

文章编号:1009-9603(2022)01-0062-07

DOI:10.13673/j.cnki.cn37-1359/te.2022.01.008

结合 SKNet 与 U-Net 的盐体识别方法

程国建¹,刘 宁¹,万晓龙²,姚卫华²,魏新善²

(1.西安石油大学 计算机学院,陕西 西安 710065; 2.中国石油长庆油田分公司 勘探开发研究院,陕西 西安 710018)

摘要:地下盐体与油气藏的关系密不可分,盐体的准确识别对油气藏勘探和钻探路径规划具有重要意义。以往的深度学习方法使用固定大小的感受野,不能根据地震图像中盐体的大小动态地调整卷积核来捕捉特征,从而忽略了部分全局信息,导致在盐体边界或狭长处识别效果较差。针对上述问题,在U-Net基础上进行改进,使用SKNet作为编码器提取盐体特征,其具有动态选择机制,根据输入信息的多个尺度自适应地调整感受野的大小,并结合位置与通道自注意力机制以及超柱体方法进行特征融合。采用改进的U-Net方法对TGS盐体数据集进行评估,取得交并比为85.66%、像素准确率为96.1%的识别效果。

关键词:盐体识别;深度学习;SKNet;U-Net;自注意力机制;特征融合

中图分类号:TE319

文献标识码:A

Salt body recognition method combining SKNet with U-Net

CHENG Guojian¹, LIU Ning¹, WAN Xiaolong², YAO Weihua², WEI Xinshan²

(1.School of Computer Science, Xi'an Shiyou University, Xi'an City, Shaanxi Province, 710065, China; 2.Exploration and Development Research Institute, Changqing Oilfield Company, PetroChina, Xi'an City, Shaanxi Province, 710018, China)

Abstract: The relationship between underground salt bodies and oil and gas reservoirs is inseparable. The accurate recognition of salt bodies is of great significance to the oil and gas reservoir exploration and drilling path planning. In existing deep learning methods, the size of the receptive field is unchanged, and the convolution kernel cannot be dynamically adjusted for the feature capture according to the size of the salt body in a seismic image. As a result, the part of the global information is ignored, which results in poor recognition at the boundaries or narrow areas of the salt bodies. In response to the above problems, this paper proposes a new method based on U-Net with SKNet as the encoder to extract salt body features. It has a dynamic selection mechanism that allows the sizes of the receptive fields to be adjusted adaptively according to multiple scales of the input information. In addition, it combines the position and channel self-attention mechanism and the hyper column method for feature fusion. The improved U-Net method is used to evaluate the TGS salt body data set. The recognition results have an intersection over union (IoU) of 85.66% and a pixel accuracy of 96.1%.

Key words: salt body recognition; deep learning; SKNet; U-Net; self-attention mechanism; feature fusion

盐体构造是指由于岩盐或其他蒸发岩的流动变形所形成的地质变形体,包括盐变形体本身及其周围的其他变形岩层^[1-2]。由于盐体运动可以形成良好的圈闭,其对于油气的生成、聚集和最终定位具有重要影响,并且盐体在常温常压下会发生假塑性流动,从而导致油井钻探过程中会遇到许多问

题。地下的地质构造一般通过收集地震反射信号呈现出来,其地震图像需要专家进行人工识别盐体,这无疑非常费时费力^[3-7]。随着计算机视觉技术的发展,边缘检测、图像分割等技术应用到盐体识别中。早期,研究者们使用传统的图像处理方法如归一化割、水平集等,这些方法具有较高的计算复

收稿日期:2021-05-19。

作者简介:程国建(1964—),男,陕西扶风人,教授,博士,从事计算智能、机器学习、人工智能与模式识别、图像处理等工作。E-mail:gjcheng@xsyu.edu.cn。

基金项目:国家自然科学基金项目“基于遥感大数据的汾渭平原空气质量时空特征及其驱动力研究与模拟”(62002286),国家自然科学基金青年科学基金项目“基于多核学习的高分辨率光学遥感图像固定结构人造目标检测方法研究”(41301480)。

杂度,在真实场景中很难实施部署。WANG等将地震属性与机器学习算法相结合,常用的地震属性有视觉显著性和无序性等^[8]。DI等对6种机器学习分类器在盐体识别问题上进行对比,得到类似的盐体分割结果,表明盐体识别问题对机器学习算法不太敏感^[9]。

随着卷积神经网络(CNN, Convolutional Neural Network)的出现,网络模型实现了端到端的特征选择与分割。WALDELAND等首次将CNN应用到盐体识别中,将3D地震图像切分成小块,以预测当前小块中心像素是否为盐体,获得了较好的盐体分割效果^[10]。全卷积神经网络(FCN, Fully Convolutional Networks)的发明,把图像级别的分类进一步延伸到像素级别,从而进行端到端的分割^[11]。为了克服FCN没有充分考虑上下文信息和实时性较差等缺点,出现了基于编码器-解码器的网络模型,U-Net是其代表之一^[12]。U-Net是一个对称的结构,由收缩路径和扩张路径组成,并通过跨层连接将编解码器联系起来。ISLAM等结合U-Net和SE-ResNet卷积模块,验证了基于跳跃连接的CNN体系结构在学习基本地震特征的能力^[13]。上述方法都采用固定的3×3的卷积核,不能提取丰富的盐体上下文信息,从而出现盐体边界分割不清晰或盐体狭长处分割不准确等问题。为此,笔者提出将SKNet(Selective Kernel Network)^[14]与U-Net相结合的方法,其可自适应地调节感受野,获得更丰富的盐体特征;并在U-Net的编解码器之间引入位置和通道自注意力机制^[15],获得盐体的长距离依赖关系,增强盐体特征表示,将所提出的方法命名为USKNet,该方法取得

了较好的盐体识别效果。

1 USKNet模型架构

USKNet模型架构基于U-Net改进(图1)。在编码器部分,将SKNet34替换原始堆叠的卷积、批量归一化与激活层,从而使编码器可以根据盐体的大小或形状动态地选择3×3或5×5的卷积核。特征图经过编码器过程中,最大池化或卷积步长为2的操作使特征图像素从128×128缩小至8×8,通道数则从8维增加至512维。在编解码器中间部分,经过2个卷积操作后,使用位置和通道自注意力机制,捕捉长距离依赖关系,同时抑制无关特征或噪声。在解码器部分,与原始U-Net基本保持一致,将编码器每层的输出与解码器经过反卷积的结果拼接,再进行卷积操作。为了融合盐体的多尺度特征,使用了超柱体方法^[16],将解码器每层的输出进行拼接,最后通过1×1的卷积核和sigmoid函数运算得到像素级盐体或非盐体分类概率。同时,为了减少数据集中不包含盐体的图片样例对分割结果的干扰,受PSPNet的启发,在编码器末端引入辅助的二分类器用来识别图像中是否包含盐体^[17]。

SK unit结构是USKNet模型架构编码器的主要组成部分,由一个3×3的卷积核和SK卷积构成。SK卷积模块(图2)可分为拆分、融合、选择3个阶段。在拆分阶段,特征图可从多个路径输入,路径数用M表示,当M为2时,分别对应3×3和5×5的卷积核,为了保持感受野的大小且减少参数,使用3×3、空洞数为2的空洞卷积代替5×5的卷积核。受ResNeXt影

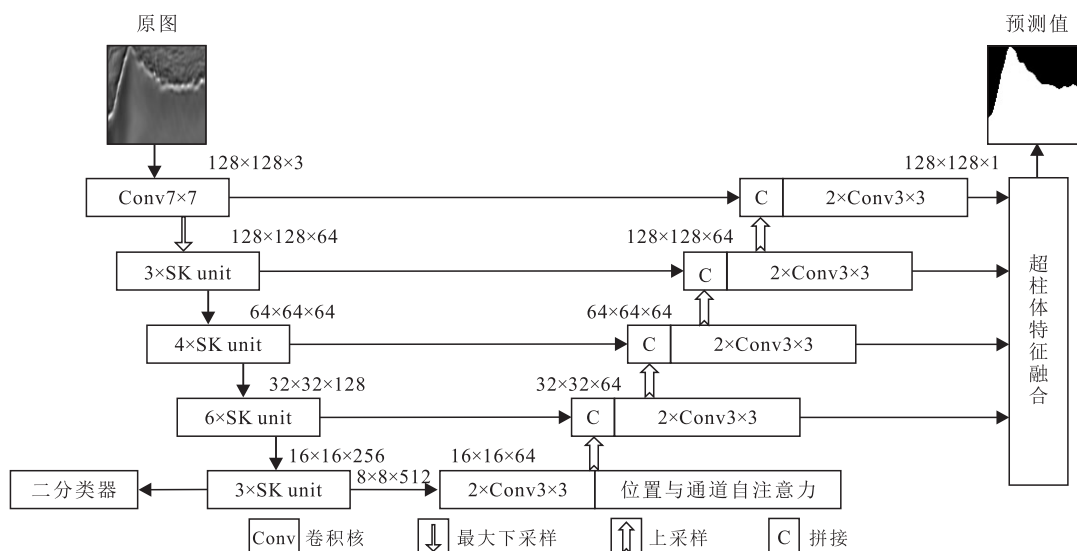


图1 USKNet模型架构

Fig.1 USKNet model architecture

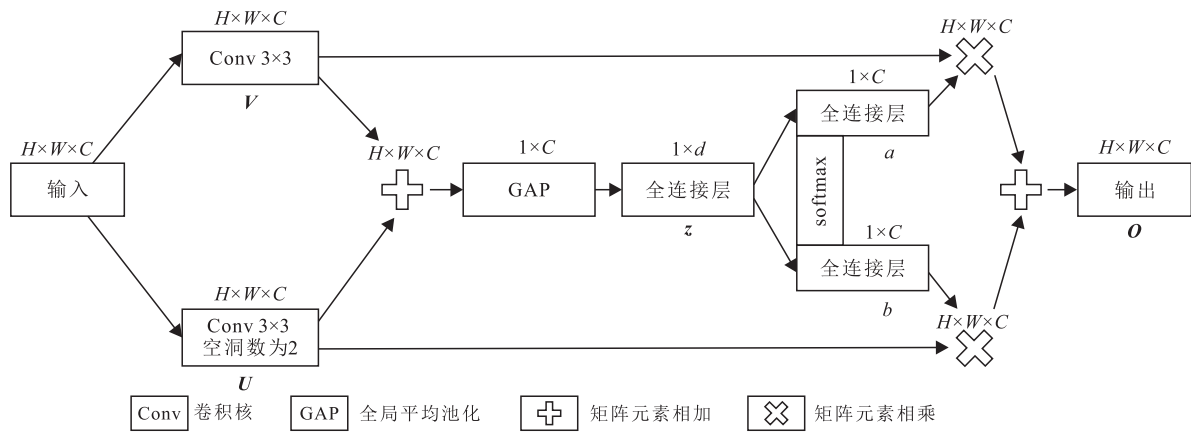


图2 SK卷积模块

Fig.2 SK convolution module

响^[18],在卷积操作时使用了分组卷积,分组数用G表示,设定G为32。在融合阶段,将每个路径得到的特征图相加,之后进行全局平均池化,特征图维度由HxWxC变为1xC,接着通过维度为Cx d的全连接层降维至1xd的输出向量z,d为一个可调节的参数,一般为C/32且最小值为32。在选择阶段,在通道维度上运用softmax函数,通过软注意力机制进行特征图选择,2条路径的注意力权重表达式分别为:

$$a_c = \frac{e^{A_c \cdot z}}{e^{A_c \cdot z} + e^{B_c \cdot z}} \quad (1)$$

$$b_c = \frac{e^{B_c \cdot z}}{e^{A_c \cdot z} + e^{B_c \cdot z}} \quad (2)$$

当M=2时,各通道对应特征图矩阵的表达式为:

$$O_c = a_c \cdot V_c + b_c \cdot U_c \quad (3)$$

其中:

$$a_c + b_c = 1 \quad (4)$$

自注意力机制是获得长距离依赖的一种方式,可动态地生成不同连接的权重,通常采用查询、键、值模式,其表达式为:

$$O = X \text{softmax} \left(\frac{K^T Q}{\sqrt{D_k}} \right) \quad (5)$$

编码器和解码器的中间部分为位置和通道自注意力机制模块(图3)。位置自注意力机制模块将输入的特征图通过3个卷积操作分别得到特征图D、E和F,其中特征图D和E经过维度调整和softmax函数运算得到维度为(HxW)x(HxW)的矩阵,此矩阵表示特征图D和E不同位置的相关性,2个位置的特征表示越相似,其相关性就越大。通道自注意力机制模块经过维度调整和softmax函数运算得到维度为Cx C的矩阵,此矩阵表示通道之间的互相影响程度。为了充分利用长距离依赖信息,对这2个自注意力机制模块得到的特征图进行聚合。

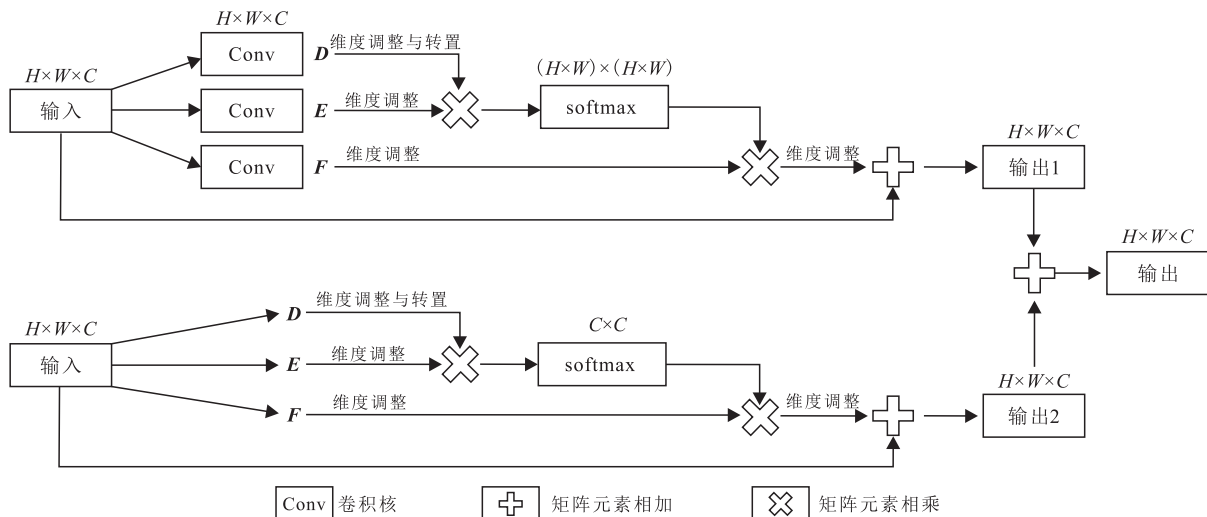


图3 位置和通道自注意力机制模块

Fig.3 Position and channel self-attention mechanism module

2 数据准备

2.1 数据集预处理

TGS盐体识别数据集由包含标签的4 000个训练集数据和不包含标签的18 000个测试集数据组成,每个数据是由地下三维地震数据进行二维切片得到的单通道灰度图像,像素为101×101。标签图像掩码分为2类,即255(白色)代表盐体,0(黑色)代表非盐体。在数据集中,由于每张图像盐体分布不均衡,在划分训练集与验证集时,为了数据分布的

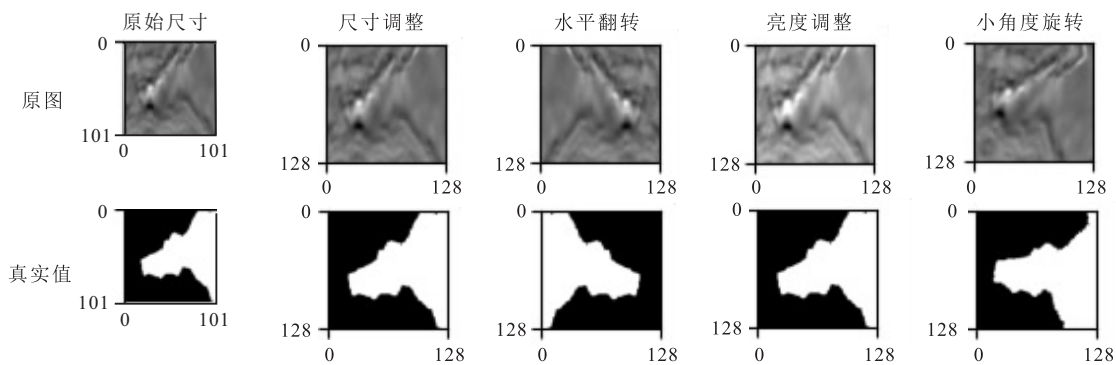


图4 数据增强

Fig.4 Data augmentation

不包含盐体,盐体占比不为0表示包含盐体。二分类器的优化运用二值交叉熵(BCE)损失函数计算,其表达式为:

$$L_{\text{BCE}}(y, \hat{y}) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (6)$$

对于盐体的语义分割,由于盐体与非盐体占比较不平衡且优化的目标是交并比(IoU),故二值交叉熵损失函数不适用。同时交并比损失函数是非凸的,不易收敛到最小值,因此选择lovasz-hinge损失函数来优化分割效果^[19]。盐体的分割损失和辅助损失总和的表达式为:

$$L = L_{\text{lovasz-hinge}}(g_{\text{all}}, \hat{p}_{\text{all}}) + \alpha L_{\text{BCE}}(y, \hat{y}) + \beta L_{\text{lovasz-hinge}}(g_{\text{have-salt}}, \hat{p}_{\text{have-salt}}) \quad (7)$$

二分类器为辅助损失,在整体损失中占比较小,本模型中 α 取值为0.05;在数据集中,盐体占比较多的图像约占50%,本模型中 β 取值为0.5。

3 模型训练

3.1 评价指标

在语义分割中,通常采用像素准确率(PA)和交并比来衡量真实值与预测值的差距,评价指标的范围都为[0, 1],数值越大表示真实值与预测值的差

一致性,按盐体占比为4:1的比例进行分层抽样,得到3 200个数据的训练集和800个数据的验证集。在预处理时,先将每张图像的像素从101×101调整至128×128,以便更易使用卷积操作;再使用数据增强技术来扩充训练集,考虑到盐体分布与深度具有一定的关系,因而避免使用垂直翻转操作。对原始图像尺寸调整后,按随机概率通过水平翻转、亮度调整、小角度旋转来数据增强(图4)。

2.2 损失函数优选

对于判断是否包含盐体的二分类器,其所需要的标签可根据盐体占比来获得,盐体占比为0表示

距越小。像素准确率和交并比的表达式分别为:

$$PA = \frac{TP + TN}{TP + FP + TN + FN} \quad (8)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (9)$$

3.2 训练过程

为节省训练时间,结合迁移学习的方法,编码器使用了在ImageNet数据集上预训练的SKNet34。由于预训练模型需要输入三通道路图像进行归一化,因此将灰度图像通过Open CV以彩色模式读取再输入模型,训练集与验证集比例为4:1,设置batchsize为32,优化算法为SGD,初始学习率为0.01,学习率调整策略采用余弦退火策略^[20],其表达式为:

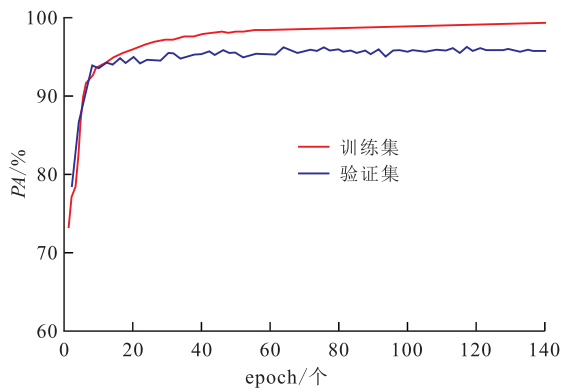
$$\eta_t = \eta_{\min}^i + \frac{1}{2} (\eta_{\max}^i - \eta_{\min}^i) (1 + \cos \frac{T_{\text{cur}}}{T_i} \pi) \quad (10)$$

模型训练了140个epoch,每2个epoch进行一次验证并保存IoU最高的模型权重,得到训练集与验证集的PA及IoU曲线(图5)。

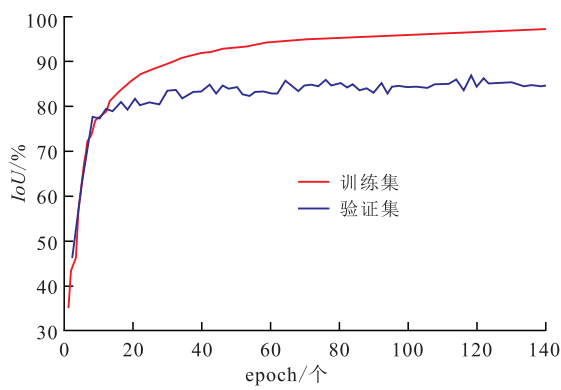
4 结果分析

4.1 不同损失函数对USKNet的影响

为了探究不同损失函数对盐体的语义分割效



a—训练集与验证集的PA曲线



b—训练集与验证集的IoU曲线

图5 训练集与验证集的PA和IoU曲线

Fig.5 PA and IoU curves of training set and validation set

果,对比了dice与lovasz-hinge损失函数。从USKNet在2种损失函数下的评价指标(表1)可以看出,采用lovasz-hinge损失的IoU和PA比dice损失分别提高2.16%和0.6%。结果表明,lovasz-hinge损失函数更适用于盐体的语义分割。

表1 不同损失函数对USKNet的影响

Table1 Influence of different loss functions on USKNet %

损失函数	评价指标	
	IoU	PA
dice	83.50	95.5
lovasz-hinge	85.66	96.1

4.2 SKNet与自注意力机制对USKNet的影响

为验证SKNet提取盐体特征的有效性和自注意力机制的效果,在使用辅助损失函数和超柱体方法的前提下,SKNet+U-Net的方法在IoU和PA上比U-Net分别提高了7.18%和2.0%;加入自注意力机制后,IoU和PA又分别提高了0.95%和0.2%,证明SKNet与自注意力机制可有效提高盐体识别效果(表2)。

4.3 USKNet与其他模型对比

将USKNet与U-Net,PSPNet盐体的语义分割评

表2 SKNet与自注意力机制对USKNet的影响

Table2 Influence of SKNet and self-attention mechanism on USKNet %

模型	评价指标	
	IoU	PA
U-Net	77.53	93.9
SKNet+U-Net	84.71	95.9
SKNet+U-Net+self-attention	85.66	96.1

价指标(表3)进行对比,USKNet在IoU和PA上都具有较大优势。从不同盐体占比图像在3种模型下的语义分割效果(图6)可以看出,USKNet在边界处分割的更清晰,在面对小目标盐体和复杂盐体形状时也更具有鲁棒性。

表3 不同模型下盐体的语义分割评价指标

Table3 Evaluation indexes of semantic segmentation of salt bodies by different models %

模型	评价指标	
	IoU	PA
U-Net	74.67	93.0
PSPNet	75.27	93.2
USKNet	85.66	96.1

5 结束语

USKNet模型可自适应地获取不同大小感受野的盐体特征,同时通过位置与通道自注意力机制来增强盐体特征表示,进一步提升了盐体识别效果,改善了盐体边界、狭长处和小目标盐体的语义分割效果。但本文提出的模型只验证了在二维地震图像上具有较好的盐体识别效果,对于三维地震数据,实际应用中更需要准确地识别出三维盐体形状,未来的研究工作聚焦于将该方法推广到三维地震数据以便提高模型在不同地质环境下的泛化能力。

符号解释

- a, b ——特征图V和U的注意力权重;
- a_c, b_c ——a和b的第c个注意力权重;
- A, B ——全连接层的权重矩阵;
- A_c, B_c ——A和B第c个行向量;
- C——特征图的通道数,维;
- c——通道序号;
- D, E, F, U, V ——特征图矩阵;
- D_k ——归一化因子;
- FN——假阴性,预测值为非盐体而真实值为盐体;

模型	盐体的语义分割					
原图						
真实值						
U-Net						
PSPNet						
USKNet						

图6 不同模型下盐体的语义分割效果

Fig.6 Results of semantic segmentation of salt bodies by different models

FP ——假阳性,预测值为盐体而真实值为非盐体;
 g_{all} ——所有输入图像的真实掩码值;
 $g_{have - salt}$ ——输入图像中包含盐体的真实掩码值;
 G ——分组数;
 H ——特征图的高度;
 i ——启动训练的次数;
 IoU ——交并比;
 K ——键向量组成的矩阵;
 L ——分割损失和辅助损失的总和;
 $L_{lovasz - hinge}$ ——lovasz-hinge 损失;
 L_{BCE} ——二值交叉熵损失;
 M ——路径数,个;
 O ——自注意力机制的输出矩阵;
 O_c ——通道 c 对应的特征图矩阵;
 PA ——像素准确率, %;
 \hat{p}_{all} ——所有数据对应的预测像素级概率;
 $\hat{p}_{have - salt}$ ——包含盐体数据对应的预测像素级概率;
 Q ——查询向量组成的矩阵;
 t ——迭代次数;
 TN ——真阴性,预测值和真实值都为非盐体;
 TP ——真阳性,预测值和真实值都为盐体;
 T_{cur} ——目前已完成的 epoch 数,个;
 T_i ——第 i 次启动时的 epoch 数,个;
 U_c ——特征图 U 的第 c 个通道对应的矩阵;

V_c ——特征图 V 的第 c 个通道对应的矩阵;
 W ——特征图的宽度;
 X ——值向量组成的矩阵;
 y ——标签值;
 \hat{y} ——预测的概率;
 z ——全连接层的输出向量;
 α, β ——损失函数影响因子;
 η_{max}^i ——第 i 次启动时的学习率最大值;
 η_{min}^i ——第 i 次启动时的学习率最小值;
 η_t ——第 t 次迭代时的学习率。

参考文献

[1] 余一欣,周心怀,彭文绪,等.盐构造研究进展述评[J].大地构造与成矿学,2011,35(2):169-182.
 YU Yixin, ZHOU Xinhui, PENG Wenxu, et al. An overview on salt structures [J]. Geotectonica et Metallogenia, 2011, 35 (2) : 169-182.
 [2] 史帅雨,余一欣,殷进垠,等.下刚果盆地盐构造变形特征及其形成机理[J].石油与天然气地质,2020,41(5):1 092-1 099.
 SHI Shuaiyu, YU Yixin, YIN Jinyin, et al. Deformation characteristics and formation mechanism of salt structure in the Lower Congo Basin [J]. Oil & Gas Geology, 2020, 41 (5) : 1 092-1 099.
 [3] 王鹏飞,霍春亮,叶小明,等.伊拉克BU油田碳酸盐岩储层沉积过程数值模拟[J].油气地质与采收率,2019,26(4):56-61.
 WANG Pengfei, HUO Chunliang, YE Xiaoming, et al. Numerical

- simulation of sedimentary process for carbonate reservoir in BU Oilfield, Iraq [J]. *Petroleum Geology and Recovery Efficiency*, 2019, 26(4): 56-61.
- [4] 李阳, 代宗仰, 黄蕾, 等. 叠合概率法在碳酸盐岩储层评价中的应用——以辽河拗陷西部凹陷高升地区沙四段为例[J]. *中国石油勘探*, 2019, 24(3): 361-368.
LI Yang, DAI Zongyang, HUANG Lei, et al. Application of overlapping probability method in carbonate reservoir evaluation: a case study on 4th member of Shahejie Formation in Gaosheng area of western sag, Liaohede depression [J]. *China Petroleum Exploration*, 2019, 24(3): 361-368.
- [5] 刘静静, 邬长武, 丁峰. 南大西洋两岸含盐盆地类型与油气分布规律[J]. *石油实验地质*, 2018, 40(3): 372-380.
LIU Jingjing, WU Changwu, DING Feng. Basin types and hydrocarbon distribution in salt basins in the South Atlantic [J]. *Petroleum Geology & Experiment*, 2018, 40(3): 372-380.
- [6] 龚兵, 杨峰, 胡博宇. 江汉盆地潜江组盐间页岩油藏储层盐析伤害特征[J]. *特种油气藏*, 2019, 26(6): 141-145.
GONG Bing, YANG Feng, HU Boyu. Salting-out damage of inter-salt shale oil reservoirs in the Qianjiang Formation of Jianghan Basin [J]. *Special Oil & Gas Reservoirs*, 2019, 26(6): 141-145.
- [7] 邵红梅, 卢曦, 高波, 等. 微区原位地球化学分析技术与应用——以古城地区碳酸盐岩储层成岩演化为例[J]. *大庆石油地质与开发*, 2019, 38(5): 160-168.
SHAO Hongmei, LU Xi, GAO Bo, et al. Geochemical analyzing technique of the microzone's normal position and its application: A case study on the diagenetic evolution of the carbonate reservoir in Gucheng area [J]. *Petroleum Geology & Oilfield Development in Daqing*, 2019, 38(5): 160-168.
- [8] WANG Z, DI H, SHAFIQ M A, et al. Successful leveraging of image processing and machine learning in seismic structural interpretation: A review [J]. *The Leading Edge*, 2018, 37(6): 451-461.
- [9] DI H, ALREGIB G. Seismic multi-attribute classification for salt boundary detection—a comparison [C]. Paris: 79th Eage Conference and Exhibition, 2017.
- [10] WALDELAND A U, SOLBERG A. Salt classification using deep learning [C]. Paris: 79th Eage Conference and Exhibition, 2017.
- [11] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 3 431-3 440.
- [12] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]//Proceedings of International Conference on Medical Image Computing and Computer-assisted Intervention. Munich: Springer, 2015: 234-241.
- [13] ISLAM M S U. Using deep learning based methods to classify salt bodies in seismic images [J]. *Journal of Applied Geophysics*, 2020, 178: 104054.
- [14] LI X, WANG W, HU X, et al. Selective kernel networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2019: 510-519.
- [15] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2019: 3 146-3 154.
- [16] HARIHARAN B, ARBELÁEZ P, GIRSHICK R, et al. Hypercolumns for object segmentation and fine-grained localization [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 447-456.
- [17] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 2 881-2 890.
- [18] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 1 492-1 500.
- [19] BERMAN M, TRIKI A R, BLASCHKO M B. The lovasz-softmax loss: A tractable surrogate for the optimization of the intersection-over-union measure in neural networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 4 413-4 421.
- [20] LOSHCHELOV I, HUTTER F. SGDR: Stochastic gradient descent with restarts [J]. *Computing Research Repository*, 2016, abs / 1608.03983.

编辑 何青芳