

碳酸盐岩岩心图像生物扰动强度智能识别方法研究*

芦碧波¹ 何佳康¹ 牛永斌² 沈文启¹ 姚康为¹

1 河南理工大学计算机科学与技术学院, 河南焦作 454003

2 河南省煤系非常规资源成藏与开发重点实验室, 河南理工大学资源环境学院, 河南焦作 454003

摘要 生物扰动是(古)生物在生命活动过程中在沉积物表面或内部形成的各种沉积结构或沉积构造,在分析沉积地层古环境、预测其分布规律、评价烃源岩生烃能力和盖层封堵能力、揭示(古)生物对油气储集层的改造机制和改造效应等方面具有重要应用。传统生物扰动强度分析主要依靠人工识别后对照生物扰动指数图版进行半定量划分,因此受主观因素影响大,执行效率低且结果容易产生较大误差。文中通过引入EMA(Efficient Multi-Scale Attention)注意力机制到ResNet-50模型中,提出了一种加入注意力机制的残差网络模型(Res-EMANet)。该模型在训练过程中采用随机梯度下降算法(Stochastic Gradient Descent, SGD),初始学习率为0.01,权重衰减参数为0.0001;批次大小设置为16,共执行了300个轮次。从准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1分数(F1-score)和混淆矩阵(Confusion Matrix)等5个方面评价了模型结构改进对模型性能的影响,并利用塔里木盆地奥陶系16口取心井3028张含不同等级生物扰动的岩心照片数据集进行了模型检验,结果表明:(1)该模型能够准确划分岩心数字图像上0~5级别的生物扰动强度,准确率高达91%,显著优于传统人工方法和已有的ResNet-50模型。(2)该模型在提升生物扰动等级识别准确度的同时,有效降低了对专家知识的依赖和人工评估生物扰动等级的劳动强度及个人主观性的影响,在生物扰动特征的自动化、智能化和量化分析等方面展现了显著的应用优势。本研究为生物扰动程度评估和识别的自动化处理提供了一款高效可靠的量化分析工具,这对油气勘探领域的沉积学和古生物学研究具有重要意义。

关键词 生物扰动 深度学习 图像分类 碳酸盐岩储集层 奥陶系 塔河油田

第一作者简介 芦碧波,男,1978年生,博士,河南理工大学计算机科学与技术学院教授,主要从事人工智能与图像处理研究工作。E-mail: lubibo@hpu.edu.cn。

通讯作者简介 牛永斌,男,1980年生,博士,河南理工大学资源环境学院教授,主要从事应用遗迹学与沉积学研究工作。E-mail: niuyongbin@hpu.edu.cn。

中图分类号: TP391.41 文献标志码: A

Intelligent identification methods for bioturbation intensity in carbonate rock core images

LU Bibo¹ HE Jiakang¹ NIU Yongbin² SHEN Wenqi¹ YAO Kangwei¹

1 School of Computer Science and Technology, Henan Polytechnic University, Henan Jiaozuo 454003, China

2 Henan Key Laboratory of Coal Measure Unconventional Resources Accumulation and Exploitation, School of Resources and Environment, Henan Polytechnic University, Henan Jiaozuo 454003, China

* 国家自然科学基金项目(编号: 41472104, 42272178)资助。[Financially supported by the National Natural Science Foundation of China (Nos. 41472104, 42272178)]

收稿日期: 2025-01-07 改回日期: 2025-02-25

Abstract Bioturbation refers to various sedimentary textures or structures formed on sediment surfaces or within sediments due to biological activity. It plays a crucial role in analyzing paleoenvironmental conditions in sedimentary strata, predicting distribution patterns, evaluating the hydrocarbon generation capacity of source rocks, assessing the sealing capacity of caprocks, and revealing the mechanisms and effects of bioturbation on hydrocarbon reservoirs. Traditional methods for analyzing bioturbation intensity mainly relies on manual identification, followed by semi-quantitative classification using bioturbation index charts. This approach is highly subjective, inefficient, and prone to large errors. In this paper, we proposed a residual network model that incorporates an attention mechanism (Res-EMANet) by integrating the Efficient Multi-Scale Attention (EMA) mechanism into the ResNet-50 model. During training, the model employs stochastic gradient descent (SGD) with an initial learning rate of 0.01, a weight decay parameter of 0.0001, a batch size of 16, and a total of 300 epochs. Model performance improvements are evaluated based on five aspects: accuracy, precision, recall, $F1$ -score, and the confusion matrix. We validated the model using a dataset of 3,028 core images from 16 wells of the Ordovician in the Tarim Basin, which contain various levels of bioturbation. The results show that: (1) The model can accurately classify bioturbation intensities ranging from level 0 to 5 in digital core images, achieving an accuracy of up to 91%. This significantly outperforms traditional manual methods as well as the original ResNet-50 model. (2) The model not only improves the accuracy of bioturbation grade recognition but also effectively reduces dependence on expert knowledge, as well as the labor intensity and subjectivity associated with manual bioturbation assessments. It demonstrates significant advantages in the automation, intelligence, and quantification of bioturbation feature analysis. This research offers an efficient and reliable quantitative analysis tool for the automated processing of bioturbation degree assessment and identification, which is of great significance to the sedimentology and paleontology studies in the field of oil and gas exploration.

Key words bioturbation, deep learning, image classification, carbonate reservoir, Ordovician, Tahe oilfield

About the first author LU Bibo, born in 1978, is a professor at the School of Computer Science and Technology, Henan Polytechnic University. He is mainly engaged in artificial intelligence and image processing. E-mail: lubibo@hpu.edu.cn.

About the corresponding author NIU Yongbin, born in 1980, is a professor at School of Resources and Environment, Henan Polytechnic University. He is mainly engaged in applied ichnology and sedimentology. E-mail: niuyongbin@hpu.edu.cn.

0 引言

在地质学研究中,生物在生命活动过程中对周围沉积物颗粒所进行的搅动、混合和破坏而形成的各种沉积结构或沉积构造被称为生物扰动 (Hülse *et al.*, 2022)。生物扰动会破坏和蚀变原生沉积的结构或构造,可增强或减弱油气水储集层质量及其流动特性 (Taylor *et al.*, 2003)。为了表征原始沉积地层被生物改造的程度,地质学家会评估沉积物受生物扰动的程度从而得到生物扰动指数 (Bioturbation Index, BI),用于解释沉积环境和识别关键地层表面,确定源岩潜力、储集层质量和石油系统

建模 (Miller and Smail, 1997; Dey and Sen, 2017)。因此,生物扰动的定量表征对重建生物生存的(古)环境和(古)生态以及研究生物扰动对储集层的改造效应具有重要意义 (牛永斌等, 2017)。

早期关于生物扰动程度的描述主要采用定性方法 (牛永斌等, 2023)。Reineck (1963) 根据生物扰动破坏的面积百分含量,提出“生物扰动指数”术语,为该领域研究奠定了基础。Taylor 和 Goldring (1993) 根据野外露头上受生物扰动或生物挖掘的沉积物在整个沉积物中的占比来定义生物扰动指数,使采用生物扰动指数表征生物扰动程度

进一步标准化。为了对岩心段的生物扰动和遗迹组构进行分析, Knaust (2012) 提出了针对岩心的划分方案。

近年来, 机器视觉在生物扰动图像分析领域已被广泛应用。Dorador 等 (2014) 利用相似像素选择法 (SPSM) 突出显示生物扰动区域, 通过直方图确定生物扰动区域的像素占比来划分生物扰动程度。Miguez-Salas 等 (2019) 使用 Fiji 和 ICY 软件, 通过限制对比度自适应直方图均衡化 (CLAHE) 方法提高扰动痕迹的可见度, 并使用 K-Means 聚类算法计算出阈值, 将图像二值化, 从而区分出扰动与非扰动区域, 计算两者比例得到生物扰动指数。Timmer 等 (2016) 开发了一款 PyCHNO 软件帮助研究者更高效地分段标注整个岩心的生物扰动指数, 提高了数据采集的效率和标准化程度, 也为遗迹化石数据采集提供了一种有效方法。以上研究成果表明, 主流的划分生物扰动指数的方法以人工视觉对比或主观判断为主, 需要具有一定的先验知识, 专业化程度高, 且非常耗费时间与精力。

随着人工智能算法被广泛地应用在地质领域的研究中, 基于深度学习的图像识别技术也被应用于岩心生物扰动强度的分析 (牛永斌等, 2021; 周永章等, 2021; 刘合等, 2024)。Timmer 等 (2021) 提出了一个深度学习模型, 该模型可以对图像中是否包含生物扰动痕迹的二分类岩心图像进行区分, 准确度达到了 88%。Ayranci 等 (2021) 提出了一种基于 VGG-16 模型的分类型算法, 实现了无扰动 (0)、中等扰动 (1%~30%) 和强扰动 (31%~100%) 的三分类, 准确度达到 84.9% 以上。Kikuchi 和 Naruse (2024) 使用 1151 张岩心图像切片训练具有残差连接和注意力机制的 U-Net 模型, 实现了对岩心背景、露头 and 遗迹化石的区域像素分类, 在测试集中准确度 (Dice 系数) 达到 89.2%。然而以上模型由于未能识别和区分出不同类别间的相似特征, 导致岩心上的生物扰动特征划分类别有限。

基于此, 笔者首先构建了塔河油田奥陶系岩心图像数据集, 并通过数据增强等方法解决了数据集的类别不平衡和样本不足问题。其次, 针对岩心图像多样性和扰动痕迹的复杂性, 本研究在 ResNet-50 模型的卷积层中引入了 EMA 注意力 (Efficient Multi-Scale Attention) 机制得到 Res-EMANet 模型,

以更有效地提取生物扰动特征。最后, 通过多个对比实验测试模型的准确率。本研究为生物扰动程度评估和识别的自动化处理提供了一款高效可靠的定量化分析工具, 这对油气勘探领域的沉积学和古生物学研究具有重要意义。

1 材料与方 法

1.1 数据集介绍

在油气、含水层和深海钻探计划的勘探过程中, 钻井取得的岩心是地下生物遗迹和沉积学信息的宝贵来源 (Sterling, 2011)。文中选用新疆塔里木盆地塔河油田的奥陶系碳酸盐岩岩心作为研究对象。塔河油田面积近 2400 km², 位于新疆维吾尔自治区塔里木盆地北缘, 地处轮台县和库车县境内 (张抗, 1999)。塔河油田是中国发现的第 1 个陆上海相古生界超亿吨级大油田, 奥陶系碳酸盐岩被认为是该地区主要的含油气层系之一 (鲁新便等, 2015; 金强等, 2020)。塔河油田奥陶系碳酸盐岩生物扰动强烈, 具有很好的储集性能, 是潜在的高质量油气储集层 (艾合买提江等, 2010; 赵佳如等, 2021; Eltom *et al.*, 2023)。

文中采用 Knaust (2017) 提出的生物扰动等级划分标准 (0~5 级), 该方法适合岩心描述, 通过等比划分生物扰动等级, 能够更好地对不同单元进行定量和统计分析。为了消除人工分类的主观影响, 笔者在划分生物扰动指数前, 对岩心图像先进行了地质研究校验和图像分析软件处理, 之后再对岩心图像中生物扰动区域进行识别和定量表征。图 1 展示了从 0 级 (无生物扰动) 到 5 级 (完全扰动) 生物扰动的特征, 包括各等级的扰动量范围、碳酸盐岩相及其对应的图像分析软件处理得到的生物扰动痕迹。

文中选取塔河油田 16 口取心井 982 m 奥陶系碳酸盐岩岩心扫描图像 (分辨率 5000×1000) 作为研究对象。经过观测和统计发现, 岩心上的生物扰动区域表现为扁圆形椭圆状、斑状、网状或绸带状等形态, 且多被沥青质重油浸染 (牛永斌等, 2020)。如图 2 所示, 生物扰动部分在外观上形态各异 (带状、斑状), 多被油气充填, 颜色较深, 而围岩基质未见油气充填, 颜色较浅。在矿物组成上, 生物扰动部分多发生白云石化, 围岩基质多为

BI 指数	特征	生物扰动量/%	碳酸盐岩岩相	生物扰动痕迹
0	无生物扰动	0		
1	生物扰动稀少, 层理明显, 很少有离散的痕迹	0~20		
2	生物扰动不常见, 层理明显, 痕量密度低	20~40		
3	中度生物扰动, 层理边界清晰, 痕迹离散, 重叠罕见	40~60		
4	常见的生物扰动, 层理边界模糊, 痕迹密度高, 重叠常见	60~80		
5	生物扰动丰富, 层理完全扰动 (仅可见)	80~100		

图 1 岩心生物扰动图版
Fig. 1 Plate of core bioturbation

泥晶灰岩 (牛永斌等, 2018)。

为了增强模型对生物扰动痕迹特征的识别能力, 减少过拟合现象, 将图 2-a 中 S80 井岩心图像均匀划分为 150×150 像素的图像块。图 2-b 展示了切分后的图像块按照 Knaust 标准 (2002) (表 1) 划分的生物扰动指数, 用于反映不同区域的生物扰动程度。图 2 中黑色斑块区域代表重油污染的遗迹潜穴。而标记红色虚线的图像 (图 2-b) 含非生物扰动区域, 不加入模型的训练, 避免干扰模型训练结果。


表 1 扩充后的塔里木盆地奥陶系生物扰动岩心图像数据集
Table 1 Expanded core photo dataset of bioturbation from the Ordovician in Tarim Basin

数据集类型	生物扰动指数					
	0	1	2	3	4	5
总数据集	533	379	569	567	464	516
训练集	426	199	432	453	371	412
测试集	54	26	54	58	47	53
验证集	53	24	54	56	56	51

1.2 数据增强

1.2.1 特殊等级图像生成

塔河油田奥陶系岩心中生物扰动区域普遍发生白云石化作用, 该成岩过程改变了储集物性特征 (刘大卫等, 2025), 具体表现为白云石化作用提高了岩石的孔隙度和渗透率, 使得生物扰动区域更易成为油气充填的对象, 颜色较深 (Niu *et al.*,



a—塔河油田, 奥陶系, S80 井, 生物扰动岩心图像 (箭头指示的潜穴); b—划分生物扰动等级后的岩心图像块
图 2 标注岩心生物扰动指数示意图

Fig. 2 Schematic diagram of bioturbation index of labeled core

2022)。即使生物扰动区域未经油气充填，但其矿物成分中白云石的含量较高，岩心在地表风化后颜色也较围岩基质更深。因此，岩心上生物扰动区域与围岩基质常呈现显著色差，且该特征在油气充注条件下更为显著。基于此，数字图像分析显示生物扰动区域多对应 0~255 灰度谱系中较低像素值的色阶范围（牛永斌等，2017）。

由于无生物扰动痕迹（BI=0）与完全扰动改造（BI=5）的塔河油田奥陶系岩心样本相对少见，这使得 BI=0 和 BI=5 的岩心图像数量稀少，造成各类别之间数据不均衡，导致模型在训练过程中对少数类样本的识别能力下降，影响最终的分类结果。为此，需要对岩心数据集进行采样，以生成 BI=0 和 BI=5 的岩心图像以扩充数据集。图 3-a 表示生成 BI=0 的岩心图片，方法是从 21 张 BI=0 岩心图片中随机选取 3 张图像对应位置的像素值相加取平均值，得到 1 张 BI=0 图像，这样做可以保留原本稀少的扰动痕迹信息，又能有效减少图像上干扰区域的影响，提高图像的整体质量与可解析性；图 3-b 表示生成 BI=5 的岩心图片，但由于井下岩心图像上扰动区域面积大于 80% 的岩心图像（BI=5）少，因此从 BI=4 的岩心图像中随机选取 3 张图像对应位置的像素值取最小值，达到扩大扰动区域面积效果，从而获得达到 BI=5 标准的岩心图像。最后通过图像处理软件，根据 Knaust 标准从生成的图像中筛选出符合实际的 533 张 BI=0 的岩心图像和 516 张 BI=5 的岩心图像，确保每个扰

动等级的图像数量充足且分布均匀。然后将这些图像与原始岩心图像组成塔里木盆地奥陶系生物扰动岩心照片数据集并按照 8:1:1 的比例进行划分（表 1），扩充后的数据集共计 3028 张图片。

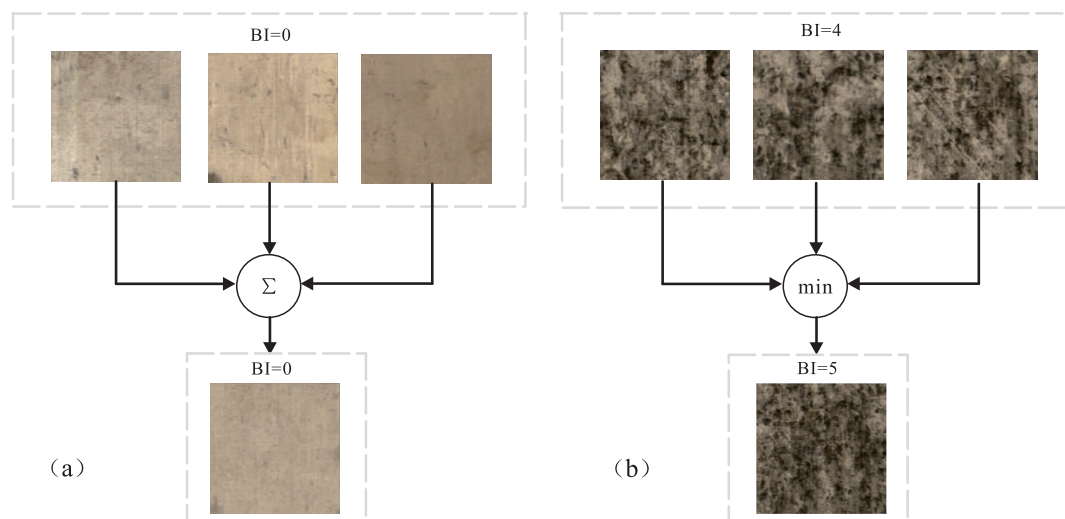
1.2.2 图像扩充

为了增加岩心图像的多样性，防止模型过拟合，随机地对岩心图像分别采用旋转、翻转和平移的数据增强操作。图 4-a 是原始生物扰动岩心图片，图 4-b、4-c 和 4-d 分别对原始图像做旋转、翻转和平移，使生物扰动痕迹位置多变，从而降低模型对角度和目标位置的敏感度，为模型提供丰富的生物扰动岩心图像信息。此操作不仅提高了数据集的完整性，也增强了深度学习模型在实际应用中的可靠性和准确性。

1.3 优化方法

1.3.1 EMA 注意力


由于生物扰动岩心的图像特征不明显，且数据集偏少，因此传统的特征提取方法可能难以有效捕捉到关键的生物扰动特征。为了加强模型在岩心图像上生物扰动痕迹特征的提取能力，笔者引入 EMA（Efficient Multi-Scale Attention，高效多尺度注意力）机制，提升模型全局信息捕获能力（Ouyang *et al.*, 2023）。EMA 将输入特征图划分为多个子特征，并通过对这些子特征的学习和编码，实现跨通道的交互和局部特征的捕获，使模型能够动态关注相关的扰动痕迹区域。



a—生成 BI=0 图像块；b—生成 BI=5 图像块。 Σ 表示图像对应位置的像素值相加取平均值；min 表示图像对应位置的像素取最小值

图 3 扩充生物扰动岩心图像块

Fig. 3 Enlarge bioturbation core image block



a—原图；b—随机旋转；c—翻转；d—平移

图 4 数据增强岩心图像结果

Fig. 4 Data-augmented core images

如图 5 所示，对于输入特征图 $X \in \mathbb{R}^{C \times H \times W}$ ，EMA 将其划分为 G 个子特征，用于学习不同语义。为聚合多尺度空间信息，EMA 将 1×1 卷积分支和 3×3 卷积分支并行放置。在 1×1 卷积分支中，利用全局平均池化对通道沿水平和垂直方向编码，并通过 2 个 Sigmoid 函数拟合二维分布，最后经过乘法结合通道间的注意力特征，实现跨通道的交互。在 3×3 卷积分支中，使用 3×3 卷积捕获局部跨通道特征，增强特征空间表达。基于此方式，EMA 不仅编码了通道间信息以调整不同通道的重要性，而且将精确的空间结构信息保留到通道中，同时也利用二维全局平均池化对 1×1 分支和 3×3 分支的输出进行全局空间信息编码。最后，将上述并行处理的输出与矩阵点积运算相乘，从而得到 2 张空间注意力图，其能够保留精确的空间位置信息，并通过聚合空间注意力权重值得到输出。通过这样的流程，EMA 可以更好地处理稀疏且信息量有限的数，且在处理复杂场景和捕获多尺度特征方面表现出明显优势，显著提升了模型对岩心图像中细微扰动特征的识别和表达能力。

1.3.2 Res-EMANet 模型

ResNet-50 模型在减少模型参数的同时，又可以保持网络的高效表征能力，有效缓解了深度学习中常见的梯度消失问题 (He *et al.*, 2016)。近年

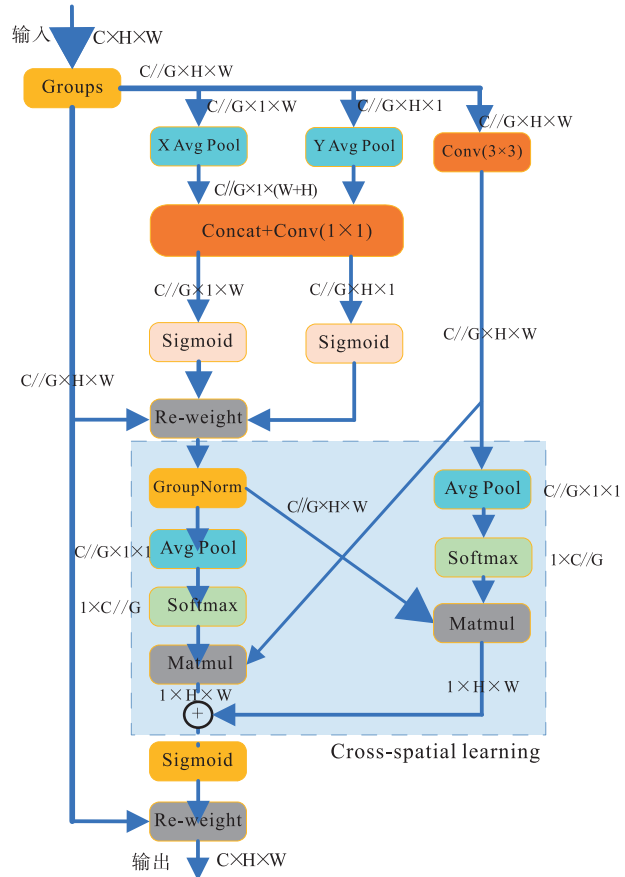


图 5 EMA 注意力机制

Fig. 5 Efficient multi-scale attention

来，ResNet 被广泛应用于地质领域，在预测分类方面具有精度高的优点 (刘大锰等, 2024; 刘艳如等, 2025)。然而，其在处理塔河岩心图像中生物扰动复杂特征提取时仍然存在局限性。为了解决塔河岩心图像中的生物扰动特征在不同井下岩心上的表现不一及特征提取困难，笔者通过在 ResNet-50 模型上引入 EMA 注意力机制，提出 Res-EMANet 模型。

具体模型结构如图 6 所示，Res-EMANet 使用 ResNet-50 的前层作为特征提取器，这些层能够捕获图像的低级到中级特征。在 ResNet-50 的 STAGE4 之后，引入 EMA 模块聚合多尺度空间信息，以增强模型对扰动痕迹特征的提取能力。在引入 EMA 模块之后，该模型通过全局平均池化层和全连接层得到最终的分类结果。

EMA 机制的引入，使 Res-EMANet 模型不仅可以提高对细节和复杂特征的捕捉能力，还能增强模型的泛化能力。通过动态调整特征图通道的权重，

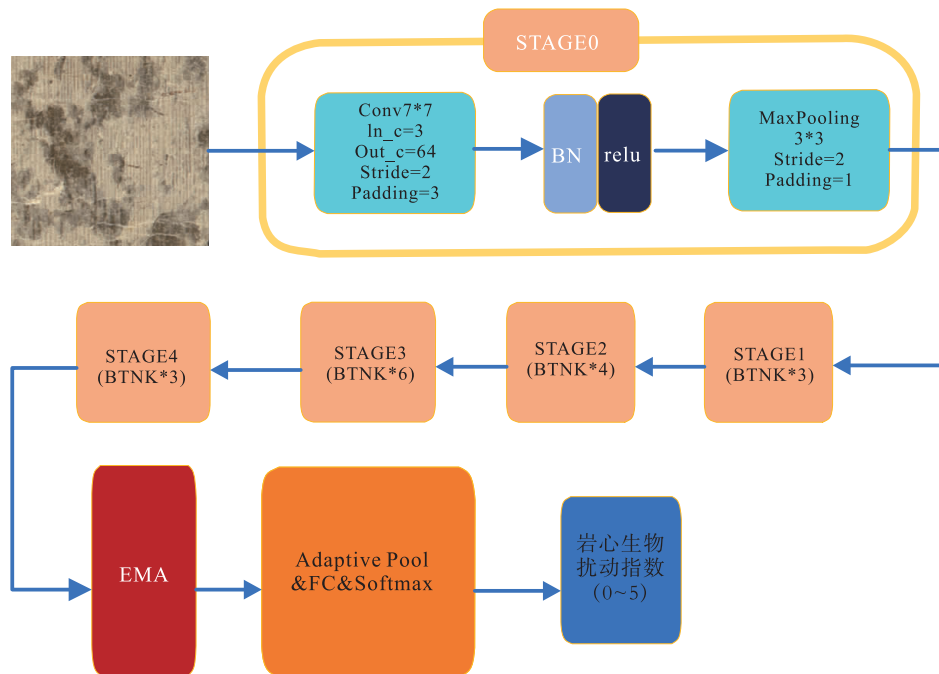


图 6 Res-EMANet 网络结构

Fig. 6 Network structure of Res-EMANet model

使得模型能够集中关注图像中的关键扰动区域，减少模型对训练数据中噪声和非关键特征的学习，从而不仅能够有效地提高模型在塔河岩心数据集上对生物扰动特征的识别能力，还可以有效降低过拟合的风险。

1.4 实验设计

本研究采用随机梯度下降 (Stochastic Gradient Descent, SGD) 优化器，初始学习率为 0.01，权重衰减参数为 0.0001，以有效防止过拟合现象。训练过程中，批次大小为 16，总共执行 300 个轮次。

为全面评估所提出的结构改进对模型性能的影响，实验采用了 4 项核心评估指标：准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、F1 分数 (F1-score) 和混淆矩阵 (Confusion Matrix)。这些指标为分析模型在各个方面的性能表现提供了重要依据 (周程阳等, 2024)。

准确率 (A): 模型预测正确的样本占有所有样本的比例，衡量模型的整体表现。在文中，模型预测正确样本指模型输出与前期地质研究结果及图像软件计算的生物扰动面积占比 (符合 Knaust 分级标准) 同时一致的样本，公式为：

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

其中， TP (True Positives) 表示真正例的数量， TN (True Negatives) 表示真负例的数量， FP (False Positives) 表示假正例的数量， FN (False Negatives) 表示假负例的数量。

精确率 (P): 预测为正样本的所有实例中，实际为正样本的比例。公式为：

$$P = \frac{TP}{TP + FP} \quad (2)$$

召回率 (R): 所有实际正样本中被正确预测为正样本的比例。召回率衡量了模型对正类的敏感性。公式为：

$$R = \frac{TP}{TP + FN} \quad (3)$$

F1 分数 ($F1$): 是精确率和召回率的调和平均值，综合考虑模型的精确性和识别率。公式为：

$$F1 = \frac{2 \times P \times R}{P + R} \quad (4)$$

混淆矩阵通过展示模型预测结果的分类情况，帮助理解模型在各类上的准确性和错误类型。

2 结果

2.1 消融实验

为了评估 Res-EMANet 模型与其他注意力机制

在塔河岩心数据集性能上的差异，笔者进行了详细的实验对比（表 2）。

表 2 中的结果表明，ResNet-50 网络基础模型的各项指标相对较低，而通过引入了不同注意力机制后，模型的整体性能都有所提升。特别是，整合了 EMA 注意力机制的 Res-EMANet 模型在各项性能指标上均超越了使用 CA（Channel Attention）、CBAM（Convolutional Block Attention Module）、SE（Squeeze-and-Excitation）和 ECA（Efficient Channel Attention）注意力机制的模型（Hu *et al.*, 2018; Woo *et al.*, 2018; Wang *et al.*, 2020; Hou *et al.*, 2021）。

具体来说，Res-EMANet（+EMA）的各项指标均为最高，其准确率、精确率、召回率和 F1 分数分别为 91.45%、92.22%、91.42% 和 91.54%，相较于基础的 ResNet-50 模型，准确率提升了 4.72 个百分点，精确率提升了 5 个百分点，说明 EMA 机制的引入显著提升了模型识别生物扰动区域的能力。相比之下，CA 机制的准确率和精确率分别为 88.03%、88.15%，不及其他更为复杂的注意力机制，且相比基础网络提升不高，这是由于其对空间信息的处理不足，导致难以有效区分岩心图像中的细微扰动特征所致。同时，ECA 机制通过轻量级的通道重要性校准，准确率达到 89.64%，但受到其简单结构的限制，在复杂的岩心图像上的表现不及 EMA 机制。采用通道和空间 2 种注意力的 CBAM 机制和专注于通道维度注意力的 SE 机制，在文中数据集上的准确率也都达到 89.32%，但其可能未能充分提取岩心图像的复杂特征，导致其效果同样低于 EMA。总体而言，EMA 注意力机制具有处理多尺度特征和动态聚焦关键区域的能力，使得其在塔河油田奥陶系岩心图像数据集上的性能优于其他注意力机制。

2.2 对比实验

实验选取 Res-EMANet 模型，和其他当下流行的多种图像分类模型进行实验对比，以验证该模型的有效性，对比模型包括 ResNet-50、Vgg-19、DenseNet121 和 EfficientNet-B0（Simonyan and Zisserman, 2014; Huang *et al.*, 2017; Tan and Le, 2019）。分别使用上述模型对文中的塔河岩心生物扰动数据集进行训练，记录每个训练周期的训练集准确率和测试准确率，以便及时掌握模型的训练情况，确保各个模型在收敛的状态下完成训练。训练过程可视化如图 7 所示，其展示了 5 种卷积神经网络模型在训练集和验证集上的准确率曲线。

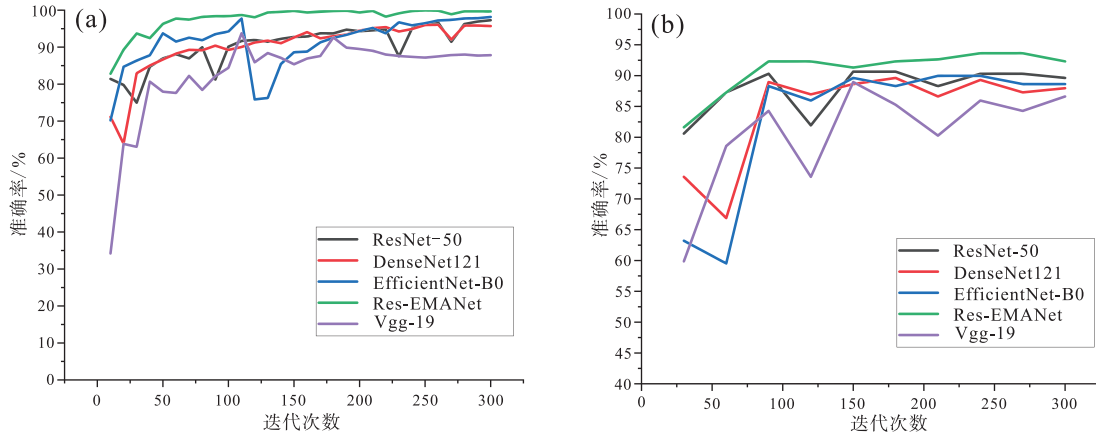
总体观察不同模型在训练集和验证集上的准确率，发现所有模型 Train_acc 和 Val_acc 在 50 轮之前呈现显著上升趋势，但在之后 ResNet-50、DenseNet121 和 Res-EMANet 开始趋于稳定，而 Vgg-19 和 EfficientNet 的 Train_acc 曲线具有很大的波动。这说明 ResNet-50 和 DenseNet 通过引入残差连接和密集连接，促进了梯度的有效流动和信息的传递，从而在训练过程中表现出更好的稳定性和收敛性。而 Vgg-19 采用的简单堆叠结构以及 EfficientNet 为追求效率而采用的深度可分离卷积等轻量化设计，虽然在参数效率上具有优势，但也限制了特征的有效传递，使得模型在面对本研究的复杂数据集时易出现优化不稳定的问题。

具体分析表明，Res-EMANet 模型在训练和验证阶段均展现出显著优势，其训练准确率在收敛后能稳定保持在 95% 的高精度水平，而其他模型的训练精度则在 85%~95% 区间大幅波动；在验证阶段，Res-EMANet 同样表现出强大的泛化能力，验证准确率稳定维持在 91% 左右，而其他模型的验证性能则存在明显的波动和衰减现象。这是因为

表 2 各种注意力机制在塔河油田奥陶系岩心图像数据集数据集上的测试结果

Table 2 Test results of various attention mechanisms on core image dataset of the Ordovician in Take Oilfield

方法	主干网络 (Backbone)	准确率 (A) / %	精确率 (P) / %	召回率 (R) / %	F1 分数 / %
Baseline		86.73	87.22	87.13	87.07
+SE		89.32	89.80	89.70	89.62
+CBAM	ResNet-50	89.32	90.25	89.07	89.54
+CA		88.03	88.15	88.83	88.28
+ECA		89.64	90.22	90.06	89.95
+EMA		91.45	92.22	91.42	91.54



a—训练集准确率 (Train_acc); b—验证集准确率 (Val_acc)

图 7 5 种模型训练准确率、验证准确率曲线

Fig. 7 Training accuracy and validation accuracy curves of five models

EMA 机制使得 Res-EMANet 模型能够通过特征平滑有效抑制训练过程中的噪声干扰, 从而在保持较高性能的同时提升了模型的稳定性和泛化能力。相比之下, ResNet-50 和 DenseNet121 在训练集上快速收敛, 但其在验证集上的性能波动较大, 这种训练集与验证集性能的显著差异表明模型可能过度拟合了训练数据中的局部特征, 未能有效提取数据的本质表征。

通过对比分析5种深度学习模型的训练曲线可以发现: 基于残差连接和密集连接的网络结构 ResNet-50 和 DenseNet121, 相比传统架构 Vgg-19 和轻量级网络 EfficientNet, 表现出更好的训练稳定性; 而融合了 EMA 机制的 Res-EMANet 模型, 通过有效的特征平滑进一步提升了模型性能, 在训练精度和泛化能力方面均实现了显著提升。

为了更全面地比较各模型在生物扰动指数 (BI) 分类任务中的性能, 笔者在独立测试集上对 Vgg-19、DenseNet121、ResNet-50、EfficientNet-B0 和本研究提出的 Res-EMANet 进行了评估, 得到各自的准确率、精确率、召回率和 F1 分数(表 3)。

根据表 3 的实验结果可知, 通过引入 EMA 机制的 Res-EMANet 模型, 相较于 ResNet-50 在准确率、精确率、召回率以及 F1 分数上均有显著提高, 增幅约为 5 个百分点。这说明, 注意力机制的引入有效地优化了模型的深层特征表达和语义信息捕获能力, 显著增强了模型的泛化能力和鲁棒性。从对比模型来看, Vgg-19 因其深层堆叠结构未能充分优化, 表现相对较差, 准确率仅为 85.76%。相较之下, DenseNet121 和 ResNet-50 借助特征传递和残差网络结构, 在准确率和其他评估指标上的表现有所提升, 但仍未达到最佳水平。EfficientNet-B0 则凭借其轻量化设计在模型复杂度和性能之间实现了良好的平衡, 准确率和精确率分别达到 88.67% 和 89.14%, 在性能和效率方面表现较为出色。然而, Res-EMANet 的引入注意力机制在所有评估指标上均取得了全面领先, 其中准确率达到 91.45%, 进一步验证了其结构设计的有效性。综上所述, Res-EMANet 在生物扰动指数 (BI) 分类任务中, 不仅显著提高了分类的准确性, 同时展现出较强的泛化能力和应用潜力。

表 3 5 种模型实验结果对比

Table 3 Comparison of experimental results for five models


网络模型	准确率(A)/%	精确率(P)/%	召回率(R)/%	F1 分数/%
Vgg-19	85.76	86.81	86.81	86.26
DenseNet121	87.38	87.95	87.91	87.72
ResNet-50	86.73	87.22	87.13	87.07
EfficientNet-B0	88.67	89.14	88.98	88.90
Res-EMANet	91.45	92.22	91.42	91.54

3 讨论

为了验证 Res-EMANet 模型的有效性及其与其他模型的差异,笔者通过对比不同注意力机制所关注的区域可视化而得到的热力图(图 8)进行分析。在图 8 中,红色区域代表注意力对该区域重点关注,其对于模型最终预测分类结果有显著影响,黄色区域代表注意力对该区域关注次于红色区域,其对预测分类结果有一定影响,蓝色区域被视为非关键特征区域,其对预测分类结果影响较小。从热力图(图 8)的对比中可以看出,Res-EMANet 模型的 EMA 注意力机制能够准确聚焦于岩心图像中的生物扰动区域,且较少受到非扰动区域的干扰(图 8-b, 8-f, 8-j)。相比之下,CA 注意力机制虽然也能聚焦于扰动区域,但存在对非扰动区域的错误

关注,这可能与其单一通道权重校准模式难以区分生物扰动区域有关(图 8-c, 8-g, 8-k)。而 CBAM 注意力机制则表现出较为混乱的聚焦模式,使其预测准确率较低,尤其对 BI=3、BI=4 岩心图像中生物扰动与非生物扰动的渐变过渡区域响应较弱,导致其精确率不高(图 8-d, 8-h, 8-l)。这表明,EMA 机制通过多尺度特征融合与跨通道交互,有效捕捉了生物扰动扰动区域及矿物组成差异。

为了更加直观地表现 Res-EMANet 在每个分类上的性能,笔者绘制出了混淆矩阵(图 9),其中混淆矩阵的每一列均代表预测类别,每一列中的总数则表示预测为该类别数据的数目。从该矩阵(图 9)中可以看到每个分类的预测结果与实际结果的对比情况。



a—塔河油田, BI=2, 岩心图像; b—BI=2, EMA 注意力机制热力图; c—BI=2, CA 注意力机制热力图; d—BI=2, CBAM 注意力机制热力图; e—塔河油田, BI=3, 岩心图像; f—BI=3, EMA 注意力机制热力图; g—BI=3, CA 注意力机制热力图; h—BI=3, CBAM 注意力机制热力图; i—塔河油田, BI=4, 岩心图像; j—BI=4, EMA 注意力机制热力图; k—BI=4, CA 注意力机制热力图; l—BI=4, CBAM 注意力机制热力图

图 8 塔河油田奥陶系岩心数据集分类过程中不同注意力机制可视化图像

Fig. 8 Visualization images of different attention comparisons in classification process of the Ordovician core dataset in Tahe oilfield

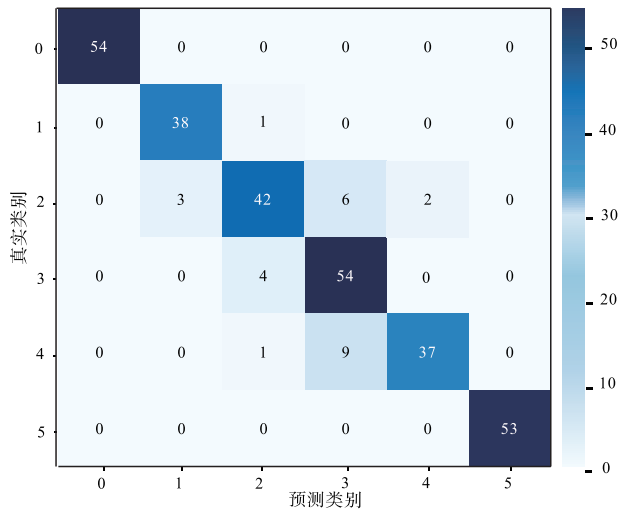


图 9 Res-EMANet 模型的混淆矩阵

Fig. 9 Confusion matrix of Res-EMANet model

如图 9 所示, 由于生物扰动指数 (BI) 0 级 (无扰动) 和 5 级 (完全扰动) 的图像特征极为显著, Res-EMANet 模型能够捕捉这些显著的视觉差异, 因此在这 2 个级别的岩心图像分类中实现了极高的真正例率, 显示出对这 2 个级别生物扰动的出色识别能力。对于 BI=1 级别的生物扰动, 尽管其特征不如 0 级和 5 级那样显著, 但模型依然能够以较高的准确度进行识别, 这表明模型在识别这一级别的生物扰动特征方面也具有较高的效能。然而, 由于 BI=2、BI=3 和 BI=4 级别的生物扰动特征在视觉上较为接近, 模型在区分这些细微差异时遇到了挑战, 导致在这些类别之间出现了一定程度的分类混淆。

总体而言, Res-EMANet 模型在区分不同岩心生物扰动图像类别时展现出良好的稳定性和高准确率, 反映其具有良好的泛化能力。这种泛化能力由于 EMA 注意力机制的集成, 使模型能够更加集中于图像中的关键扰动区域, 从而提升了对生物扰动特征的识别精度。混淆矩阵的结果进一步证实了 Res-EMANet 模型在训练过程中有效控制了过拟合风险, 其不仅在训练集上表现优异, 而且在验证集上也维持了高准确率, 进一步验证了模型的有效性和鲁棒性。

4 结论与展望

1) 笔者提出了一种基于深度学习的岩心图像

生物扰动指数预测模型 Res-EMANet, 其通过引入 EMA 注意力机制, 有效提高了对生物扰动特征的捕捉能力。在塔河油田奥陶系岩心图像数据集上对该模型进行了训练和验证, 结果显示其能够准确划分岩心数字图像上 0~5 级别的生物扰动强度, 准确率高达 91%, 从而实现了岩心生物扰动指数的精确预测。

2) Res-EMANet 模型在生物扰动等级识别的准确性上取得了显著提升, 其效率超越了传统的人工评估方法和现有的深度学习模型。该模型的应用可以减少对资深专家知识的依赖, 有效消除个人主观性对评估结果的潜在影响, 从而不仅推动了生物扰动特征分析向自动化和智能化方向发展, 而且实现了对生物扰动指数的精确量化。Res-EMANet 模型在生物扰动特征的自动化、智能化和量化分析方面展现出显著的应用优势, 为油气勘探和地质学研究提供了一个高效且精确的新工具, 因此具有重要的学术意义和应用价值。

3) 生物扰动占比的定量识别是地质学中的关键研究方向之一, 精确测量生物扰动的程度, 在重建古环境条件和评估沉积物储层特征时具有重要意义。文中通过人工智能自动划分生物扰动指数 BI (0~5), 为评估岩心中生物扰动对沉积物改造的程度提供了系统化框架, 进一步推动了深度学习技术在生物扰动定量分析领域的应用。随着深度学习技术在地质领域中的不断发展, 图像处理和模式识别算法有望为岩心图像中生物扰动区域的像素级精确识别提供有力支持, 从而实现生物扰动区域占整个岩心图像比例的高效计算。同时, 将具有不同类型生物潜穴特征的图像以及生物扰动功能的描述输入深度学习模型, 对实现各类生物扰动潜穴的精确分类与定量分析具有重要意义。这将为生物扰动类型的自动化识别和定量评估开辟新的技术路径, 推动生物扰动定量研究的智能化和高效化进程, 提升生物扰动定量分析的精度与自动化水平。通过深度学习解释沉积环境分布规律和生物扰动对沉积物的影响, 实现各种生物扰动类型的分类并提供合理的开发方案, 对揭示沉积过程中的生态演变、量化生物扰动对沉积物微观结构的改造作用具有重要意义, 也为沉积物的储层特征评估、油气勘探及其他地质研究提供了更为精准的科学依据。

参考文献 (References)

- 艾合买提江·阿不都热和曼, 钟建华, 李阳, 陈鑫. 2010. 塔河油田奥陶系缝合线特征及石油地质意义. 中国石油大学学报(自然科学版), 34(1): 7-11, 17. [Ahmatjan A, Zhong J H, Li Y, Chen X. 2010. Stylolite characteristics and petroleum geology significance of Ordovician carbonate rocks in Tahe Oilfield. Journal of China University of Petroleum (Edition of Natural Science), 34(1): 7-11, 17]
- 金强, 张三, 孙建芳, 魏荷花, 程付启, 张旭栋. 2020. 塔河油田奥陶系碳酸盐岩岩溶相形成和演化. 石油学报, 41(5): 513-525. [Jin Q, Zhang S, Sun J F, Wei H H, Cheng F Q, Zhang X D. 2020. Formation and evolution of karst facies of Ordovician carbonate in Tahe Oilfield. Acta Petrolei Sinica, 41(5): 513-525]
- 刘大猛, 王子豪, 陈佳明, 邱峰, 朱凯, 高羚杰, 周柯宇, 许少博, 孙逢瑞. 2024. 基于 ResNet 残差神经网络识别的深部煤层显微组分和微裂缝分类: 以鄂尔多斯盆地石炭系本溪组 8# 煤层为例. 石油与天然气地质, 45(6): 1524-1536. [Liu D M, Wang Z H, Chen J M, Qiu F, Zhu K, Gao L J, Zhou K Y, Xu S B, Sun F R. 2024. Classification of macerals and microfractures in deep coal seams based on ResNet: a case study of the No. 8 coal seam of the Carboniferous Benxi Formation in the Ordos Basin. Oil & Gas Geology, 45(6): 1524-1536]
- 刘大卫, 李映涛, 韩俊, 张继标, 汝智星, 杨孝群, 王石, 黄诚, 肖重阳. 2025. 塔里木盆地顺北地区奥陶系鹰山组超深层白云岩类型及成储潜力评价. 古地理学报, 27(1): 126-140. [Liu D W, Li Y T, Han J, Zhang J B, Ru Z X, Yang X Q, Wang S, Huang C, Xiao C Y. 2025. Ultra-deep dolomite types and their reservoirs potential of the Ordovician Yingshan Formation in Shunbei area, Tarim Basin. Journal of Palaeogeography (Chinese Edition), 27(1): 126-140]
- 刘合, 任义丽, 李欣, 朱如凯, 胡延旭, 刘茜, 苏乾潇, 吴健平, 李彬. 2024. 岩心智能识别技术内涵与展望. 石油学报, 45(8): 1296-1308. [Liu H, Ren Y L, Li X, Zhu R K, Hu Y X, Liu X, Su Q X, Wu J P, Li B. 2024. Connotation and prospect of intelligent recognition technology for cores. Acta Petrolei Sinica, 45(8): 1296-1308]
- 刘艳如, 吴晓红, 何小海, 罗彬彬, 滕奇志. 2025. 基于改进 ResNet50 的岩心图像分类研究. 智能计算机与应用, 15(2): 10-16. [Liu Y R, Wu X H, He X H, Luo B B, Teng Q Z. 2025. Research on core image classification based on improved ResNet50. Intelligent Computer and Applications, 15(2): 10-16]
- 鲁新便, 胡文革, 汪彦, 李新华, 李涛, 吕艳萍, 何新明, 杨德彬. 2015. 塔河地区碳酸盐岩断溶体油藏特征与开发实践. 石油与天然气地质, 36(3): 347-355. [Lu X B, Hu W G, Wang Y, Li X H, Li T, Lü Y P, He X M, Yang D B. 2015. Characteristics and development practice of fault-karst carbonate reservoirs in Tahe area, Tarim Basin. Oil & Gas Geology, 36(3): 347-355]
- 牛永斌, 崔胜利, 胡亚洲, 钟建华, 王培俊. 2017. 塔里木盆地塔河油田奥陶系数字岩心图像中生物扰动的定量表征. 古地理学报, 19(2): 353-363. [Niu Y B, Cui S L, Hu Y Z, Zhong J H, Wang P J. 2017. Quantitative characterization of bioturbation based on digital image analysis of the Ordovician core from Tahe Oilfield of Tarim Basin. Journal of Palaeogeography (Chinese Edition), 19(2): 353-363]
- 牛永斌, 崔胜利, 胡亚洲, 钟建华, 潘结南. 2018. 塔河油田奥陶系生物扰动型储集层的三维重构及启示意义. 古地理学报, 20(4): 691-702. [Niu Y B, Cui S L, Hu Y Z, Zhong J H, Pan J N. 2018. Three-dimensional reconstruction and their significance of bioturbation-type reservoirs of the Ordovician in Tahe Oilfield. Journal of Palaeogeography (Chinese Edition), 20(4): 691-702]
- 牛永斌, 徐资璐, 刘圣鑫, 钟建华, 赵佳如, 王培俊. 2020. 塔河油田奥陶系生物扰动碳酸盐岩储集层微观孔隙结构的数字化表征与连通性分析. 古地理学报, 22(4): 785-798. [Niu Y B, Xu Z L, Liu S X, Zhong J H, Zhao J R, Wang P J. 2020. Digital characterization and connectivity analysis of microcosmic pore structures of the Ordovician bioturbated carbonate rock reservoirs in Tahe Oilfield. Journal of Palaeogeography (Chinese Edition), 22(4): 785-798]
- 牛永斌, 赵佳如, 钟建华, 王敏, 徐资璐, 程梦园. 2021. 基于神经网络模型的生物扰动碳酸盐岩储集层识别与孔隙度预测: 以塔里木盆地塔河油田奥陶系生物扰动碳酸盐岩储集层为例. 地质论评, 67(6): 1898-1909. [Niu Y B, Zhao J R, Zhong J H, Wang M, Xu Z L, Cheng M Y. 2021. Identification of the bioturbated carbonate reservoir and their porosity prediction based on conventional well logging data using artificial neural networks: take the Ordovician bioturbated carbonate reservoir in Tahe oilfield, Tarim Basin, as an example. Geological Review, 67(6): 1898-1909]
- 牛永斌, 荆楚涵, 邵威猛, 程怡高, 李志远. 2023. 生物扰动油气水储层的研究现状及展望. 沉积学报, 41(6): 1934-1953. [Niu Y B, Jing C H, Shao W M, Cheng Y G, Li Z Y. 2023. A review and perspective of bioturbated hydrocarbon and water reservoirs. Acta Sedimentologica Sinica, 41(6): 1934-1953]
- 张抗. 1999. 塔河油田的发现及其地质意义. 石油与天然气地质, 20(2): 24-28. [Zhang K. 1999. The discovery of Tahe oilfield and its geological significance. Oil & Gas Geology, 20(2): 24-28]
- 赵佳如, 牛永斌, 王敏, 徐资璐, 崔胜利, 王培俊. 2021. 塔河油田奥陶系生物扰动型碳酸盐岩储集层特征及其孔隙度计算样本检验模型. 沉积学报, 39(2): 482-492. [Zhao J R, Niu Y B, Wang M, Xu Z L, Cui S L, Wang P J. 2021. Reservoir characteristics and porosity calculation sample inspection model of Ordovician bioturbated carbonate reservoirs in Tahe oilfield. Acta Sedimentologica Sinica, 39(2): 482-492]
- 周程阳, 刘伟, 吴天润, 李鹭, 韩霄松. 2024. 基于混合专家模型的岩石薄片图像分类. 吉林大学学报(理学版), 62(4): 905-914. [Zhou C Y, Liu W, Wu T R, Li A, Han X S. 2024. Classification of rock thin section images based on mixture of expert models. Journal of Jilin University (Science Edition), 62(4): 905-914]
- 周永章, 左仁广, 刘刚, 袁峰, 毛先成, 郭艳军, 肖凡, 廖杰, 刘艳鹏. 2021. 数学地球科学跨越发展的十年: 大数据、人工智能算法正在改变地质学. 矿物岩石地球化学通报, 40(3): 556-573. [Zhou Y Z, Zuo R G, Liu G, Yuan F, Mao X C, Guo Y J, Xiao F, Liao J, Liu Y P. 2021. The great-leap-forward development of mathematical geoscience during 2010-2019: big data and artificial intelli-

- gence algorithm are changing mathematical geoscience. *Bulletin of Mineralogy, Petrology and Geochemistry*, 40(3): 556–573]
- Ayranci K, Yildirim I E, Waheed U B, MacEachern J A. 2021. Deep learning applications in geosciences: insights into ichnological analysis. *Applied Sciences*, 11(16): 7736.
- Dey J, Sen S. 2017. Impact of bioturbation on reservoir quality and production: a review. *Journal of the Geological Society of India*, 89(4): 460–470.
- Dorador J, Rodríguez-Tovar F J, Expedition I. 2014. Quantitative estimation of bioturbation based on digital image analysis. *Marine Geology*, 349: 55–60.
- Eltom H A, Syahputra M R N, El-Husseiny A, La Croix A D. 2023. Spatial complexity of burrow attributes and their impact on porosity and permeability distributions in bioturbated reservoirs. *Sedimentary Geology*, 450: 106395.
- He K M, Zhang X Y, Ren S Q, Sun J. 2016. Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). June 27–30, 2016, Las Vegas, NV, USA. IEEE: 770–778.
- Hou Q B, Zhou D Q, Feng J S. 2021. Coordinate attention for efficient mobile network design. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). June 20–25, 2021. Nashville, TN, USA. IEEE: 13713–13722.
- Hu J, Shen L, Sun G. 2018. Squeeze-and-excitation networks. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18–23, 2018. Salt Lake City, UT, USA. IEEE: 7132–7141.
- Huang G, Liu Z, Van Der Maaten L, Weinberger K Q. 2017. Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*: 4700–4708.
- Hülse D, Vervoort P, van de Velde S J, Kanzaki Y, Boudreau B, Arndt S, Bottjer D J, Hoogakker B, Kuderer M, Middelburg J J, Volkenborn N, Kirtland Turner S, Ridgwell A. 2022. Assessing the impact of bioturbation on sedimentary isotopic records through numerical models. *Earth-Science Reviews*, 234: 104213.
- Kikuchi K, Naruse H. 2024. Abundance of trace fossil phycosiphon incertum in core sections measured using a convolutional neural network. *Sedimentary Geology*, 461: 106570.
- Knaust D. 2012. *Methodology and Techniques. Developments in Sedimentology*. Elsevier: 245–271.
- Knaust D. 2017. *Atlas of Trace Fossils in Well Core: Appearance, Taxonomy and Interpretation*. Springer: 1–209.
- Miguez-Salas O, Dorador J, Rodríguez-Tovar F J. 2019. Introducing Fiji and ICY image processing techniques in ichnological research as a tool for sedimentary basin analysis. *Marine Geology*, 413: 1–9.
- Miller M F, Smail S E. 1997. A semiquantitative field method for evaluating bioturbation on bedding planes. *Palaios*, 12(4): 391–396.
- Niu Y B, Cheng M Y, Zhang L J, Zhong J H, Liu S X, Wei D, Xu Z L, Wang P J. 2022. Bioturbation enhanced petrophysical properties in the Ordovician carbonate reservoir of the Tahe Oilfield, Tarim Basin, NW China. *Journal of Palaeogeography*, 11(1): 31–51.
- Ouyang D L, He S, Zhang G Z, Luo M Z, Guo H Y, Zhan J, Huang Z J. 2023. Efficient multi-scale attention module with cross-spatial learning. *ICASSP 2023–2023 IEEE International Conference on Acoustics, Speech and Signal Processing*: 1–5.
- Simonyan K, Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. *Arxiv Preprint: 1409.1556* (published as a conference paper at ICLR 2015).
- Sterling S N. 2011. Cores and core logging for geoscientists. *Environmental and Engineering Geoscience*, 17: 307–308.
- Tan M, Le Q. 2019. Efficientnet: rethinking model scaling for convolutional neural networks. *International conference on machine learning*. PMLR: 6105–6114.
- Taylor A M, Goldring R. 1993. Description and analysis of bioturbation and ichnofabric. *Journal of the Geological Society*, 150(1): 141–148.
- Taylor A, Goldring R, Gowland S. 2003. Analysis and application of ichnofabrics. *Earth-Science Reviews*, 60(3–4): 227–259.
- Timmer E R, Gingras M K, Zonneveld J P. 2016. Pychno: a core-image quantitative ichnology logging software. *Palaios*, 31(11): 525–532.
- Timmer E, Knudson C, Gingras M. 2021. Applying deep learning for identifying bioturbation from core photographs. *AAPG Bulletin*, 105(4): 631–638.
- Wang Q L, Wu B G, Zhu P F, Li P H, Zuo W M, Hu Q H. 2020. Eca-Net: efficient channel attention for deep convolutional neural networks. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). June 13–19, 2020. Seattle, WA, USA. IEEE: 11534–11542.
- Woo S, Park J, Lee J Y, Kweon I S. 2018. Cbam: convolutional block attention module. *Proceedings of the European Conference on Computer vision(ECCV)*: 3–19.
- Reineck H E. 1963. Sedimentgefüge im Bereich der südlichen Nordsee. *Abhandlungen der se Ckenbergischen Naturforschenden Gesellschaft*, 505: 1–138.

(责任编辑 张西娟; 英文审校 刘贺娟)