

基于改进 Stacking 方法的成像测井裂缝识别

史鹏达, 刘孙俊, 王琪凯, 吴秋伶

(成都信息工程大学 软件工程学院, 成都 610225)

摘要: 传统成像测井裂缝识别依赖专家经验, 主观性强; 深度学习方法可提取多维度特征构建裂缝识别模型, 集成学习方法融合多个模型提升精度, 但简单融合策略精度提升不明显, 复杂融合策略易过拟合, 需探索更有效融合方法提升裂缝识别准确性; 针对上述问题, 提出了一种基于 Stacking 方法改进的集成深度学习模型, 将 Deeplabv3+, YOLOv8, SegFormer 三个模型进行融合, 并设计了跳跃连接模块将原始图像骨干特征传递至元模型层, 避免在模型融合时由于特征不足产生的错误拟合; 经实验, 该模型在构建的测井图像裂缝识别数据集上 Dice 系数可达 89.6%, 优于单一模型与少数模块构建的集成模型; 将该方法用于柴达木盆地实际成像测井资料的裂缝识别, 能够准确地提取出测井图像的裂缝信息, 证明了该模型的有效性, 为成像测井裂缝识别提供了新的思路。

关键词: 成像测井; 裂缝识别; 深度学习; 集成学习; 图像处理

Imaging Logging Fracture Identification Based on Improved Stacking Algorithm

SHI Pengda, LIU Sunjun, WANG Qikai, WU Qiuling

(School of Software Engineering, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: Traditional imaging logging fracture identification relies on expert experience, which has strong subjectivity. Deep learning methods can extract multidimensional features to build fracture identification models. Ensemble learning method integrates multiple models to improve accuracy, but simple fusion strategies do not significantly improve accuracy, and complex strategies are prone to overfitting. It is necessary for effective fusion methods to enhance the precision of fracture identification. To address this issue, an improved ensemble deep learning model based on the Stacking method is proposed. The model combines the Deeplabv3+, YOLOv8, and SegFormer, and designs a skip continuous module to transfer the backbone features of the original images to the meta-model layer, avoiding wrong fitting caused by insufficient features during the fusion. Through experiments, the Dice coefficient of the model reaches up to 89.6% on a constructed logging image fracture identification dataset, outperforming the integrated model built by a single model and a few modules. Applying this method to fracture identification of actual imaging logging data in the Qaidam Basin, it can accurately extract fracture information from logging images, proving the effectiveness of the model and offering a new approach to identify logging fracture images.

Keywords: imaging logging; fracture identification; deep learning; ensemble learning; image processing

0 引言

地层中的裂缝是油气重要的储存空间与渗流通道, 准确识别裂缝对于储层评价、单井产能评估等具有重要意义。裂缝识别可以通过常规测井资料与成像测井资料完成, 利用双侧向测井曲线的幅度差、声波时差测井曲线的周波跳跃现象可以定性识别地层中的裂缝, 但存在一定的多解性, 无法准确表征裂缝的发育情况。电成像

测井资料可以生成井壁岩石电阻率分布的图像, 能够直观、有效地识别裂缝, 因此在裂缝识别中应用广泛。传统的裂缝识别通过人工寻找符合裂缝特征的正弦曲线, 但该类方法受限于专家经验, 缺乏统一的识别标准。随着计算机视觉技术的发展, 研究者们开始尝试将图像处理技术与数学模型相结合以进行裂缝识别。文献 [1] 对 FMI 图像进行处理后, 利用 Hough 变换识别符合固

收稿日期: 2024-10-30; 修回日期: 2024-11-22。

作者简介: 史鹏达(1998-), 男, 硕士研究生。

通讯作者: 刘孙俊(1975-), 男, 博士, 副教授。

引用格式: 史鹏达, 刘孙俊, 王琪凯, 等. 基于改进 Stacking 方法的成像测井裂缝识别[J]. 计算机测量与控制, 2025, 33(4): 217-224, 231.

定模式的裂缝；文献 [2] 将多种基于图像灰度直方图的阈值分割方法应用于 FMI 图像的裂缝识别；文献 [3] 提出了一种基于元胞自动机的模型，根据测井图像特点定义适应的免疫规则，并运用并行的局部演化方法来识别裂缝区域；文献 [4] 在 Hough 变换的基础上引入方向滤波机制，从测井成像中提取裂缝。这些方法实现了裂缝的自动识别，但其依赖于固定的识别模式，对图像特征的提取能力不足。

近年来，深度学习技术的快速发展为测井图像的裂缝识别提供了新的解决方案。文献 [5] 提出了基于深度学习的断层与裂缝识别方法，利用 AlexNet 模型发现可能的断层及裂缝并进行区分；文献 [6] 将 DeepLabV3+ 算法应用于裂缝区域的像素级分割，通过对图像进行逐像素精细分类，将图像分割成若干具有明确标签的区域，实现了裂缝带的自动提取；文献 [7] 使用 Fast-RCNN 算法从声成像测井图像中学习裂缝与断层的定位方式，提取定位到的候选区块的特征并预测，实现了对裂缝和断层的识别，并给出相应的置信度评估；文献 [8] 将条件生成对抗网络 (CGAN) 应用于测井图像的裂缝识别，CGAN 将裂缝标签作为条件变量，对图像进行监督学习，然后生成与原图像特征相似的裂缝图像。上述模型在应用中并未针对具体问题进行了结构调优，由于模型结构设计应用在广义任务中，因此在特定任务中的性能无法得到完全发挥。为解决适用性不足的问题，文献 [9] 在 Deeplabv3+ 的基础上添加了双序列注意力模块，构建了 DSAM-Deeplabv3+ 模型，并将其应用至测井图像砾石识别任务中，通过模型改进提升了 Deeplabv3+ 模型在砾石提取任务中的性能；文献 [10] 提出了一种融合多尺度空洞卷积和注意力机制的神经网络，该网络对 FMI 成像进行多尺度特征提取与融合，经通道调整与像素点概率计算后输出裂缝结果；文献 [11] 将融合通道和空间交叉注意力机制引入到全卷积网络 (FCN) 中，结合上下文信息与图像像素之间的语义信息进行裂缝提取，改进模型能够较好的提取测井图像中的裂缝信息；文献 [12] 在 V-net 网络的基础上引入空间注意力机制和动态调整学习率模块，构建了 SA-VNet 网络的断层识别方法，提升了断层识别的准确率。经由结构改进的模型在处理复杂信息时具有较好的准确性，但受限于单一模型结构，其多样性不足，在某些特定任务上出现性能瓶颈问题^[13]。文献 [14] 将常规测井数据作为输入，应用极端梯度提升树进行裂缝预测并取得了一定的效果。但该方法也存在对噪声较为敏感、逐轮提升时会放大误差的干扰的缺点。同时，常规测井曲线输入包含的特征有限，其输出结果也仅为裂缝位置点，不包括裂缝形态等信息；文献 [15] 使用软投票法对若干个使用不同初始参数的 PSPNet 进行融

合，构建集成模型进行页岩孔隙 SEM 图像分割任务，结果表明，集成学习可以有效降低模型的方差。文献 [16] 使用投票法对多个 CNN 与 Transformer 模型进行集成，并将集成模型应用于矿物图像识别任务中，在包含 36 种矿物的数据集中能够进行准确识别。

集成模型性能相较于单一模型有一定提升，然而，目前图像处理任务中采用的集成学习方法仍存在 3 点不足：1) 采用简单的投票策略进行融合，对异常值敏感，整体模型的鲁棒性较低；2) 对同质化模型进行集成，模型结构差异性不足，进而限制了整体模型的性能；3) 仅根据各模型的输出结果进行融合，无法利用原始数据的特征，融合后的模型存在过拟合问题。为此，本文提出一种集成深度学习算法，针对测井图像裂缝识别问题的实际需求，基于 Stacking 方法对异质深度学习图像处理模型进行融合，通过增加子模型结构多样性与精确化融合策略的方式提升整体模型的准确性与鲁棒性；并在传统 Stacking 架构的基础上增加跳跃连接模块 (SCM, skip connection module)，传递成像测井图像骨干特征，根据原始数据中的特征进行模型融合，提升模型的泛化能力，避免产生过拟合。经验证，本文方法可较好地识别成像测井图像中的裂缝。

1 基于改进 Stacking 方法的成像测井裂缝识别模型架构

传统的 Stacking 方法是一种层次化模型集成技术^[17]，将元学习器作为组合器寻找基模型更精确的组合方式，相较于 Voting, Bagging 等集成学习方法，Stacking 方法可以根据数据和特征的变化动态调整权重，使得它能捕获更多的复杂模式。在传统 Stacking 结构中，元学习器仅学习基学习器结果的组合方式，不需要考虑原始数据的特征，然而在测井图像裂缝识别任务中，由于电阻率成像中的像素点之间存在局部纹理、形状特征等复杂非线性关系，基模型预测结果经二值化处理后缺乏有效特征，存在显著的信息不足问题，如果直接组合并输入元学习器进行学习可能会导致模型过度依赖少量的特征，增加了模型对训练数据的过拟合风险，使其泛化能力降低。针对上述问题，本文提出了一种基于改进 Stacking 架构的集成深度学习模型，采用 DeepLabv3+, SegFormer, YOLOv8 三个深度学习模型作为基模型，并使用 SCM 提取原始测井图像中的骨干特征向后传递；最后使用一个 U-net 网络作为元学习器，在原始图像关键特征的基础上对上述基模型的结果进行组合并输出预测结果。

1.1 基模型层

1.1.1 Deeplabv3+

DeepLabv3+ 是一种基于 FCN 的深度学习模型^[18]，

其特点是在特征提取过程中使用空洞卷积进行跨像素的特征点提取, 通过增加感受野使每个卷积输出都包含较大范围的信息。

Deeplabv3+ 采用了编码器-解码器架构, 编码器部分由骨干特征提取网络和 ASPP 模块组成, 其中 ASPP 模块使用多分支的并行结构, 包含了卷积、空洞卷积和全局平均池化层。输入样本图像经骨干网络中的卷积操作提取特征得到两个有效特征层, 其中浅层特征直接传入解码器中, 深层特征经 ASPP 模块提取多尺度特征后进行堆叠, 再经卷积调整通道数后传入解码器中。解码器首先对深层特征进行上采样, 使之与具有较高空间分辨率的浅层特征图空间尺寸一致, 并将两者拼接, 融合不同尺度的特征信息。经由一组卷积块细化处理后, 再次进行上采样得到最终预测结果, 整体网络结构如图 1 (a) 所示。

1.1.2 SegFormer

SegFormer 是基于 Transformer 提出的语义分割模型, 其将图像转化为高维向量后再进行特征抽取, 同时使用自注意力机制动态地分配注意力权重, 使模型专注于当前像素点的相关特征上, 并探索像素点在全局范围内的上下文关系^[19]。通过比较和整合这些上下文信息, SegFormer 能够更好地理解图像中物体的边界、结构和语义信息, 其结构如图 1 (b) 所示。

SegFormer 的编码器采用了一系列具有相同架构但不同大小的 Transformer 模块组成, 用于生成不同分辨率的特征^[20]。首先使用 Overlap Patch Embeddings 方法将图像分成多个重叠的图像块, 然后将这些图像块作为分层 Transformer 编码器的输入; 最后将每个编码器处理后的结果分别输入下一个编码器与解码器中, 以获得原始图像在不同分辨率下的多级特征。解码器由 MLP 层构成, 来自各编码器的多级特征通过第一个 MLP 层的线性变换统一通道维度, 将特征上采样后进行拼接, 然后输入第二个 MLP 层进行预测并输出最终结果。

1.1.3 YOLOv8

YOLOv8 是由 Ultralytics 在 Redmon 等提出的 YOLO 框架的基础上改进的目标检测算法。其将目标检测问题转化为回归问题, 通过将图像分成网格并在每个网格中预测边界框和类别信息来实现目标检测^[21-22]。YOLOv8 模型主要包括 Backbone 主干网络、Neck 瓶颈结构以及 Head 输出头, 其结构如图 1 (c) 所示。

Backbone 主干网络部分负责特征提取, 经过若干个串联的 Conv 模块卷积与 C2f 模块处理, 最终通过 SPPF 模块进行最大池化和结果拼接, 完成浅层到深层特征的提取。Neck 颈部网络用于特征融合和信息传递, 其采用 PAN-FPN 架构进行了高层与底层的特征结合, 能同时在多层级上实现多尺度感知与特征融合, 使得模

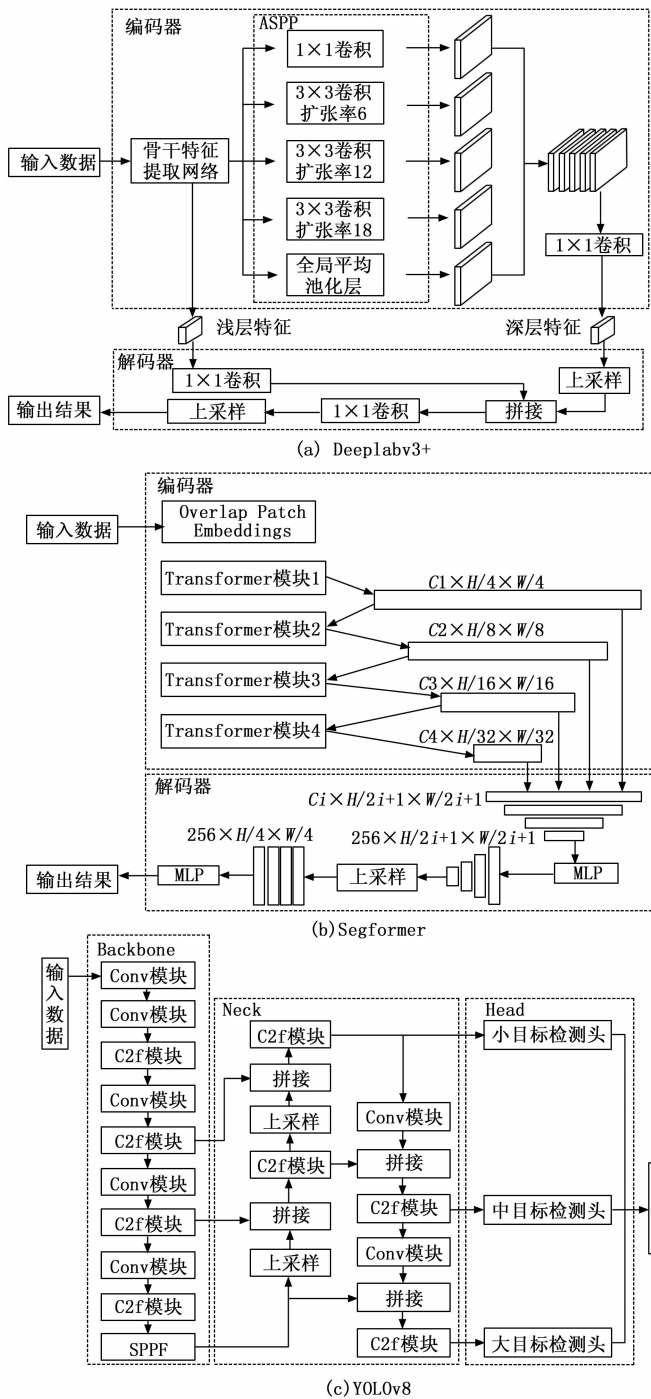


图 1 基模型结构

型在各个层次上都能学习到准确的细节特征。Head 输出头采用 YOLOX 的头部分离技术, 使用解耦头结构对经过 Neck 部分的特征信息进行解耦, 该结构在每个尺度都有由一组卷积和全连接层组成的独立的检测头, 用于预测该尺度上的边界框。这种设计使 YOLOv8 能够捕捉不同尺度目标的信息, 以提高目标检测的准确性。

1.2 跳跃连接模块 (SCM)

跳跃连接允许信息直接跳过一些层并传递到后续

层, 帮助网络更容易地学习有效的特征^[24]。SCM 将原始图像中的信息传递至元模型层, 使元学习器在原始图像特征的基础上学习基模型的组合方式, 同时, 由于原始图像中包含大量冗余信息, SCM 对其进行特征提取, 仅传递更具判别性的骨干特征。边缘是图像中亮度或色彩变化最大的地方, 也是图像信息最集中的部分。在测井图像中, 边缘包含着裂缝、砾石等轮廓、形状以及不同区域之间的分界线等信息。使用 Canny 算法^[25] 构建 SCM 对测井图像进行边缘检测提取关键信息, 并将得到的边缘图像作为骨干特征传递至元模型层, 可以帮助元学习器更好地学习基模型结果的组合方式, SCM 结构如图 2 所示。

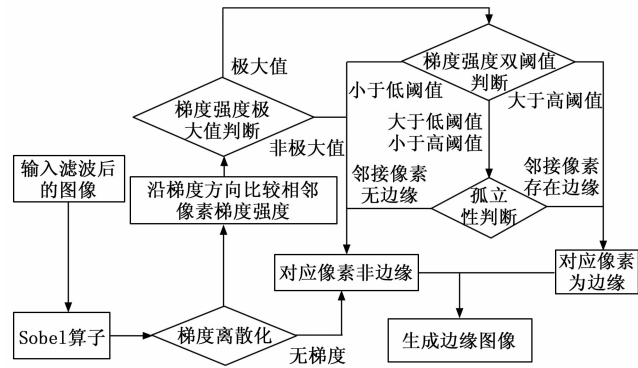


图 2 SCM 结构

首先使用 Sobel 算子卷积计算图像中每个像素点水平和垂直方向的梯度值 G_x 、 G_y , 该算子包含两组 3×3 的卷积因子, 如式 (1) 所示:

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \times A, G_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \times A \quad (1)$$

式中, A 为原始图像中卷积因子对应的 3×3 大小像素块。

根据梯度值计算像素点的梯度强度 G 与梯度方向 θ , 如式 (2) (3) 所示:

$$G = \sqrt{G_x^2 + G_y^2} \quad (2)$$

$$\theta = \arctan \frac{G_y}{G_x} \quad (3)$$

计算得到梯度值和梯度方向后, 将像素点 (x, y) 的梯度方向 $\theta(x, y)$ 离散化为水平、竖直和对角线方向。比较其梯度强度 $G(x, y)$ 与沿梯度方向的两个相邻像素的梯度强度, 如果 $G(x, y)$ 是 3 个值中的最大值, 则保留该像素值, 否则将其抑制为零。

最后对梯度图像进行阈值处理, 排除噪声点。设定两个阈值, $minVal$ 和 $maxVal$ 。高于 $maxVal$ 的像素被视为确定边缘, 低于 $minVal$ 的像素则被排除为零, 介

于两个阈值之间的像素被视为候选边缘。遍历候选像素的 8 个邻域像素, 若其中一个为确定边缘像素, 则该候选边缘保留, 若无确定边缘像素, 则排除为零, 如果某个弱边缘像素点被标记为边缘点, 则会继续检查该像素点的相邻像素点, 进行递归连接, 以将所有与强边缘像素点相邻的弱边缘像素点连接到边缘线上。经过边缘连接后, 所有未被标记为边缘点的像素点视为非边缘点, 并抑制其梯度值为零, 从而得到最终的边缘图像作为骨干特征。经由 SCM 提取的图像骨干特征跳过基模型层直接输入元模型层, 使元学习器在测井图像骨干特征的基础上学习基模型的组合方式, 而非仅依赖于经由特征变换的基模型结果进行学习。

1.3 元模型层

元模型层由图像融合模块与元学习器构成。图像融合模块的作用是将基模型的输出结果与 SCM 传递的骨干特征进行融合。

首先将训练集均匀划分为不交叉的 K 折, 迭代取其中不重复的 $K-1$ 折作为训练集, 1 折作为验证集, 分别对基模型进行 K 次训练与验证, 得到各模型的验证结果集合; 然后将该集合中的图像与 SCM 传递的测井图像骨干特征进行通道堆叠; 最后对堆叠后的数据集进行整合, 并结合原数据集中对应的标签输入元学习器进行训练。元学习器通过最小化图像融合模块的输出与目标标签之间的损失函数, 寻找基模型的最优组合方式, 以产生更准确的预测结果, 元模型层训练架构如图 3 所示。

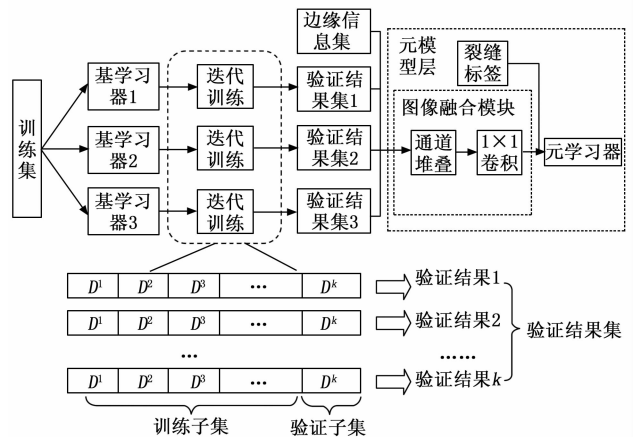


图 3 元学习器训练架构

1.4 改进的 Stacking 方法

针对测井图像裂缝识别问题, 本文应用上述组件构建 Stacking 架构并加以改进。将测井图像数据预处理后, 经输入层分别输入至基模型层与 SCM 中; 基模型层中的各模型分别预测并输出相应结果, 为统一模型输出形式, 对 YOLOv8 的输出结果进行二值化处理;

SCM 使用 Sobel 算子计算图像中各像素点的梯度值与梯度方向, 根据离散化后的梯度方向进行非最大值抑制, 之后进行阈值处理, 并对处理结果进行边缘连接, 生成边缘信息图像作为骨干特征; 元模型层将各基模型的预测结果与 SCM 传递的骨干特征进行图像融合, 再输入至元学习器进行二阶预测。由于元学习器的输入仅包含骨干特征与各模型的预测结果, 图像结构清晰、特征明显, 本文采用基础 U-net 网络作为元学习器以避免过拟合。结构如图 4 所示。

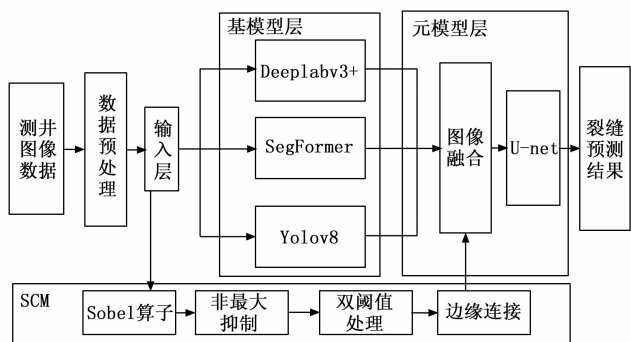


图 4 基于改进 Stacking 方法的裂缝识别模型结构

2 实验与分析

2.1 数据处理

本次研究收集 D 油田 D36、D171、D106 三口井的成像测井资料, 通过图形软件裁剪与人工解释标注, 共计 937 条测井图像样本与对应的裂缝标签构成数据集。为提高模型的泛化能力, 对训练用样本进行数据增强操作, 包括 HSV 变换、直方图均衡化、随机旋转和白平衡, 通过变换样本提高数据集的多样性, 增强效果如图 5 所示。

图像数据输入模型前需进行像素归一化与图像滤波处理。像素归一化将每个图像的像素值范围缩放至固定范围内, 消除不同图像之间的尺度差异。测井图像构成较为复杂, 不同层段的色彩分布存在差异。本文采用 Min-Max 标准化对图像进行归一化处理, 将图像进行通道分离后对每个通道分别执行归一化, 再进行通道合并, 在不改变像素点数据分布的基础上统一图像尺度,




图 5 数据增强示意图

如式 (4) 所示:

$$x' = \frac{x - Min}{Max - Min} \quad (4)$$

式中, x' 为归一化后像素点值, x 为原始像素点值, Min 为图像中像素点最小值, Max 为最大值。

图像滤波在保留图像细节特征的前提下对目标图像的噪声进行抑制, 减少图像中的不规则变化, 在像素值归一化的基础上, 本文应用高斯滤波器去除噪声。高斯滤波器将高斯函数离散化, 每一个像素点的值都由其本身和邻域内的其他像素值经过加权平均后得到, 如式 (5) 所示。

$$H(i, j) = \frac{1}{2\pi\sigma^2} e^{-\frac{(i-(K-1/2)-1)^2 + (j-(K-1/2)-1)^2}{2\sigma^2}} \quad (5)$$

式中, $H(i, j)$ 为滤波后的像素点值, K 为滤波器大小, σ 为滤波器内值标准差。经过像素归一化尺度统一与高斯滤波消除噪声后的数据集相较于原始数据集具有更高的一致性、稳定性与泛化能力。下面将基于此数据集采用五折交叉验证的形式进行消融实验。将数据集五等分, 每次用 4 份作训练集, 一份作测试集 (比例约 8 : 2), 重复 5 次且每次更换不同测试集, 最后平均 5 次评估结果以评估模型有效性, 并在实例应用中将该数据集作为训练集对模型进行训练。

2.2 有效性评估

2.2.1 评估指标

准确率是评价模型性能的重要指标, 由于在裂缝识别任务中仅区分裂缝与非裂缝两类像素点, 存在明显的类别不平衡问题, 当模型过度倾向非裂缝时准确率可能仍处于理想阈值内, 会产生不公正评估, 进而对结果产生误导。为了避免模型的性能被错误量化, 本文使用 Dice 系数、交并比 (IoU) 和 Kappa 系数 3 个指标衡量裂缝识别模型的性能。

Dice 系数是一种集合相似度度量函数, 其能全面且有效地度量图像识别算法的性能。Dice 系数的取值范围为 $[0, 1]$, 取值越大说明模型性能越强, 如式 (6) 所示:

$$Dice = \frac{2 \times Intersection}{predicted\ Area + True\ Area} \quad (6)$$

式中, *Intersection* 表示实际标签与预测结果两者裂缝的交集; *Predicted Area* 表示预测结果裂缝区域; *True Area* 表示实际标签裂缝区域。*Dice* 系数同时考量预测结果与实际结果, 并在此基础上评估预测正确的裂缝区域, 为模型提供全面的性能度量。

IoU 反映预测结果与真实标签中裂缝区域的重叠程度, 取值范围为 [0, 1], 如式 (7) 所示:

$$IoU = \frac{Intersection}{Union} \quad (7)$$

式中, *Intersection* 表示实际裂缝标签与预测结果两者的交集; *Union* 表示两者的并集。

IoU 在实际标签与预测结果的裂缝区域的并集上关注预测正确的裂缝区域, 对细微的裂缝区域更敏感。

Kappa 系数通过比较实际观测的总体一致率与偶然预期的总体一致率之间的差异, 来评估模型在整个数据集上的一致性和稳定性。*Kappa* 系数的取值范围为 [-1, 1], 取值越接近 1 则表明模型的一致性和稳定性越高, 如式 (8) 所示:

$$Kappa = \frac{P_o - P_e}{1 - P_e} \quad (8)$$

式中, P_o 表示实际观测的总体一致率; P_e 表示偶然预期的总体一致率。*Kappa* 系数着重评估预测的正确性是否独立于随机因素, 进而评估模型在不同条件下的适应能力。通过综合考虑这 3 个指标, 能够全面评估模型在不同环境下的精确度与稳定性表现。

2.2.2 消融实验

本文模型属于多模块融合的集成学习模型, 为保证训练过程中各模块的加入均对整体模型产生确定性的提升, 在训练过程中以 *Dice* 系数、*IoU*、*Kappa* 系数作为

评估指标, 对基模型层中的 Deeplabv3+、SegFormer、YOLOv8 以及 SCM 四个关键模块进行消融实验, 量化其对整体模型性能的具体贡献。各指标的计算均基于训练集的五折交叉验证结果, 如表 1 所示。此外, 选取消融实验中各模块在验证时的部分输出以及本文方法的输出进行可视化, 便于辅助分析。可视化结果如图 6 所示。

表 1 消融实验对比

实验编号	消融模块				评价指标		
	Deeplabv3+	SegFormer	YOLOv8	SCM	Dice	IoU	Kappa
1	✓				0.695	0.534	0.549
2		✓			0.671	0.506	0.503
3			✓		0.744	0.596	0.622
4	✓	✓			0.709	0.563	0.553
5	✓		✓		0.751	0.602	0.635
6		✓	✓		0.738	0.587	0.581
7	✓	✓	✓		0.754	0.604	0.637
8	✓			✓	0.761	0.621	0.689
9		✓		✓	0.752	0.603	0.642
10			✓	✓	0.798	0.667	0.699
11	✓	✓		✓	0.827	0.705	0.715
12	✓		✓	✓	0.871	0.774	0.776
13		✓	✓	✓	0.865	0.762	0.764
14	✓	✓	✓	✓	0.896	0.812	0.796

由 1~3 号实验可见, YOLOv8 在单个模型集成中, 性能优于 SegFormer 与 Deeplabv3+; 1~3 号实验与 4~6 号实验结果对比显示, YOLOv8、Deeplabv3+ 融合模型与 Deeplabv3+、SegFormer 融合模型相比于其中性能较高的单个模型集成, 性能得到少量提升; YOLOv8 与 SegFormer 融合的集成模型的性能相较于




图 6 消融实验结果示例

YOLOv8 的单个模型集成的性能产生了负提升; 7 号实验结果显示, 当 3 个模型进行融合时, 整体模型性能仅轻微提升。

根据图 6 (a) (b) (c) 分析上述问题的产生原因, 3 个基模型均能根据输入的成像测井数据推演裂缝基本形态, 但是, Deeplabv3 + 预测裂缝的连贯性较差, SegFormer 的结果有部分裂缝段消失, 同时存在错误识别; YOLOv8 的预测的裂缝具有较好的准确性与连贯性, 但是存在部分被错误识别的微小裂缝点或裂缝段。在模型融合过程中, 上述 3 类模型结果的融合图像在裂缝段产生重复, 融合图像的特征不充分, 其错误预测的部分作为特征可能对元学习器产生误导, 进而导致集成模型预测效果不佳。

8~10 号实验模型的性能相比未添加 SCM 的 1~3 号实验模型性能产生明显提升; 11~13 号实验显示, 添加 SCM 后, 任意两模型集成后的性能对比其采用模型的单个模型集成, 均存在正提升; 14 号实验模型为本文模型, 在融合全部模块后, 其性能高于上述所有实验模型, 对比 7 号实验中未添加 SCM 的三模型集成及 11~13 号实验中添加了 SCM 的双模型集成, 其 Dice 系数提升在 0.025~0.14 之间, 具有确定性的提升。

根据图 6 (d) 结果分析上述正提升的原因, SCM 对输入图像进行边缘检测提取边缘信息, 并将其作为骨干特征结果向后传递与模型结果进行融合; 边缘信息与裂缝的位置、形状密切相关, 元学习器可以根据其中包含的特征进行充分学习, 在各模型的结果基础上进行二阶预测, 最终得到精确的裂缝结果如图 6 (e) 所示。

2.3 实例分析

为进一步展示所提出方法的实际应用效果, 截取 D105 井部分裂缝发育的井段作为测试数据进行识别, 根据人工分析结果可见: 该井段发育裂缝 13 条, 包括斜交缝、高角度缝及交叉缝, 裂缝种类多样且部分裂缝成像效果不佳, 增加了裂缝识别的难度。如图 7 所示, 本文方法对特征较为明显, 干扰因素较少的 11, 12, 13 号裂缝定位、识别精准; 对周边色彩干扰较大且存在纹理轮廓模糊的 1 号与 6 号裂缝也进行了准确的辨别。

然而, 5 号裂缝的识别结果存在裂缝断开的情况, 这是因断裂处周围背景干扰过

大, 为避免训练时错误拟合, 在样本标注时未对此类裂缝进行封闭所致 (图 6); 在 5 号裂缝下方有小部分非裂缝区域被误识别为裂缝段, 主要原因是该区域部分特征与裂缝特征相似度高, 因此造成小范围误识别; 10 号裂缝存在漏识别情况。

由于其角度过高, 本次研究中对类似样本收集数量较少, 且其处于复杂裂缝层段, 周边特征对其产生一定影响, 导致未能对其正确识别。

但是, 以上现象大部分为漏识别, 错误识别的状况较少, 说明该模型可正确学习并提取裂缝特征, 能在复杂图像中识别出裂缝区域, 后续可通过扩充样本集的方式提升识别效果。另外, 2, 3 号裂缝与 7, 8, 9 号裂缝均为交叉裂缝, 识别有一定难度, 但本文方法对这两组缝的定位与识别结果较为准确, 裂缝连贯性较好; 4 号裂缝周边存在疑似裂缝, 本文模型通过对该区域特征进行分析, 对 4 号裂缝进行识别的同时捕捉到潜在的裂缝区域, 提供了额外的信息。

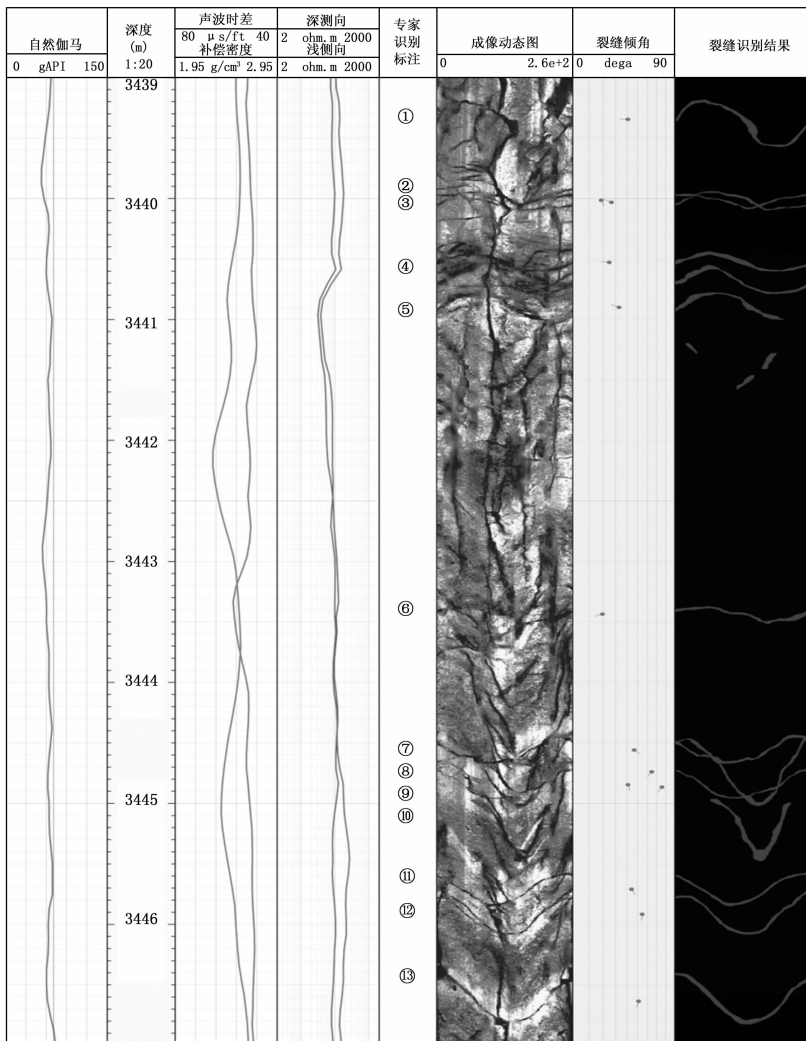


图 7 D105 井裂缝识别结果

最终在人工标注的该井段 13 条裂缝中, 通过本文方法识别出 11 条完整裂缝, 存在两条漏识别裂缝与少量错误识别裂缝, 对该井段裂缝图像的识别结果基本符合专家识别结果, 并且在已标注结果外识别出了疑似裂缝, 有助于辅助专家分析工作, 具有较好的实际应用意义。

3 结束语

现有的图像处理集成学习模型多采用投票策略集成子模型, 该类策略虽能突破单个模型局部最优解达到全局最优, 但基于固定规则, 如加权、平均等, 容易忽略掉分类器之间的差异性和互补性, 且对噪声较为敏感, 模型的鲁棒性不佳。故本文采用 Stacking 融合策略将 Deeplabv3+, SegFormer, YOLOv8 三个异质深度学习模型作为子模型进行集成, 通过不同架构的模型对裂缝特征进行多角度捕捉和综合分析, 充分利用模型的多样性; 针对子模型的输出结果中存在冗余, 缺乏充分的特征供元学习器进行学习的问题, 设计 SCM 组件, 将原始数据的边缘信息提取并向后传递, 与子模型的结果进行融合后输入至元学习器, 使元学习器基于原始图像主要特征组合子模型, 有效避免了由于二阶预测时裂缝形态特征冗余与整体图像特征不足导致的过拟合, 以解决在复杂密集环境下裂缝检测不连贯与存在多条交叉裂缝时检测效果差等问题, 提升裂缝识别任务的精确性。

本文对方法中使用的图像识别算法与 SCM 组件进行消融实验, 并以指标的形式展示各项融合实验的效果, 包括交并比, Dice 系数, Kappa 系数三项, 以证明该方法的有效性。实验结果表明, 在不添加 SCM 时, 使用 Stacking 对单个模型进行二阶预测时仅有微小提升, 多个模型的融合时存在负提升。添加 SCM 后, 由于特征清晰且充分, 模型的整体精度相较于无 SCM 时显著提升, 在全部模块融合时算法的效果达到最优, 证明了本文方法在测井图像裂缝识别任务中的有效性。

然而, 本研究仍存在一些局限性, 如模型复杂度高、训练时间长等问题, 这些问题限制了模型的性能, 在未来研究中可以在融合策略、子模型调优等方面进行改进。此外, 本研究仅使用基于电阻率测井的图像数据, 未来还可以通过常规测井数据、阵列声波测井数据等多模态数据联合应用, 进一步丰富特征。

参考文献:

[1] TORRES D, STRICKLAND R, GIANZERO M. A new approach to determining dip and strike using borehole images [C] //SPWLA 31st Annual Logging Symposium, Louisiana: SPWLA, 1990: 1-20.

- [2] 赵军, 祁兴中, 刘瑞林, 等. 基于图像分割的成像测井资料目标拾取与计算 [J]. 地球物理学进展, 2007 (5): 1502-1509.
- [3] 张群会, 师玉璞, 陈有兰. 成像测井裂缝自动识别元胞自动机方法研究 [J]. 西安科技大学学报, 2012, 32 (6): 772-775.
- [4] TAIEBI F, AKBARIZADEH G, FARSHIDI E. Detection of reservoir fractures in imaging logs using directional filtering [C] //5th Iranian Joint Congress on Fuzzy and Intelligent Systems-16th Conference on Fuzzy Systems and 14th Conference on Intelligent Systems, USA: IEEE, 2017: 150-154.
- [5] CRUZ R A Q, CACAU D C, SANTOS R M D, et al. Improving accuracy of automatic fracture detection in borehole images with deep learning and GPUs [C] //30th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). USA: IEEE, 2017: 345-350.
- [6] 李冰涛, 王志章, 孔垂显, 等. 基于成像测井的裂缝智能识别新方法 [J]. 测井技术, 2019, 43 (3): 257-262.
- [7] DIAS LO, BOM C R, FARIA E L, et al. Automatic detection of fractures and breakouts patterns in acoustic borehole image logs using fast-region convolutional neural networks [J]. Journal of Petroleum Science and Engineering, 2020, 191: 107099.
- [8] 魏伯阳, 潘保芝, 殷秋丽, 等. 基于条件生成对抗网络的成像测井图像裂缝计算机识别 [J]. 石油物探, 2020, 59 (2): 295-302.
- [9] JIAO Z, XING Q, ZHANG J, et al. Gravel extraction from FMI based on DSAM-DeepLabV3+ network [C] //16th IEEE International Conference on Signal Processing (ICSP), USA: IEEE, 2022: 405-410.
- [10] 夏文鹤, 朱喆昊, 韩玉娇, 等. 电阻率测井成像图井壁裂缝智能识别与分割方法 [J]. 石油地球物理勘探, 2023, 58 (5): 1042-1052.
- [11] 马同乐, 刘红岐, 廖海博, 等. 融合通道和空间交叉注意力的裂缝识别方法 [J]. 地球物理学进展, 2024, 39 (2): 727-736.
- [12] 张陈强, 贺锡雷, 湛洪平, 等. 基于 SA-VNet 卷积神经网络的低序级断层识别方法 [J]. 地球物理学进展, 2024, 39 (2): 634-646.
- [13] GANAIE M A, HU M, TANVEER M, et al. Ensemble deep learning: a review [DB/OL]. (2021-04-06) [2024-09-02]. <https://doi.org/10.48550/arXiv.2104.02395>.
- [14] 陆国青, 董少群, 黄立良, 等. 准噶尔盆地玛湖凹陷风城组陆相页岩油储层测井裂缝智能识别 [J]. 地球科学, 2023, 48 (7): 2690-2702.
- [15] 王宸章, 王彦飞, 白治经. 基于伪标签方法的页岩孔隙语义分割网络 [J]. CT 理论与应用研究, 2015, 34 (1): 89-98.

(下转第 231 页)