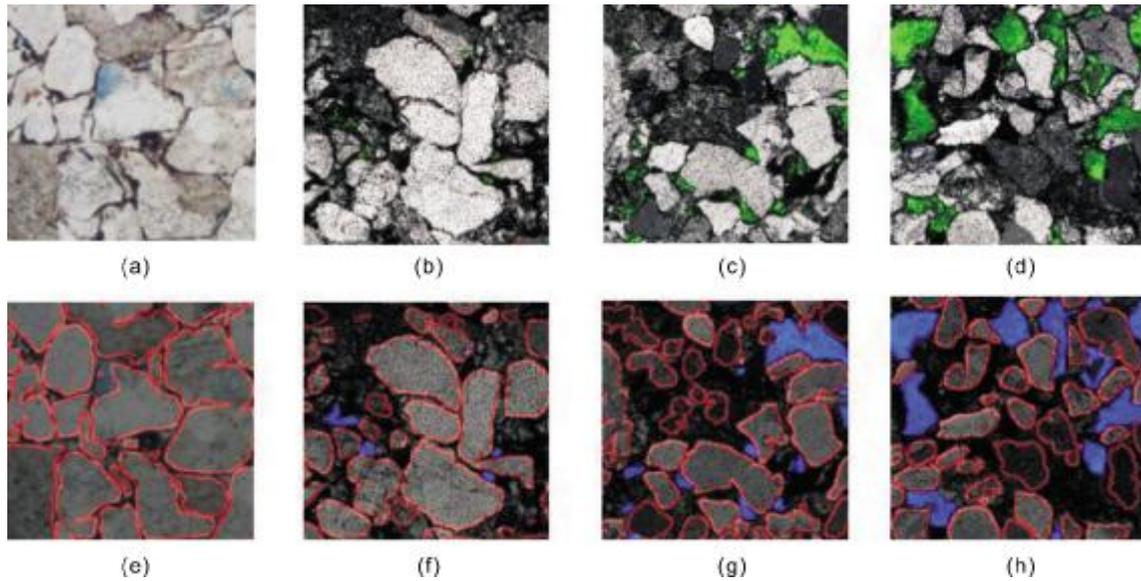


图 6 部分不同面孔率致密砂岩薄片颗粒、孔隙识别

Fig. 6 Particle and pore recognition of tight sandstone thin sections with different porosity

a, b, c, d—原图(original image); e, f, g, h—识别结果(recognition result)

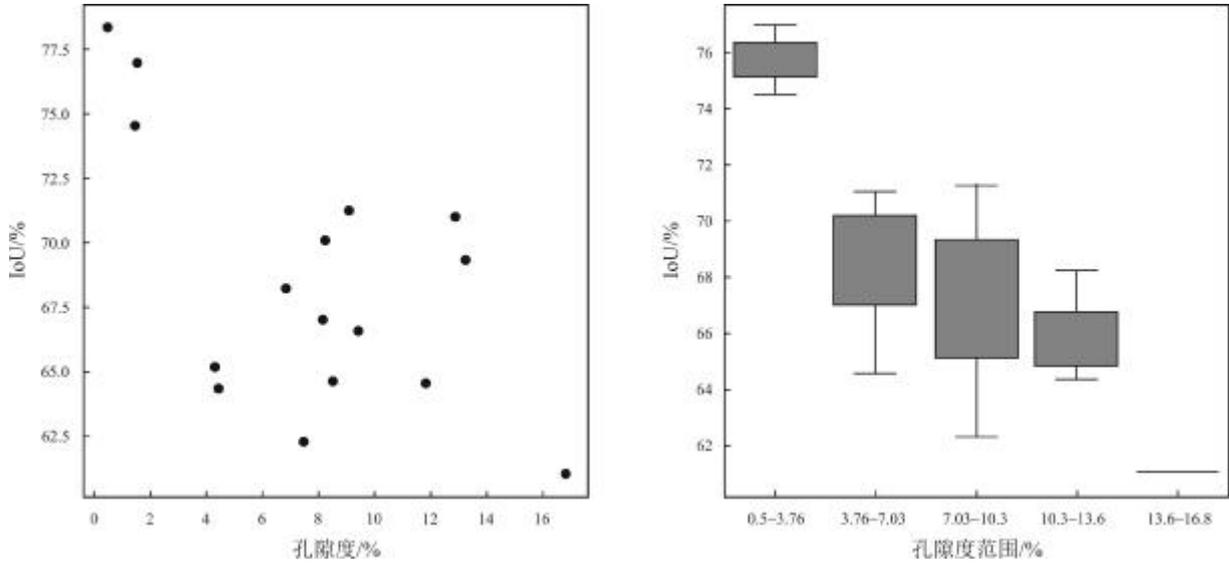


图 7 交并比与孔隙度关系图  
Fig. 7 Relationship between IoU and porosity

部不同面孔率的致密砂岩储层薄片图像进行实验,结果如图 7 所示.

最后为了验证粒度分析的效果,对薄片图像粒度、孔隙识别结果进行一定范围的无重叠图像拼接(如图 8 所示),然后参照 McManus 计算公式(1988)得到相应的粒度参数<sup>[24]</sup>.将计算得到的粒度参数与人工识别数据比对可知,平均粒径相差在 0.1 左右,标准偏差相差在 0.3 左右.平均粒径(Mz)、标准偏差(Sd)、偏度(Sk)、峰度(Kg)、计算公式如下:

$$Mz=0.01 \sum_{k=1}^n x_k f_k \quad (5)$$

$$Sd=[0.01 \sum_{k=1}^n (x_k-Mz)^2 f_k]^{1/2} \quad (6)$$

$$Sk=0.01 \sum_{k=1}^n (x_k-Mz)^3 f_k Sd^3 \quad (7)$$

$$Kg=0.01 \sum_{k=1}^n (x_k-Mz)^4 f_k Sd^4 \quad (8)$$

其中,  $f_k$  为各粒级组的频率百分数,  $x_k$  为各粒级组的中值.

### 4.3 讨论与分析

由表 2 以及图 4、5、6 可以看出 Unet 和 TransUnet 整体分割性能较好,TransUnet 的 MIoU 指标显著高于 Unet 的 MIoU 指标,但是从 Recall、Precision 以及 F1-score 三者指标来看,TransUnet 显著落后于 Unet,

这与模型架构以及两者的损失函数选择有一定关系.从粒度识别表征图可以看出,TransUnet 相对于 Unet 的分割更为彻底,尤其对于局部像素差异较大的情况(如图 4 黄框位置).同样对于 Unet 而言,选用不同的损失函数所呈现的结果也是不同,选用交叉熵损失的 Unet 指标高于或相近选用 Dice 损失的 Unet.从孔隙识别表征图可以看出,两者整体分割效果差异不大,但是 Dice\_Loss\_Unet 对微小目标的捕获更为灵敏(如图 5 黄框位置).

由图 7 可以看出,TransUnet 网络模型对于不同面孔率的薄片识别效果有所不同.对于面孔率在 0.5%~3.76%之间,IoU 数值较高,而随着面孔率升高,IoU 数值存在缓慢下降的趋势.

由表 3 以及图 8 可以看出,采用 TransUnet 以及 CE\_Loss\_Unet 进行薄片颗粒表征与真实粒度参数计算差距不大.因此对于紧密颗粒且语义信息比较多的薄片图像进行颗粒、孔隙分割时,采用深度学习方法是一种非常科学有效的手段.

表 3 模型识别与人工识别粒度分析参数结果

**Table 3 Particle size parameter results by model recognition and manual recognition analysis**

识别方式	平均粒径(Mz)/ $\mu$	标准偏差(Sd)/ $\mu$	偏度(Sk)	峰度(Kg)
模型识别分析	2.70	1.26	3.539	21.7
人工识别分析	2.61	1.08	1.642	10.2

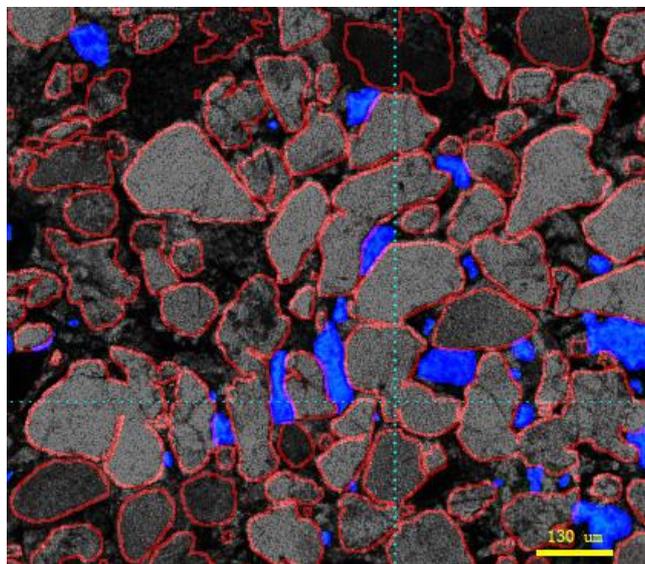


图 8 大范围薄片图像拼接

Fig. 8 Large scale thin section image stitching

## 5 结论

利用深度学习技术进行薄片图像颗粒、孔隙表征在未来将会作为薄片鉴定分析的一种高效手段。Unet 是经典卷积神经网络模型之一，而 TransUnet 是一个结合了 Transformer 和 Unet 的深度学习网络模型。Transformer 网络能够捕获图像中的长范围依赖关系，具有 CNN 所不具备的效果，将 Transformer 与 CNN 结合，这对于致密储层薄片图像的颗粒分割具有很大的帮助。

局部不同面孔率在 0.5%~3.76% 之间，MIoU 为 75.7%；面孔率在 3.76% 至 7.03% 之间，MIoU 为 68.3%；面孔率在 7.03%~10.3% 之间，MIoU 为 66.9%；面孔率在 10.3% 至 13.6% 之间，MIoU 为 65.9%；面孔率在 13.6%~16.8% 之间，MIoU 为 61%。在未来随着将大量不同面孔率薄片的数据加入 TransUnet 深度学习网络模型中，粒度识别效果将会有显著提升，不同面孔率薄片的适用范围也会有很大的扩展。

最后，将深度学习用于颗粒、孔隙特征识别后的表征图进行图像拼接，生成更大视域的表征图像用于薄片粒度分析、孔隙分析，从而使分析结果更具有代表性、科学性。

## 参考文献 (References):

[1] 苏程, 朱孔阳. 岩石薄片图像智能分析研究进展[J]. 矿物岩石地球

化学通报, 2023, 42(1): 13-25.

Su C, Zhu K Y. Research progress of intelligent image analysis for petrographic thin section images[J]. Bulletin of Mineralogy, Petrology and Geochemistry, 2023, 42(1): 13-25.

[2] 陈宇豪. 简述薄片鉴定在岩石特征分析中的应用[J]. 新疆有色金属, 2022, 45(4): 23-24.

Chen Y H. The application of thin section identification in rock characteristic analysis[J]. Xinjiang Nonferrous Metals, 2022, 45(4): 23-24. (in Chinese)

[3] Tang D G, Milliken K L, Spikes K T. Machine learning for point counting and segmentation of arenite in thin section[J]. Marine and Petroleum Geology, 2020, 120: 104518.

[4] Das R, Mondal A, Chakraborty T, et al. Deep neural networks for automatic grain-matrix segmentation in plane and cross-polarized sandstone photomicrographs[J]. Applied Intelligence, 2022, 52(3): 2332-2345.

[5] 姜枫, 顾庆, 郝慧珍, 等. 基于语义特征提取的砂岩薄片图像颗粒分割方法[J]. 中国科学: 信息科学, 2020, 50(1): 109-127.

Jiang F, Gu Q, Hao H Z, et al. Grain segmentation of sandstone thin section images based on semantic feature extraction[J]. Scientia Sinica Informationis, 2020, 50(1): 109-127.

[6] 张利军, 鲁文豪, 张建东, 等. 基于深度学习的镜下岩石、矿物薄片识别[J]. 地学前缘, 2024, 31(3): 498-510.

Zhang L J, Lu W H, Zhang J D, et al. Rock and mineral thin section identification based on deep learning[J]. Earth Science Frontiers, 2024, 31(3): 498-510.

[7] Saxena N, Day-Stirrat R J, Hows A, et al. Application of deep learning for semantic segmentation of sandstone thin sections [J]. Computers & Geosciences, 2021, 152: 104778.

[8] 徐圣嘉, 苏程, 朱孔阳, 等. 基于深度学习的岩石薄片矿物自动识别方法[J]. 浙江大学学报(理学版), 2022, 49(6): 743-752.

Xu S J, Su C, Zhu K Y, et al. Automatic identification of mineral in petrographic thin sections based on images using a deep learning method[J]. Journal of Zhejiang University (Science Edition), 2022, 49(6): 743-752.

[9] Koh E J Y, Amini E, McLachlan G J, et al. Utilising convolutional neural networks to perform fast automated modal mineralogy analysis for thin-section optical microscopy[J]. Minerals Engineering, 2021, 173: 107230.

[10] 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 Z M, Tang X, Liang G D, 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.

[11] Liu H, Ren Y L, Li X, et al. Rock thin-section analysis and identification based on artificial intelligent technique [J]. Petroleum

- Science, 2022, 19(4): 1605–1621.
- [12] Zou C N, Zhu R K, Liu K Y, et al. Tight gas sandstone reservoirs in China: Characteristics and recognition criteria[J]. Journal of Petroleum Science and Engineering, 2012, 88–89: 82–91.
- [13] 林森虎, 邹才能, 袁选俊, 等. 美国致密油开发现状及启示[J]. 岩性油气藏, 2011, 23(4): 25–30, 64.
- Lin S H, Zou C N, Yuan X J, et al. Status quo of tight oil exploitation in the United States and its implication[J]. Lithologic Reservoirs, 2011, 23(4): 25–30, 64.
- [14] 贾承造, 邹才能, 李建忠, 等. 中国致密油评价标准、主要类型、基本特征及资源前景[J]. 石油学报, 2012, 33(3): 343–350.
- Jia C Z, Zou C N, Li J Z, et al. Assessment criteria, main types, basic features and resource prospects of the tight oil in China[J]. Acta Petroli Sinica, 2012, 33(3): 343–350.
- [15] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation [C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015: 234–241.
- [16] 王媛媛, 董芳, 尚丽娜, 等. 基于改进 TransUnet 网络的血管内超声图像边界提取方法研究[J]. 中国生物医学工程学报, 2023, 42(1): 41–50.
- Wang Y Y, Dong F, Shang L N, et al. Research on the IVUS border detection method based on improved TransUnet[J]. Chinese Journal of Biomedical Engineering, 2023, 42(1): 41–50.
- [17] Shorten C, Khoshgoftaar T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data, 2019, 6(1): 60.
- [18] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc. 2017: 6000–6010.
- [19] 王金祥, 付立军, 尹鹏滨, 等. 基于 CNN 与 Transformer 的医学图像分割[J]. 计算机系统应用, 2023, 32(4): 141–148.
- Wang J X, Fu L J, Yin P B, et al. Medical image segmentation based on CNN and transformer[J]. Computer Systems & Applications, 2023, 32(4): 141–148.
- [20] 于营, 王春平, 付强, 等. 语义分割评价指标和评价方法综述[J]. 计算机工程与应用, 2023, 59(6): 57–69.
- Yu Y, Wang C P, Fu Q, et al. Survey of evaluation metrics and methods for semantic segmentation [J]. Computer Engineering and Applications, 2023, 59(6): 57–69.
- [21] 王茂桢, 王冰洁, 郝轶伟, 等. 辽中凹陷南洼中深层储层孔隙度分布特征及影响因素分析[J]. 长江大学学报(自然科学版), 2023, 20(3): 23–32.
- Wang M Z, Wang B J, Hao Y W, et al. Analysis of porosity distribution characteristics and influencing factors of middle-deep reservoirs in the southern subsag of Liaozhong Sag[J]. Journal of Yangtze University (Natural Science Edition), 2023, 20(3): 23–32.
- [22] 刘毅, 林承焰, 林建力, 等. 东海盆地西湖凹陷深层低渗-致密砂岩孔隙结构特征及成因分析[J]. 天然气地球科学, 2024, 35(3): 405–422.
- Liu Y, Lin C Y, Lin J L, et al. Pore structure characteristics and genesis analysis of deep tight sandstone in Xihu Depression, East China Sea Basin[J]. Natural Gas Geoscience, 2024, 35(3): 405–422.
- [23] 龚建涛, 白艳军. 致密砂岩储层微观孔隙结构表征研究——以鄂尔多斯盆地东南部地区延长组为例[J]. 地质与资源, 2024, 33(5): 662–670. DOI: 10.13686/j.cnki.dzyzy.2024.05.006shu
- Gong J T, Bai Y J. Characterization of microscopic pore structure in tight sandstone reservoir: A case study of Yanchang Formation in southeastern Ordos Basin[J]. Geology and Resources, 2024, 33(5): 662–670. DOI: 10.13686/j.cnki.dzyzy.2024.05.006
- [24] 方梦阳, 何建宁, 王万虎, 等. 一种基于 MATLAB 的碎屑岩粒度分析方法[J]. 岩石矿物学杂志, 2020, 39(4): 504–510.
- Fang M Y, He J N, Wang W H, et al. A particle size analysis method for clastic rock based on MATLAB[J]. Acta Petrologica et Mineralogica, 2020, 39(4): 504–510.