

文章编号: 0253-2697(2024)03-0548-11 DOI:10.7623/syxb202403005

基于卷积神经网络与特征聚类的荧光薄片分析方法

孙歧峰¹ 李克昊¹ 段友祥¹ 张依旻² 宫法明¹

(1. 中国石油大学(华东)青岛软件学院 计算机科学与技术学院 山东青岛 266580;

2. 中国石油大学(华东)地球科学与技术学院 山东青岛 266580)

摘要: 荧光薄片是研究储层原油性质、分布特征以及孔隙结构的重要手段。但目前荧光薄片数据处理仍以人工方式为主,分析效率低且受人为主观因素影响。基于卷积神经网络,提出一种无监督自动分割方法。首先统计出不同组分在紫外光源激发下产生的荧光颜色,建立出荧光颜色图版与标准色系图谱以此确定划分标准,然后使用卷积神经网络提取出荧光图像的高级语义特征,通过相似性和连续性约束进行特征融合,通过计算与荧光色系图谱的空间距离与角度确定相似度划分类别,最终实现荧光图像中颗粒、孔隙、油质沥青、胶质沥青、沥青质沥青等组分的自动划分与定量分析。荧光薄片图像的实验证明,该方法不需要大量标记样本且总体各项平均误差较低,能够满足实际生产需求。

关键词: 荧光薄片;微观剩余油;卷积神经网络;无监督学习;特征聚类

中图分类号: TE135

文献标识码: A

Fluorescent thin section analysis method based on convolutional neural network and feature clustering

Sun Qifeng¹ Li Kehao¹ Duan Youxiang¹ Zhang Yimin² Gong Faming¹

(1. Qingdao Institute of Software, College of Computer Science and Technology, China University of Petroleum, Shandong Qingdao 266580, China; 2. School of Geosciences, China University of Petroleum, Shandong Qingdao 266580, China)

Abstract: Fluorescent thin section is an important tool to study the properties, distribution characteristics and pore structure of crude oil in reservoirs. However, the data of fluorescent thin section is mainly processed by hand, so that the analysis efficiency is low and easily affected by human factors. This paper proposes an unsupervised automatic segmentation method based on convolutional neural network(CNN). Firstly, fluorescent colors generated by different components under the excitation of ultraviolet light source were listed and used to establish fluorescent color chart and standard color system map, thus determining the division standard. Later, after extracting the advanced semantic features of fluorescent images by CNN, feature fusion was achieved through similarity and continuity constraints, and the space distance and angle of fluorescence spectrum was calculated to determine the similarity classification. Finally, the automatic division and quantitative analysis of particles, pores, oily asphalt, colloidal asphalt, and asphaltene in fluorescent images was completed. The experiment of fluorescence thin section images demonstrates that this approach does not rely on a substantial quantity of labeled samples and generally exhibits a low average error, thereby satisfying the practical production demands.

Key words: fluorescent thin section; microscopic remaining oil; convolutional neural network; unsupervised learning; feature clustering

引用: 孙歧峰,李克昊,段友祥,张依旻,宫法明. 基于卷积神经网络与特征聚类的荧光薄片分析方法[J]. 石油学报,2024,45(3):548-558.

Cite: SUN Qifeng, LI Kehao, DUAN Youxiang, ZHANG Yimin, GONG Faming. Fluorescent thin section analysis method based on convolutional neural network and feature clustering[J]. Acta Petrolei Sinica, 2024, 45(3): 548-558.

当前中国大多数油田已经进入到开发中一后期高含水阶段,复杂的地质情况加大了开采难度,使得油田的水驱采收率较低^[1]。剩余油研究从储层微观孔隙角度研究剩余油的赋存量、空间分布,可以揭示剩余油微观特性和科学开采规律^[2],对于指导油田后续开发和提高采收率具有重要的现实意义^[3]。微观剩余油研究目前已经形成了多种实验方法,如含油薄片技术、CT

技术、核磁共振成像技术、扫描电镜技术、激光共聚焦技术等^[2,4-6]。含油薄片技术可以直观真实反映出剩余油在孔隙中的微观分布特点,由于技术成熟且价格低廉是研究微观剩余油的基本方法^[3]。

荧光薄片分类方法主要根据图像的颜色、饱和度、亮度、形状等^[7-8]特征以人工方式进行,这些特征只描述了荧光薄片低级语义特征,没有对不同组分之间的

基金项目: 中国石油天然气集团有限公司科技重大项目(ZD2019-183-006)和中央高校基本科研业务费专项资金项目(20CX05017A)资助。

第一作者及通信作者: 孙歧峰,男,1976年8月生,2011年获中国石油大学(华东)地质资源与地质工程专业博士学位,现为中国石油大学(华东)副教授,主要从事人工智能与机器学习及其在石油行业中的应用研究。Email: sunqf@upc.edu.cn

关系进行更高层次的理解,未能描述其语义分割特征^[9],对成像复杂情况下的油质特征表示能力受到限制。荧光薄片图像越复杂,对图像的特征提取方法要求越高^[10]。目前,基于荧光薄片法的剩余油自动化分析研究较少,高文彬等^[11]结合彩色图像分割、种子生长算法、分水岭算法对孔隙、剩余油、颗粒区域进行分离,通过支持向量机、分类树算法实现了剩余油赋存类型的自动分类。

作为人工智能研究的热点,深度学习技术已经广泛应用于石油勘探与开发中的各个环节。在地质领域,有学者已经实现油田沉积环境与烃源岩研究^[12]、油气储层预测^[13]、学习沉积构造生成三维油藏模型^[14]。在地震勘探领域,有学者已经实现盐体结构识别^[15]、煤层气智能决策系统^[16]、相控孔隙度预测^[17]、陆相页岩油地震勘探开发^[18]。在测井领域,有学者已经实现测井岩性识别^[19-20]、测井曲线补全^[21-22]、智能化防漏堵漏技术^[23]。卷积神经网络(CNN)是一种广为人知的深度学习模型,其设计灵感来自生物体的自然视觉感知机制^[24],能够有效地提取深层特征,在识别与分割方面取得了巨大成功^[25-27],被广泛地应用于目标检测、物体识别、姿态识别等方面。

针对传统剩余油数据处理效率低且受人为因素干

扰、标记分类工作量大等问题,笔者基于卷积神经网络提出一种荧光薄片剩余油自动识别、定量分析方法。

1 荧光颜色划分标准

石油沥青物质在紫外光源激发下会产生不同的可见光,且原油中不同组分产生的荧光颜色不同。因此可以根据荧光颜色来判断油质成分^[11,28]。根据荧光特点与统计结果,可以把荧光颜色分为5类:黑绿系(暗绿色、墨绿色、黑绿色)表示图像中的颗粒;绿色系(绿色、浅绿色、浅绿黄色)表示图像中的孔隙;黄色系(浅黄绿色、浅黄色、亮黄色)表示图像中的油质沥青;橙色系(黄橙色、橙黄色、橙色)表示图像中的胶质沥青;褐色系(褐色、红褐色、褐红色)表示图像中的沥青质沥青。不同类别的荧光图像及标准色系图谱(图1)的建立过程为:对荧光图像典型区域进行初步聚类分析,并计算该区域的平均颜色值。该过程属于定量分析,图谱中每条色带的RGB值均不同,且在RGB空间分布中存在差异。通过建立图谱,可以提供一组标准化的颜色,使得在计算颜色相似度时可以基于同一个依据进行比较,减少因为不同的颜色定义导致的误差,为计算聚类结果与不同种类间的色差,进而确定最终分类结果,提供数据标准。

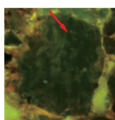

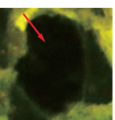

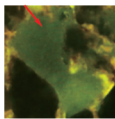
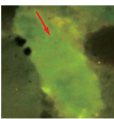


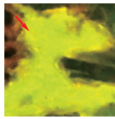
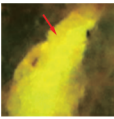


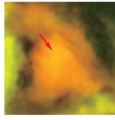
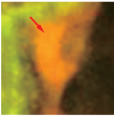
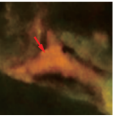

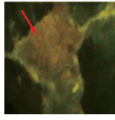
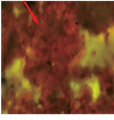
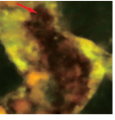

类别	荧光颜色	荧光图像			标准色系图谱
类别1 (颗粒)	黑绿系 (暗绿色、墨绿色、黑绿色)				
		暗绿色	墨绿色	黑绿色	
类别2 (孔隙)	绿色系 (绿色、浅绿色、浅绿黄色)				
		绿色	浅绿色	浅绿黄色	
类别3 (油质沥青)	黄色系 (浅黄绿色、浅黄色、亮黄色)				
		浅黄绿色	浅黄色	亮黄色	
类别4 (胶质沥青)	橙色系 (黄橙色、橙黄色、橙色)				
		黄橙色	橙黄色	橙色	
类别5 (沥青质沥青)	褐色系 (褐色、红褐色、褐红色)				
		褐色	红褐色	褐红色	

图1 不同种类的荧光颜色图像及标准色系图谱

Fig. 1 Different kinds of fluorescent color images and standard color system map

2 基于卷积神经网络的分割方法

2.1 技术方案

该方法采用无监督语义分割技术来识别荧光薄片中的剩余油、孔隙、颗粒。首先将输入图像通过 Felzenszwalb 算法^[29]进行初步分类,由于不同类别的组分可能拥有相似的颜色,仅仅依靠颜色特征无法进行有效分类,需要增加对纹理、边缘部分的感知,通过卷积神经网络提取深层特征^[30-31],利用特征相似性、连续性约束优化分类效果,充分考虑到像素点之间的依赖关系,随后进行反向传播,输出优化聚类图。经过计算聚类图中的簇与标准色系图谱间的相似度,最终确定图像分割结果。识别流程如图 2 所示。

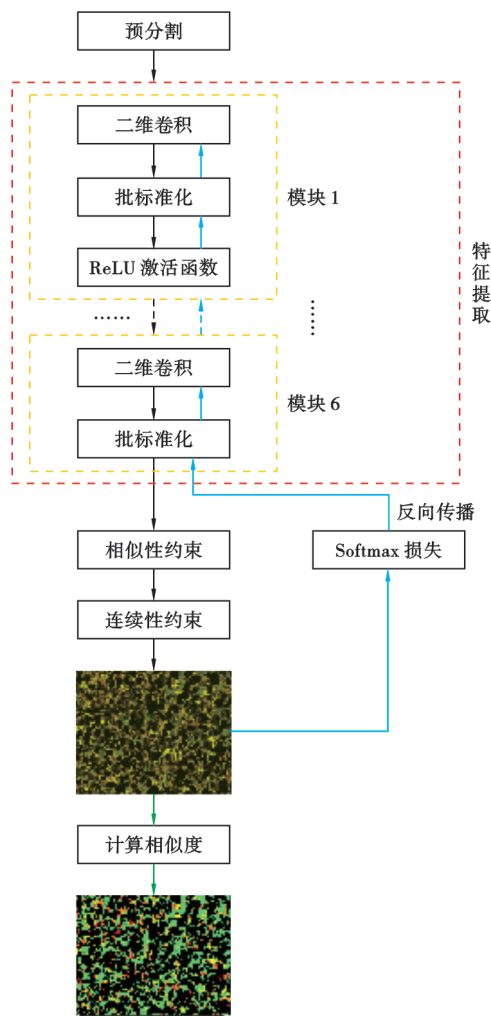


图 2 荧光图像识别流程

Fig. 2 Fluorescent image recognition process

输入荧光图像后,通过无监督分类 Felzenszwalb 算法^[29]对图像进行预分类。通过调整算法参数,为颜色相近、纹理相近、空间位置相近的像素点分配相同的语义标签,随后进行迭代。通过卷积神经网络得到特

征图,对输入的图像进行进一步特征提取。根据特征相似性约束,得到对应像素的标签,根据特征连续性约束,统计每个聚类中出现最多的类别,并将此次聚类中的所有像素都记录为该类型,使输出的分割结果尽可能符合预分类结果。随后,通过计算网络响应的 f'_n 和聚类优化标签 q'_n 间的交叉熵损失进行反向传播误差来更新参数,直到迭代完成结束上述流程。最终,计算每个簇与标准色系图谱间的相似度来确定最终的分割结果。

2.2 关键技术

2.2.1 Felzenszwalb 算法

Felzenszwalb 算法由 Felzenszwalb 和 Huttenlocher 提出^[29]。该算法的原理基于底层向上的策略,并使用分层聚类和基于图像表示的图形模型。其目标是捕捉有意义的区域并将目标与背景区分开。算法过程基于 3 点:①基于像素相似度计算初始的图像区域集。算法通过计算相邻图像区域之间的相似度来评估其之间的相似性。②使用基于图形的方法生成初始的区域层次结构。③通过迭代将区域合并成较大的集群,算法构建了一个图像区域的层次结构。

2.2.2 卷积神经网络

卷积神经网络能够有效提取出图像的深层特征,包含卷积计算并具有一定深度结构,属于前馈神经网络,采用局部连接与权值共享的方式,减少了权值数量与模型复杂度。卷积神经网络的基本构成为特征提取层与特征映射层,通过感受野相连,提取局部特征。特征映射结构通常采用非线性激活函数进行激活,进而增强模型的表达能力。

卷积层是卷积神经网络提取特征数据的核心,内部包含多个卷积核。在特征提取过程中,卷积窗口在图像上进行滑动,将对应元素进行卷积操作,操作结果按照相应位置组成特征图。该过程计算式为:

$$R^{k+1}(i, j) = [R^k \times \omega^k](i, j) + b(i, j) \quad (1)$$

图 3 为 8×8 的图像块经过 3×3 大小的卷积核卷积操作生成 6×6 的卷积特征的过程。卷积操作本质上是对图像信号进行低通滤波处理,反映了滤波器与局部感受野之间的相似性。

2.2.3 交叉熵损失函数

交叉熵损失函数是一种常用的损失函数,广泛应用于分类问题中。其度量了预测值与真实值之间的差异,并通过最小化该差异来优化模型的训练。对于多分类问题,交叉熵损失函数的公式为:

$$\text{loss} = - \sum_{c=1}^M q'_c \lg(f'_c) \quad (2)$$

该函数在深度学习中被广泛应用于分类任务,特

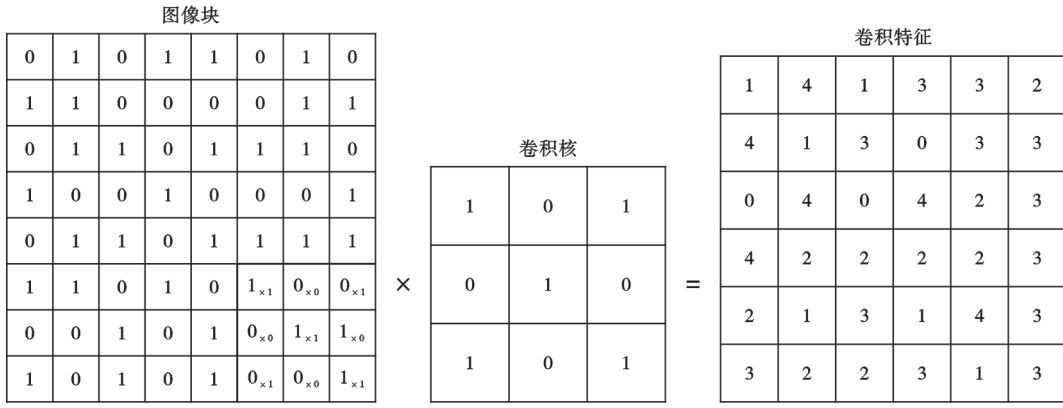


图 3 卷积及池化过程示意

Fig. 3 Schematic diagram of convolution and pooling process

别是在神经网络中,用于训练多分类模型,并最小化预测值与真实值之间的差异,从而获得更准确的分类结果。

2.2.4 特征相似性约束

荧光薄片图像中某个区域所代表的具体成分是由多个具有相似特征的像素点组合而成。使用线性分类器通过对特征的线性组合,把相同的标签属性分配给相似的像素点。

通过分类器操作,荧光图像的每个像素点可以被分为 5 个类型之一(颗粒、孔隙、油质沥青、胶质沥青、沥青质沥青)。将输入的特征向量经过若干个卷积分量,每个卷积分量由二维卷积、批归一化函数、ReLU 激活函数组成,为卷积分量设置大小为 3×3 若干个过滤器。构造出第 i 个类的线性分类器:

$$f_i(x, w_i) = w_i^T x + b_i (i = 1, \dots, 5) \quad (3)$$

根据决策最大值规则:如果 $f_i(x) > f_j(x), \forall i \neq j$ 则判定输入图像 x 属于第 i 类。将分类器的响应结果 f_n 映射为具有零均值和单位方差的 f'_n 。通过 f'_n 决

策最大值原则,得到每个像素点的标签,由此将输入的特征向量分成 5 个类型。

2.2.5 特征连续性约束

图像聚类的基本思想是把相似的像素分类为簇。荧光图像中同种油质的分布在某一区域里呈聚集态,即相似的像素集群在空间上的分布具有一定的连续性。在聚类时,未聚类的像素点更倾向于与相邻像素聚类同样的类别标签 i 。从输入的荧光图像中提取出 K 个超像素 $\{SegImg_k\}_{k=1}^K$,令 q_j 为 $SegImg_k$ 中属于第 j 簇的像素的数目,选择数量最多的簇标签 q_{max} ,且 $q_{max} \geq q_j$,随后把该集合中的像素标签全都替换为 q_{max} 所对应的标签。

2.2.6 相似度分类

经过模型处理后,依次计算出每个簇的颜色均值。每个标准色系颜色的 RGB 值都是在一定范围内的,可以通过计算每个簇的颜色均值与标准色系图谱(图 4)间的色差来确定簇与色系间的相似度。




图 4 标准色系 RGB 值的空间分布

Fig. 4 Spatial distribution of RGB values of standard color system

利用杨振亚等^[32]提出的色差公式,结合颜色空间距离与角度,使用动态权重,补偿了RGB空间的非均匀性,解决不同油质间部分颜色相似的问题,提高色差度量的精准度。RGB颜色空间中两个颜色,坐标为 $C_1 = (r_1, g_1, b_1)$ $C_2 = (r_2, g_2, b_2)$,两者间色差值计算为:

$$D_C = \{[S_r^2 \cdot \alpha_r \cdot (r_1 - r_2)^2 + S_g^2 \alpha_g \cdot (g_1 - g_2)^2 + S_b^2 \cdot \alpha_b \cdot (b_1 - b_2)^2] / [(\alpha_r + \alpha_g + \alpha_b) \cdot 255^2] + S_\theta \cdot S_{\text{ratio}} \theta^2\}^{\frac{1}{2}} \quad (4)$$

$$S_r = \min\left\{\frac{r_1 + r_2}{\sum(r, g, b)}, 1\right\} \quad (5)$$

$$S_g = \min\left\{\frac{g_1 + g_2}{\sum(r, g, b)}, 1\right\} \quad (6)$$

$$S_b = \min\left\{\frac{b_1 + b_2}{\sum(r, g, b)}, 1\right\} \quad (7)$$

$$\sum(r, g, b) = \frac{1}{3}(r_1 + r_2 + g_1 + g_2 + b_1 + b_2) \quad (8)$$

$$\theta = \frac{2}{\pi} \arccos\left[\frac{r_1 \cdot r_2 + g_1 \cdot g_2 + b_1 \cdot b_2}{\sqrt{(r_1^2 + g_1^2 + b_1^2) \cdot (r_2^2 + g_2^2 + b_2^2)}}\right] \quad (9)$$

$$S_\theta = S_{\theta_r} + S_{\theta_g} + S_{\theta_b} \quad (10)$$

$$S_{\theta_r} = \frac{\frac{|r_1 - r_2|}{r_1 + r_2}}{\frac{|r_1 - r_2|}{r_1 + r_2} + \frac{|g_1 - g_2|}{g_1 + g_2} + \frac{|b_1 - b_2|}{b_1 + b_2}} \cdot S_r^2 \quad (11)$$

$$S_{\theta_g} = \frac{\frac{|g_1 - g_2|}{g_1 + g_2}}{\frac{|r_1 - r_2|}{r_1 + r_2} + \frac{|g_1 - g_2|}{g_1 + g_2} + \frac{|b_1 - b_2|}{b_1 + b_2}} \cdot S_g^2 \quad (12)$$

$$S_{\theta_b} = \frac{\frac{|b_1 - b_2|}{b_1 + b_2}}{\frac{|r_1 - r_2|}{r_1 + r_2} + \frac{|g_1 - g_2|}{g_1 + g_2} + \frac{|b_1 - b_2|}{b_1 + b_2}} \cdot S_b^2 \quad (13)$$

$$S_{\text{ratio}} = \frac{\max(r_1, r_2, g_1, g_2, b_1, b_2)}{255} \quad (14)$$

依次计算出簇颜色 C_1 与每个色系 C_2 之间的色差值,簇颜色设定为色差值最小的那组 C_2 所对应的颜色。

2.3 算法流程

输入图像后,首先通过 Felzenszwalb 算法进行预分割处理,随后进行若干次迭代:使用卷积神经网络获

取特征图,由线性分类器实现图像特征相似性约束,通过决策最大值规则,为像素分配相应标签,针对于预分类结果,统计出每个聚类中出现最多的类别,进行特征连续性约束,随后计算交叉熵损失函数进行反向传播。上述过程直至模型迭代完成,最终通过计算聚类图中的簇与标准色系图谱间的颜色相似度,确定分类结果。

3 实验应用

3.1 评价指标

3.1.1 像素准确率

像素准确率 λ_{PA} 表示正确分类的像素数量与所有像素数量的比值:

$$\lambda_{\text{PA}} = \frac{\sum_{i=0}^{m-1} p_{ii}}{\sum_{i=0}^{m-1} \sum_{j=0}^{m-1} p_{ij}} \quad (15)$$

3.1.2 类别平均像素准确率

类别平均像素准确率 λ_{MPA} 表示每个类别正确的像素总数与每个类别像素总数比值求和得到的均值:

$$\lambda_{\text{MPA}} = \frac{1}{m} \sum_{i=0}^{m-1} \frac{p_{ii}}{\sum_{j=0}^{m-1} p_{ij}} \quad (16)$$

3.1.3 平均交并比以及时延

在语义分割任务中, λ_{MIoU} 是标准的准确率度量方法,绝大多数语义分割中的模型评估都以此为指标,其是计算所有类别预测结果和真实值的交集与并集的比值 λ_{IoU} ,再对所有类别的 λ_{IoU} 求均值:

$$\lambda_{\text{MIoU}} = \frac{1}{m} \sum_{i=0}^{m-1} \frac{p_{ii}}{\sum_{j=0}^{m-1} p_{ij} + \sum_{j=0}^{m-1} p_{ji} - p_{ii}} \quad (17)$$

评价指标时延为在实验环境下,通过模型对图像进行分割的耗时。

3.2 确定模型参数

由于聚类结果具有不确定性,其优劣是由实际分类结果决定,针对 Felzenszwalb 算法的超参数设置,采取了随机搜索法,具体过程为:①首先,需要确定参数的取值范围。在 Felzenszwalb 算法中, scale 参数控制着目标的大小,可以设置为一个较小的值,如 10~100。min_size 用于指定最小区域尺寸,需要根据图像大小进行设置,通常是 20 或更高。sigma 表示分割算法中高斯分布的标准差,默认值为 0.8。②根据计算资源,设置迭代次数为 500,每次迭代中,从搜索空间中随机采样一组超参数。③通过 Felzenszwalb 算法去评估目标检测结果的准确性,评价标准为像素精度。④每次迭代后,记录当前的性能指标,通过比较不同超

参数组合,找到最好的一组超参数。上述过程直至迭代完成。

上述随机搜索法重复 10 次取均值,确定出 Felzenszwalb 算法的参数取值:scale、sigma、min_size 参数分别设置为 28、0.4、64,为了加快迭代速度与稳定性避免陷入局部最优的情况,将动量因子设置为 0.8。一般情况下,对于基本的图像分割任务,可以采用深度较浅的网络,文中全卷积网络由 6 层卷积构成,结构如图 2 中“特征提取”部分所示。通过 3×3 与 1×1 核函数互相交替的方式进行构建(表 1),不仅可以扩大感受野,增加特征提取范围,捕捉更大范围内的特征,而且还可以降低特征维度,从而减少计算量,加速训练过程,使用 Padding 操作保证了输出特征图的大小不变。每一层使用 BatchNorm 作批量归一化处理,使 ReLU 激活函数的非线性特性得到良好地发挥,进而使神经网络更快地收敛^[33-36]。

表 1 模型参数

Table 1 Model parameters

卷积	Kernel 参数	Stride 参数	Padding 参数	InChannels 参数	OutChannels 参数
Conv2d	3×3	1	1	3	32
Conv2d	1×1	1	0	32	16
Conv2d	3×3	1	1	16	32
Conv2d	1×1	1	0	32	16
Conv2d	3×3	1	1	16	32
Conv2d	1×1	1	0	32	16

对于全卷积神经网络来说,迭代次数确定了训练过程中权重更新的次数。过少的迭代次数可能导致模型未能充分学习到特征,而过多的迭代次数可能会导致过拟合。为了确定合适的迭代次数,在确定好 Felzenszwalb 算法参数的基础上,进行了参数敏感性分析。根据数据集规模、网络层数结构,按照以往经验将迭代次数设置在 10~30,为研究不同迭代次数对模型的影响,经过多次试验记录平均损失值,绘制的曲线变化情况如图 5 所示。当迭代次数为 10 次时,曲线呈现缓慢下降的趋势;迭代次数为 15 次时,曲线下降略大于迭代 10 次时的曲线;迭代次数为 20 次时,曲线下降速度较快,最终呈现出平滑趋势;迭代次数为 25 次时,20~25 轮次损失值虽仍在下降,但下降趋势已经相对平缓;迭代次数为 30 次时,曲线最终下降速度变慢,下降幅度较小,并且略呈现待上升趋势。可以看出:①在前几次迭代中,曲线下降较为明显,损失值快速减小。随后,曲线下降的速度逐渐减缓,趋于平缓。这表明初始阶段的网络更新幅度大,而后期更新逐渐稳定。②迭代约 20 次,平均损失值相对于其他迭代次数来说较低,此时网络已经取得了相对较好的性能。

随后的迭代次数增加对损失值的改善效果不明显。因此,实验最终所采用的迭代次数设置为 20 轮次。




图 5 训练中的平均损失值

Fig. 5 Average loss during training

3.3 实验结果对比及分析

研究选取冀东油田高浅北油田区块样品,磨制荧光薄片,共拍摄得到 282 张图像,该井自 2000 年钻井以来油层经历了约 10 年的水驱。目前,未有通过 Felzenszwalb 算法^[29]、FCN 模型^[37]直接进行荧光薄片分析的报道,笔者通过传统图像分割 Felzenszwalb 算法、有监督学习方法 FCN 模型与本文无监督模型方法进行对比。经过多次实验,对 4 组高分辨率荧光图像进行识别(图 6)。

表 2—表 4 展示了 4 组样品的 λ_{PA} 、 λ_{MPA} 、 λ_{MIoU} 、时延性能指标及孔隙度、含油饱和度、油质沥青、胶质沥青、沥青质沥青含量与专家标注真值的对比情况。图 7 为 3 种方法的平均误差值对比。

由统计数据可知,无监督模型识别结果的 λ_{PA} 、 λ_{MPA} 、 λ_{MIoU} 值均高于 FCN 模型与 Felzenszwalb 算法,4 组样品各项数据的总体误差均值均不超 5%,除在油质沥青识别方面要略差于 FCN 模型,其余识别效果均优于 FCN 模型。通过对比直接使用 Felzenszwalb 算法与本文在此算法基础上使用的无监督模型,有效证明了 CNN 高级语义聚类模块的有效性。

在时延方面,FCN 模型需要专家耗费大量时间去标注样本,且训练时间都是数小时起,而无监督模型识别高分辨率图像只需要几百秒的时间,Felzenszwalb 算法虽然分割时间快于本文无监督模型,但总体精度较低。综上所述,本文方法能够满足在没有标记的情况下对荧光图像的识别精度要求与定量分析。

根据 Li 等^[38]、程小龙等^[39]的分类标准,结合工区实际剩余油发育类型,将剩余油分为孤岛状、膜状、




图 6 图像分割结果

Fig. 6 Image segmentation results

表 2 实验评价指标数据

Table 2 Experimental evaluation index data

序号	λ_{PA}			λ_{MPA}			λ_{MIU}		
	无监督模型	FCN模型	Felzenszwalb算法	无监督模型	FCN模型	Felzenszwalb算法	无监督模型	FCN模型	Felzenszwalb算法
1	0.8974	0.8414	0.7812	0.9027	0.8611	0.7651	0.8122	0.7207	0.6851
2	0.9032	0.8592	0.8048	0.9106	0.8761	0.7943	0.8202	0.7463	0.6844
3	0.9088	0.8550	0.7744	0.9120	0.8830	0.7866	0.8306	0.7373	0.6417
4	0.9059	0.8692	0.8234	0.9148	0.8938	0.8149	0.8248	0.7612	0.7015

表 3 时延、孔隙度、含油饱和度实验数据对比

Table 3 Comparison of experimental data on time delay, porosity and oil saturation

序号	时延			孔隙度差值/%			含油饱和度差值/%			
	无监督模型/s	FCN模型训练/h	Felzenszwalb识别/s	无监督模型	FCN模型	Felzenszwalb算法	无监督模型	FCN模型	Felzenszwalb算法	
1	348	5.15	287	298	-0.95	-6.98	-10.34	5.07	10.71	8.74
2	398	5.15	321	325	-2.34	-6.32	-9.08	4.03	5.54	6.89
3	351	5.15	377	296	-0.93	-9.18	-12.34	3.57	7.13	8.67
4	376	5.15	369	311	-2.50	-7.91	-9.96	3.46	6.13	5.79

表 4 沥青含量实验数据对比

Table 4 Comparison of asphalt content experimental data

序号	油质沥青占比差值/%			胶质沥青占比差值/%			沥青质沥青占比差值/%		
	无监督模型	FCN模型	Felzenszwalb算法	无监督模型	FCN模型	Felzenszwalb算法	无监督模型	FCN模型	Felzenszwalb算法
1	1.72	0.68	3.46	2.16	-2.56	-3.66	-1.19	7.47	5.48
2	1.52	1.03	2.94	1.48	-2.24	-2.45	-1.03	2.72	2.88
3	0.92	0.68	4.10	1.56	-1.81	-3.46	-1.09	4.64	4.72
4	0.83	1.06	2.33	1.52	-1.96	-2.37	-1.11	3.11	7.69




图 7 总体误差均值对比

Fig. 7 Comparison of the overall average error

簇状、滴状。参考高文彬等^[11]利用实心度与离心率结合,通过支持向量机进行剩余油形状判别,对 4 组样品的剩余油、孔隙、颗粒进行数据量化统计、赋存形态统计,如图 8 和图 9 所示。

根据识别和统计结果:高含水期的砂岩油藏样品经过水驱后,原油组分以轻质油为主,微观剩余油呈现整体分散、局部富集的分布形式,微观剩余油赋存形态




图 8 样品组分划分结果

Fig. 8 Sample component division results




图 9 剩余油量化学统计结果

Fig. 9 Quantitative statistical results of remaining oil

主要为膜状、簇状、孤岛状、分散油滴。高含水阶段注入表面活性剂可以驱替出簇状非均质剩余油、膜状剩余油、孤岛状剩余油以及分散油滴进而提高采收率，簇状非均质剩余油的减少是采收程度提高的主要原因^[40]。因此，微观剩余油的定量分析结果是指导后续油藏开发方式，提高采收率的关键。

4 结论

(1) 通过建立荧光颜色图版与标准色系图谱，确定出不同组分的划分标准，经过优化聚类，结合 RGB 颜色空间距离与角度计算色差等提出了一种基于卷积神经网络的无监督颜色阈值分割方法，实现了对荧光薄片图像中剩余油、孔隙、颗粒的自动划分及定量分析。

(2) 根据荧光图像中剩余油的成像特点，通过相似性与连续性特点进行约束，使得聚类结果更加准确，该约束条件也可适用于其他具有相似特征的显微图像处理。

(3) 通过样本实验，从像素准确率 λ_{PA} 、类别平均像素准确率 λ_{MPA} 、平均交并比 λ_{MIOU} 、时延、含油饱和度、孔隙度、油质占比等角度进行评价对比，证明了所提出的方法能够有效地提取荧光薄片图像的语义信息从而进行分类，达到预期的分类统计效果，从而开展后期的剩余油研究工作。

符号注释: f'_n —模型响应结果; q'_n —聚类优化标签; R^k —第 k 层的卷积输出; R^{k+1} —第 $k+1$ 层的卷积输出; ω^k —第 k 层的卷积核; $R(i, j)$ —特征图的像素值; $b(i, j)$ —偏置量; M —类别数量; q'_c —聚类优化标签, 等于 0 或 1, 如果预测出的类别和样本标记相同就是 1, 否则是 0; f'_c —模型响应结果, 属于第 c 个类别的概率; \mathbf{x} —输入的特征向量; \mathbf{w}_i —第 i 个类别的权重向量, $\mathbf{w}_i = [\omega_{i1} \cdots \omega_{im}]^T$; $f_i(\mathbf{x})$ —第 i 类的分类器响应

结果; $f_j(\mathbf{x})$ —第 j 类的分类器响应结果; f_n —分类器响应结果; $SegImg_k$ —属于第 k 个超像素的像素索引集合; q_j —属于第 j 簇的像素数目; q_{max} —数量最多的簇标签; D_c —RGB 颜色空间中两个颜色色差值; C_1 、 C_2 —颜色色系; (r_1, g_1, b_1) 、 (r_2, g_2, b_2) —RGB 颜色空间坐标点; α_r 、 α_g 、 α_b —人眼对 RGB 三原色变化的敏感程度系数, 取值为 $(1, 2, 1)$; S_r 、 S_g 、 S_b —RGB 分量的重要性; θ —RGB 空间中颜色坐标点矢量角度的归一化值; S_θ —RGB 三原色变化对颜色坐标点在 RGB 空间的矢量角度的贡献, θ 值随着颜色分量的重要程度而变化; S_{θ_r} 、 S_{θ_g} 、 S_{θ_b} —分别代表红、绿、蓝通道值变化对颜色坐标点在 RGB 空间的矢量角度的贡献; S_{ratio} —调整系数, 防止 RGB 空间底部 θ 过大; p_{ij} —错误地把真实类别为 i 的像素预测为类别 j 的总个数; p_{ji} —错误地把真实类别为 j 的像素预测为类别 i 的总个数; p_{ii} —正确地把真实类别为 i 的像素预测为类别 i 的总个数; m —类别数; λ_{PA} —像素准确率; λ_{MPA} —类别平均像素准确率; λ_{IOU} —所有类别预测结果和真实值的交集与并集的比值; λ_{MIOU} —所有类别预测结果和真实值的交集与并集的平均比值。

参考文献

- [1] 袁庆峰, 朱丽莉, 陆会民, 等. 水驱油田晚期开发特征及提高采收率主攻方向[J]. 大庆石油地质与开发, 2019, 38(5): 34-40. YUAN Qingfeng, ZHU Lili, LU Huimin, et al. Development characteristics and main tackled EOR research direction for the waterflooded oilfield at the late stage[J]. Petroleum Geology & Oilfield Development in Daqing, 2019, 38(5): 34-40.
- [2] 闫伟超, 孙建孟. 微观剩余油研究现状分析[J]. 地球物理学进展, 2016, 31(5): 2198-2211. YAN Weichao, SUN Jianmeng. Analysis of research present situation of microscopic remaining oil[J]. Progress in Geophysics, 2016, 31(5): 2198-2211.
- [3] 袁士义, 王强. 中国油田开发主体技术新进展与展望[J]. 石油勘

- 探与开发,2018,45(4):657-668.
YUAN Shiyi,WANG Qiang. New progress and prospect of oil fields development technologies in China[J]. Petroleum Exploration and Development,2018,45(4):657-668.
- [4] 李宜强,何书梅,赵子豪,等. 基于剩余油动用规律的高含水油藏水驱扩大波及体积方式实验[J]. 石油学报,2023,44(3):500-509.
LI Yiqiang,HE Shumei,ZHAO Zihao,et al. Experiment on enlargement of swept volume by water flooding in high water cut reservoir based on the remaining oil displacement law[J]. Acta Petrolei Sinica,2023,44(3):500-509.
- [5] 王文明,衣晓东,殷代印. 应用激光共聚焦研究特低渗透储层微观剩余油分布——以榆林林油田扶杨油层为例[J]. 石油地质与工程,2021,35(2):50-55.
WANG Wenming,YI Xiaodong,YIN Daiyin. Microscopic remaining oil distribution in ultra-low permeability reservoir by laser confocal method; by taking Fuyang reservoir of Yushulin oilfield as an example[J]. Petroleum Geology and Engineering,2021,35(2):50-55.
- [6] 张小静,段秋红,申乃敏,等. 聚驱后油藏微观剩余油水驱启动方式及优化挖潜——以双河油田为例[J]. 石油地质与工程,2020,34(5):63-68.
ZHANG Xiaojing,DUAN Qihong,SHEN Naimin,et al. Starting mode and tapping potential of micro remaining oil-water drive after polymer flooding; by taking Shuanghe oilfield as an example[J]. Petroleum Geology and Engineering,2020,34(5):63-68.
- [7] GONZALEZ R C,WOODS R E,EDDINS S L. 数字图像处理(MATLAB 版)[M]. 2 版. 阮秋琦,译. 北京:电子工业出版社,2013.
GONZALEZ R C,WOODS R E,EDDINS S L. Digital image processing using MATLAB[M]. 2nd ed. RUAN Qiuqi,trans. Beijing:Publishing House of Electronics Industry,2013.
- [8] 张月. 萨北油水过渡带储层孔隙结构及其微观剩余油特征[D]. 大庆:东北石油大学,2016.
ZHANG Yue. Microscopic pore structure and microscopic remnant oil of reservoir in Sabei oil-water transition area [D]. Daqing:Northeast Petroleum University,2016.
- [9] GENG Huiqiang,ZHANG Hua,XUE Yanbing,et al. Semantic image segmentation with fused CNN features[J]. Optoelectronics Letters,2017,13(5):381-385.
- [10] 马文礼,李治平,卢婷,等. 机器视觉在油气勘探开发中的应用现状[J]. 科学技术与工程,2018,18(17):112-119.
MA Wenli,LI Zhiping,LU Ting,et al. Application of machine vision in oil & gas exploration and exploitation; a review[J]. Science Technology and Engineering,2018,18(17):112-119.
- [11] 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[J]. 石油学报,2020,41(11):1406-1415.
GAO Wenbin,LI Yiqiang,HE Shumei,et al. Classification method of occurrence mode of remaining oil based on fluorescence thin sections[J]. Acta Petrolei Sinica,2020,41(11):1406-1415.
- [12] OGIESOBA O,AMBROSE W. Seismic attributes investigation of depositional environments and hydrocarbon sweet-spot distribution in Serbin Field,Taylor Group,Central Texas[C]//Proceedings of the SEG Technical Program Expanded Abstracts 2017. Houston:SEG,2017:2274-2278.
- [13] 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.
LIN Niantian,ZHANG Dong,ZHANG Kai,et al. Predicting distribution of hydrocarbon reservoirs with seismic data based on learning of the small-sample convolution neural network[J]. Chinese Journal of Geophysics,2018,61(10):4110-4125.
- [14] ZHANG Tuanfeng,TILKE P,DUPONT E,et al. Generating geologically realistic 3D reservoir facies models using deep learning of sedimentary architecture with generative adversarial networks[J]. Petroleum Science,2019,16(3):541-549.
- [15] Lewis W,Vigh D. Deep learning prior models from seismic images for full-waveform inversion[C]//Proceedings of the SEG Technical Program Expanded Abstracts 2017. Houston:SEG,2017:1512-1517.
- [16] 龚斌,王虹雅,王红娜,等. 基于大数据分析算法的深部煤层气地质—工程一体化智能决策技术[J]. 石油学报,2023,44(11):1949-1958.
GONG Bin,WANG Hongya,WANG Hongna,et al. Integrated intelligent decision-making technology for deep coalbed methane geology and engineering based on big data analysis algorithms[J]. Acta Petrolei Sinica,2023,44(11):1949-1958.
- [17] 孙歧峰,段友祥,柳璠,等. 多阈值 BIRCH 聚类在相控孔隙度预测中的应用[J]. 石油地球物理勘探,2020,55(2):379-388.
SUN Qifeng,DUAN Youxiang,LIU Fan,et al. Application of multi-threshold BIRCH clustering to facies-controlled porosity estimation[J]. Oil Geophysical Prospecting,2020,55(2):379-388.
- [18] 刘喜武,王心宇,刘宇巍,等. 中国陆相页岩油地震勘探技术现状及发展方向[J]. 石油学报,2023,44(12):2270-2285.
LIU Xiwu,WANG Xinyu,LIU Yuwei,et al. Current status and development direction of seismic prospecting technology for continental shale oil in China[J]. Acta Petrolei Sinica,2023,44(12):2270-2285.
- [19] 安鹏,曹丹平. 基于深度学习的测井岩性识别方法研究与应用[J]. 地球物理学进展,2018,33(3):1029-1034.
AN Peng,CAO Danping. Research and application of logging lithology identification based on deep learning[J]. Progress in Geophysics,2018,33(3):1029-1034.
- [20] 马陇飞,萧汉敏,陶敬伟,等. 基于深度学习岩性分类的研究与应用[J]. 科学技术与工程,2022,22(7):2609-2617.
MA Longfei,XIAO Hanmin,TAO Jingwei,et al. Research and application of lithology classification based on deep learning[J]. Science Technology and Engineering,2022,22(7):2609-2617.
- [21] 陈云天. 基于机器学习的测井曲线补全与生成研究[D]. 北京:北京大学,2019.
CHEN Yuntian. Research on well log completion and generation based on machine learning[D]. Beijing:Peking University,2019.
- [22] 潘少伟,王朝阳,张允,等. 基于长短期记忆神经网络补全测井曲线和混合优化 XGBoost 的岩性识别[J]. 中国石油大学学报:自然科学版,2022,46(3):62-71.
PAN Shaowei,WANG Zhaoyang,ZHANG Yun,et al. Lithology identification based on LSTM neural networks completing log and hybrid optimized XGBoost[J]. Journal of China University of Petroleum:Edition of Natural Science,2022,46(3):62-71.
- [23] 孙金声,刘凡,程荣超,等. 机器学习在防漏堵漏中研究进展与展

- 望[J]. 石油学报, 2022, 43(1): 91-100.
- SUN Jinsheng, LIU Fan, CHENG Rongchao, et al. Research progress and prospects of machine learning in lost circulation control [J]. *Acta Petrolei Sinica*, 2022, 43(1): 91-100.
- [24] 陈超, 齐峰. 卷积神经网络的发展及其在计算机视觉领域中的应用综述[J]. 计算机科学, 2019, 46(3): 63-73.
- CHEN Chao, QI Feng. Review on development of convolutional neural network and its application in computer vision[J]. *Computer Science*, 2019, 46(3): 63-73.
- [25] HARIHARAN B, ARBELÁEZ P, GIRSHICK R, et al. Hypercolumns for object segmentation and fine-grained localization[C] // *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015.
- [26] 葛轶洲, 刘恒, 王言, 等. 小样本困境下的深度学习图像识别综述[J]. 软件学报, 2022, 33(1): 193-210.
- GE Yizhou, LIU Heng, WANG Yan, et al. Survey on deep learning image recognition in dilemma of small samples[J]. *Journal of Software*, 2022, 33(1): 193-210.
- [27] SONG Lei, LIU Guixia, MA Mingrui. TD-Net: unsupervised medical image registration network based on Transformer and CNN[J]. *Applied Intelligence*, 2022, 52(15): 18201-18209.
- [28] 王津. 荧光显微图像技术在油气勘探开发中的应用综述[J]. 石油化工应用, 2016, 35(9): 1-4.
- WANG Jin. The application about fluorescent micro-image technology in the oil and gas exploration and development[J]. *Petrochemical Industry Application*, 2016, 35(9): 1-4.
- [29] FELZENSZWALB P F, HUTTENLOCHER D P. Efficient graph-based image segmentation[J]. *International Journal of Computer Vision*, 2004, 59(2): 167-181.
- [30] HARIHARAN B, ARBELÁEZ P, GIRSHICK R, et al. Simultaneous detection and segmentation[C] // *Proceedings of the 13th European Conference on Computer Vision*. Zurich: Springer, 2014.
- [31] CARREIRA J, CASEIRO R, BATISTA J, et al. Semantic segmentation with second-order pooling[C] // *Proceedings of the 12th European Conference on Computer Vision*. Florence: Springer, 2012.
- [32] 杨振亚, 王勇, 杨振东, 等. RGB 颜色空间的矢量-角度距离色差公式[J]. 计算机工程与应用, 2010, 46(6): 154-156.
- YANG Zhenya, WANG Yong, YANG Zhendong, et al. Vector-Angular distance color difference formula in RGB color space[J]. *Computer Engineering and Applications*, 2010, 46(6): 154-156.
- [33] 王攀杰, 郭绍忠, 侯明, 等. 激活函数的对比测试与分析[J]. 信息工程大学学报, 2021, 22(5): 551-557.
- WANG Panjie, GUO Shaozhong, HOU Ming, et al. Comparative test and analysis of activation function library[J]. *Journal of Information Engineering University*, 2021, 22(5): 551-557.
- [34] 杜圣杰, 贾晓芬, 黄友锐, 等. 面向 CNN 模型图像分类任务的高效激活函数设计[J]. 红外与激光工程, 2022, 51(3): 20210253.
- DU Shengjie, JIA Xiaofen, HUANG Yourui, et al. High efficient activation function design for CNN model image classification task[J]. *Infrared and Laser Engineering*, 2022, 51(3): 20210253.
- [35] 蒋昂波, 王维维. ReLU 激活函数优化研究[J]. 传感器与微系统, 2018, 37(2): 50-52.
- JIANG Angbo, WANG Weiwei. Research on optimization of ReLU activation function[J]. *Transducer and Microsystem Technologies*, 2018, 37(2): 50-52.
- [36] SCHMIDT-HIEBER J. Nonparametric regression using deep neural networks with ReLU activation function[J]. *The Annals of Statistics*, 2020, 48(4): 1875-1897.
- [37] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C] // *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015.
- [38] LI Junjian, JIANG Hanqiao, WANG Chuan, et al. Pore-scale investigation of microscopic remaining oil variation characteristics in water-wet sandstone using CT scanning[J]. *Journal of Natural Gas Science and Engineering*, 2017, 48: 36-45.
- [39] 程小龙, 王正勇, 滕奇志. 基于 KNN 的剩余油形态识别[J]. 信息技术与网络安全, 2020, 39(1): 104-107.
- CHENG Xiaolong, WANG Zhengyong, TENG Qizhi. K-nearest neighbor method for recognizing the shape of residual oil[J]. *Cyber Security and Data Governance*, 2020, 39(1): 104-107.
- [40] 朱光普, 姚军, 张磊, 等. 特高含水期剩余油分布及形成机理[J]. 科学通报, 2017, 62(22): 2553-2563.
- ZHU Guangpu, YAO Jun, ZHANG Lei, et al. Pore-scale investigation of residual oil distributions and formation mechanisms at the extra-high water-cut stage [J]. *Chinese Science Bulletin*, 2017, 62(22): 2553-2563.

(收稿日期 2023-09-24 改回日期 2023-12-30 编辑 王培玺)