

生成对抗网络算法在电成像测井裂缝空白条带填充中的应用

康正明 武辰升 杨国栋 武迪生 王瑞飞 杨湘雨 甘伟

引用本文:

康正明, 武辰升, 杨国栋, 等. 生成对抗网络算法在电成像测井裂缝空白条带填充中的应用[J]. 煤田地质与勘探, 2025, 53(3): 197–207.

KANG Zhengming, WU Chensheng, YANG Guodong, et al. Application of a generative adversarial network algorithm to filling blank strips of fractures in formation microresistivity imaging images[J]. *Coal Geology & Exploration*, 2025, 53(3): 197–207.

在线阅读 View online: <https://dx.doi.org/10.12363/issn.1001-1986.24.07.0472>

您可能感兴趣的其他文章

Articles you may be interested in

基于CT和深度学习的煤裂隙智能提取方法

A method for intelligent information extraction of coal fractures based on CT and deep learning
煤田地质与勘探. 2025, 53(2): 1–12 <https://doi.org/10.12363/issn.1001-1986.24.09.0609>

基于穿层钻孔声波远探测有限元方法的煤岩界面成像

Coal–rock interface imaging based on acoustic remote reflection logging within crossing boreholes using the finite element method
煤田地质与勘探. 2024, 52(3): 118–129 <https://doi.org/10.12363/issn.1001-1986.23.06.0366>

油气井雷达成像测井仪改进及试验

Improvement and test of radar imaging logging tool for oil and gas wells
煤田地质与勘探. 2021, 49(5): 253–259 <https://doi.org/10.3969/j.issn.1001-1986.2021.05.028>

基于混合网格有限元的直流电阻率法三维正演研究

3D forward modeling of DC resistivity method based on finite element with mixed grid
煤田地质与勘探. 2022, 50(5): 136–143 <https://doi.org/10.12363/issn.1001-1986.21.06.0338>

基于随钻振动信号与深度学习的岩性智能预测方法

Intelligent lithology prediction method based on vibration signal while drilling and deep learning
煤田地质与勘探. 2023, 51(9): 51–63 <https://doi.org/10.12363/issn.1001-1986.23.03.0149>

基于有限元模拟的矿井微震源高精度定位方法

High-Precision Localization Method for Mine Microseismic Sources Based on Finite Element Simulation
煤田地质与勘探. 2025, 53(2): 1–12 <https://doi.org/10.12363/issn.1001-1986.24.10.0615>



移动阅读

康正明, 武辰升, 杨国栋, 等. 生成对抗网络算法在电成像测井裂缝空白条带填充中的应用[J]. 煤田地质与勘探, 2025, 53(3): 197–207. doi: 10.12363/issn.1001-1986.24.07.0472
KANG Zhengming, WU Chensheng, YANG Guodong, et al. Application of a generative adversarial network algorithm to filling blank strips of fractures in formation microresistivity imaging images[J]. Coal Geology & Exploration, 2025, 53(3): 197–207. doi: 10.12363/issn.1001-1986.24.07.0472

生成对抗网络算法在电成像测井裂缝空白条带 填充中的应用

康正明¹, 武辰升¹, 杨国栋^{2,3}, 武迪生⁴, 王瑞飞⁵, 杨湘雨¹, 甘伟¹

(1. 西安石油大学 电子工程学院, 陕西 西安 710065; 2. 中国石油川庆钻探地质勘探开发研究院, 四川 成都 610051; 3. 四川恒溢石油技术服务有限公司, 四川 成都 610051; 4. 长庆油田分公司第十一采油厂, 甘肃 庆阳 745000; 5. 西安石油大学 石油工程学院, 陕西 西安 710065)

摘要: 【目的】电成像测井仪器极板之间存在间隔, 测得的井壁电阻率图像存在空白条带, 对井壁附近裂缝参数评价影响较大。针对裂缝空白条带填充没有全井眼图像, 填充质量评价难的问题, 提出一种模拟数据与真实数据相结合构造数据集, 基于生成对抗网络的电成像测井裂缝空白条带填充方法。【方法】首先, 基于三维有限元法对裂缝地层的电阻率测井响应进行模拟。采用过渡边界条件代替实体裂缝的方法提升了多尺度模型的计算效率, 满足了深度学习对样本的需求。其次, 将模拟得到的裂缝与实际测井图像相结合构建了全井眼图像, 用电成像测井图像制作的掩码作为空白条带。通过图像填充指标评价裂缝空白条带填充能力的方式优选超参数, 获得最佳空白条带填充效果。最后, 采用不同占比的掩码进行裂缝空白条带填充, 并评价裂缝填充质量。【结果和结论】结果表明: 模型能够在不同占比的空白条带情况下进行填充, 对粗糙裂缝有较好的填充效果且裂缝形态平滑, 能更准确地恢复边缘轮廓与细节。在真实测井数据上的填充进一步验证了其适用性, 填充后的图像自然且能有效恢复裂缝特征, 有助于裂缝提取及定量计算, 为裂缝储层的精准评价提供基础, 支撑油气产能的准确预测。

关 键 词: 电成像测井; 空白条带填充; 深度学习; 生成对抗网络; 有限元法; 井壁裂缝

中图分类号: P631 **文献标志码:** A **文章编号:** 1001-1986(2025)03-0197-11

Application of a generative adversarial network algorithm to filling blank strips of fractures in formation microresistivity imaging images

KANG Zhengming¹, WU Chensheng¹, YANG Guodong^{2,3}, WU Disheng⁴, WANG Ruifei⁵,
YANG Xiangyu¹, GAN Wei¹

(1. School of Electronic Engineering, Xi'an Shiyou University, Xi'an 710065, China; 2. Sichuan Hengyi Petroleum Technology Service Company, Chengdu 610051, China; 3. Sichuan Hengyi Petroleum Technology Service Company, Chengdu 610051, China;
4. No.11 Oil Production Plant, Changqing Oilfield Company, Qingyang 745000, China; 5. College of Petroleum Engineering, Xi'an Shiyou University, Xi'an 710065, China)

Abstract: [Objective] Gaps between the electrodes of formation microresistivity imaging (FMI) imagers lead to blank strips in the resistivity images of borehole walls, significantly influencing the parameter assessment for fractures near borehole walls. The absence of full-borehole images renders it challenging to assess the blank strip filling quality for fractures in FMI images. Using a dataset constructed utilizing both simulated and actual data, this study proposed a generative adversarial network (GAN)-based method for filling the blank strips of fractures in FMI images. [Methods] First,

收稿日期: 2024-07-21; 接收日期: 2025-02-19

基金项目: 国家自然科学基金项目(42304138); 陕西省教育厅重点科学研究计划项目(22JY053); 西安石油大学研究生创新与实践能力培养计划(YCS23215348)

第一作者: 康正明, 1989 年生, 男, 陕西靖边人, 博士, 副教授。E-mail: 190720@xsyu.edu.cn

© Editorial Office of *Coal Geology & Exploration*. OA under CC BY-NC-ND

the resistivity logging responses of a fractured formation were simulated using the 3D finite element method. Actual fractures were simplified using the transition boundary condition, improving the computational efficiency by avoiding multi-scale models and meeting the requirements of deep learning for substantial samples. Second, full-borehole images were attained by integrating the simulated fractures with actual FMI images, and masks generated from FMI images were used as blank strips. To achieve the optimal filling effects, hyperparameters were optimized by assessing the capacity of blank strip filling for fractures using image filling indicators. Finally, the blank strips of fractures were filled using masks with varying proportions, followed by a filling quality assessment. [Results and Conclusions] The results indicate that the proposed method allows for the filling of blank strips with varying proportions. Notably, it yields encouraging filling effects and smooth morphology for coarse fractures and can restore their margins and details more accurately. Its applicability was further verified using actual log data, revealing that it produced natural-looking filled images that can effectively restore fracture features. The proposed method facilitates the extraction and quantitative analysis of fractures, laying a foundation for the precise assessment of fractured reservoirs and supporting the accurate prediction of hydrocarbon productivity.

Keywords: formation microresistivity imaging (FMI) log; blank strip filling; deep learning; generative adversarial network (GAN); finite element method; borehole wall fracture

微电阻率成像测井是复杂储层评价的重要技术手段之一。基本原理是将极板推靠在井壁后,测量极板上多个纽扣电极向地层发射聚焦电流,得到每个纽扣电极对应位置的地层电导率,通过对其进行色标刻度,得到井眼周向二维图像^[1]。利用电导率图像可直观分析碳酸盐岩、砂砾岩等储层中的裂缝分布、地层层理及砾岩颗粒,因此,被广泛应用于复杂储层的测井评价^[2]。由于电成像测井仪器不同测量极板张开时,极板之间存在测量盲区,井壁图像覆盖率无法达到100%,造成部分信息缺失,在图像上会出现的空白条带影响了图像视觉效果与地质目标的精确识别与评价。为使图像能完整地反映井壁附近地质体信息,需要对这些空白条带进行填充。

裂缝是井壁附近地质体中最常见的一种,既是油气的储集空间,又是油气的流动通道^[3],因此,裂缝参数的解释是油气储量评价和产能预测的关键^[4]。目前,最常用的人机交互的解释方法人力资源消耗大且易受主观因素影响,缺乏统一的裂缝参数定量计算标准,因此,裂缝参数的精准评价成为研究重点,而裂缝评价精度和所在图像处空白条带的填充效果息息相关。电缆测井时全井眼图像难以获取,导致裂缝处空白条带的填充效果无法通过相互对比来准确评估,可借鉴随钻电阻率成像测井仪器全井眼覆盖优势,采用数值模拟的方法获得裂缝的完整图像。在裂缝响应数值模拟方面,国外学者模拟了双侧向仪器^[5]、随钻测井仪器^[6]在单一水平裂缝的测井响应。在随钻测井仪器模拟基础上,国内学者对单一裂缝地层及网状裂缝地层中的随钻电阻率成像测井响应进行了模拟,并分析了模型参数^[7]、裂缝倾角^[8]对测井响应的影响。但由于裂缝延伸长度和张开度对比度较大,需要过度剖分网格以捕获目标几何特征,导致全域网格呈现多尺度特征,因此,上述方法在进行数值模拟时效率较低。

目前成像测井空白条带填充主要方法包括插值法和Filtersim方法。基于多点地质统计学的Filtersim算法是一种基于模式匹配的图像修复方法^[9],这种方法对电成像测井中的空白条带填充也有效果^[10]。插值法应用比较广泛的有:反距离加权插值法^[11],奇异谱分析插值法^[12]等。插值方法通常基于已知数据点进行数值估算,适用于连续变化的光滑区域,但不适用于复杂地质结构。通过多点地质统计与插值方法相结合的混合图像修复方法兼顾局部细节与全局结构^[13],对储层非均匀性较强的地层图像填充效果较好。上述方法在复原小面积空白区域或者均匀性比较好的地层结构中能获得良好的修复效果,但对于修复大面积或者非均匀性比较严重的图像(例如砂砾岩图像),由于不能获取图像的深层特征,会出现填充模糊或者填充后的结构纹理连续性不强的现象。

随着深度学习的发展,尤其是深度卷积神经网络^[14]的提出使图像提取更深层次的特征更加容易,如人脸识别^[15]、超分辨率重建等图像领域被成功应用^[16]。神经网络方法主要采用Encoder-Decoder结构、U-Net网络、生成对抗网络等。Encoder-Decoder结构^[17]用于砂泥岩和砂砾岩电阻率图像填充,并可结合通道-空间注意力机制和变形卷积^[18]提高修复效果。U-Net网络^[19]通过多次训练填充模型,在碳酸盐岩地层电成像图像中取得良好效果,并通过空洞卷积^[20]增强感受野和特征提取能力,适用于自然场景和砂砾岩图像修复。此外,融合低层语义特征和高层语义特征^[21]的方法能够增强填充区域的细节保留能力。与传统CNN方法^[22]对比,GAN展现了在复杂地层填充中的优势,能够生成更加逼真的填充结果,同时结合傅里叶卷积^[23]可进一步提升纹理细节和连续性。由于缺少完整的全井眼图像,上述研究使用自然场景图像训练与测试后对填充效果进

行评价。但自然场景图像并不能完全代表测井图像的复杂性,因此,限制了模型的训练效果。此外,测井图像空白条带填充效果评估依赖主观评判图像的连续性和地质特征,因而缺乏科学依据,容易导致评估结果的不准确。

针对上述问题,本文采用生成对抗网络算法对空白带进行填充。首先,使用过渡边界条件(transition boundary condition, TBC)将薄板状裂缝实体进行等效和简化,结合有限元数值模拟方法实现了裂缝地层的电阻率成像测井高效建模,完成了对含裂缝地层电阻率图像的快速模拟。然后,将模拟得到的全井眼裂缝图像与真实测井图像背景相结合作为数据集,使用生成对抗网络对数据集进行训练和测试。最后,利用训练得到的模型对实际测井图像进行空白带填充。

1 样本制备方法

1.1 随钻电成像数值计算模型

为了制备含全井眼的井壁电阻率图像样本集,采用有限元数值模拟方法建立含裂缝的3D电阻率成像测井数值计算模型,如图1所示。模型包括井眼、随钻电阻率成像测井仪器、圆盘状裂缝和地层。井眼位于背景地层的中心,直径为0.2159 m(8.5 in)。为提升激励信号幅度,使用双螺绕环作为发射,源距0.65 m,纽扣电极直径1 cm。模型只模拟裂缝响应,因此,将背景地层相对电导率设置为0.001 S/m。裂缝延伸度0.5 m,井眼电导率为1 S/m,默认裂缝中充满泥浆;发射电流为1 A,激励频率为1 kHz。

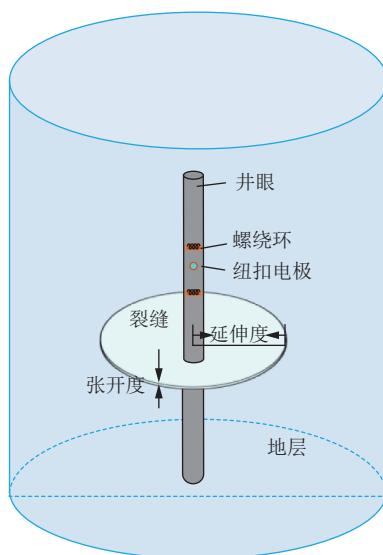


图1 裂缝地层数值计算模型

Fig.1 Numerical calculation model of a fractured formation

1.2 裂缝等效理论

图1所示的有限元模型中裂缝延伸长度较张开度

相差较大,需要过度剖分网格以捕获目标几何特征,导致全域网格呈现多尺度特征,进而产生多尺度物理场求解问题。为提高计算效率,采用将薄导电裂缝体近似为面,该方法称之为过渡边界条件(TBC)。TBC适用于简化导电薄板的模拟,本文中涉及的天然裂缝在测井中一般认为在探测范围内都被导电泥浆所充填,因此,满足TBC的使用条件:

$$\sigma \geq \omega \epsilon \quad (1)$$

对称裂缝两侧边界条件可满足:

$$\mathbf{n} \times \mathbf{H}_{t1} = \frac{Z_s E_{t1} - Z_t E_{t2}}{Z_s^2 - Z_t^2} \quad (2)$$

$$-\mathbf{n} \times \mathbf{H}_{t2} = \frac{Z_s E_{t2} - Z_t E_{t1}}{Z_s^2 - Z_t^2} \quad (3)$$

阻抗 Z_s 和 Z_t 可表示为:

$$Z_s = \frac{j\omega\mu}{k} \frac{1}{\tan(kd)} \quad (4)$$

$$Z_t = \frac{j\omega\mu}{k} \frac{1}{\sin(kd)} \quad (5)$$

在含裂缝地层的建模中,裂缝上下表面的电场和磁场可用上述公式进行关联,裂缝张开度将在计算过程中仅作为常数出现并且不再参与几何网格剖分中,该方法可避免对裂缝内部进行网格剖分和计算,可显著减少自由度,提高求解效率。

1.3 数据集构建

深度学习训练时依赖大量的样本支撑,采用上述过渡边界条件等效的方法提高了裂缝样本生成效率。为提升样本的多样性,裂缝几何参数在一定范围内随机选择。其中,裂缝倾角范围为0~75°、倾向范围为0~360°、张开度范围为0.1~1.0 mm、电导率范围为1~3 S/m。

数值模拟过程中,通过控制纽扣电极的采样间隔,仪器在井中移动测量实现井周全方位电阻率扫描成像。为进一步减少计算时间,对纽扣采样得到64条方位电导率曲线进行三次样条插值,将64条方位曲线插值到128条方位曲线来增加采样点数。通过读取电导率曲线数值范围实现电导率曲线转换为图像显示,将电导率范围映射到0~255的像素区间,并基于像素值生成图像。插值前和插值后图像分别如图2a、图2b所示。此外,将同一条裂缝按不同倾向展开并改变成像深度可实现数据的扩充,如图2c所示。

对电缆成像测井静态图像以0.5 m自动截取,选取不含任何地质体的图像作为背景。空白带填充主要关注裂缝、层理等地质体特征修复效果,但电缆电阻率成像测井扫描得到的地质体没有完整特征。因此,本文将随钻电阻率模拟得到的裂缝图像与电缆成像测井静态图像背景相结合作为深度学习的数据集,这种方法降低

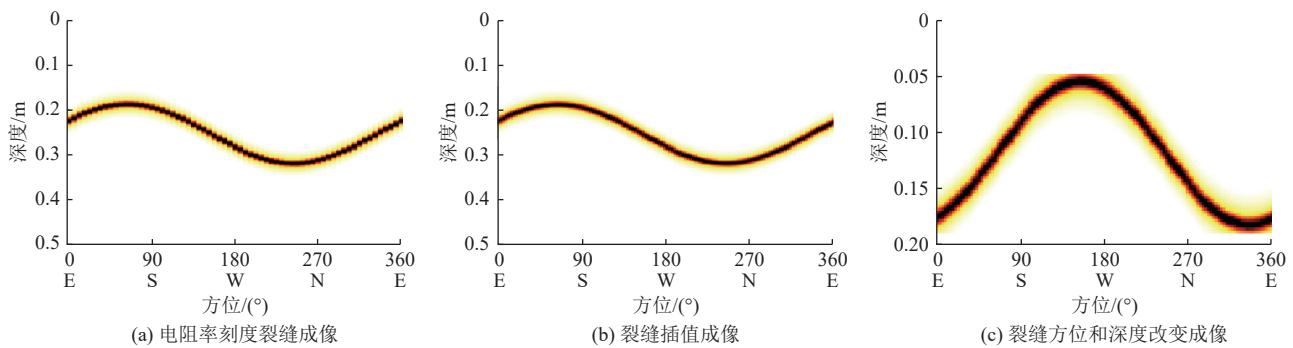


图 2 裂缝成像与数据扩充
Fig.2 Fracture imaging and data augmentation

了模拟样本和实际测井图像之间的差异,组合后的电阻

率成像结果如图 3 所示。

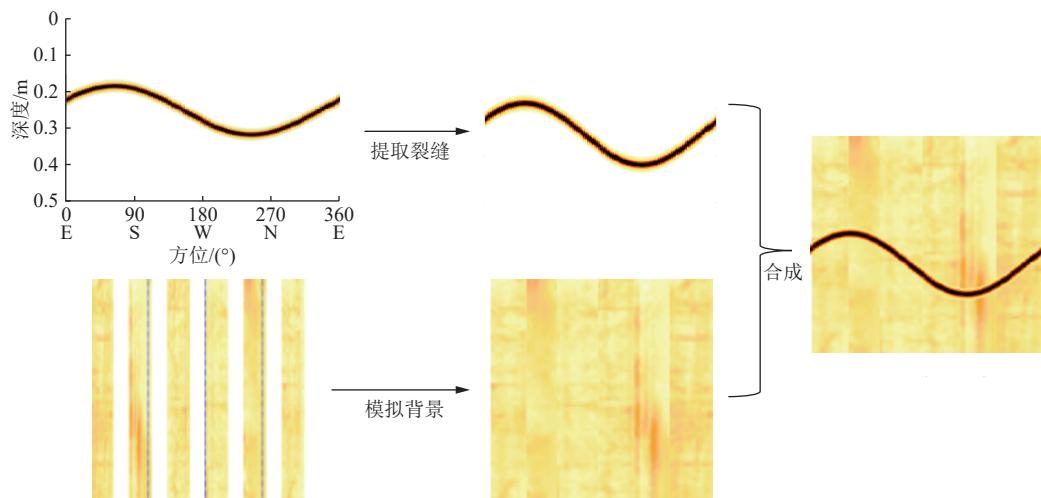


图 3 数据集制备方法
Fig.3 Method of the sample data preparation

2 基于 GAN 的空白带填充模型

2.1 模型网络结构

生成对抗网络(generative adversarial network, GAN)是一种新型无监督学习的机器学习算法,其核心思想在于零和博弈^[24]。GAN 组成包括生成器(generator)与判别器(discriminator),其中,生成器主要负责学习真实数据的潜在特征,根据学习到的特征生成新样本数据;判别器为二分类器,主要用于判别生成数据与真实数据的差异,并最大化判别准确率。判别器的存在迫使生成器生成更逼真的数据样本。生成器的目标是尽可能地欺骗判别器,而判别器则不断提高自己的区分能力。生成器和判别器之间形成一种动态的对抗过程,推动模型的训练和提升生成数据的质量。DCGAN 将深度卷积神经网络与生成对抗网络结合实现图像的处理^[25]。根据 DCGAN 的灵活性以及生成对抗网络的思想, R. A. Yeh 等^[26]首次将 DCGAN 应用在图像修复领域。本文网络结构以 Yeh 的网络结构为基础,判别器使用 PatchGAN 判别器。PatchGAN^[27]判别器是一种常用于图像生成

领域的判别器结构,与传统的 GAN 中使用的全局判别器不同, PatchGAN 判别器将图像分割成小的块(或“补丁”),然后预测每个补丁的真实性。

网络模型工作流程如图 4 所示,设定生成器和判别器的初始参数。生成器产生样本输入到判别器评价损失。计算梯度,更新生成器参数,使其生成的样本更接近真实样本。判别器分别计算真实样本损失和生成样本损失。计算梯度并更新判别器参数,提高判别器的区分能力,直到训练轮数(Epoch)到设定值。生成器和判别器相互对抗进行训练,生成器试图最小化生成样本被判别为假的概率,而判别器试图最大化正确区分真实和生成样本的概率。

本文模型网络结构如图 5 所示,模型包含 1 个生成器网络、1 个判别器网络。空白带填充网络的生成器在网络中输入 4 个通道,其中包括 RGB(红、绿、蓝)3 个通道的空白带图像和 1 个通道的掩码图像。生成器网络结构是编码器-解码器结构,编码器对输入图像的特征进行提取及压缩。提取到的图像特征输入 8 个残差块,防止网络出现梯度消失的问题。解码器的作用是将

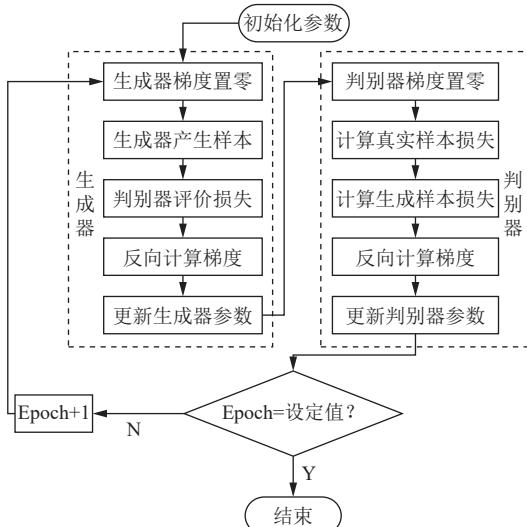


图4 空白带填充模型工作流程

Fig.4 Workflow of the blank strip filling model

图像上采样回原始大小, 根据输入的特征表示和上下文信息, 对图像空白带部分进行填充。在卷积每一层中使

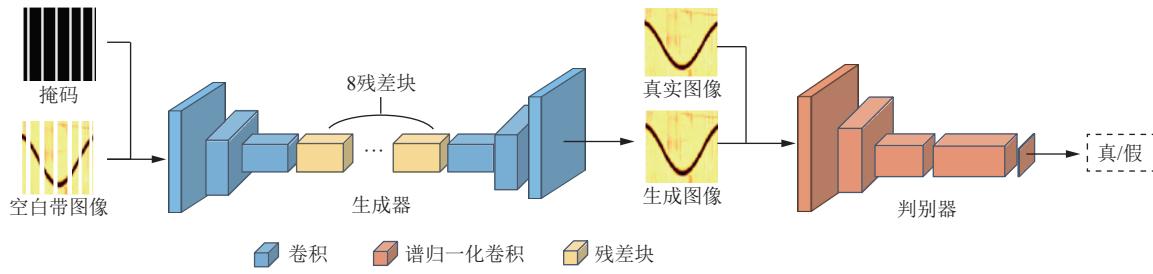


图5 空白带填充模型网络架构

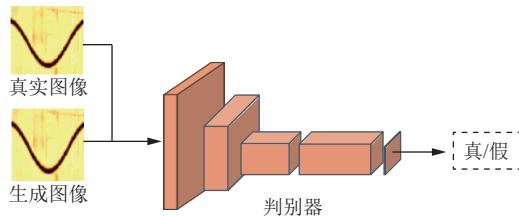
Fig.5 Network architecture of the blank strip filling model

2.2 损失函数设计

损失函数是网络训练的重要组成部分, 依据网络生成结果与映射目标之间的差异反馈信息指导权重更新。测井图像空白带填充模型的总体性能不仅取决于网络结构, 损失函数的选取也至关重要, 在训练过程中, 损失函数误差值作为反馈引导网络参数的优化, 故而训练目标是最小化损失函数值。在图像修复任务中一般使用 L1, L2 损失函数, 基于目标值与预测值差异的损失误差通常能得到较好的结果, 但同时也会产生过度平滑, 存在峰值信噪比与结构相似性指标虚高的问题。为了更好地修复测井图像的纹理细节和语义结构, 综合采用对抗损失、L1 损失、感知损失^[30] 以及风格损失^[31] 来训练空白带填充模型。

空白带填充模型包括, 1个生成网络和1个判别网络。生成网络生成合理、真实的空白带。判别器对空白带填充效果进行衡量。通过网络的不断训练, 空白带填充图像将逐渐变得逼真。当满足以下公式时, GAN 将获得最优结果。损失函数为:

用实例归一化加速深度神经网络的学习过程, RELU 激活函数增加非线性映射能力^[28]。解码器最后一层使用 Tanh 激活函数^[29], 将特征映射的通道转换为 3 个通道。判别器网络输入的数据为真实数据(来自训练数据集)或生成数据(由生成器生成)。将随机输入的数据进行区分, 通过学习训练数据中的特征分布。判别器可以区分出真实样本和生成样本。判别器网络使用 70×70 PatchGAN 架构, 其提供了更丰富的图像信息, 并使生成器更好地控制图像的细节。PatchGAN 架构将输入图像切分为多个小块, 每个小块对应一个输出值, 然后对这些输出值取平均或求和, 最终得到一个单一的预测结果。判别器由 5 个卷积块组成, 输入为三通道的生成图像或真实图像, 通过卷积逐步提取图像特征, 最终生成的特征图大小为 30×30 , 通道为 1。每一个特征图上的一个点对应原始图的 70 个点, 同时输入到 GAN 的损失函数中, 最终对特征图上的点求平均值, 得到最终的判别器损失。



$$L_{\text{GAN}} = E_{x \sim P_{\text{data}}(x)} [\ln D(x)] + E_{z \sim P_{\text{out}}(z)} [\ln (1 - D(G(z)))] \quad (6)$$

由目标函数可知, 训练判别器的过程中优化目标是最大化 $D(x)$ 接近于 1, 最小化 $D(G(z))$ 并使其接近于 0。

L_1 损失用于衡量真实图像与生成图像之间的像素级差:

$$L_1 = \|I_{\text{out}} - I_{\text{gt}}\|_1 \quad (7)$$

感知损失通过预训练的神经网络提取图片上的特征。然后将这些特征作为输入, 计算 2 张图片之间的差别。感知损失更注重图像的感知质量, 更符合人眼对图像质量的感受。感知损失为:

$$L_p = E \left[\sum_{i=1}^N \|\phi_i(I_{\text{out}}) - \phi_i(I_{\text{gt}})\|_1 \right] \quad (8)$$

风格损失通过比较生成图像与参考图像之间的特征表示来量化它们之间的风格差异。风格损失的计算基于 VGG 网络中间层的特征表示。使用预训练的 VGG 网络提取图像特征, 比较这些特征的 Gram 矩阵以捕捉图像的风格信息。Gram 矩阵是特征图之间的

相关性矩阵, 它反映了特征图中不同通道之间的相关性, 即特征之间的“风格”。通过比较生成图像和真实图像的 Gram 矩阵, 可以量化它们之间的风格差异。风格损失为:

$$L_s = E \left[\sum_{i=1}^N \|\mathbf{G}_i^\phi(I_{\text{out}}) - \mathbf{G}_i^\phi(I_{\text{gt}})\|_1 \right] \quad (9)$$

本文将上述损失函数进行综合, 得到最终的生成器损失函数为:

$$L_G = c_1 L_1 + c_{\text{adv}} L_{\text{adv}} + c_p L_p + c_s L_s \quad (10)$$

通过对生成器生成结果进行约束和训练, 可以有效提升其修复能力。优化器则采用自适应运动估计梯度下降(Adam)优化进行损失函数的迭代优化。

3 网络训练及结果分析

3.1 网络训练及优化

利用数值模拟得到含裂缝的随钻电阻率图像样本共有 240 张, 其中 0.5 m 成像深度 160 张、0.2 m 成像深度 80 张, 训练集与测试集按照 9:1 划分。由于图像样本数量较少, 属于小样本情况下生成对抗网络训练, 过大的批尺寸可能会导致模型陷入局部最优解或过早收敛, 较小的批尺寸会增加训练的随机性, 可能导致训练过程不稳定。学习率决定每次参数更新的步长, 学习率过高可能会导致模型过早收敛或不稳定, 学习率过低模型训练时间很长。因此, 固定损失函数权重 $c_1=1$ 、 $c_{\text{adv}}=0.2$ 、 $c_p=0.2$ 、 $c_s=200$ 前提下, 使用不同的学习率和批尺寸对生成对抗网络进行遍历寻优。

均方误差(mean squared error, MSE) 所反映的是网

络的预测值与实际值之差平方和的平均值, 该参数对数据集中异常值较为敏感, 性能比较稳定。因此, 使用 E_{MS} 作为网络模型的评价指标:

$$E_{\text{MS}} = E[(I_{\text{out}} - I_{\text{gt}})^2] \quad (11)$$

针对空白带填充问题, 选用生成器学习率 η 分别为 0.000 1、0.000 3、0.000 5、0.001 0、0.003 0 和 0.005 0, 判别器学习率为生成器的 0.1 倍。批尺寸分别为 4、8、16 和 32 时, GAN 网络训练时的 E_{MS} 曲线如图 6 所示, 不同批尺寸和学习率下 E_{MS} 的最小值见表 1。由表 1 可知, 在学习率固定的情况下, 随着批尺寸的减少, 精度逐渐增加。小批量训练使得网络在训练过程中见到更多样本的不同组合, 促进模型学习到更丰富的特征。在批尺寸固定的情况下, 随着学习率的减小, 精度逐渐增加。较低的学习率会使模型在训练时更稳定, 避免过大的更新步骤导致的振荡, 从而有助于模型收敛到更好的局部最优解。根据数据集的规模, 调整批量大小和学习率能够优化模型性能。在小数据集上, 较小的批量和学习率通常更有效。当批尺寸为 4、学习率为 0.000 3 时, GAN 网络训练的误差最小, 精度最高。由于图像空白带填充只在空白带部分有区别, 且 E_{MS} 是归一化后的计算结果。因此, 需要选取最小的 E_{MS} 权重以得到最优的空白带填充效果。

3.2 训练结果及分析

本文预训练权重采用由 R. A. Yeh 等^[26] 经过 CelebA 数据集训练的神经网络模型, 并使用 1.3 节构建的全井眼图像数据集进行迁移学习。设置训练轮数为 100 轮, 图 7 展示了原图和多轮深度学习填充结果。从图 7c 可

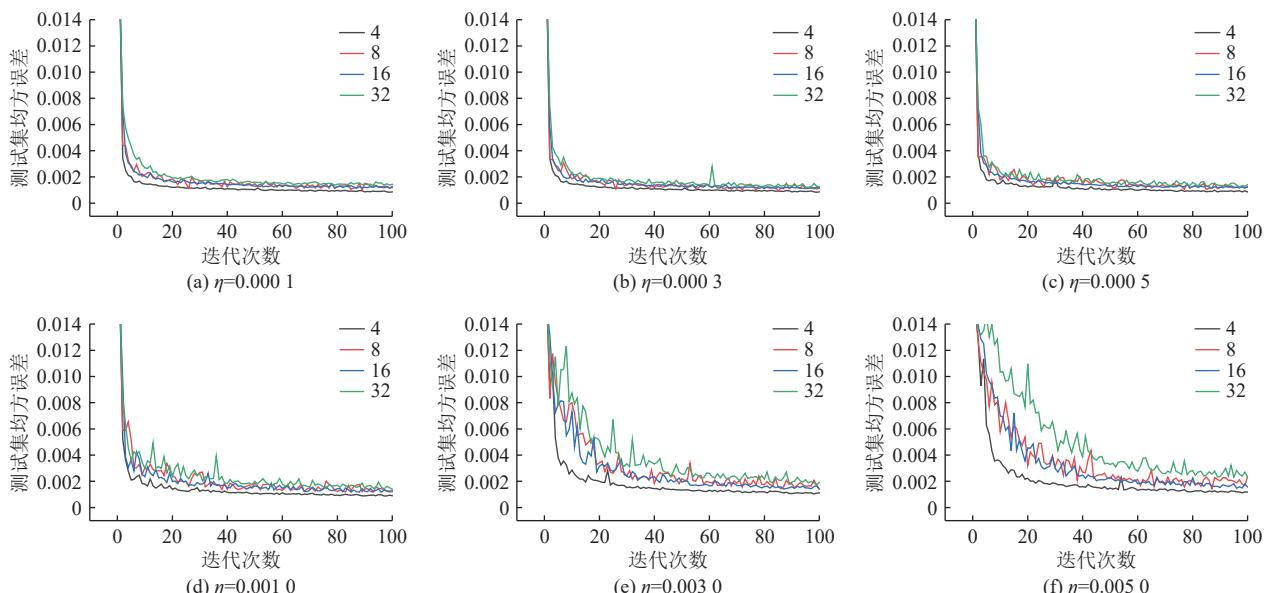


图 6 不同学习率和批尺寸下测试集均方误差曲线对比

Fig.6 Comparison of MSE curves under different learning rates and batch sizes

表1 不同批尺寸和学习率的均方误差
Table 1 MSEs under varying batch sizes and learning rates

η	训练集				测试集			
	4	8	16	32	4	8	16	32
0.000 1	0.000 584	0.000 725	0.000 837	0.001 028	0.000 908	0.001 040	0.001 183	0.001 379
0.000 3	0.000 580	0.000 631	0.000 706	0.001 013	0.000 841	0.000 926	0.001 177	0.001 291
0.000 5	0.000 594	0.000 587	0.000 624	0.001 011	0.000 865	0.001 196	0.001 063	0.001 277
0.001 0	0.000 648	0.000 704	0.000 948	0.001 290	0.000 882	0.001 199	0.001 272	0.001 441
0.003 0	0.000 876	0.001 041	0.001 278	0.001 438	0.001 044	0.001 399	0.001 416	0.001 894
0.005 0	0.001 004	0.001 038	0.001 380	0.002 179	0.001 200	0.001 677	0.001 472	0.002 636

以看出,训练1轮的空白带处填充后颜色与背景色彩接近,经过10轮训练,网络模型学习到图像背景的大致信息,但在裂缝区域输出为模糊图像。随着迭代次数的增

加,裂缝区域的图像细节被网络模型学习到。由最终填充图像(图7e)可知,当迭代结束时网络能够较为完整和清晰地填充图像的缺失区域。

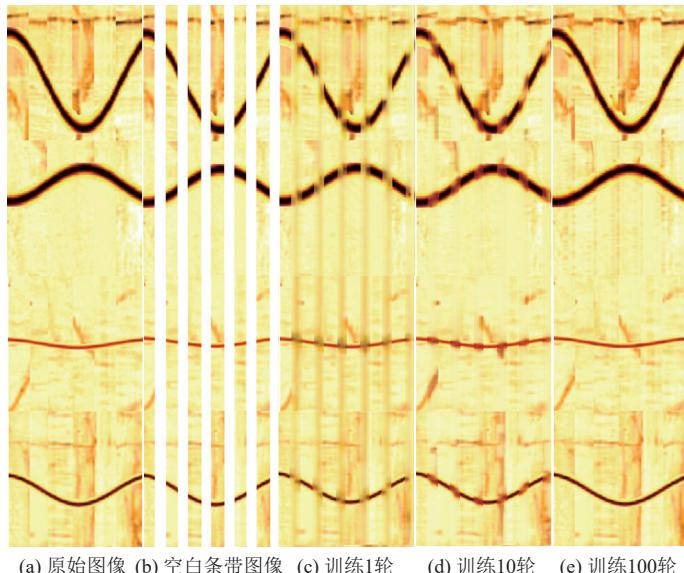


图7 网络训练多轮迭代输出图像
Fig.7 Images output after multiple rounds of training

由于井眼半径和测量仪器结构的不同,空白带占比及形状存在差异。竖直状掩码的占比设置考虑了电成像测井仪器 FMI、XRMI、STAR II 中空白条带的真实场景,即占比分别为 20%、30% 和 40%,见表2。设置训练轮数为 100 轮,超参数及数据集和前文相同,并对空白带填充质量进行评价。

表2 典型仪器掩码示例
Table 2 Examples of masks of typical imagers

掩码类型	FMI	STAR II	XRMI
掩码			

本文采用峰值信噪比、结构相似性 2 种图像质量评价指标对比修复后的效果。其中,峰值信噪比^[32]是反映修复图像与真实图像之间像素误差大小的客观指

标,数值越大,修复图像的质量越接近于真实图像;结构相似性^[33]是考虑人眼感知特性的评价指标,取值区间为 [0,1],它的计算方式是基于局部图案的亮度、对比度进行。测试时使用不同占比的条带状掩码,分别对 24 张原始图像和所提模型对应填充生成的图像计算峰值信噪比和结构相似性,结果见表3。可以看出,虽然随着空白带部分的扩大,峰值信噪比和结构相似性有所下降,但仍处于良好范围内。

利用数值模拟方法得到的数据集中裂缝形态均为规则形态,而实际地层中裂缝形态并非如此理想。由于裂缝表面的随机性和不规则性与高斯噪声的统计特性相似,都表现为在空间中的局部波动和不规则变化。因此,对这类裂缝进行建模时,可以视为一种高斯随机噪声,模拟其对测量结果的影响。为了验证该模型对不规则裂缝的修复能力,通过基本余弦波叠加的方式得到一

种高斯随机粗糙裂缝。修复结果如图 8 所示。其中, 图 8c 为本文方法填充结果, 图 8d 为某商用软件填充结果。可以看出, 相比商用软件填充结果, 本文方法在裂缝处形态连贯, 随着裂缝形态不规则程度增大, 商用软件填充的裂缝形态不连贯逐渐增加, 裂缝轮廓边缘信息失真严重。

表 3 不同掩码情况下空白带网络填充性能
Table 3 Performance of GAN-based blank strip filling under varying mask types

掩码类型	峰值信噪比/dB	结构相似性
FMI	36.307 6	0.984 4
STAR II	32.421 3	0.956 9
XRMI	30.983 1	0.942 1

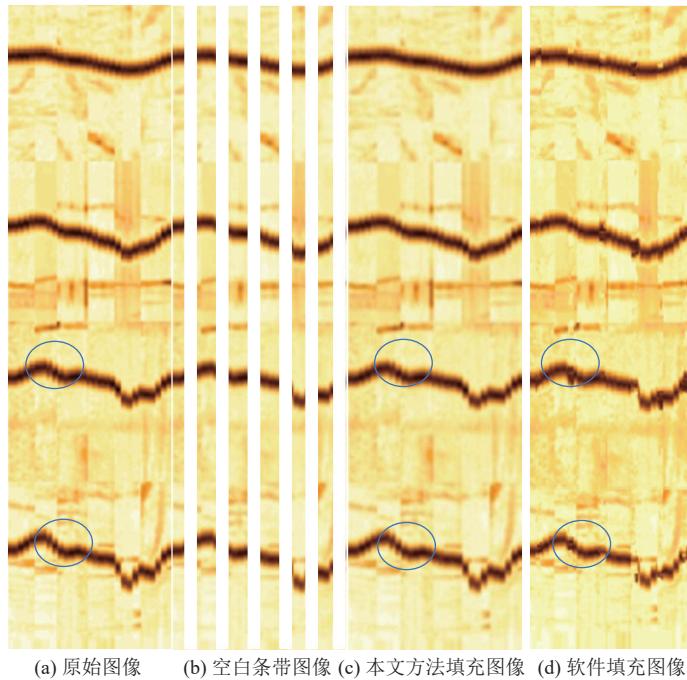


图 8 粗糙裂缝填充结果
Fig.8 Filling results of rough fractures

3.3 真实测井图像填充结果

根据真实测井图像中裂缝特征, 挑选样本后进行训练, 并使用包含裂缝的图像进行测试。图 9 展示了其中具有代表性的裂缝图像及其测试结果, 可以看出本文方法较为准确和真实地填充了宽带较大的空白条带部分, 且基本无法辨别空白条带边缘的填充痕迹。同时较为完整地填充了裂缝的边缘轮廓, 准确地恢复了裂缝的细节信息, 有利于后期利用测井图像进行岩性识别、提高边缘提取和裂缝拟合的精度, 并进一步进行裂缝倾角、裂缝倾向、裂缝张开度等定量计算。需要注意的是, 在深度 3 425.8~3 426.1 m 空白带填充结果过渡不够柔和, 空白带处背景偏亮。分析原因, 训练时图像背景电导率高的样本较少, 造成图像上半段填充效果不自然。其他深度段空白条带处填充后过渡自然, 几乎找不到填充痕迹。该方法填充速度为 0.725 s/m。与文献 [13] 中记录的时间比较, 插值方法填充速度为 0.86 s/m、基于多点地质统计方法填充速度为 1.74 s/m。说明本文方法空白带填充速度亦具有一定的优势。

4 结论

(1) 提出的生成对抗网络算法能够获取图像的地质体结构信息与背景特征, 从而更加准确地填充空白条带。相比于传统的空白条带填充方法, 在填充效果和填充速度上均有优势。

(2) 使用全井眼图像数据集进行样本训练, 并对深度学习网络参数进行了调整与优化。本文提出的填充方法不仅能够有效填充图像中的空白带, 还能够准确衡量填充后地质体特征的完整性。由于模拟数据的干扰较少, 确保了地质体形态的完整性, 为空白带的精准填充提供了可靠保障。

(3) 提出的空白条带填充方法能够适应不同类型的空白条带情况, 并通过与实际测井数据结合, 能够针对实际测井电成像图像中的空白带进行有效填充。这种方法在一定程度上克服了深度学习对训练图像的严格要求, 提高了模型在实际应用中的灵活性。

(4) 本文仅制作了规则裂缝地层的测井响应样本, 后续将对不规则形状的裂缝、更加复杂的多裂缝地层

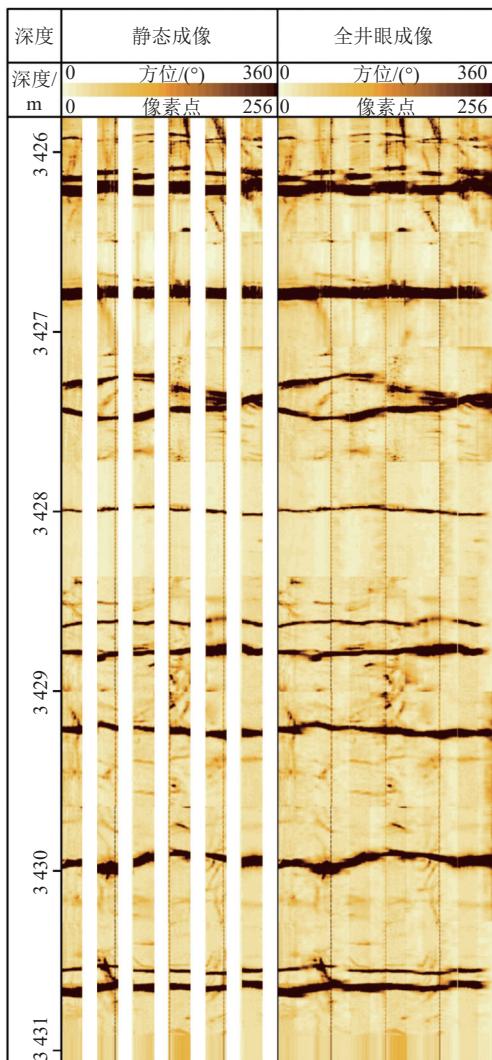


图9 测井图像填充结果

Fig.9 The filling result of the Logging image

图像和缝洞型地层图像样本进行考察,并通过引入多样的测井电成像背景来扩充数据集,提高该智能处理算法在实际应用中的准确性与可靠性。

符号注释:

c_1 为像素损失权重; c_{adv} 为对抗损失权重; c_p 为感知损失权重; c_s 为风格损失权重; d 为裂缝张开度, mm; $D(x)$ 为真实数据 x 的概率值; $D(G(z))$ 为生成器所生成的样本作为判别器的输入时所对应的概率值; E 为期望; E_{MS} 为均方误差; E_{t1}, E_{t2} 分别为裂缝两侧电场的切向分量; \mathbf{G}_i^ϕ 为输入图像通过 VGG 网络提取第 i 层特征图的 Gram 矩阵; H_{t1}, H_{t2} 分别为裂缝两侧磁场的切向分量; I_{out} 为生成图像; I_{gt} 为真实图像; j 为虚数单位; k 为传播系数, m^{-1} ; L_1 为像素损失; L_{adv} 为对抗损失; L_p 为感知损失; L_s 为风格损失; L_G 为综合损失; L_{GAN} 为生成对抗损失; \mathbf{n} 为法向量; N 为特征图的数量; $P_{\text{data}(x)}$ 为真实数据 x 的概率分布; $P_{\text{out}(z)}$ 为噪声数据 z 的概率分布; Z_s 为表面

阻抗; Z_T 为过渡带阻抗; ω 为角频率, rad/s; μ 为磁导率, H/m ; ϵ 为裂缝绝对介电常数, F/m ; σ 为裂缝的电导率, S/m ; ϕ_i 为预训练的 VGG 网络第 i 层的特征图; $\|\cdot\|_1$ 为 L1 范数。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References)

- [1] EKSTROM M P, DAHAN C A, CHEN Minyi, et al. Formation imaging with microelectrical scanning arrays[C]//The SPWLA 27th Annual Logging Symposium. Houston, Texas, June 9–13, 1986: SPWLA-1986-BB.
- [2] 侯振学, 于雪娴, 李东旭, 等. 电成像测井处理新技术在储层评价方面的应用[J]. 地球物理学进展, 2020, 35(2): 573–578. HOU Zhenxue, YU Xuexian, LI Dongxu, et al. Application of new processing technology of electrical imaging logging in reservoir evaluation[J]. Progress in Geophysics, 2020, 35(2): 573–578.
- [3] 邹才能, 朱如凯, 吴松涛, 等. 常规与非常规油气聚集类型、特征、机理及展望: 以中国致密油和致密气为例[J]. 石油学报, 2012, 33(2): 173–187. ZOU Caineng, ZHU Rukai, WU Songtao, et al. Types, characteristics, genesis and prospects of conventional and unconventional hydrocarbon accumulations: Taking tight oil and tight gas in China as an instance[J]. Acta Petrolei Sinica, 2012, 33(2): 173–187.
- [4] 黄振华, 程礼军, 刘俊峰, 等. 微电阻率成像测井在识别页岩岩相与裂缝中的应用[J]. 煤田地质与勘探, 2015, 43(6): 121–123. HUANG Zhenhua, CHENG Lijun, LIU Junfeng, et al. Application of micro-resistivity image logging in identifying shale facies and fractures[J]. Coal Geology & Exploration, 2015, 43(6): 121–123.
- [5] SIBBIT A M, FAIVRE O. The dual laterolog response in fractured rocks[C]//The SPWLA 26th Annual Logging Symposium. Dallas, Texas, June 17–20, 1985: SPWLA-1985-T.
- [6] RITTER R N, CHEMALI R, LOFTS J, et al. High resolution visualization of near wellbore geology using while-drilling electrical images[C]//The SPWLA 45th Annual Logging Symposium. Noordwijk, Netherlands, June 6–9, 2004: SPWLA-2004-PP.
- [7] 蔡亚琳, 柯式镇, 康正明, 等. 随钻电阻率成像测井在裂缝地层中的响应模拟[J]. 石油科学通报, 2020, 5(3): 327–336. CAI Yalin, KE Shizhen, KANG Zhengming, et al. Logging response simulation of a LWD resistivity imaging tool in fractured formations[J]. Petroleum Science Bulletin, 2020, 5(3): 327–336.
- [8] KANG Zhengming, LI Xin, NI Weining, et al. Using logging while drilling resistivity imaging data to quantitatively evaluate fracture aperture based on numerical simulation[J]. Journal of

Geophysics and Engineering, 2021, 18(3): 317–327.

[9] ZHANG Tuanfeng, SWITZER P, JOURNEL A. Filter-based classification of training image patterns for spatial simulation[J]. *Mathematical Geology*, 2006, 38: 63–80.

[10] HURLEY N F, ZHANG Tuanfeng. Method to generate full-bore images using borehole images and multipoint statistics[J]. *SPE Reservoir Evaluation & Engineering*, 2011, 14(2): 204–214.

[11] 孙建孟, 赵建鹏, 赖富强, 等. 电测井图像空白条带填充方法[J]. *测井技术*, 2011, 35(6): 532–537.

SUN Jianmeng, ZHAO Jianpeng, LAI Fuqiang, et al. Methods to fill in the gaps between pads of electrical logging images[J]. *Well Logging Technology*, 2011, 35(6): 532–537.

[12] 李振苓, 沈金松, 李思, 等. 成像测井电导率图像空白带奇异谱插值和缝洞孔隙度分离方法[J]. *测井技术*, 2017, 41(1): 33–40.

LI Zhenling, SHEN Jinsong, LI Si, et al. Singular spectral interpolation of blank strips in formation micro-scanner conductivity image and separation of porosity between fracture and karst cave[J]. *Well Logging Technology*, 2017, 41(1): 33–40.

[13] 张翔, 张猛, 肖小玲, 等. 复杂地层情况下全井周电成像图像修复方法[J]. *石油物探*, 2018, 57(1): 148–153.

ZHANG Xiang, ZHANG Meng, XIAO Xiaoling, et al. Image inpainting for fullbore electrical imaging logging in complex formations[J]. *Geophysical Prospecting for Petroleum*, 2018, 57(1): 148–153.

[14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25: 1–9.

[15] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: A unified embedding for face recognition and clustering[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA, June 07–12, 2015. doi: 10.1109/CVPR.2015.7298682.

[16] DONG Chao, LOY C C, HE Kaiming, et al. Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295–307.

[17] 王哲峰, 高娜, 曾蕊, 等. 基于深度学习模型的测井电成像空白条带充填方法[J]. *测井技术*, 2019, 43(6): 578–582.

WANG Zhefeng, GAO Na, ZENG Rui, et al. A gaps filling method for electrical logging images based on a deep learning model[J]. *Well Logging Technology*, 2019, 43(6): 578–582.

[18] 杜春雨, 邢强, 张晋言, 等. 基于注意力约束深度生成网络的测井电成像空白条带填充[J]. *地球物理学进展*, 2022, 37(4): 1548–1558.

DU Chunyu, XING Qiang, ZHANG Jinyan, et al. Blank strips filling for electrical logging images based on attention-constrained deep generative network[J]. *Progress in Geophysics*, 2022, 37(4): 1548–1558.

[19] 张浩, 司马立强, 王亮, 等. 基于卷积神经网络的电成像图像空白条带填充方法[J]. *地球物理学进展*, 2021, 36(5): 2136–2142.

ZHANG Hao, SIMA Liqiang, WANG Liang, et al. Blank strip filling method for resistivity imaging image based on convolution neural network[J]. *Progress in Geophysics*, 2021, 36(5): 2136–2142.

[20] 陈建华, 杨丽丽, 赵延静, 等. 深度神经网络模型在测井电成像图像处理中的应用[J]. *电子测量技术*, 2021, 44(4): 138–143.

CHEN Jianhua, YANG Lili, ZHAO Yanjing, et al. Application of deep neural network model in processing of electrical logging images[J]. *Electronic Measurement Technology*, 2021, 44(4): 138–143.

[21] 袁晓涛, 马旭成, 肖仕军, 等. 融合多层语义特征的测井电成像空白条带填充深度神经网络方法[J]. *西安石油大学学报(自然科学版)*, 2022, 37(6): 133–139.

YUAN Xiaotao, MA Xucheng, XIAO Shijun, et al. A deep neural network method for filling blank strips in electrical logging images based on fusion of multi-level semantic features[J]. *Journal of Xi'an Shiyou University (Natural Science Edition)*, 2022, 37(6): 133–139.

[22] WU Yuyan, DENG Rui, LINGHU Song, et al. Method of image restoration of the blank strips of electric imaging logs[J]. *Arabian Journal of Geosciences*, 2022, 15(13): 1189.

[23] 苏乾潇, 乔德新, 任义丽, 等. 基于傅里叶卷积的电成像测井图像修复[J/OL]. *北京航空航天大学学报*, 2024: 1–11 [2025-02-17]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0754>

SU Qianxiao, QIAO Dexin, REN Yili, et al. Inpainting of blank strips in imaging logging images based on Fourier convolution[J/OL]. *Journal of Beijing University of Aeronautics and Astronautics*, 2024: 1–11 [2025-02-17]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0754>.

[24] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 53–65.

[25] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[C]//4th International Conference on Learning Representations. San Juan, 2016.

[26] YEH R A, CHEN Chen, LIM T Y, et al. Semantic image inpainting with deep generative models[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA, July 21–26, 2017. doi: 10.1109/CVPR.2017.728.

[27] ISOLA P, ZHU Junyan, ZHOU Tinghui, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA, July 21–26, 2017. doi: 10.1109/CVPR.2017.632.

[28] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//Proceedings of the 14th International Conference

on Artificial Intelligence and Statistics. Fort Lauderdale, 2010.

[29] MISRA D. Mish: A self regularized non-monotonic activation function[C]//Mish Activation Function. Bhubaneswar, India 2019.

[30] JOHNSON J, ALAHI A, LI Feifei. Perceptual losses for real-time style transfer and super-resolution[C]//Computer Vision–ECCV 2016; 14th European Conference. Amsterdam, 2016; 694–711.

[31] GATYS L, ECKER A, BETHGE M. A neural algorithm of artistic style[J]. *Journal of Vision* September, 2016, 16: 326.

[32] GUPTA P, SRIVASTAVA P, BHARDWAJ S, et al. A modified PSNR metric based on HVS for quality assessment of color images[C]//2011 International Conference on Communication and Industrial Application. Kolkata, India, December 26–28, 2011. doi: 10.1109/ICCIIndA.2011.6146669.

[33] HORÉA, ZIOU D. Image quality metrics: PSNR vs. SSIM[C]// 20th International Conference on Pattern Recognition. Istanbul, Turkey, August 23–26, 2010. doi: 10.1109/ICPR.2010.579.

(责任编辑 聂爱兰)