

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.

FLU-net: 用于表征页岩储层微观孔隙的深度全卷积网络

陈雁^{1,2}, 李祉呈¹, 程超^{3*}, 焦世祥¹, 蒋裕强³, 宋敏¹, 王占磊³

(1 西南石油大学计算机科学与技术学院, 成都 610500; 2 西南石油大学人工智能研究院, 成都 610500;

3 西南石油大学地球科学与技术学院, 成都 610500)

摘要: 页岩孔隙是页岩气储集的主要空间, 孔隙的形状、大小、连通性与发育程度很大程度上决定了页岩储集层的储集性能, 因此, 页岩气开采首先需要对其孔隙有充分的认识。基于阈值分割法获取页岩孔隙结构参数是目前页岩微观结构表征的一种重要手段, 但是受扫描电镜图像灰度分布差异的影响, 该方法需要逐一修改图像的最佳分割阈值以达到最好的孔隙分割效果, 且阈值分割方法无法直接划分孔隙类别, 这给后续的页岩微观结构定量表征带来了麻烦。为了实现页岩孔隙的智能识别和分类, 笔者设计基于像素级语义分割的深度全卷积神经网络 FLU-net, 对页岩孔隙识别并分类为有机孔、无机孔(粒内孔、粒间孔)及裂缝, 并结合孔隙尺度分类统计方法, 分析不同类型孔隙发育数量、孔径大小、孔隙度等参数, 实现页岩储层微观孔隙结构的自动化定量表征。以重庆渝西区块足 201 井区和四川盆地威远地区威 204 井区的页岩扫描电镜图像为研究对象, 在对 1 600 幅页岩扫描电镜图像原始数据进行人工标注并划分数据集后, 使用 FLU-net 进行孔隙识别, 结果表明, 本方法具有较高的准确率, 同时自动化程度和泛化能力均高于传统预测方法。因此, 扫描电镜与基于深度学习的语义分割模型结合是定量研究页岩微观结构表征的有效手段。

关键词: 页岩孔隙; 页岩储层; 语义分割; 孔隙识别; 深度学习

中图分类号: P744.4; P628

文献标识码: A

DOI: 10.16028/j.1009-2722.2019.196

0 引言

美国海相页岩气藏的成功勘探开发, 展现了页岩气的巨大潜力和发展空间, 同时也极大地促进了页岩储层微观结构表征分析技术的发展, 而孔隙作为页岩储层中最重要的储集空间, 是页岩储层微观

结构的研究重点^[1-3]。目前, 在页岩储层微观孔隙研究中, 多使用以扫描电镜等微区分析为主的图像分析技术^[4-8], 该技术直观可见, 尤其在孔隙形态学方面具有优势, 结合统计学方法还能获取孔隙度、孔径分布等定量信息^[5-12]。因此, 基于扫描电镜图像的分析方法研究对定量分析页岩储层微观孔隙结构具有重大意义。

在页岩高分辨率扫描电镜图像的基础上, 前人常使用阈值分割的方式划分出图像孔隙^[5,7-8], 但该方法并不适用于具有大量页岩样本的数据集, 首先, 由于页岩的微观非均质性很强, 在扫描成像过程中往往需要根据样品自身特点调节亮度、对比度等参数以达到较好的成像效果, 这将会使得不同视域、不同样品的图像灰度分布特征发生变化^[13], 从而导致孔隙所处的灰度阈值区间产生差异^[14-15]; 其次, 页岩的孔隙结构复杂多样、孔隙类别划分规则复杂^[16-17], 导致即使选取了合适的灰度阈值区间来分

收稿日期: 2019-10-21

资助项目: 四川省科技厅重点研发项目“深层页岩智能孔隙分析及孔隙网络建模技术研究”(20ZDYF1215); 油气藏地质及开发工程国家重点实验室开放研究课题“页岩气孔隙网络建模技术”(PLN201931); 四川省科技厅科技计划项目省级重点项目“海相页岩气建产核心区智能评价系统研究”(19YYJC1055); 四川省科技厅苗子工程项目“基于全景分割的岩石薄片图像智能鉴定的研究”(2021007)

作者简介: 陈雁(1982—), 女, 博士, 副教授, 主要从事人工智能和复杂网络方面的研究工作. E-mail: carly.chenyan@gmail.com

* 通讯作者: 程超(1979—), 男, 博士, 副教授, 主要从事储层评价、油气藏精细描述方面的研究工作. E-mail: 105964461@qq.com

割扫描电镜图像, 仍然需要花费大量时间人工标注孔隙类别。鉴于页岩扫描电镜的以上特点, 目前使用阈值分割方法研究页岩微观孔隙结构时, 主要依靠人为主观判断来确定阈值区间和孔隙类别。

深度学习是近年发展起来的具有多层次特征抽象归纳与知识发现能力的机器学习算法, 目前已经被广泛应用到了语音识别、计算机视觉、自然语言处理等众多领域^[18-20]。在地质和岩石物理领域也有了初步的应用, 如张东晓等^[21]为补充缺失的测井信息, 根据已有的部分测井曲线使用循环神经网络和 LSTM 进行补全, 生成人工测井曲线; 林年添等^[22]在小样本条件下, 利用有限的已知含油气井段信息构建卷积核, 以地震数据为驱动, 借助卷积神经网络提取、识别蕴藏其中的地震油气特征; 占文枢等^[23]为实现页岩图像超分辨率重建, 以深度卷积神经网络为基础, 利用像素域进行上采样, 梯度信息作为正则项进行约束, 得到了重建后的高分辨率页岩图像。上述研究均体现出了深度学习方法在地质数据的特征提取及预测识别方面有着广阔的应用前景, 但是目前在页岩储层微观结构表征研究中, 尤其是在使用扫描电镜等微区分析方法定量表征微观孔隙结构的方向上, 人工智能的方法尚未取得突出进展。

为解决在页岩储层微观孔隙研究中阈值分割方法的不足, 实现页岩孔隙的自动化智能识别, 本文设计了采用深度全卷积神经网络的 FLU-net, 基于页岩图像识别问题的特殊性, 在 U-net 网络^[24]的基础上加深网络层数并引入 Dropout(随机失活)处理和 Focal Loss 损失函数, 使得模型可以应对高分

辨率图像下稀疏分布的微观孔隙识别场景。本文以四川盆地渝西区块足 201 井区和威远地区威 204 井区的页岩扫描电镜图像为例^[25-27], 使用 FLU-net 针对页岩扫描电镜图像中的 4 类孔隙(有机质孔隙、晶(粒)间孔、晶(粒)内孔和微裂缝)进行训练和预测, 并对预测出的图像应用孔隙尺度分类统计方法, 统计不同类型孔隙发育数量、孔径大小、孔隙度等参数, 实现了页岩储层微观孔隙的自动化定量表征, 最大程度降低了人为因素对图像孔隙参数观测统计结果的影响。

1 研究区概况和数据源

本文页岩样品采自威远地区威 204 井及渝西地区足 201 井, 首先使用氩离子抛光仪进行抛光, 再经过扫描电镜观察, 得到共 680 张高精度扫描电镜图像, 扫描电镜分辨率多为 1、3 和 5 nm, 存在少量分辨率为 500 nm 的扫描电镜图像。分别统计威 204 井和足 201 井的扫描电镜图像孔隙度(表 1), 各类别孔隙占比之和均 $\leq 7\%$, 基质占比 $> 90\%$ 且不同类别孔隙的孔隙度略有差异。为了在保证图像显示精度, 同时最大程度降低对计算机显存的需求, 扫描电镜图像经过缩放切割后尺寸统一为 512 pixel $\times$ 512 pixel 大小, 使用切割和添加噪声点的方式扩充样本数据量: 将 512 pixel $\times$ 512 pixel 大小的图像切割为 4 张 256 pixel $\times$ 256 pixel 大小的图像, 并根据图片的像素点数量在图片的随机位置处加入 0.2% 总图像像素点总数的白色像素点。最终经人工筛选后形成共计 1 600 张图片的图像样本数据集。

表 1 威 204 井和足 201 井图像样本中各类别孔隙的孔隙度
Table 1 Porosity of all kinds of pores in image samples from Well Wei-204 and Well Zu-201


所属井	样本编号	有机质孔	晶(粒)间孔	晶(粒)内孔	微裂缝
威204	1号	0.05%	1.86%	1.56%	8.87%
威204	2号	0.71%	0.51%	1.65%	1.77%
威204	3号	5.90%	1.88%	0.29%	0.00%
...	...	...	...	...	...
威204	平均值	3.45%	1.92%	0.88%	0.63%
足201	1号	0.42%	0.11%	0.07%	0.00%
足201	2号	0.45%	0.00%	0.06%	4.92%
足201	3号	0.72%	0.13%	0.07%	0.22%
...	...	...	...	...	...
足201	平均值	1.02%	0.51%	0.33%	0.44%

为了能够在后续工作中验证本文方法的有效性, 在收集完数据之后, 针对图像样本数据集, 首先

以阈值分割方法提取孔隙, 之后以人工标注的方式, 用不同颜色标注孔隙类型, 将微裂缝、晶(粒)间孔、

晶(粒)内孔、有机质孔隙分别标记为蓝色、黄色、红色和绿色, 共计 4 类孔隙, 并以此数据作为真实

标签。图 1 为图像样本数据集中部分原始图像与其对应的人工标注图像。



蓝色为微裂缝; 红色为粒内孔; 绿色为有机孔; 黄色为粒间孔

图 1 页岩扫描电镜图像数据集中部分图像(上)及其对应的人工标注图像(下)

Fig.1 Some shale SEM image data (up) and their corresponding manually-annotated images (down)

2 研究方法

本文使用基于深度学习的语义分割方法^[28-29]处理页岩孔隙识别和分类问题, 其中语义分割指对图像中的每个像素点进行类别标注, 最终将图像分割成若干个具有特定语义类别的区域。基于深度学习的语义分割方法进行页岩孔隙结构表征是一种端到端的方式, 可以同时做到分割孔隙和标注孔隙类别。因此与传统的阈值分割方法相比, 基于深度学习的语义分割方法抛弃了人工选取灰度阈值和人工识别孔隙的步骤, 极大降低了人为主观判断对结果的影响。

2.1 现有的语义分割方法

语义分割(应用于静态 2D 图像、视频甚至 3D 数据、体数据)是计算机视觉的关键问题之一, 而随着深度学习的广泛应用, 包括语义分割在内的许多计算机视觉问题都开始使用深度架构来解决^[28-29]。目前用于语义分割的深度学习方法绝大多数是基于卷积神经网络 CNN^[30], 如全卷积网络 FCN^[31], 其将卷积神经网络的全连接层替换为卷积层, 通过反卷积方法增大特征图的尺寸, 逐个像素地求其最大预测概率, 作为该像素的类别, 实现端到端的图像语义分割处理。用于语义分割的深度学习神经网络结构, 如图 2 所示^[32]。

U-net 是一种基于 FCN 改进的端到端图像语

义分割网络^[24], 其包含特征提取的收缩路径和用于扩大特征图尺寸的扩张路径 2 个对称部分(即编码器-解码器结构), 输入图像先通过卷积-池化操作对图像进行特征提取, 然后在扩张路径中使用 2×2 的反卷积放大特征图尺寸至原始图像大小, 最后预测每个像素的类别, 以实现输入图像的语义分割。为了使预测结果可以更多的考虑到多尺度特征, U-net 使用了一种跳跃连接结构, 将收缩路径中获取的图像高分辨率特征作为相应的扩张路径中的部分输入, 使得浅层特征和深层特征都能得以保留, 同时减少了原图像在下采样过程中的信息损失, 使网络获得更高的分割准确率。

在使用 U-net 模型对威 204 井图像数据进行训练之后, 验证集图像的预测结果如图 3 所示, 可以看到在预测结果中, 存在单一孔隙被识别为多种类别的情况。我们认为出现这种情况的原因是, 在页岩中不同类型孔隙在形态上多有相似之处, 如粒间孔、粒内孔、微裂缝都可以发育成狭长形孔隙, 此时必须观察孔隙在基质中的分布位置以及周围孔隙的类型才能确定其类型。因此, 当模型提取页岩孔隙特征的能力不足时, 一些孔隙的预测结果便会出现上述情况。

2.2 FLU-net

针对 U-net 模型在页岩扫描电镜孔隙识别问题上的不足和页岩孔隙分布的实际特点, 本文提出了一种基于 U-net 结构的改进模型 FLU-net, 相对于





图 2 用于语义分割的深度学习网络结构

Fig.2 DL network structure for semantic segmentation



(a) 输入图像的真实标签

(b) U-net 预测图像

图 3 由 U-net 模型预测的扫描电镜图像

Fig.3 SEM images predicted by U-net model

U-net 网络进行了 3 点具有针对性的改进: ①在 U-net 的基础上加深了网络层数, 使网络层数从 5 层增加至 6 层; ②引入了 Dropout 解决深层网络的过拟合问题; ③使用多分类 Focal Loss 损失函数以处理样本分布极度不平衡的数据。FLU-net 网络结构如图 4 所示。

标准 U-net 网络包含 4 次池化、4 次上采样以

及 19 次卷积操作。相对于 U-net 来说, FLU-net 有更多的网络层数, 包含 5 次池化、5 次上采样和 23 次卷积操作, 而更多的卷积操作可以使模型获得更强的特征提取能力, 但加深网络层数会带来更多的隐含层参数, 导致过拟合风险加大, 使模型泛化能力变差。为消除模型训练过程中的过拟合问题, FLU-net 在池化层后加入了 Dropout^[33] 处理。




图 4 FLU-net 网络结构

Fig.4 The network structure of FLU-net

2.3 Dropout

随机失活(Dropout)^[33]是为了解决深度神经网络的过拟合和梯度消失问题而被提出的优化方法。在神经网络的学习过程中,以概率 p 随机将部分隐含层节点的权重归零,其他隐含层节点的权重以概率 $q = 1 - p$ 被保留,在训练过程中对于输入特征向量 $X = (x_1, x_2, \dots, x_n)$,Dropout处理的激活函数表达式由如下:

$$f(h) = D \cdot a(h) \quad (1)$$

式中: $a(h)$ 为原始激活函数;

$D = (x_1, x_2, \dots, x_d)$ 是一个由伯努利随机变量组成的向量。

如果将Dropout应用在第 i 个神经元上,则第 i 个神经元的表达式可以表示为如下公式:

$$O_i = X_i a \left(\sum_{k=1}^{d_i} w_k x_k + b \right) = \begin{cases} a \left(\sum_{k=1}^{d_i} w_k x_k + b \right), & X_i = 1 \\ 0, & X_i = 0 \end{cases} \quad (2)$$

式中: $w_k x_k + b$ 为激活函数的输入, w 和 b 分别表示输入权重和偏移常数。

由于在训练阶段引入Dropout会使得隐含层节点以 q 概率被保存(3),因此在测试阶段必须模拟出在训练阶段时的网络行为(公式4):

$$\text{train_}O_i = X_i a \left(\sum_{k=1}^{d_i} w_k x_k + b \right) \quad (3)$$

$$\text{test_}O_i = q a \left(\sum_{k=1}^{d_i} w_k x_k + b \right) \quad (4)$$

式中: $\text{train_}O_i$ 和 $\text{test_}O_i$ 分别表示训练和测试阶段的Dropout计算公式;

k 表示该层神经元的数目。

通常将Dropout应用在卷积神经网络中获得的效果没有在全连接神经网络获得的效果明显。但是由于我们能够得到的SEM图像样本很少,需要提高模型的泛化能力。因此,FLU-net加入了Dropout,而本文后面的实验证明了这样做是有效的。

2.4 多分类焦点损失函数

由于富有机质页岩具有较强的非均质性,因此不同区域的孔隙分布存在较大差异,具体表现为单张扫描电镜图像中孔隙占比小且分布稀疏,这种基质与孔隙分布严重不均的现象会影响孔隙识别效果。

交叉熵函数不关注样本分布是否均匀,它仅关注各类别样本是否被分类正确。当类别极度不平衡时,交叉熵函数倾向于将难以区分的像素划分为在所有类别中数量占比最大的类别,以保证自身的最小化,这必然会影响模型的预测效果。为解决样本比例严重失衡的问题,本文改进的模型使用Focal Loss^[34]函数作为损失函数。Focal Loss函数是基于二分类交叉熵函数改进而来,二分类任务的Focal Loss公式如下:

$$FL(p_t) = -(1 - p_t)^\gamma \log(p_t)$$

$$p_t = \begin{cases} p, y = 1 \\ 1 - p, otherwise \end{cases} \quad (5)$$

式中: γ 反应了权值系数的影响程度, 当 $\gamma=0$ 时, Focal Loss 为交叉熵函数。

y 表示像素点是否被预测正确, 当预测正确时, $y=1$, 否则为 0。

在添加 $(1 - p_t)^\gamma$ 后, 难以区分的样本的损失函数权重会增加, 从而加强网络对困难样本的关注度, 而针对深层页岩微观孔隙识别问题的“四孔隙”微观类型, 本文将 Focal Loss 改进为可以预测多类别的 Focal Loss, 其公式如下:

$$FL(p_t) = -(1 - p_t)^\gamma \log(p_t)$$

$$p_t = y_{\text{pred}} * y_{\text{label}} \quad (6)$$

在实际操作中, y_{label} 是经过 one-hot^[35] 处理的标签, y_{pred} 是经过激活函数的输出, 在分类错误的情况下有可能发生 $p_t = 0$, 所以需要使 p_t 非零以保证 $\log(p_t)$ 不会错误。常见的方法是令 $p_t = p_t + c$, c 为一个足够小的非零数。

3 实验与讨论

本文实验中涉及的所有网络模型的超参数统一设置如下: 训练集和验证集的划分比例为 4:1;


训练批次大小设为 12; 初始学习率设为 0.001; 学习率下降因子设为 0.001; 容忍轮次设为 10; 学习率下限设为 0.00001; 最大迭代次数为 100 次。实验过程首先将训练数据输入至设计好的 U-net 网络和 FLU-net 网络中训练网络模型, 再使用训练好的模型对新输入的扫描电镜图像进行孔隙识别, 最终将预测结果和真实结果作比较以评价 2 种方法的性能。

3.1 孔隙识别

图 5 展示了使用 U-net 和 FLU-net 对页岩扫描电镜孔隙的识别结果。可以看出, 基于 2 种方法识别出的孔隙形态基本与人工标注图像相符合。同时, 观察图 5c 至图 5f, 与 U-net 的预测结果相比, 在 FLU-net 的预测结果中单一孔隙被识别为多种类别的情况相对减少。从识别结果上看, FLU-net 更适合处理孔隙。而为了进一步证明 FLU-net 在孔隙识别问题上的优越性, 本文分别从识别准确度和孔隙度 2 个角度分析。

3.1.1 识别准确度分析

考虑到可以用于衡量识别准确度的指标众多, 我们只采用 2 种具有代表性的: 正确率 (accuracy) 和语义分割任务中常用的指标 mIoU^[36] (mean Inter-



(a、b) 人工标注图片; (c、d) U-net 预测图像; (e、f) FLU-net 预测图像

图 5 深层页岩扫描电镜孔隙识别结果

Fig.5 Recognition results of deep shale SEM images

section over Union)对模型的孔隙识别结果进行量化评价。mIoU 指所有类别的平均交叠率,多用于图像识别任务中,其计算公式如下:

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (7)$$

式中: p_{ji} 表示被分为 j 类的第 i 类像素的个数;

k 表示总类别个数。

分别把 FLU-net 的 3 个改进部分和 U-net 结合,形成新的网络,再使用 U-net、FLU-net 和新网络在本文数据集上进行孔隙识别,最后对比它们的结果。图 6 展示了这 5 种网络在验证集上的 mIoU 变化曲线,由图可以看出,FLU-net 需要更多的迭代轮次以达到网络收敛,但收敛时的 mIoU 优于其他方法。表 2 展示了消融实验的 ACC 值和 mIoU 值。观察实验结果可知:① FLU-net 在 mIoU 指标上均要优于 U-net;② U-net+Dropout 网络和 6 层 U-net 网络的 mIoU 低于标准 U-net,而 U-net+FocalLoss 网络的 mIoU 高于 U-net,但低于 FLU-net。实验结果证明,本文改进方法可以在一定程度上优化孔隙识别的效果,但是使用时应考虑数据集的实际情况,单纯增加网络的复杂度并不一定能够对结果带来提升。




图 6 随迭代轮次变化的验证集 mIoU 曲线, 其中 deeper U-net 指具有 6 层网络的 U-net 模型

Fig.6 mIoU curves of validation set changing with the iteration rounds (deeper U-net is a 6-layer U-net model)

表 2 5 种网络的验证集评价指标

Table 2 The ACC and mIoU indexes of the five networks on the validation set

模型	ACC	mIoU
U-net	0.9855	0.4381
deeperU-net	0.9854	0.4284
U-net+Dropout	0.9850	0.4264
U-net+Focal Loss	0.9864	0.4588
FLU-net	0.9853	0.4726

3.1.2 孔隙度分析

由于正确率和 mIoU 都是基于图像的像素分类结果的分析指标,更注重图像微观识别的正确性,尤其是 mIoU,如果孔隙区域识别有少量偏移,其结果都会产生较大偏差。考虑到孔隙度的获取是孔隙识别的主要目的之一,而孔隙度在计算时更注重孔隙的面积占比,因此进一步对本文方法所得出的各类孔隙度与真实孔隙度作对比,以验证本文方法获取的孔隙度的正确性。

为了定量衡量语义分割方法预测的孔隙度同人工标注的孔隙度之间的差异,本文引入均方根误差(root mean square error, RMSE)^[37] 评价 U-net 和 FLU-net 的预测孔隙度同真实孔隙度之间的偏差,其计算公式如下:

$$RMSE(X, h) = \sqrt{\frac{1}{m} \sum_{i=1}^m (h(x^{(i)}) - y^{(i)})^2} \quad (8)$$

式中: $h(x^{(i)})$ 和 $y^{(i)}$ 分别表示第 i 个样本孔隙度的预测值和真实值。

表 3 展示所有测试样本的 4 类孔隙度预测值同真实孔隙度的均方根误差,可以看到,FLU-net 模型在 4 类孔隙的孔隙度均方根误差指标上均优于 U-net 模型,进一步证明了 FLU-net 在页岩微观孔隙识别问题上的优越性。

表 3 U-net 和 FLU-net 的 4 种微观孔隙度预测结果与真实孔隙度的均方根误差 (RMSE)

Table 3 The RMSE of the predicted porosity by U-net and FLU-net and the real porosity of the four kinds of pores

	微裂缝	晶(粒)间孔	晶(粒)内孔	有机质孔	总孔隙
U-net	0.005099	0.008179	0.00500	0.006296	0.008250
FLU-net	0.004260	0.004707	0.003918	0.005116	0.006283

3.2 孔隙定量表征

实验采用语义分割方法对 $\times 30\,000$ 至 $\times 100\,000$ 多种放大倍率下的 55 个扫描电镜图像进行孔隙识别,并结合统计学方法定量表征孔隙特征,然后比较语义分割图像与人工标签图像的定量信息,研究基于深度学习的语义分割方法对孔隙进行定量表征的准确度。

在进行定量表征时,选取当量圆直径来表征孔隙大小,狭长不规则孔隙的当量圆直径(D)可表示为:

$$D = \frac{4A}{L} = \frac{2ab}{a+b} \quad (9)$$

式中: a 、 b 分别为孔隙的长度和宽度。

选取形状系数^[5-7,38](公式 10)表征不同孔隙的形态分布特征:

$$F = 4 \times \pi \times S / C^2 \quad (10)$$

式中: S 为孔隙面积, C 为孔隙周长; S 、 C 分别是通过计算孔隙区域内的像素个数和孔隙区域边缘的像素个数来获得。

此外, 还引入了分形维数作为复杂形体不规则性的度量, 用于描述某个形状的本质特征, 其公式如下:

$$\log(C) = \frac{D_f}{2} \times \log(S) \quad (11)$$

式中: S 为孔隙面积;

C 为孔隙周长;

D_f 为分形维数。

通过统计不同类型孔隙发育比例(图 7)可知, 有机孔、晶(粒)间孔、晶(粒)内孔和微裂缝采用 FLU-net 模型的识别结果与人工标签统计结果分别相差 0.44%、1.08%、10.24% 和 10.89%。有机孔、晶(粒)间孔、晶(粒)内孔和微裂缝采用 U-net 模型的识别结果与人工标签统计结果分别相差 3.39%、17.01%、23.42% 和 9.8%。采用 U-net 模型与人工标签的孔隙发育比例相差较大, 发育比例相差在 3%~23%, 而采用 FLU-net 模型与人工标签的孔隙发育比例相差较小, 差别均在 11% 以内, 尤其是有机孔比例和晶(粒)间孔比例, 仅相差 0.44% 和 1.08%。




图 7 不同语义分割模型预测出的各类型孔隙发育比例

Fig. 7 The development degrees of four kinds of pores by different semantic segmentation models

通过统计孔径长度、孔隙面积、形状系数和分形维数等数据(表 4), 可以直观清晰的比较 U-net 和 FLU-net 模型的孔隙识别效果。与 U-net 模型的统计效果相比, FLU-net 模型的统计效果在孔径长度、孔隙面积和分形维数等方面更接近于人工标签的统计数据。在最大孔径长度、平均孔径长度、最大孔隙面积、平均孔隙面积、平均形状系数和分型

维数参数中, FLU-net 模型预测结果和人工标签结果相差无几。由于基于深度学习的语义分割模型采用下采样—上采样的网络结构, 因此, 图像中过于微小的孔隙会在不断的池化操作中完全被丢弃, 导致在孔隙总面积参数中, 无论是 FLU-net 模型还是 U-net 模型, 其统计结果都远小于人工标签统计结果。

表 4 通过不同语义分割模型定量表征的孔隙特征

Table 4 The quantitatively characterized porosity characters by different semantic segmentation models

	人工标签	U-net	FLU-net
最大孔径长度	3 728.82 nm	2 614.7 nm	3 728.82 nm
平均孔径长度	112.679 6 nm	101.551 nm	110.056 4 nm
孔隙总面积	189 540 μm^2	50 999 μm^2	109 802 μm^2
最大孔隙面积	3 195 μm^2	3 195 μm^2	3 195 μm^2
平均孔隙面积	20.714 8 μm^2	18.226 9 μm^2	19.660 2 μm^2
平均形状系数	0.509 731	0.518 09	0.522 732
周长面积法分形维数	5.204 74	5.577 75	5.335 28

4 总结

通过使用基于深度学习的语义分割方法,实现了页岩储层微观孔隙结构的自动化定量表征,并对孔隙识别结果和孔隙特征统计结果进行了评价,结论如下:

(1)利用基于深度学习的语义分割方法识别页岩孔隙,能够同时做到分割孔隙和标注孔隙类别,在自动化和泛化能力上均优于传统阈值分割方法,且语义分割方法抛弃了人工选取灰度阈值和人工识别孔隙的步骤,降低了人为主观判断对结果的影响,因此扫描电镜与基于深度学习的语义分割模型结合是定量研究页岩微观结构表征的有效手段。

(2)在高分辨率图像下稀疏分布的微观孔隙识别场景下设计的 FLU-net 网络具有良好的孔隙识别能力,在构造的样本数据集中,FLU-net 预测的孔隙分布与人工标签的孔隙分布某种程度上表现出一致性,且 FLU-net 预测的多项统计参数与人工标签参数无差别或差别很小。

参考文献:

- [1] ADNAN A, REZA R, LIONEL E, et al. Comparisons of pore size distribution: a case from the Western Australian gas shale formations[J]. *Journal of Unconventional Oil and Gas Resources*, 2014, 8(12): 1-13.
- [2] 赵日新, 卢双舫, 薛海涛, 等. 扫描电镜分析参数对定量评价页岩微观孔隙的影响[J]. *石油与天然气地质*, 2019, 40(5): 1141-1154.
- [3] 张林晔, 李钜源, 李政, 等. 北美页岩油气研究进展及对中国陆相页岩油气勘探的思考[J]. *地球科学进展*, 2014, 29(6): 700-711.
- [4] 李俊乾, 卢双舫, 张婕, 等. 页岩油吸附与游离定量评价模型及微观赋存机制[J]. *石油与天然气地质*, 2019, 40(3): 583-592.
- [5] 孙寅森, 郭少斌. 基于图像分析技术的页岩微观孔隙特征定性及定量表征[J]. *地球科学进展*, 2016, 31(7): 751-763.
- [6] 王羽, 金婵, 汪丽华, 等. 应用氩离子抛光-扫描电镜方法研究四川九老洞组页岩微观孔隙特征[J]. *岩矿测试*, 2015(3): 278-285.
- [7] 白名岗, 夏响华, 张聪, 等. 场发射扫描电镜及PerGeos系统在安页1井龙马溪组页岩有机质孔隙研究中的联合应用[J]. *岩矿测试*, 2018, 37(3): 225-234.
- [8] 武瑾, 梁峰, 吝文, 等. 渝东北地区龙马溪组页岩储层微观孔隙结构特征[J]. *成都理工大学学报(自然科学版)*, 2016, 43(3): 308-319.
- [9] 王欣, 齐梅, 李武广, 等. 基于分形理论的页岩储层微观孔隙结构评价[J]. *天然气地球科学*, 2015, 26(4): 754-759.
- [10] 焦淑静, 张慧, 薛东川, 等. 泥页岩有机显微组分的扫描电镜形貌特征及识别方法[J]. *电子显微学报*, 2018, 37(2): 137-144.
- [11] 姜振学, 唐相路, 李卓, 等. 川东南地区龙马溪组页岩孔隙结构全孔径表征及其对含气性的控制[J]. *地学前缘*, 2016, 23(2): 126-134.
- [12] YU L, ZHU Y M. Comparison of pore characteristics in the coal and shale reservoirs of Taiyuan Formation, Qinshui Basin, China[J]. *International Journal of Coal Science & Technology*, 2016, 3(3): 1-9.
- [13] 傅志强, 贺翠翠, 刘锡贝, 等. 扫描电镜测量纳米尺度的影响因素[J]. *电子显微学报*, 2012, 31(3): 226-229.
- [14] 吴一全, 孟天亮, 吴诗嫒. 图像阈值分割方法研究进展20年(1994—2014)[J]. *数据采集与处理*, 2015, 30(1): 1-23.
- [15] 俞雨溪, 王宗秀, 程明, 等. 页岩微观结构灰度图像的标准化方法[J]. *煤炭学报*, 2019, 44(7): 2178-2187.
- [16] 于炳松. 页岩气储层孔隙分类与表征[J]. *地学前缘*, 2013, 20(4): 211-220.
- [17] 杨峰, 宁正福, 胡昌蓬, 等. 页岩储层微观孔隙结构特征[J]. *石油学报*, 2013, 34(2): 301-311.
- [18] DENG L, YU D. Deep learning: methods and applications[J]. *Foundations and Trends in Signal Processing*, 2013, 7(3/4): 197-387.
- [19] 刘建伟, 刘媛, 罗雄麟. 深度学习研究进展[J]. *计算机应用研究*, 2014, 31(7): 1921-1930.
- [20] XING H, ZHANG G, SHANG M. Deep learning[J]. *International Journal of Semantic Computing*, 2016, 10(3): 417-439.
- [21] 林年添, 张栋, 张凯, 等. 地震油气储层的小样本卷积神经网络学习与预测[J]. *地球物理学报*, 2018, 61(10): 4110-4125.
- [22] 张东晓, 陈云天, 孟晋. 基于循环神经网络的测井曲线生成方法[J]. *石油勘探与开发*, 2018, 45(4): 598-607.
- [23] 占文枢, 伦增琨, 陈洪刚, 等. 基于像素及梯度域双层深度卷积神经网络的页岩图像超分辨率重建[J]. *科学技术与工程*, 2018, 18(3): 85-91.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[J]. *Springer, Cham*, 2015, 234-241.
- [25] 赵子元. 威204井区页岩气井早期产能评价[D]. 重庆: 重庆科技学院, 2018.
- [26] 梁峰. 中上扬子地区五峰组—龙马溪组页岩气富集模式及有利区优选评价[D]. 徐州: 中国矿业大学, 2018.
- [27] 马新华, 谢军. 川南地区页岩气勘探开发进展及发展前景[J]. *石油勘探与开发*, 2018, 45(1): 161-169.
- [28] 姜枫, 顾庆, 郝慧珍, 等. 基于内容的图像分割方法综述[J]. *软件学报*, 2017, 28(1): 160-183.
- [29] 魏云超, 赵耀. 基于DCNN的图像语义分割综述[J]. *北京交通大学学报*, 2016, 40(4): 82-91.
- [30] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//*International Conference on Neural Information Processing Systems*. 2012, 25: 1097-1105.
- [31] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2014, 39(4): 640-651.

- [32] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, 2016: 770-778.
- [33] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [34] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal Loss for Dense Object Detection[C]//Proceedings of the IEEE international conference on computer vision, Honolulu. 2017: 2980-2988.
- [35] CHOU W C, BEEREI P A, GINOSAR R, et al. Average-case optimized technology mapping of one-hot domino circuits[C]//Proceedings Fourth International Symposium on Advanced Research in Asynchronous Circuits and Systems, IEEE. San Diego, 1998: 80-91, doi: 10.1109/ASYNC.1998.666496.
- [36] GARCIA-GARCIA A, ORTOS-ESCOLANO S, OPREA S, et al. A review on deep learning techniques applied to semantic segmentation[J]. arXiv preprint: 1704.06857, 2017: 1-22.
- [37] CHAI T, DRAXLER R. Root mean square error (RMSE) or mean absolute error (MAE)? arguments against avoiding RMSE in the literature[J]. Geoscientific Model Development, 2014, 7(3): 1247-1250.
- [38] 焦堃, 姚素平, 吴浩, 等. 页岩气储层孔隙系统表征方法研究进展[J]. 高校地质学报, 2014, 20(1): 151-161.

FLU-NET: A DEEP FULLY CONVOLUTIONAL NEURAL NETWORK FOR SHALE RESERVOIR MICRO-PORE CHARACTERIZATION

CHEN Yan^{1,2}, LI Zhicheng¹, CHENG Chao^{3*}, JIAO Shixiang¹, JIANG Yuqiang³, SONG Min¹, WANG Zhanlei³

(1 School of Computer Science, Southwest Petroleum University, Chengdu 610500, China; 2 Artificial Intelligence Institute of Southwest Petroleum University, Chengdu 610500, China; 3 School of Geoscience and Technology, Southwest Petroleum University, Chengdu 610500, China)

Abstract: Shale pores are the main space of shale gas reservoir. The shape, size, connectivity and development degree of pores may determine the performance of reservoir to a great extent. A full understanding of shale pores is critical before exploitation. At present, obtaining structure parameters of shale pores based on threshold segmentation method plays an important role in shale microstructure characterization. However, due to the difference in gray distribution of SEM images, this method requires modification of the best segmentation threshold individually to achieve the best pore segmentation effect, and the threshold segmentation method cannot classify the pore directly. It may cause trouble to the subsequent quantitative characterization of shale microstructure. In order to realize the intelligent recognition and classification of shale pores, a Deep Convolution Neural Network FLU-net based on pixel-level semantic segmentation is designed in this paper. The pores of shale are identified and classified into organic pores, inorganic pores (intragranular pores and intergranular pores) and fractures. Combined with the statistical method of pore scale classification, the number of pores, pore size, porosity and other parameters for different types of pores are analyzed, and thus automatic quantitative characterization of micro pore structure of shale reservoir is realized. This paper takes the Scanning Electron Microscope (SEM) images of shale from the Zu-201 well area, Yuxi block in Chongqing and the Wei-204 well area, Weiyuan area in Sichuan Basin as the research objects. After manually labeling and dividing the original dataset of 1 600 SEM images of shale, FLU-net is used for pore recognition. The results show that this method not only keeps high accuracy, but also has higher automation and generalization ability than traditional prediction methods. Therefore, the combination of SEM and semantic segmentation model based on Deep Learning is an effective mean for quantitative study of shale microstructure characterization.

Key words: shale pores; shale reservoir; semantic segmentation; pore identification; deep learning