

基于深度学习的微观剩余油赋存形态分类识别综述^①



赵 娅, 管 玉, 贾 迪

(东北石油大学 计算机与信息技术学院, 大庆 163318)

通信作者: 赵 娅, E-mail: 261980020273@mail.nepu.edu.cn

摘 要: 微观剩余油赋存形态分类识别研究在剩余油开采领域发挥着至关重要的作用, 其对油田提高采收率具有重要的意义. 近年来, 该领域的大量研究通过引入深度学习方法来推动微观剩余油识别技术的发展, 但深度学习技术在微观剩余油识别领域尚未形成一个较为统一的框架, 也没有一个规范化的操作流程. 为了给今后的研究人员提供指导, 对目前的剩余油识别方法进行梳理, 从图像采集及类别划分标准、图像处理、剩余油识别方法等方面介绍了基于机器视觉的微观剩余油识别技术. 将剩余油识别方法分为基于传统和基于深度学习的识别方法, 传统识别方法分为基于人工特征提取和基于机器学习分类, 基于深度学习的识别方法划分为单阶段和两阶段方法, 并对其中数据增强、预训练、图像分割和图像分类方面进行详细归纳. 最后, 讨论了将深度学习应用于微观剩余油识别领域面临的挑战, 并对未来的发展趋势进行了展望.

关键词: 微观剩余油; 分类识别; 机器视觉; 图像分割; 图像分类

引用格式: 赵娅,管玉,贾迪.基于深度学习的微观剩余油赋存形态分类识别综述.计算机系统应用,2025,34(1):26-36. <http://www.c-s-a.org.cn/1003-3254/9733.html>

Survey on Classification and Identification of Microscopic Remaining Oil Occurrence Forms Based on Deep Learning

ZHAO Ya, GUAN Yu, JIA Di

(School of Computer & Information Technology, Northeast Petroleum University, Daqing 163318, china)

Abstract: The research on the classification and identification of microscopic residual oil occurrence states plays a vital role in residual oil exploitation and is of great significance for improving oil field recovery. In recent years, a large number of studies in this field have promoted the development of technologies for identifying microscopic residual oil by introducing deep learning. However, deep learning has not yet established a unified framework for microscopic residual oil identification, nor has it formed a standardized operation process. To guide future research, this study reviews existing methods for identifying residual oil and introduces the identification technologies for microscopic residual oil based on machine vision from several aspects, including image acquisition and classification standards, image processing, and residual oil identification methods. Residual oil identification methods are categorized into traditional and deep learning-based methods. The traditional methods are further divided into those based on manual feature extraction and those based on machine learning classification. The deep learning-based methods are divided into single-stage and two-stage methods. Detailed summaries are provided for data enhancement, pre-training, image segmentation, and image classification. Finally, this study discusses the challenges of applying deep learning to microscopic residual oil identification and

^① 基金项目: 国家自然科学基金 (61702093); 黑龙江省自然科学基金 (LH2022F006)

收稿时间: 2024-06-09; 修改时间: 2024-07-03; 采用时间: 2024-07-18; csa 在线出版时间: 2024-11-25

CNKI 网络首发时间: 2024-11-26

explores future development trends.

Key words: microscopic residual oil; classification identification; machine vision; image segmentation; image classification

随着中国多数中、高渗油藏进入高含水、高采出程度的“双高”开发阶段^[1], 70%以上的原油产量是在双高期采出的, 面临着产量递减、效益降低等现实问题. 油田复杂的地质情况和地层中更加复杂的流体分布成为制约油气采收率的主要因素^[2]. 因此, 掌握油层孔隙中剩余油的赋存形态对油田增加可采储量、提高采收率以及科学高效挖潜剩余油具有重要意义^[3].

传统人工方法识别剩余油赋存形态, 需要多位专家鉴定剩余油的具体特征, 经过多次商讨来判别剩余油类型, 这种方法不仅费时费力, 而且误差较大. 随着计算机图像识别技术的不断发展, 微观剩余油智能识别技术进入了研究人员的日常工作中, 运用机器视觉技术识别微观剩余油赋存形态已经广泛应用. 早在2011年, 孙先达^[4]就通过自主研发的剩余油分析软件完成剩余油赋存状态信息的提取, 通过观察分割后的荧光图像对剩余油赋存形态进行人工判别; 2022年, 成璐璐^[5]使用机器学习方法设计了一套微观剩余油赋存形态智能识别系统, 该系统可以直接反馈微观剩余油赋存形态的类型, 最大化减少人工判别产生的误差.

基于微观剩余油图像的识别技术已经取得了较大进展, 但由于微观剩余油赋存形态类型众多、形态各异, 且不同研究人员采用不同的分类标准, 还没有一种通用的方法能够实现微观剩余油赋存形态智能分类识别. 目前剩余油分类识别的相关研究综述相对较少, 但仍有不少极具参考价值的文献. 2013年, Teklu等人^[6]对实验室和现场尺度的残余油饱和度测定方法进行了综述, 分析了各种测定方法的优缺点及适用范围. 2018年, Guo等人^[7]通过CT技术对比不同渗透率等级砂岩样品, 定量分析了孔隙结构对驱油效率和剩余油簇形态的影响, 为进一步优化剩余油开采方法提供了新的视角和方法. 2022年, Fang等人^[8]利用多种物理实验技术进行的聚合物驱油, 总结了微观尺度上聚合物驱油后的剩余油类型与饱和度情况.

尽管以上文献为剩余油识别技术的发展提供了重要的参考, 但仍存在以下不足: 在图像处理和数据分析方面, 现有的综述大多集中于总结物理实验技术在剩

余油类型划分中的应用, 缺乏对机器学习和人工智能等先进方法的应用探索, 并且没有对微观剩余油赋存形态的进行详细划分, 进而限制了不同文献间微观剩余油类型与分布规律的深入对比.

因此, 有必要对当前微观剩余油识别方法及剩余油类型划分标准进行分析和归纳, 为未来的研究人员提供参考. 为此, 本文对该领域的图像采集及类别划分标准、图像处理方法、传统剩余油识别方法、基于深度学习的剩余油识别方法及评价指标进行总结, 分析研究中遇到的问题并探究解决思路, 最后对该领域未来可行的研究方向进行展望.

1 图像采集及类别划分标准

1.1 图像采集

随着新的理论提出和实验仪器的改良, 微观剩余油的研究技术已经从宏观技术手段向精细的微观认识方向发展, 形成了多种微观剩余油分布的物理实验技术. 这些物理实验技术主要包括CT成像技术^[9]、扫描电镜技术、含油薄片技术和核磁共振成像技术等.

CT成像技术: 该技术可以实现无损成像, 通过捕获X射线穿过被测样本的衰减信号, 再依据一定算法重建样本每个同角度的断面图像, 最后进行叠加形成三维剩余油图像. 邱茂鑫结合CT成像技术对微观剩余油的形态、分布规律进行定量描述和分析, 实验中该技术能够直观地展现剩余油的形态、含量等参数^[10].

扫描电镜技术: 通过发射加速的电子在样本表面形成细小的电子束, 利用双偏转线圈进行扫描成像, 可以清晰地观察岩心的孔隙结构. Kareem等人^[11]基于扫描电镜技术对石英晶体进行研究, 总结了石英晶体表面的湿润性改变情况. 林艳波等人^[12]针对水驱冲刷实验时发生的储层欠注现象, 利用扫描电镜观察岩心冲刷前后的微观变化, 明确了低渗油藏中剩余油成因, 并据此提出针对性挖潜措施.

含油薄片技术: 对密闭且无污染的岩心进行切割取样, 利用黏合剂固结制作而成, 能保持岩心剩余油的原始分布状态. 李忠诚等人^[13]采用液氮冷冻技术制作

岩心薄片, 并利用高压汞灯荧光显微镜分析各个阶段的微观剩余油赋存状态。

核磁共振成像技术: 该技术基于岩心中剩余油和水的原子核在磁场中表现出共振的特性进行分析^[14]。刘晓蕾等人^[15]基于核磁共振方法区分孔隙结构差异, 并确定了采收率最高时的孔隙结构类型和注入水样。

CT 成像、核磁共振成像和扫描电镜技术都是可以重建三维数字岩心模型; CT 成像和核磁共振成像因成本较高, 难以大规模推广; 扫描电镜技术因无法观察到物质的分子和原子, 难以获取较大尺度的高分辨率剩余油分布图像, 在微观级别剩余油研究中使用较少; 相较而言, 含油薄片技术虽然只能反应流体的二维特征, 但其凭借着制作简便、成本较低等优势, 依然是研究微观剩余油的主要实验方法之一。

能否选择合适的方法采集到大量较为清晰的微观剩余油图像对后续的工作往往起到关键性作用, 它决定了数据集质量的高低, 影响着分类网络的识别准确度。

1.2 类别划分

对于不同方法采集的剩余油图像, 往往存在各

种各样的分类方法, 分类指标也不尽相同。目前, 石油行业对剩余油赋存形态的划分并没有明确的规范, 依据现有的文献数据, 剩余油赋存形态主要以形状和形成原理进行划分, 近年来剩余油赋存形态分类识别研究的相关文献如表 1 所示。由表 1 可以看出, 当前研究者大多以形状参数作为划分依据对剩余油进行分类, 由于缺乏统一的命名规范, 尽管是同一种剩余油赋存形态, 但在不同文献中的命名却有所差异。

本文基于冷冻制片荧光显微镜制作的微观剩余油图像, 对油藏高含水开发阶段常见的薄膜状、簇状、角隅状以及粒间吸附状这 4 类剩余油赋存形态^[5]进行简要介绍, 具体形态如图 1 所示。薄膜状剩余油如一层薄膜覆盖岩石四周, 由原油附着在亲油岩石表面而形成, 常常呈现环状; 角隅状剩余油是由于流线难以驱扫到孔隙死角而形成, 往往呈现不规则三角状; 簇状和粒间吸附状剩余油皆是由孔隙非均质性导致驱替流体绕流后富集而形成, 前者赋存于多个岩石颗粒相接处呈网状, 而后者赋存于岩石缝隙之间, 呈长条状分布且存在大量杂质^[16]。

表 1 不同文献中微观剩余油赋存形态划分对比

方法	剩余油赋存形态划分	数据来源	划分依据	识别方法	精度 (%)	年份	文献
人工方法	束缚态、半束缚态和自由态	冷冻制片、荧光显微镜	形成机理以及最终存在的状态	人工判别	—	2011	孙先达 ^[4]
	滴状, 柱状, 油膜型, 分支状, 连片型	微观驱替实验	剩余油联通孔隙系数、外形因子和油孔径比	图像处理软件Imagepro plus 6.0 对照片进行定量分析	—	2015	吴聘等人 ^[17]
	单孔状、油膜状、多孔状及连片状	CT成像技术	形状因子	指示克里金分割、定量表征方法	—	2015	邱茂鑫 ^[10]
	束缚态、半束缚态和自由态	冷冻制片荧光显微镜技术	形成机理以及最终存在的状态	根据油、水、岩石的灰度差异进行二值化处理	—	2024	李忠诚等人 ^[13]
机器学习	孤岛状、凝块状、膜状、网状、条带状	微观驱替实验	圆形成度、凹度、长宽比、最小Feret直径、周长、面积、Feret直径比	KNN算法	90.8	2020	程小龙等人 ^[18]
	单孔型、油膜型、多孔型、连片型	微观驱替实验	偏心率、形状因子、长宽比、联通孔隙系数	多叉判决树	90	2017	陈浩等人 ^[19]
	狭缝状、孔表薄膜状、角隅状、粒间吸附状和簇状	紫外荧光实验	荧光颜色、形状、接触关系	彩色图像分割、分水岭颗粒分割、支持向量机和分类树算法	—	2020	高文斌等人 ^[16]
深度学习	薄膜状、簇状、角隅状以及粒间吸附状	冷冻制片荧光显微镜技术	荧光颜色、形状	边缘检测法、加权随机森林	78.2	2023	成璐璐 ^[5]
	孤岛状、网络状、条带状、柱状、塞状、膜状	微观驱替实验	圆形成度、长宽比、矩形成度、凹度、偏心率、半径	BP神经网络分类器	84.1	2014	毛国庆等人 ^[20]
	簇状、喉道状、盲端状、膜状、油滴状	构建数字化孔隙网络模型	油状类型	DeepLabV3+模型分割, MobileNetV2分类	91.8	2021	赵玲 ^[21]
	塞状、柱状、网状、孤岛状、膜状、条带状	微观驱替实验	多维度多尺寸的特征信息	ACGAN数据增强、VGG分类	92	2023	李望奇等人 ^[22]




图1 冷冻制片荧光显微镜拍摄的剩余油图像

2 图像处理

对于不同微米级别的仪器拍摄出的微观剩余油图像,分辨率或高或低,无法获取大量高清晰度的微观图像;同时微观剩余油图像采集过程中,还会受到现场环境、岩心制片质量、操作方法等客观因素影响,拍摄的微观剩余油图像质量会产生较大偏差,引入较多的噪声,导致部分图像存在剩余油、水和岩石基质边界不清晰的情况,大大增加分辨难度.为了算法更好地识别剩余油赋存形态,在识别前选择合适的图像去噪方法显得尤为重要.常见的图像去噪方法有双边滤波、引导图滤波、中值滤波等.

双边滤波:双边滤波是一种非线性的滤波方法,不仅考虑像素的空间位置,还考虑像素的颜色相似度,因而能够较好地保持边缘的清晰度,有效地抑制边缘噪声.然而,当滤波的窗口较大时,邻域内参与滤波的像素点变多,可能会导致边缘保护效果下降,无法充分保护图像的纹理和边缘细节信息.文献[5]针对传统双边滤波器对剩余油边缘保护不够彻底的问题,对双边滤波方法进行改进,将双边滤波中的灰度核函数改进为分段函数,改进方法在消除图像噪声的同时最大程度保护剩余油区域的边缘信息,提高了剩余油图像的质量.实验结果表明,改进后的双边滤波的PSNR值和SSIM相较于原方法平均提高了1.09 dB和0.15,客观证明了双边滤波方法的有效性.

引导图滤波:引导图滤波是一种邻域运算,但在计算输出像素的值时,会考虑引导图像中对应空间邻域中某个区域的统计量.文献[23]通过引导图滤波对色彩迁移中损失掉的剩余油边缘信息进行修复,同时降低噪声的影响,以获得更好的视觉效果.引导图滤波具有对剩余油区域边缘保存较好的特点.

中值滤波:中值滤波是一种非线性的滤波方法,基本原理是选取临近像素点的像素值进行排序,找到中

间像素值替换当前像素点的像素值,让周围的像素值接近真实值,从而消除孤立的噪声点.文献[24]基于CT扫描技术的剩余油图像,使用均值滤波器、高斯平滑滤波和中值滤波进行对比后发现,高斯平滑滤波法对于抑制正态分布的噪声是非常有效的;均值滤波器不能很好地保存图像细节,导致图像模糊,不利于孔隙结构的研究;中值滤波在平滑噪声的同时不会使图像产生模糊的界限,可以很好地保护图像轮廓特征,这使得中值滤波较为广泛应用.

3 传统微观剩余油赋存形态分类识别方法

3.1 人工方法

早期研究人员和经验丰富的石油行业从业者可通过目视或者将制片样本送入实验室经专业设备测量对比等手段来辨别剩余油的赋存形态.例如2011年,孙先达^[4]依靠专业知识手动地进行划分,然而剩余油的油簇数量众多,人工逐一判别效率低下.因此,传统人工手段均有着相当的局限性.

(1) 对于微观剩余油赋存形态的分类需要专业知识储备,普通工作人员往往不具备这种能力;即使该领域富有经验的工作人员,也会因个人经验水平和能力因素的差异性,不能准确地辨别出所有剩余油形态.

(2) 部分微观剩余油的形态特征在视觉上有着极高的相似度,即使是专业人员也有可能因为视觉疲劳、光线不足而做出误判.

(3) 微观剩余油图像中往往存在大量不同形态的剩余油,逐一判断耗费大量的人力物力,而且识别准确率难以保证.

3.2 基于机器学习的方法

基于机器学习的微观剩余油赋存形态分类识别方法需要根据图像特点来设计特征提取方法.此类方法只需少量标注的数据集即可进行训练,可分为传统图像分割方法分割剩余油区域和机器学习算法分类这两个主要步骤.

3.2.1 基于机器学习的图像分割

剩余油图像的分割在实际应用中能提供可靠的关键信息,精确的分割可以有助于图像更加直观、清晰,为后续的图像分类打好基础.传统的剩余油图像分割主要利用图像的浅层特征信息,如形状、边缘、颜色和纹理等信息.常用的传统分割方法有彩色图像分割法、边缘检测法和阈值分割方法等.2020年,文献[16]利用彩色图像分割方法分割出剩余油区域,由于彩色

图像分割方法对噪声具有较高的敏感性,对于灰度差异较小的区域以及不同目标灰度值存在重叠的部位,其分割效果不明显,导致剩余油边缘区域分割不准确。2023年,文献[5]采用边缘检测法对剩余油图像进行分割,但微观剩余油分布图像中剩余油与岩石基质、水之间的边界区域相互交融,颜色、纹理变化不明显,使用基于边缘检测的分割方法提取图像中剩余油边缘信息时,容易导致边缘信息的丢失,无法确保边缘区域的连续性和封闭性。文献[25]针对岩心切片进行阈值分割,首先使用灰度阈值法,仅能区分出少部分的岩石颗粒,无法分离岩石颗粒和孔隙区域;接着,针对岩心薄片的特点,选取色差作为分割标准,逐步调整阈值,从而得到较为清晰的分割图像,但还是有很多深浅不一的色块,无法有效根据颜色计算剩余油区域的面积[25]。

通过传统分割方法对微观剩余油图像进行分割,受剩余油图像的复杂性、操作繁琐等因素的影响,往往存在较大的误差与局限性,对后续的分类影响较大。同时,需要人工选择合适的滤波器或阈值,对研究人员的专业性与经验要求较高。

3.2.2 基于机器学习的图像分类

在分割出剩余油区域图像后,通常使用机器学习算法对其进行分类,例如支持向量机(support vector machine, SVM)、K-邻近算法(K-nearest neighbor, KNN)和多叉判决树(multi branch decision tree)等。

支持向量机最初由Cortes等人[26]在1995年提出,它在处理小样本数据、非线性问题以及高维模式识别方面表现出了显著的优势。此外,支持向量机还可以拓展应用于函数拟合等其他机器学习问题。文献[16]利用彩色图像分割出剩余油区域后,使用支持向量机对剩余油形态进行分类识别。但支持向量机选择合适的核函数较为困难,在剩余油分类研究中适用性不强。

K-邻近算法于1968年提出的,该算法使用节点的最临近节点信息构建最近邻图来进行分类,是一种将所有计算推迟到分类之后的惰性学习(lazy learning)算法。2020年,文献[18]采用KNN分类方法近邻投票确定剩余油类别,虽然达到了较好的效果,但没有解决样本不均衡带来的问题。

多叉决策树是一种决策树模型,每个节点代表一个特征且拥有多个分支,而分支则表示该特征的不同取值。相较于二叉决策树,多叉决策树可以更好地处理多分类问题。然而,多叉决策树的模型复杂度较高,需要更多的计算资源和时间。文献[19]选取形状因子、长

宽比、偏心率等参数构建多叉判决树,实现了剩余油形态的自动识别,文中作者仅采用4种剩余油类型共40组数据进行训练,虽达到不错的精度,但剩余油类别繁多,仅靠判别树难以实现精准分类,不具备泛化性。

相较于传统人工识别剩余油类型的方法,基于机器学习的方法在识别精度上取得了显著提升。但基于机器学习的方法依旧需要人工对剩余油图像进行信息提取,设计专门设计的机器学习分类算法进行分类识别,模型的泛化性能不高,自动化水平有待进一步提升。

4 基于深度学习微观剩余油赋存形态分类识别方法

卷积神经网络模型在剩余油赋存形态识别任务取得了不错的成绩,这些网络模型在大规模识别任务中,已能实现优于传统机器学习方法的识别准确度。目前,基于深度学习的微观剩余油赋存形态识别方法主要分为单阶段和两阶段,两者不同之处在于单阶段方法利用分类模型直接对原始图像进行分类,而两阶段方法则是采用图像分割技术分割出剩余油区域,再使用分类网络对分割出的剩余油图像进行识别。具体流程如图2所示。

4.1 单阶段剩余油识别方法

在微观剩余油图像预处理后,单阶段剩余油识别方法主要包括数据增强、网络模型预训练、图像分类这3个主要步骤。

4.1.1 数据增强

在实验中,大多数研究人员为了提升实验的精确度,选择成像效果较好的CT扫描技术、冷冻制片荧光显微镜技术等方法制作微观剩余油图像,这类技术往往成本较高以及采集的图片存在保密性等原因导致收集的剩余油图像样本集数量较少。然而深度学习需要从大量的训练样本中提取特征以满足神经网络训练的条件。样本数据集小,容易在训练过程中产生过拟合现象,即模型在训练集上表现出良好的性能,却在交叉验证集上表现一般,无法对未知数据进行识别。可以说数据集的质量对深度学习模型的识别效果有决定性的影响,是能否实现目标对象被准确识别的关键。因此,通常选择数据增强的方法对样本数据集进行扩充,以满足深度学习模型的要求。数据增强方法可以分为有监督的数据增强和无监督的数据增强,具体方式见表2。同时使用表2中的一种或几种数据增强方式,可以从少量数据集中生成大量数据。

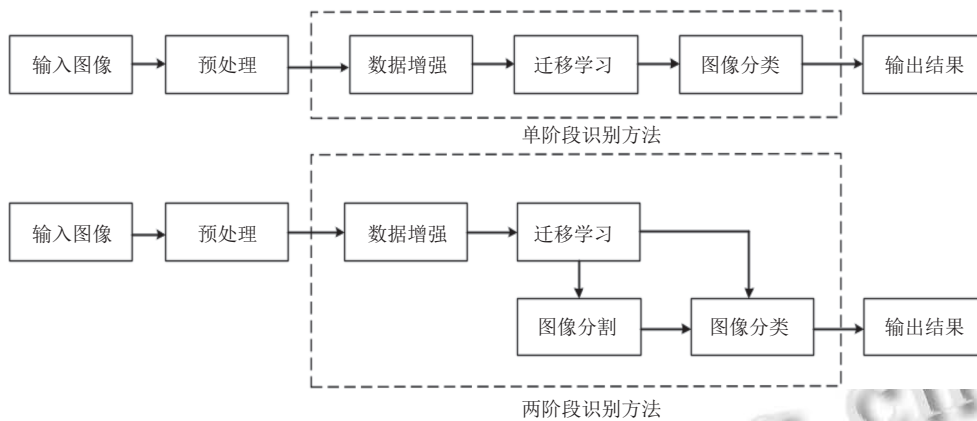


图2 单阶段识别方法与两阶段识别方法简要流程

表2 数据增强方法

数据增强类型		说明
有监督数据增强	单样本数据增强	几何变换类 空间变换类 颜色变换类
	多样本数据增强	对图像进行几何变换,包括翻转,旋转,移位,裁剪,变形,缩放等 变形、透视、折叠等 改变图像本身的内容,包括噪声、模糊、颜色变换、擦除、填充等
	GAN ^[27]	利用多个样本来产生新的样本,包括SMOTE、Mixup等
无监督数据增强	Autoaugmentation ^[28]	通过模型学习数据的分布,随机生成与训练数据集分布一致的图片 根据数据自动选择最佳的数据增强方案,并利用强化学习的方法,从数据本身出发,寻找到最佳的图像变换方式

一般来说数据增强是指用已有数据来创造新数据的过程。但是创造数据的过程是有所讲究的,数据增强之所以不叫数据增多也意味着它不单单是增多数据,更多的是数据本身特征的“增强”,需要分析已有的数据和要完成的任务,去选择更加合适的增强方式。例如2022年,杨轩^[29]选用Vaihingen数据集来研究大尺度多时相地表覆被分类方法,针对数据集的特点,分析出真实场景中地物的朝向是完全没有规律的,可以朝着任何方向,因此,文中设置了任意角度旋转增强操作;又因为遥感影像的辐射差异以及匀色等各种因素,影像往往会出现色彩差异,为了降低网络对色彩的敏感度,作者采用随机辐射抖动操作,可以模拟出不同的成像条件下的影像,使得网络更关注地物的空间纹理信息,从而提高模型的泛化能力。2023年,李望奇等人^[22]对比GAN网络及其变体模型,最终选择了生成剩余油形态效果较好的ACGAN网络进行数据增强,极大地丰富了剩余油数据集形态多样性。

因此,为了获取更高质量的数据集,需要依据不同剩余油识别方法和微观剩余油图像的特点,选用不同数据增强方式。例如单阶段剩余油识别网络,考虑到剩余油相较于水和岩石具有独特的纹理、形状、颜色等特征,这些特征对模型学习性能影响较大,而传统的数

据增强方法主要依据人工选择的几何、颜色变换来生成图像,导致生成的图像过于相似,缺乏多样性,相比之下,生成对抗网络(GAN)可以学习数据分布并生成与训练数据相似但又不完全相同的新样本,不仅更加智能,而且生成图像具备更复杂的语义信息,此时选择无监督数据增强的方法最优。对于两阶段网络,剩余油分割时需要原始图像与标签图像进行对比,标签图像需要人工进行大量的语义标注,可以采用监督数据增强方法对少量图像及其标签进行同步的数据扩充,以此达到减轻标注压力的目的。

4.1.2 网络模型预训练

虽然数据增强可以极大丰富数据集的规模与多样性,然而数据增强毕竟不是真正地实现了数据的无中生有,新数据与旧数据之间的差异依然比较小,并不能看作自然地依理想数据概率分布采样,所以数据增强的边际效益可能比较有限。

为了在有限的数量下达到良好的分类精度,许多研究人员选择了迁移学习的方式来训练自己的模型,从而节约成本、加快网络收敛速度。该方法把在相似任务中预训练好的模型参数加载到新的模型中,起到参数初始化的作用,减少对训练数据的依赖,用较少的数据和训练次数即可得到不错的训练模型。近几年随

着 ImageNet、VOC 等大型数据集的建立,公开的标注图像数据越来越多,这也为迁移学习预训练网络提供大量的数据支撑。

2014年, Yosinski 等人^[30]率先探索了深度神经网络的可传递性,得出了3个主要结论:(1)神经网络的前几层学习图像的基本特征,并且基于这些特征训练出来的参数有较好的识别效果。(2)对深度迁移网络进行微调的效果要比初始训练好。(3)微调可以克服数据之间的差异。

基于以上发现,迁移学习技术被广泛应用于解决训练网络模型收敛缓慢,模型在小数据集上产生的过拟合现象等问题。

2023年,闫志蕊等人^[31]对自制煤岩分割数据集进行数据增强处理,采用迁移学习训练方法,克服样本分布差异性,增强模型泛化性,以适应于不同应用场景下的煤岩识别任务。同年,徐慧等人^[32]采用基于微调的迁移学习来预训练论文中提出的模型,在经过翻转、旋转、噪声等图像增强处理后的黑色素瘤数据集上进行对比实验后,发现网络模型使用迁移学习后得到的 ACC 比没用迁移学习得到的 ACC 的值要高 0.02–0.03。

结合以上文献可以发现,在数据量不足的情况下使用迁移学习可以有效地提升网络性能,并且目前大多数论文采用数据增强与迁移学习结合的方法,从而弥补数据增强获取的边际效益比较有限的问题。

4.1.3 基于深度学习的图像分类

随着深度学习技术不断发展,卷积神经网络也被应用于微观剩余油赋存形态分类领域。2022年,Zhao 等人^[33]提出了一种基于 MobileNets 的剩余油分类网络,该网络虽具有较快速度,但轻量化网络由于参数量较小,对剩余油特征提取不够充分,分类精度较低。2023年,李望奇等人^[22]使用 VGG 网络识别剩余油,引入 SENet 注意力机制并增加网络层数,改善模型特征表达能力,虽然分类精度有所提高,但所提模型占用大量内存,实际运用较为困难。

表 3 展示了目前典型分类网络模型在微观剩余油数据集上的性能指标,从 VGG16 到 VGG19,再从 ResNet18 到 ResNet50,可以看出更深的网络模型对识别准确率有一定的提升,但其代价是显著增加的参数数量和浮点运算数,例如 VGG19 的参数量达到 144M,浮点运算数达到 19.6G,ResNet50 的参数量为 25.6M,浮

点运算数为 3.8G,不仅对计算资源提出了更高的要求,还可能导致模型的训练和推理时间显著增加,从而影响其在实际应用中的可行性和效率。

表 3 目前典型分类网络在剩余油数据集上的性能比较

文献	模型	数据集	准确率 (%)	参数量 (M)	浮点运算数 (G)
[21,34]	MobileNetV2	自制岩心水驱剩余油分布图像数据集	91.8	3.4	0.3
[33,35]	MobileNetV1	基于水驱实验自制数据集	83.8	4.2	0.5
[22,36]	VGG16		90	138	15.5
	VGG19		91	144	19.6
[22,37]	ResNet18	结合ACGAN网络生成	89	11.7	1.8
	ResNet34		90	21.8	3.6
	ResNet50		86	25.6	3.8
[38]	DenseNet-121		87	7.9	2.9

针对目前网络深度的增加带来的准确率的提升越来越少,网络宽度的增加往往会导致参数规模指数级增长的问题,Xie 等人^[39]摒弃了单纯依靠加深和加宽网络层次来提升网络性能的传统思路,提出了 ResNeXt 网络模型。ResNeXt 是 ResNet 和 Inception^[40]的结合体,采用 Inception 中分组卷积的思想。相较于 Inception,ResNeXt 的每个分支都采用了相同的拓扑结构,仅需调整几个超参数。这种高度模块化的设计降低了网络设计的难度和计算开销,同时还有利于模型移植。在保持整体复杂度相同的情况下,通过分组卷积,每个小网络的参数量可降低到原来的 $1/n$ (n 为相同拓扑分支数)。这不仅能降低过拟合的风险,还能提高模型准确率。另外,采用相同拓扑结构的分支设计符合 GPU 的硬件设计原则,因此,运行速度得到了显著提升。

修改模型结构能使其符合 GPU 运算规律,ResNeXt 可以训练更深的网络结构,在精度提升的同时运行时间也得到缩减。以上设计方案也将为深度学习图像分类模型的选择与优化提供新思路。

4.1.4 两阶段剩余油识别方法

与单阶段不同的是,两阶段识别网络添加图像分割这一步骤,具体如图 2 所示。由于单阶段网络需要在有限的数据集中精准识别剩余油,识别精度难以提升。因此,一些学者尝试模仿传统剩余油识别方法,先对剩余油区域进行分割,再进行分类识别。2019年,赵玲^[21]采用 DeepLabV3+模型对剩余油区域进行分割,再利用 MobileNetV2 对分割出的剩余油图像进行分类,取

得优于单阶段方法的精度,但所提模型没有针对剩余油图像的特点加以改进,对于边缘模糊的剩余油区域,分割性能较差,未充分发挥出模型优异的性能;同时该论文未考虑模型大小与运行效率,不利于实际应用。

表4 多种语义分割模型结构特点及优缺点

模型名称	网络结构特点	优点	缺点
FCN ^[41]	通过全卷积操作、多尺度信息和跳跃连接实现图像语义分割	接受任意大小的输入图像,避免由于使用像素块而带来的重复存储和计算卷积的问题	处理高分辨率图像时可能会导致内存和计算负担较大
U-Net ^[42]	采用编码-解码架构和跳跃连接	解决了FCN无法捕获上下文的信息和位置信息的弊端	每个patch单独运行且存在重复计算问题,运行速度慢
SegNet ^[43]	采用了编码器-解码器结构,通过分层特征提取和像素分配实现语义分割	内存消耗低、在训练和测试期间内存需求都较小	相对较慢,因其包含解码器架构
RefineNet ^[44]	采用多层次的特征融合和级联结构	充分利用了多层次特征信息,能够提高语义分割的性能	需要更多的计算资源和训练时间
PSPNet ^[45]	采用金字塔池化模块来捕获多尺度上下文信息	聚合不同场景的上下文特征,提高语义分割性能	需要更多计算资源
DeepLabV1-V3 ^[46-48]	V1使用多尺度处理,V2引入金字塔池化(ASPP)模块,V3加入空洞卷积、解码器模块	较高的分割精度和多尺度特征融合	V1到V3复杂度不断变高,计算资源需求更大
DeepLabV3+ ^[49]	引入了改进的解码器模块	更好地捕捉物体和区域的细节和上下文信息,在V3的基础上进一步提高了分割性能	更高的计算复杂性和资源需求
FastFCN ^[50]	使用多次下采样,采用了联合金字塔上采样(JPU)模块,最终接入多尺度文本模块(PSP)	使用联合上采样模块JPU代替空洞卷积,有效降低了计算复杂度和内存占用	性能略低于其他模型
TransUNet ^[51]	在U-Net上加入了一个Transformer分支	利用CNN获取的高分辨率空间信息,利用了Transformer编码的全局上下文	TransUNet使用了多个组件,需要更多的经验和时间来调优超参数
Swin-Unet ^[52]	在U-Net上引入跳跃连接,替换卷积block为Transformer block	通过将注意力计算限制在当前区域附近的窗口内,更好地保留位置信息	整个网络都采用swin Transformer构建,模型庞大、训练困难

随着深度学习技术的不断发展,越来越多优秀模型开始涌现,针对分割边缘不清晰与实际运用的效率问题也得到相应解决。表4展示了经典语义分割网络以及分割性能优异的网络,并对他们的结构特点以及优缺点进行归纳。针对分割边界如何清晰划分以及模型轻量化的问题,目前已经有不少学者提出了解决方法。2016年,Zhao等人提出PSPNet,本质是基于编码器解码器结构的一个网络,使用空间金字塔模块融合全局特征,同时捕获上下文信息,在复杂场景解析中取得较好的分割效果。2014-2018年,Chen等人提出DeepLab系列,DeepLabV1采用空洞卷积提取特征,利用全连接条件随机场精细化目标边界;DeepLabV3+则是仿照U-Net的结构添加了一个向上采样的解码器模块,将其底层特征与高层特征进一步融合,提升分割边界准确度。2021年,桑永龙等人^[53]对DeepLabV3+模型进行改进,特征提取部分使用分组的ResNeSt网络,以实现各类目标赋予不同的训练权重。同时,桑永龙等人还对ASPP模块进行改进,使用密集连接的方式实现空洞空间金字塔池化模块的信息传递,以确保在不牺牲特征空间分辨率的前提下扩大感受野,并提高特征复用效

率。2022年,闫志蕊等人^[31]使用轻量化MobileNetV2模块作为DeepLabV3+的骨干特征提取网络,减少网络模型参数,提高语义分割效率,并引入了注意力机制模块,使得模型拥有更强的边界细节特征提取能力。

综上所述,虽然两阶段方法取得优于单阶段的识别精度与效果,但模型运行效率有所欠佳。当下越来越多学者开始着重于提升模型精准分割边缘能力的同时降低模型的参数量,不断涌现的改进算法将推动剩余油分割任务向着实际运用快速发展。

5 评价指标

目前,图像识别模型多种多样,建立一个完善的评价标准不仅有助于选择适合的算法,还能为研究人员进一步改进和优化提供参考,提高模型在实际应用中的有效性和可靠性。在微观剩余油图像分割和分类领域,除了当前最常用的评价指标,如像素精度、类别像素准确度、交并比、准确率和召回率外,还有一些在剩余油识别领域应用较好或者特有的评价指标。

含油饱和度(oil saturation)^[54]:表示在岩石孔隙中的含油量占总孔隙体积的百分比,评估模型对图像中

含油区域的识别能力. 计算公式为:

$$S_o = \frac{V_o}{V_p} \quad (1)$$

其中, S_o 为剩余油饱和度 (%), V_o 为岩石孔隙中剩余油含量 (m^3), V_p 为孔隙体积 (m^3).

结构相似性 (structural similarity index, *SSIM*): 衡量剩余油识别模型输出结果与标签间的相似程度^[5].

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2)$$

其中, μ_x 和 μ_y 为输出结果 x 和标签 y 的平均值, σ_x 、 σ_y 是方差, σ_{xy} 是协方差, C_1 和 C_2 为常数.

油质占比 (oil quality ratio): 指不同类型剩余油在总剩余油中的比例, 以评价微观剩余油分布特征.

$$S_i = \frac{A_i}{A} \quad (3)$$

其中, S_i 为 i 类剩余油比例 (%), A 为剩余油总面积 (μm^2), A_i 为 i 类剩余油面积 (μm^2).

6 展望与挑战

在微观剩余油分布图像上区分油、水、岩石这3种物质依旧以传统识别方法为主. 随着识别技术的不断更新, 使用基于深度学习的剩余油图像分类识别方法取得了不错的成果, 但是, 该技术在微观剩余油识别领域的应用尚处于起步阶段, 面临着诸多问题与挑战.

6.1 微小剩余油检测问题

微小剩余油的边界可能模糊不清, 与周围环境融合, 使得一般的深度学习模型很难准确检测其边界. 同时, 准确标注微小剩余油的位置可能需要专业知识和大量的人力成本, 这可能成为数据集获取的瓶颈.

为了提高微小剩余油的检测准确性, 可以引入先进的注意力机制或多尺度特征融合方法, 增强模型对微小目标的感知能力. 此外, 开发或使用自动标注工具, 结合计算机视觉技术自动标注微小剩余油, 利用自动标注工具进行初步标注和专家验证相结合的方式, 提高标注效率和准确性.

6.2 数据不平衡问题

由于剩余油的赋存形态在高含水油藏中的占比不同, 制作的剩余油分类数据集存在样本不平衡问题, 对于图像分类任务, 导致模型偏向于多数类别, 这可能会影响对少数类别的准确分类. 尽管使用基于数据增强技术可以有效地扩充类别样本较少剩余油, 但大量剩余油

图像中难免存在无效信息, 类别不平衡问题依旧存在.

针对以上问题, 可以采用欠采样和过采样技术平衡数据集, 并结合生成对抗网络 (GAN) 生成少数类别样本. 此外, 引入代价敏感学习和数据加权策略, 增强模型对少数类别的学习能力, 提高分类准确率.

6.3 实际运行效率问题

许多移动设备或嵌入式设备面临内存不足、处理器性能低、功耗限制等挑战, 这使得高精度模型无法在其上进行实时运行和部署. 现有的剩余油分析软件与识别模型的研究过程中, 很少考虑到运行效率问题, 存储空间和算力资源的限制下, 剩余油识别网络模型在资源受限的设备上的存储与计算仍然是一个巨大的挑战. 引入轻量级模型是目前最常用的解决方法, 但仅依靠轻量化设计可能无法满足高精度的要求, 因此, 可以采用模型剪枝、量化和知识蒸馏等技术优化模型结构, 在保证精度的前提下减少模型参数量和计算复杂度.

6.4 结合传统方法与深度学习方法

深度学习得益于优异的特征提取能力, 已经取得优于传统方法的准确度. 然而, 较好的识别精度背后需要大量的数据作为支撑, 具有精细标注的训练样本数据集获取费时、费力且特殊领域难以大量获取, 进而限制了深度学习在剩余油领域的实际应用. 其次, 模型超参数调优复杂, 需要大量经验与实验, 耗费成本较高. 对于以上问题, 传统机器视觉对数据集依赖较小, 开发成本较低, 模型更具可解释性. 将传统机器学习技术轻量且简洁的设计结构和深度学习强大的特征提取能力相结合, 提高剩余油识别模型在实际场景下的可行性, 是未来需要研究的课题.

7 总结

面对少量的数据和复杂的剩余油类型, 相较于传统微观剩余油识别方法, 通过深度学习所构建的智能识别模型往往识别效率更高, 且不会受到人为因素的干扰, 展现出极强的非线性处理能力和特征自适应提取能力. 本文从图像采集和分类标准、剩余油图像处理 and 剩余油识别方法方面介绍了微观剩余油赋存形态分类识别技术, 给出了常用的剩余油识别评价指标, 并对当前基于深度学习的剩余油赋存形态识别方法存在的问题和未来的研究方向进行了讨论和展望. 总的来说, 微观剩余油赋存形态分类识别研究发展势头正猛, 而深度学习本身也在迅速发展着, 各种新型算法、思

想层出不穷,这必将带动微观剩余油智能识别方法的不断改进提升。

参考文献

- 1 于志浩. 中高渗油藏水驱全过程微观剩余油演化规律及动用方法 [硕士学位论文]. 北京: 中国石油大学, 2021.
- 2 王浩南, 吕文雅, 冯敏, 等. 层状砂岩油藏协同开发优势渗流通道分布规律——以非洲 M 盆地 P 油田 Y 油组为例. 东北石油大学学报, 2022, 46(6): 75–87. [doi: 10.3969/j.issn.2095-4107.2022.06.007]
- 3 王哲麟, 师永民, 潘懋, 等. 微观剩余油赋存状态的矿物学机制探讨——以鄂尔多斯盆地中部中-低渗砂岩储层为例. 北京大学学报 (自然科学版), 2021, 57(1): 111–120. [doi: 10.13209/j.0479-8023.2020.116]
- 4 孙先达. 储层微观剩余油分析技术开发与应用研究 [博士学位论文]. 长春: 吉林大学, 2011.
- 5 成璐璐. 基于机器学习的微观剩余油赋存形态分类识别研究 [硕士学位论文]. 大庆: 东北石油大学, 2023: 16–40.
- 6 Teklu TW, Brown JS, Kazemi H, *et al.* A critical literature review of laboratory and field scale determination of residual oil saturation. Proceedings of the 2013 SPE Production and Operations Symposium. Oklahoma City: SPE, 2013. Paper ID: SPE-164483-MS. [doi: 10.2118/164483-MS]
- 7 Guo CH, Wang X, Wang H, *et al.* Effect of pore structure on displacement efficiency and oil-cluster morphology by using micro computed tomography (μ CT) technique. Fuel, 2018, 230: 430–439. [doi: 10.1016/j.fuel.2018.05.058]
- 8 Fang YJ, Yang EL, Guo SL, *et al.* Study on micro remaining oil distribution of polymer flooding in Class-II B oil layer of Daqing Oilfield. Energy, 2022, 254: 124479. [doi: 10.1016/j.energy.2022.124479]
- 9 Appoloni CR, Fernandes CP, Rodrigues CRO. X-ray microtomography study of a sandstone reservoir rock. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2007, 580(1): 629–632. [doi: 10.1016/j.nima.2007.05.027]
- 10 邱茂鑫. 基于 CT 的剩余油微观赋存状态描述方法研究 [硕士学位论文]. 青岛: 中国石油大学, 2013.
- 11 Kareem R, Cubillas P, Riggs HJ, *et al.* Towards a Nanoscopic understanding of oil-sandstone wettability-implications for enhanced oil recovery. Proceedings of the 18th European Symposium on Improved Oil Recovery. Dresden: European Association of Geoscientists & Engineers, 2015. 14–16.
- 12 林艳波, 李军建, 程林松, 等. 物理模拟融合油藏精细刻画法表征特低渗油藏中高含水期剩余油分布. 石油钻采工艺, 2024, 26(2): 175–188. [doi: 10.13639/j.odpt.202405050]
- 13 李忠诚, 鲍志东, 王洪学, 等. 基于高压汞灯荧光显微观测的剩余油定量分析方法. 石油钻探技术, 2024, 52(3): 112–117.
- 14 Tian H, He K, Huangfu YH, *et al.* Oil content and mobility in a shale reservoir in Songliao basin, northeast China: Insights from combined solvent extraction and NMR methods. Fuel, 2024, 357: 129678. [doi: 10.1016/j.fuel.2023.129678]
- 15 刘晓蕾, 朱光亚, 熊海龙, 等. 中东碳酸盐岩油藏孔隙结构对驱油效果的影响. 科学技术与工程, 2017, 17(1): 182–186.
- 16 高文彬, 李宜强, 何书梅, 等. 基于荧光薄片的剩余油赋存形态分类方法. 石油学报, 2020, 41(11): 1406–1415. [doi: 10.7623/syxb202011010]
- 17 吴聃, 鞠斌山, 陈常红, 等. 基于微观驱替实验的剩余油表征方法研究. 中国科技论文, 2015, 10(23): 2707–2710, 2715.
- 18 程小龙, 王正勇, 滕奇志. 基于 KNN 的剩余油形态识别. 信息技术与网络安全, 2020, 39(1): 104–107.
- 19 陈浩, 滕奇志, 何小海, 等. 基于几何形状特征的剩余油形态识别. 微型机与应用, 2017, 36(1): 18–21, 28.
- 20 毛国庆, 滕奇志, 吴拥, 等. 基于 BP 神经网络的剩余油形态识别. 太赫兹科学与电子信息学报, 2014, 12(6): 858–864.
- 21 赵玲. 基于数字化孔道的聚驱后微观剩余油定量描述研究 [博士学位论文]. 大庆: 东北石油大学, 2019.
- 22 李望奇, 滕奇志, 何小海, 等. 基于深度学习的剩余油形态分类. 计算机系统应用, 2023, 32(12): 224–232. [doi: 10.15888/j.cnki.csa.009349]
- 23 王杰. 岩石薄片荧光图像分析相关技术研究 [硕士学位论文]. 成都: 四川大学, 2021.
- 24 于滕龙. 基于 CT 扫描的微观剩余油量化表征 [硕士学位论文]. 大庆: 东北石油大学, 2017.
- 25 宋立甲. 特高含水油田储层物性时变规律及水驱-化学驱调整挖潜方法研究 [博士学位论文]. 大庆: 东北石油大学, 2023.
- 26 Cortes C, Vapnik V. Support-vector networks. Machine Learning, 1995, 20(3): 273–297.
- 27 Goodfellow IJ, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets. Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014. 2672–2680.
- 28 Cubuk ED, Zoph B, Mané D, *et al.* AutoAugment: Learning augmentation strategies from data. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 113–123. [doi: 10.1109/CVPR.2019.00020]
- 29 杨轩. 基于深度学习的大尺度多时相地表覆被分类方法研究 [博士学位论文]. 北京: 中国科学院大学 (中国科学院空天信息创新研究院), 2022.
- 30 Yosinski J, Clune J, Bengio Y, *et al.* How transferable are features in deep neural networks? Proceedings of the 27th

- International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014. 3320–3328.
- 31 闫志蕊, 王宏伟, 耿毅德. 基于改进 DeepLabV3+和迁移学习的煤岩界面图像识别方法. 煤炭科学技术, 2023, 51(S1): 429–439.
- 32 徐慧, 邹俊忠, 张见, 等. 基于改进残差网络的黑色素瘤图像分类. 计算机工程与设计, 2023, 44(5): 1495–1501.
- 33 Zhao L, Sun XD, Liu F, *et al.* Study on morphological identification of tight oil reservoir residual oil after water flooding in secondary oil layers based on convolution neural network. *Energies*, 2022, 15(15): 5367. [doi: [10.3390/en15155367](https://doi.org/10.3390/en15155367)]
- 34 Sandler M, Howard A, Zhu ML, *et al.* MobileNetV2: Inverted residuals and linear bottlenecks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 4510–4520.
- 35 Howard AG, Zhu ML, Chen B, *et al.* MobileNets: Efficient convolutional neural networks for mobile vision applications. arXiv:1704.04861, 2017.
- 36 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. Proceedings of the 3rd International Conference on Learning Representations. San Diego, 2015.
- 37 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770–778.
- 38 Huang G, Liu Z, Van Der Maaten L, *et al.* Densely connected convolutional networks. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 2261–2269.
- 39 Xie SN, Girshick R, Dollár P, *et al.* Aggregated residual transformations for deep neural networks. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 5987–5995.
- 40 Szegedy C, Liu W, Jia YQ, *et al.* Going deeper with convolutions. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015. 1–9.
- 41 Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015. 3431–3440.
- 42 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention. Munich: Springer, 2015. 234–241.
- 43 Badrinarayanan V, Kendall A, Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for Image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481–2495. [doi: [10.1109/TPAMI.2016.2644615](https://doi.org/10.1109/TPAMI.2016.2644615)]
- 44 Lin GH, Milan A, Shen CH, *et al.* RefineNet: Multi-path refinement networks for high-resolution semantic segmentation. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 5168–5177.
- 45 Zhao HS, Shi JP, Qi XJ, *et al.* Pyramid scene parsing network. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 6230–6239.
- 46 Chen LC, Papandreou G, Kokkinos I, *et al.* Semantic image segmentation with deep convolutional nets and fully connected CRFs. Proceedings of the 3rd International Conference on Learning Representations. San Diego, 2015. 357–361.
- 47 Chen LC, Papandreou G, Kokkinos I, *et al.* DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834–848. [doi: [10.1109/TPAMI.2017.2699184](https://doi.org/10.1109/TPAMI.2017.2699184)]
- 48 Chen LC, Papandreou G, Schroff F, *et al.* Rethinking atrous convolution for semantic image segmentation. arXiv:1706.05587, 2017.
- 49 Chen LC, Zhu YK, Papandreou G, *et al.* Encoder-decoder with atrous separable convolution for semantic image segmentation. Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich: Springer, 2018. 833–851.
- 50 Wu HK, Zhang JG, Huang KQ, *et al.* FastFCN: Rethinking dilated convolution in the backbone for semantic segmentation. arXiv:1903.11816, 2019.
- 51 Chen JN, Lu YY, Yu QH, *et al.* TransUNet: Transformers make strong encoders for medical image segmentation. arXiv:2102.04306, 2021.
- 52 Cao H, Wang YY, Chen J, *et al.* Swin-Unet: Unet-like pure Transformer for medical image segmentation. Proceedings of the 2022 European Conference on Computer Vision. Tel Aviv: Springer, 2023. 205–218. [doi: [10.1007/978-3-031-25066-8_9](https://doi.org/10.1007/978-3-031-25066-8_9)]
- 53 桑永龙, 韩军. 用于场景分割的改进 DeepLabV3+算法. 电光与控制, 2022, 29(3): 47–52.
- 54 Jiang N, Zhang ZL, Qu GH, *et al.* Distribution characteristics of micro remaining oil of class III reservoirs after fracture flooding in Daqing oilfield. *Energies*, 2022, 15(9): 3385. [doi: [10.3390/en15093385](https://doi.org/10.3390/en15093385)]

(校对责编: 张重毅)