

基于U-CNNformer网络的地震断层智能识别方法

安虹伊¹, 文馨¹, 李居正¹, 张惊喆¹, 张琳智¹, 房平超¹, 杜天玮², 张奎³, 王群武³

1 中国石油西南油气田公司勘探事业部; 2 昆仑数智科技有限责任公司; 3 北京普瑞斯安能源科技有限公司

摘要 高精度的断层检测是油气勘探开发过程中的核心任务之一,是规避潜在的工程风险、确保钻井操作安全的重要手段。随着勘探规模的扩大,传统的人工断层解释和常规的断层检测方法难以满足实际需求。深度学习方法为地震断层智能识别提供了一种重要途径,其中以Unet为代表的深度网络模型在该类任务中取得了诸多成功的案例。然而,由于卷积运算的特殊性,该方法在特征提取过程中丢失了部分信息,导致断层识别的准确性和鲁棒性有待进一步提升。将CNN-Transformer混合模块嵌入Unet网络框架中,提出了一种基于U-CNNformer的混合网络模型。混合网络模型提高了对样本集全局特征与局部细节的挖掘能力,克服了传统Unet网络在断层识别中信息关联性不强的局限,在保证断层识别精度的同时,提高了模型的鲁棒性。北海F3公开数据测试和我国四川盆地某实际数据的应用表明,混合网络模型不仅能更精确地检测断层特征,对断层分布的刻画也更为细致,实现了高精度的断层智能识别,可为钻井高效、安全地开发提供良好的支撑。

关键词 断层识别; 深度学习; U形网络; 卷积神经网络; 自注意力机制; 模型训练; 数据测试

中图分类号: TE19 **文献标识码**: A

引用: 安虹伊, 文馨, 李居正, 等. 基于U-CNNformer网络的地震断层智能识别方法[J]. 海相油气地质, 2025, 30(3): 277-288.

AN Hongyi, WEN Xin, LI Juzheng, et al. Intelligent identification method of seismic faults based on U-CNNformer network[J]. Marine origin petroleum geology, 2025, 30(3): 277-288.

0 前言

断层是油气运移的主要通道,对油气藏的形成和开发具有重要影响。然而,位于褶皱区的地层构造起伏大、断层非常发育,可能导致探井在钻进过程中发生井涌、井漏和钻空等问题,影响钻井安全。最初,地质专家通常手动解释三维地震数据来识别断层,但由于其严重依赖于专家经验和相关的地质学科知识,因此这种方法存在较大的主观性,解释结果难以复制且效率不高。随着图像处理技术的快速发展,基于这些技术的断层识别方法不断涌现,在一定程度上提高了效率。断层识别方法主要包括各种地震属性分类识别方法,如相干、曲率^[1]、倾角方位角、三维体曲率^[2]、C3相干体技术^[3]、断层似然度^[4-5];断层增强分类识别方法,如蚁群算法^[6]、构造导向滤波^[7]、最优曲面投票^[8];以及边缘检测类方法。尽管

断层通常被认为是横向不连续的反射,理论上可以通过检测不连续点来确定其位置,但由于上述地震属性对噪声和地层特征极为敏感,因此仅仅依靠测量地震反射的连续性不足以实现精确的断层识别。

近年来,人工智能技术在各个学科进行了成功的应用。在地质勘探领域,该技术为地震解释的各项任务提供了一种强有力的智能化支持^[9-11]。董守华等^[12]首次采用多参数的BP神经网络进行小断层识别;崔若飞等^[13]则通过分形技术提取地震数据的多维参数,用于训练BP神经网络模型以提高断层的识别效率和精度。然而,BP神经网络存在网络收敛缓慢、对初始权重敏感等问题,需要训练大量的数据集才能得到一个相对合理的结果。Tingdahl等^[14]将相干、频率、曲率等属性结合,利用MLP(多层感知器神经网络)进行训练,但该方法计算量大、抗噪性差,且没有充分考虑断层在空间上的展布特性,

收稿日期: 2024-10-26; 改回日期: 2025-03-13

本文受中国石油西南油气田项目《勘探事业部2024年探井随钻地震跟踪技术服务(北京普瑞斯安)》(编号: XNS勘探部YT2023-35)资助

第一作者: 安虹伊, 工程师, 主要从事石油与天然气勘探技术工作。通信地址: 610095 四川省成都市武侯区天府大道北段12号; E-mail: anhongyi@petrochina.com.cn

通信作者: 杜天玮, 硕士, 工程师, 主要从事储层预测及断裂检测等相关研究工作。通信地址: 102206 北京市昌平区黄河北街1号院中国石油科技园; E-mail: 1984055727@qq.com

因此难以实现推广应用。Di等^[15]提出了基于多属性的SVM(支持向量机)断裂识别流程,但SVM更适用于小样本数据,对于大数据量的三维地震资料,其效率与精度难以尽如人意。Lu等^[16]利用生成对抗网络(GAN)提高地震数据的采样率,以使断层特征更加明显,尽管该方法提高了断层识别精度,但其属于地震资料的前期解释性处理工作,主要目的是数据优化与质控,并没有改善现有的断层识别算法的不足。Yasin等^[17]通过搭建一个深度神经网络,实现了深层碳酸盐岩储层的裂缝参数综合预测与表征。

当前主流的断层自动识别技术主要利用了卷积神经网络的深度学习方法。卷积神经网络通过其复杂的神经元结构实现了局部感知与权值共享,多层卷积与池化操作也使其具备较好的特征提取能力。Huang等^[18]研究了一种可扩展的深度学习平台,应用于不同的地震属性,以多属性输入的形式实现对地震断层的自动识别。然而,深度学习的效果主要依赖于人为选择的敏感地震属性(训练集)及其相应的智能算法(网络与超参数等),其结果受到主观性的影响。Wu等^[19]采用了卷积神经网络(CNN)来识别断层,然后构建各向异性高斯函数以估计裂缝倾角和方位角延伸。然而,该方法使用局部像素块进行训练,只对小尺度范围内的像素点提取特征,因此计算效率非常有限。Xiong等^[20]使用基于骨架化地震相干属性体作为裂缝标签训练CNN网络。这种方法提供了比骨架化地震相干体分辨率更高的裂缝识别结果,但其本质上是相干属性的一个优化结果,同样也继承了相干属性的算法缺陷和识别伪影。段艳廷等^[21]提出了一种基于3D半密度卷积神经网络的断层自动识别方法,该方法的网络结构考虑了不同尺度的信息并保持了空间分辨率,然而与卷积神经网络相比,识别精度并未明显提高。Wu等^[22]通过使用人工合成地震记录训练卷积神经网络,实现了对断层概率、走向及倾角的预测。然而,这两种方法的识别效果受到合成地震复杂性、断层标签准确性以及网络参数合理性等多方面因素的影响。Di等^[23]提出了一种深度卷积神经网络,以高效完成断层的自动解释工作。然而,该研究训练及展示的断层数据基本都属于同一类型,因此无法检验其对更为复杂类型断层的识别准确率。Liu等^[24]在传统Unet的基础上引入了ResNet-34的残差模块,以提高计算效率。杨午阳

等^[25]结合UNet和Res-50网络模型构建了新的网络模型ResUNet用于训练断层数据,提高了断层识别效率和网络泛化能力。王作乾等^[26]尝试将基于特征压缩激活的Unet的卷积网络结构用于此类任务,优化了断层的识别效果。陈继兴等^[27]提出了一种基于CUnet网络的断层智能识别方法,采用卷积操作代替下采样中的最大池化。刘贵鑫等^[28]、张利霞等^[29]则在传统Unet网络中加入了注意力机制,增强了网络对断层特征的提取能力,但这种提升仅考虑了数据的局部特征。

为了充分考虑地震数据的全局和局部特征,提高断层智能识别的准确性和鲁棒性,本文设计了基于卷积-自注意力机制的混合网络结构(CNN-Transformer),分别捕获局部和全局特征,并将其嵌入到一个Unet框架中,提出了一种针对全域断层信息智能识别的U-CNNformer网络。CNN通过提取图像局部区域的特征,利用卷积滤波器捕捉像素之间的空间关系,而Transformer则将多个训练补丁(patches)馈送到基于Transformer的编码器中,以获取全局信息,最终增强了对断层的识别能力。该方法将CNN-Transformer的全局信息引入Unet结构的解码器,借助注意力机制,使模型更关注图像中的关键区域与有效信息,从而提升了断层识别的准确性和鲁棒性。

1 方法原理

1.1 断层识别原理

对于断层识别,本质上涉及对断层和非断层样本点进行二分类任务,可以归结为图像分割。在训练阶段,使用地震数据及其相应的断层解释标签来构建网络模型的训练集,并通过定义对应的损失函数对其进行迭代训练。在经过参数调整和优化后,最终得到经过训练的断层识别深度学习网络模型。当输入需要预测的地震数据并调整相关参数时,该模型可以准确地识别区域中的断层。

1.2 CNN-Transformer混合结构

传统的CNN卷积在局部感知能力方面表现出色,具备对局部空间信息的有效提取能力,而不同的卷积核能够拥有不同的感受野。然而,它也存在一个固有缺陷,即无法很好地综合全局信息,因为池化层可能会导致部分特征信息的丢失,从而缺乏局部与整体信息的关联性。与此不同,Transformer

网络采用 self-attention 结构,更注重全局信息的综合提取,但在提取细节信息方面相对较弱。

综合考虑两种网络结构分别在不同尺度信息提取的特点,本次研究在网络编码部分引入了一种卷积-自注意力机制混合模块(CNN-Transformer Block, CTB)。在设计CTB中,将CNN和Transformer结合以实现一种特征增强的表征学习,依靠特征耦合单元(Feature Coupling Unit, FCU),通过交互的方式在不同分辨率下融合局部特征和全局特征。此外,CTB采用了局部并行结构,以最大限度地保留数据的局部和全局特征,防止训练过程中的信息泄露。CTB可以分为一个CNN分支(Branch 1)和一个Transformer分支(Branch 2),这两个分支由局部卷积块、自注意力模块组合而成。其中CNN分支被用作特征提取,通过卷积操作实现对网络的特征学习,从而获取详细的高分辨率空间信息。然后,引入自注意力机制进行特征编码,通过Transformer内部的自注意力机制改善了卷积感受野的局限性。这种结合了CNN和Transformer的混合模块旨在综合利用它们各自的优势,以更全面、准确地提取断层特征。

1.3 U-CNNformer网络

首先,考虑到CNN与Transformer特征之间的不对称性,设计了FCU作为CNN与Transformer之间的桥梁。在设计流程中,FCU由一个下采样重构层和一个上采样重构层组成,如图1所示。一方面,为了融合两种结构的特征,耦合单元采用 1×1 卷积尺寸对齐通道尺寸,用下/上采样策略对齐特征分辨率,最后通过层标准化(LayerNorm)和批量标准化(BatchNorm)实现信息传递。另一方面,由于CNN和Transformer分支倾向于捕获不同尺度的特征,考虑两种不同尺度特征的互补性,将来自CNN分支的局部特征通过FCU的下采样重构层送入到Transformer中,以增强Transformer分支的局部感知能力。类似地,将来自Transformer分支的全局特征通过FCU的上采样重构层送入CNN中,以增强CNN分支的全局感知能力。因此引入耦合单元可以极大地提高局部特征的全局感知能力和全局表示的局部细节,从而更好地识别断层。

为了有效整合地震数据中的全局与局部特征的关系,实现更高精度的断层智能识别,提出了如图2所示的网络模型。

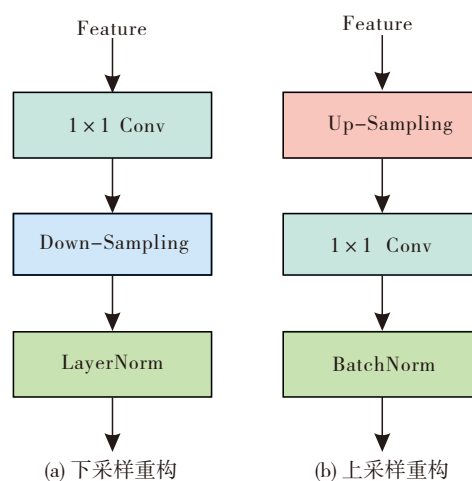


图1 FCU采样重构层细节

Fig. 1 FCU sampling-reconstruction layer details

网络结构首先通过一个初始特征层来接收地震断层识别任务的地震图像数据。该层作为一个接口,不仅接收预处理后的地震数据,还通过特定的操作(如卷积、池化等)对高维数据进行降维,提取出关键特征信息,如数据的边缘、纹理、形状等,以减少后续层的计算量,并为网络提供一个良好的学习起点。随后,网络采用了多个CTB模块(CNN-Transformer混合模块),这些模块结合了CNN在局部空间信息提取上的优势和Transformer在全局依赖关系捕获上的优势,能够同时捕获数据的局部和全局特征。最终,卷积输出层将CTB模块输出的特征图转换为地震断层识别的预测结果。在网络深度的选择上,经过反复实验验证,4个CTB模块在性能与计算成本之间取得了平衡,使得网络能够充分捕获数据特征,同时保持较低的计算成本。因此,网络结构由1个初始特征层,4个CTB模块,以及1个卷积输出层构成。其中,初始层和前2个CTB模块为数据的特征编码层,第3个CTB模块为中间层,后2个CTB与输出层为特征解码层。为保护信息传递,网络模仿了Unet结构,第2和第4个CTB模块引入了一个跳跃连接,使得整个网络结构呈现U形,故称U-CNNformer网络。

图2中的黄色虚线框展示了网络的初始层,其由一个步长为2的 7×7 卷积和步长为2的 3×3 最大池化层组成,这部分用于提取地震数据的初始局部特征,然后进入CTB模块通过各自的映射层送入到不同的分支中。图2中的紫色虚线框展示了CTB结构,其中CNN分支采用特征金字塔结构,特征图的分辨率随着网络深度的增加而降低,而通道数随着网络深度

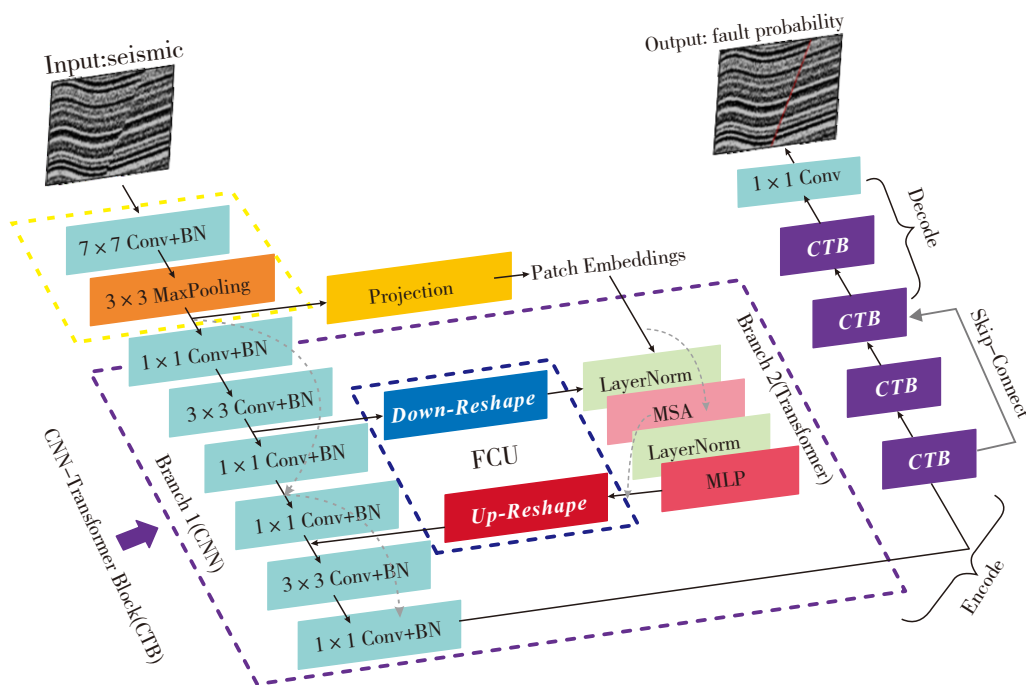


图2 U-CNNformer网络结构
Fig. 2 U-CNNformer network architecture

的增加而增加。Transformer通过一个简单的 patch embeddings 步骤将一个数据补丁投影到一个特征向量中,导致局部细节的丢失。而在CNN中,卷积核在具有重叠的特征映射上滑动,最大程度的保留了局部特征。因此,CNN分支能够连续地为Transformer分支提供局部的特征细节。在Transformer分支中,每个Transformer层由一个多头注意力模块(MSA)和一个多层感知模块(MLP)组成,同时,为凸显训练特征,在每个MSA和MLP模块都用了LayerNorm操作进行特征归一化。在U-CNNformer的每一个CTB模块中,FCU作为桥接模块,将CNN分支的局部特征与Transformer分支的全局表示融合,如图2中的蓝色虚线框所示。在经过各模块的编码和解码后,最后由一个 1×1 的卷积输出层实现对断层特征的重构,输出断层概率作为最终的预测结果。值得注意的是,U-CNNformer网络为了保留更多的数据特征信息,采用了ReLU函数进行非线性激活,而考虑到概率的非负性,输出层则采用了Sigmoid函数。本文利用均方误差作为损失函数来量化模型预测结果与实际标签之间的差异,从而指导模型参数的优化,最终实现对不同尺度特征的有效提取。

1.4 模型训练

模型训练所采用的数据集源自Wu等^[8]创建的

合成地震记录数据,总计包括240个三维合成地震记录及相应的标签集,每个数据的尺寸为 $128 \times 128 \times 128$ 。其中,有200个用于训练,20个用于验证,另外20个用于测试。在进行训练之前,对样本标签数据体进行了预处理。鉴于不同地震图像的振幅值可能存在显著差异,因此对所有训练的地震图像进行了归一化处理,以确保数据具有相似的尺度和范围,避免某些特征对模型训练的主导影响。同时对地震记录数据进行了平滑处理,以提高模型对地质结构的准确识别能力。这些预处理步骤有助于使模型更好地理解数据特征,提升模型在断层识别领域的可靠性。

为了确保有足够的断层样本以提高模型预测断层的有效性,对Wu等制作的合成地震记录数据进行了加工处理:①进行旋转、平移和缩放操作,随机生成三维水平反射率模型;②添加褶积和断层结构,增加地震数据的复杂度;③对数据随机添加噪声,合成地震数据。通过对这些数据集进行训练,发现它们包含多种不同断层特征,因此使用这些数据集进行模型训练能够更好地评估模型在断层预测方面的性能。

传统的池化操作在下采样过程中丢失了一部分图像特征信息,而混合结构中使用卷积操作代替

下采样的池化层可以避免这种信息损失。池化操作引入了不可逆的操作,导致在反向传播过程中梯度无法完全传播到原始输入,而卷积操作是可逆的,有助于梯度完全传播到原始输入,从而更好地优化模型参数。

图3展示了传统Unet网络和U-CNNformer网络的训练收敛曲线对比,验证方法的有效性。从图中可以看出,与传统Unet网络相比,U-CNNformer网络在训练过程中的准确度提高了12.96%,平均损失值降低了18.44%。这是因为CNN-TransUnet网络能够同时捕获图像的全局和局部特征,而传统的UNet

网络主要依赖卷积操作来提取局部特征。在地震断层识别中,断层通常具有复杂的形态和结构,需要同时考虑局部和全局信息。因此,CNN-TransUnet网络更容易学习到断层的特征表示,从而在训练过程中更快地收敛。Transformer架构中的self-attention机制使CNN-TransUnet网络能够更好地处理长距离依赖关系。在地震数据中,断层往往跨越多个地震道或时间切片,需要模型能够捕捉这种长距离的信息。CNN-TransUnet网络中的Transformer模块通过self-attention机制建立不同位置之间的依赖关系,从而提高了模型对断层特征的识别能力。

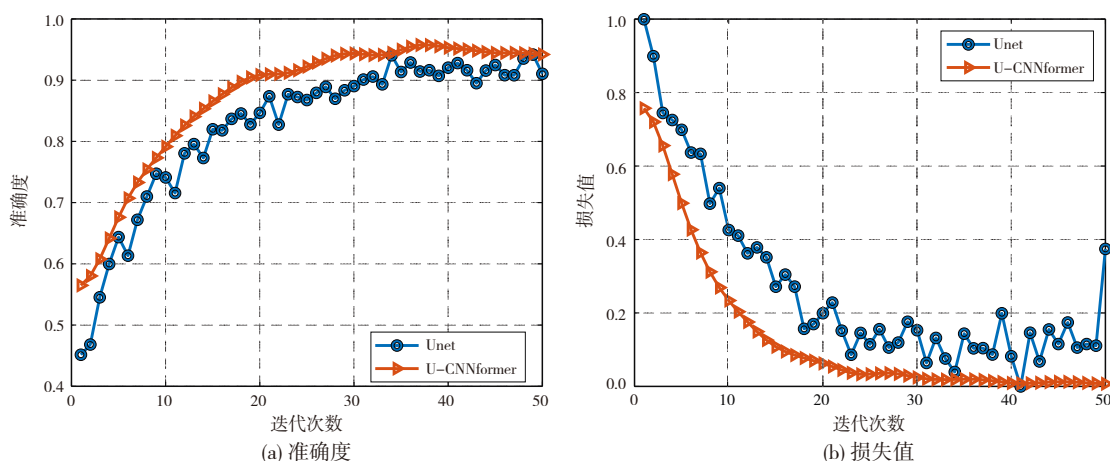


图3 传统Unet网络和U-CNNformer网络的收敛曲线对比

Fig. 3 Convergence curve comparison between the conventional Unet network and the U-CNNformer network

2 北海F3公开数据测试

将本文建立的U-CNNformer深度学习模型应用到北海F3公开数据进行测试。工区位于荷兰北部,断裂较为发育,这为深度学习断裂检测方法的验证提供了理想的数据基础。数据的Inline线为1 022条,Crossline线为383条,时间范围为0~254 ms,采样间隔为2 ms,数据体大小为141 M。本次研究将U-CNNformer深度学习的断层识别结果与传统的相干、曲率属性以及传统Unet深度学习方法识别的断裂进行对比,并将18079线的对比结果展示在图4中。原始地震剖面中同相轴错断明显,发育多条阶梯状的直立断层和倾斜断层(图4a);相干属性能够识别大部分的直立断层,但断层形态刻画模糊,精度低,纵向延续性差,倾斜断层识别效果也不理想(图4b);曲率属性在识别倾斜断层方面略优于相干属性,但同样存在纵向延续性较差和精度不足的

缺点,对断层的刻画也显得不够精细(图4c);蚂蚁体属性几乎能够识别所有的断裂,并且具有良好的纵向连续性,但非断裂因素的干扰较多(图4d);似然体属性的识别效果优于相干和曲率属性,但不及蚂蚁体属性,其纵向连续性稍逊且非断裂因素的干扰更为显著(图4e);基于传统Unet深度学习方法刻画的断层在纵向延续性方面明显优于前述属性,能够识别大部分的倾斜断层,然而该方法仍然存在断层刻画不够精细及部分断裂未能识别的缺点(图4f)。相比之下,基于U-CNNformer深度学习的断层检测效果最佳,它几乎能够全面捕捉到包括倾斜断裂在内的各类断裂特征,而且在断裂边缘的精细度、形态的准确性以及纵向连续性方面均实现了显著提升(图4g)。得益于混合网络模型对样本集全局特征与局部细节特征的卓越挖掘能力,此18079线的测试结果证明了基于U-CNNformer的深度学习方法在断层识别方面的高准确性和良好的连续性。

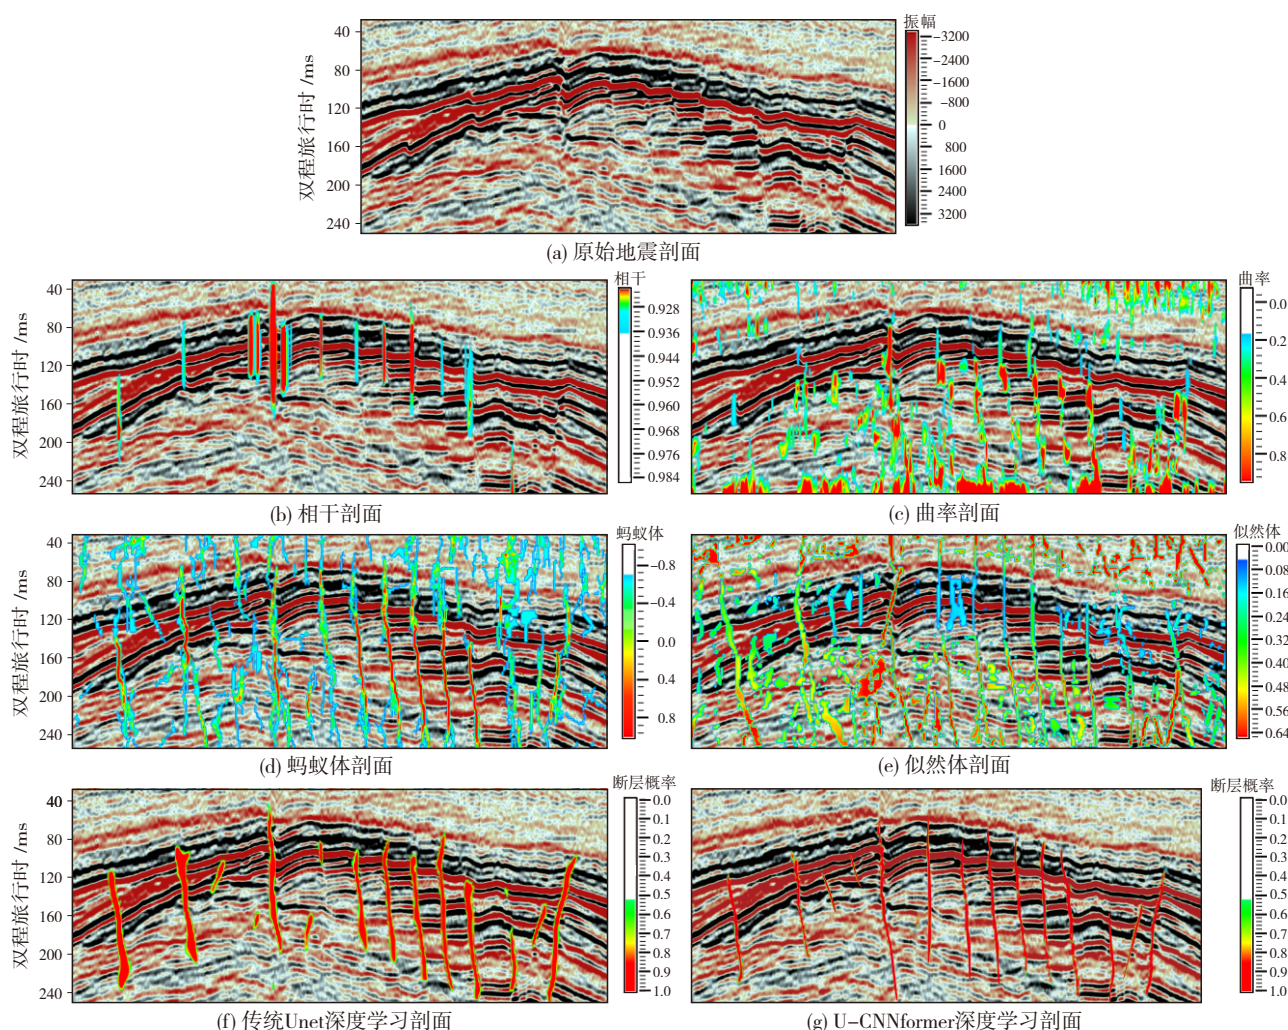


图4 北海F3数据不同方法断层识别效果的剖面对比

Fig. 4 Profile comparison of fault identification results by different methods for the North Sea F3 data

在经过单条测线的验证后,将基于U-CNNformer的深度学习技术应用到的整块三维地震数据中来开展精细的断层检测,并提取时间切片来反映断层平面展布。图5展示了沿着150 ms提取的6种断层检测属性时间切片,并分别投在原始地震切片上来评价断层检测效果。从图中可以明显看出,研究区主要发育南西—北东向的断层,局部发育近东西向断层。相干属性的切片基本能反映断层展布特征,但存在较多的杂乱干扰,其与地震数据切片的吻合度并不理想(图5a和图5d);曲率属性的切片在断层形态和清晰度方面较相干属性有所提升,展现了更为丰富的断层细节,与地震数据切片的匹配度略高于相干属性,但其仍然存在部分干扰能量(图5b和图5e);蚂蚁体属性的切片主干断裂刻画较好,其横向连续性好,但存在部分杂乱干扰(图5c和图5f);

似然体刻画的断裂更为细碎,横向连续性较差,同样存在杂乱干扰多的问题(图5g和图5j);基于传统Unet深度学习的切片刻画断裂的连续性得到明显增强,且杂乱干扰较少,能够更为准确地呈现研究区的断层展布特征,但是其识别的断层精细度欠佳(图5h和图5k)。而基于U-CNNformer深度学习的切片在刻画断层边缘特征方面表现得非常出色,它刻画的断裂数量增加,精度明显提升,横向连续性明显增强,且与地震数据切片的匹配度最高,杂乱干扰较少(图5i和图5l)。这项对北海F3数据的测试初步证实了基于U-CNNformer深度学习的断层识别结果在纵向连续性和边缘精细度方面均优于传统方法,显示出其在断层识别任务中的潜力和卓越性能,为地质勘探和断裂解释提供了更为精确和可靠的数据支持。

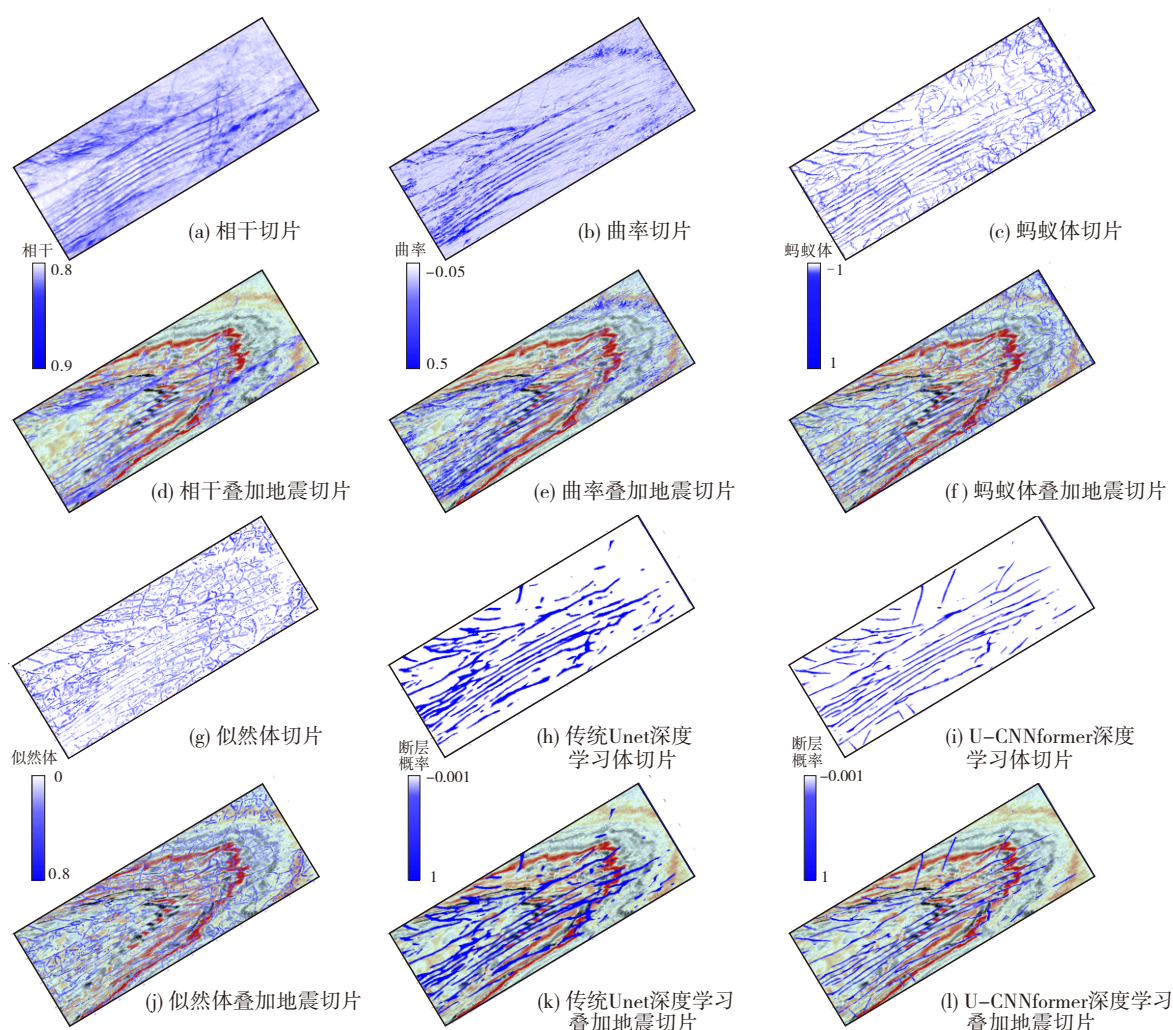


图5 北海F3数据沿150 ms的断层检测属性切片及其与地震切片的叠加显示

Fig. 5 Fault identification attribute slices and their overlay with seismic slice at 150 ms for the North Sea F3 data

3 实际资料应用及效果分析

为了进一步测试效果,将提出的智能识别方法应用于实际数据。研究区位于四川盆地川中古隆起平缓构造区仪陇构造群,属于川中低缓褶皱构造带^[30-31]。区内嘉四—嘉五段膏盐岩为一套塑形软弱地层,膏盐岩的盐底辟构造作用和区域上的挤压构造作用共同造就雷一¹亚段的盐背斜构造,整体影响上覆地层变形。膏盐岩变形导致盐岩之上形成一系列逆断层,如图6所示。研究区是一个地质结构复杂的区域,其特殊的地质条件对钻井工程的实施构成了严峻挑战。在该地区的钻探过程中,发现在雷口坡组至嘉陵江组漏失问题频繁发生,这一现象直接影响了钻井施工的安全性。因此,采用高精度的断层识别手段,准确地预测并定位断层,对于

规避潜在风险、保障钻井安全至关重要。

本次研究针对原始地震数据,采用本文提出的U-CNNformer深度学习方法进行了断层识别,并将识别结果与传统的相干和曲率属性检测结果进行了详细的对比。图7展示了断裂较为发育的两条剖面的对比结果。从图中可以清晰看出:相干属性识别的断层精度较低,其纵向连续性差,尤其在面对具有一定倾角的断层时,其识别效果明显欠佳(图7b,图7f);相对而言,曲率属性可以识别有一定倾角的断层,但是仍然存在精度低、纵向连续性差的情况,难以反映断层的空间展布(图7c,图7g);与传统的相干和曲率属性检测结果相比,基于U-CNNformer的深度学习方法在断层识别的精度和纵向连续性方面表现更优,预测的断裂可解释性强,能够准确地反映断层的空间延伸情况(图7d,图7h)。




图6 研究区雷口坡组至嘉陵江组构造特征展示

Fig. 6 Structural characteristics of Leikoupo Formation-Jialingjiang Formation in the study area

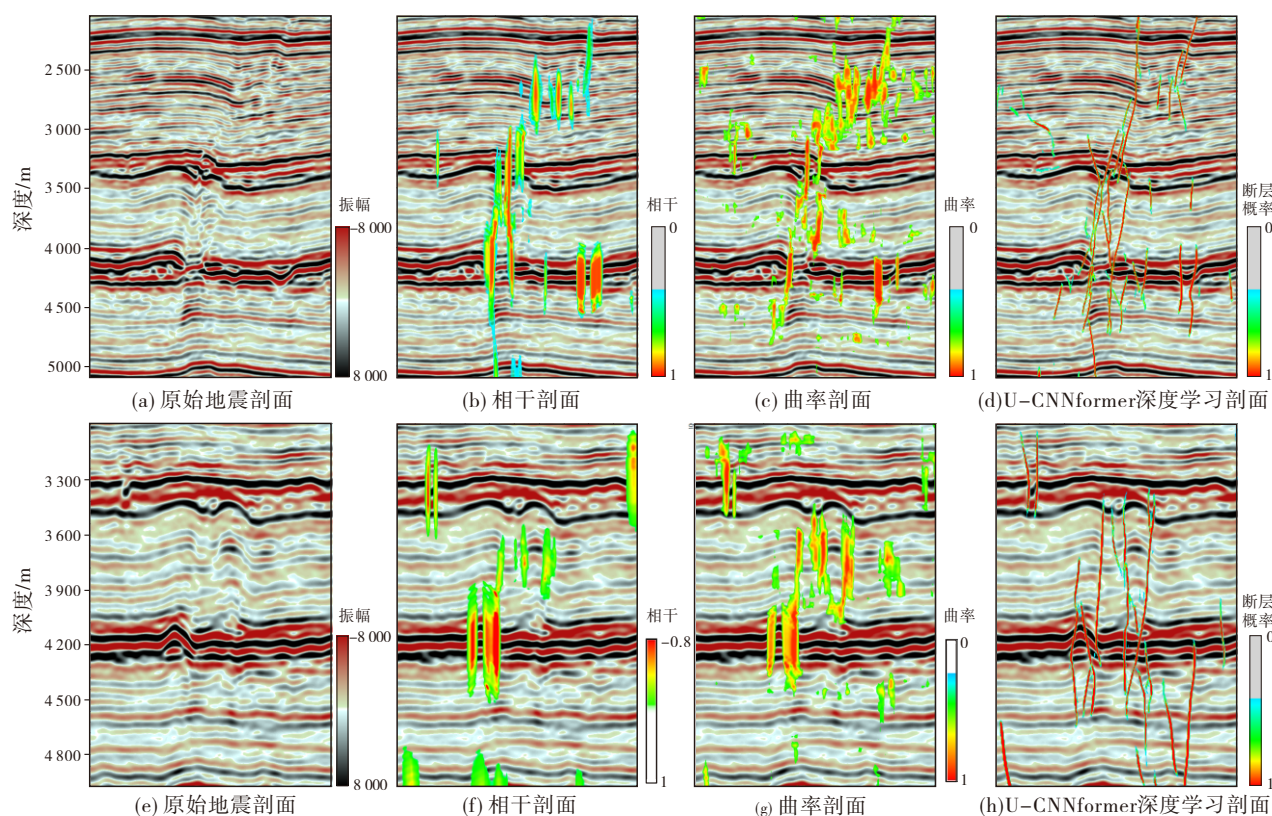


图7 研究区断层识别效果的剖面对比

Fig. 7 Profile comparison of fault identification results in the study area

图8是基于U-CNNformer的深度学习预测的断层平面展布图,由图可见此技术对断层特征具有很好的表征,预测的断层细节丰富、精度高。依据此结果可知研究区雷口坡组断层主要呈北西—南东走向。由于雷口坡组的构造具有继承性,因此雷三²亚段的构造图基本可以反映膏岩揉皱发育区的分布(构造高位对应膏岩揉皱区)。将本文方法预测的断层叠加在雷三²亚段底界面构造图上(图9a),结果显示断层主要发育在膏岩揉皱区附近。构造挤压使得雷一¹亚段和嘉五段的膏岩层形成盐

底辟构造,也使得雷口坡组内部地层产生断层,因此膏岩揉皱区的钻井更容易发生漏失,而平缓区的钻井漏失的可能性较小。图9b是沿着图9a中剖面线方向的连井剖面图,图中本文方法识别的断层与错断位置对应良好,空间连续性强,可以有效反映雷口坡组内部断层展布特征。图中PS16井位于膏岩揉皱区,井周发育多条断层,该井在雷一¹亚段和嘉五段钻进过程中均发生漏失,而PY1井、PS17井和PY3井位于膏岩平缓区,井周断层不发育,在雷口坡组和嘉五段钻进过程中未发生漏失。





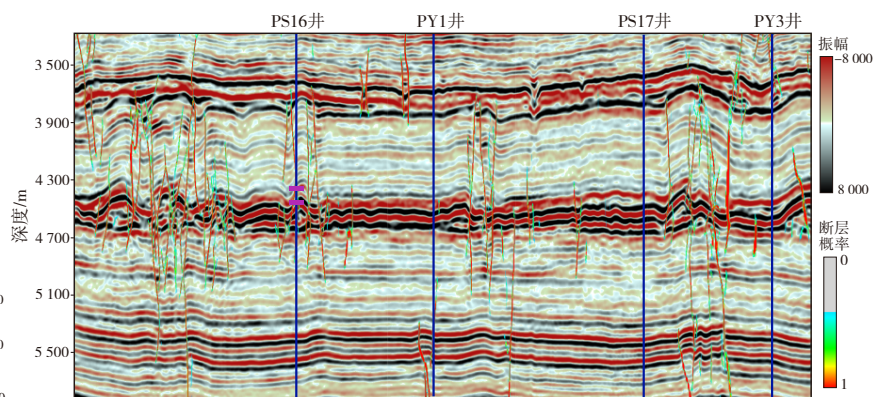
图8 U-CNNformer深度学习方法识别的雷三²亚段底界断裂切片显示

Fig. 8 Slice showing faults identified by the U-CNNformer deep learning method along the base of the $T_2L_3^2$ sub-member

方法的评估离不开实钻数据的验证。PS9井在雷一段发生两段漏失,深度分别是4 261.00~4 263.63 m和4 321.84~4 321.94 m,钻井液密度为2.35 g/cm³。第1段漏失最大漏速48.0 m³/h,最小漏速27.8 m³/h,平均漏速37.9 m³/h,累计漏失钻井液33.5 m³,漏失段岩性为深灰色白云岩。第2段漏失最大漏速6.4 m³/h,最小漏速1.2 m³/h,平均漏速3.8 m³/h,累计漏失钻井液34.5 m³,漏失段岩性为灰褐色灰质白云岩。该井在嘉五段发生的第3段漏失深度为4 357.21~4 357.31 m,钻井液密度为2.23 g/cm³,累计漏失钻井液27.2 m³。此3段漏失在PS9井的录井综合柱状图中可见,3个漏失段分别标注为1、2和3(图10a)。将3段漏失位置标定在地震剖面上,结果显示相干属性在漏失段显示出明显的异常响应,但却难以准确描述断裂形态,并且纵向连续性较差(图10b)。曲率属性未能准确识别断裂,并且在漏失段没有




(a) 雷三²亚段底界面构造图叠加U-CNNformer深度学习断层识别结果




(b) U-CNNformer深度学习断层识别连井剖面(剖面位置见a图)

图9 雷三²亚段底界面构造与U-CNNformer深度学习识别断层叠合图及U-CNNformer深度学习断层识别连井剖面


Fig. 9 Overlay map of the base structure and faults identified by U-CNNformer deep learning method of the $T_2L_3^2$ sub-member, and inter-well section showing faults identified by U-CNNformer deep learning method




(a) PS9井综合柱状图



(b) 相干剖面



(c) 曲率剖面



(d) U-CNNformer深度学习剖面

图10 PS9井综合柱状图及不同方法识别的断裂与漏失段的关联性

Fig. 10 Comprehensive column of Well PS9, and correlation of faults identified by different methods and the location of leakage occurrences

检测到异常响应(图10c)。相较之下,3个漏失段均与U-CNNformer深度学习预测的断层发育位置相符,且井筒正好穿过了断层(图10d)。因此分析3段漏失均是钻遇断层引起的。PS16井在雷一段底部和嘉五段共发生2次漏失,深度分别是4 346.00~4 346.22 m和4 445.00~4 445.53 m。第1段漏失钻井液密度为2.26 g/cm³,最大漏速42.0 m³/h,最小漏速6.0 m³/h,平均漏速15.0 m³/h,累计漏失有机盐聚磺钻井液22.4 m³,漏失段岩性为灰色石膏质白云岩;第2段漏失钻井液密度为2.20~2.23 g/cm³,累计漏失钻井液357.5 m³,漏失浓度19%~40%的堵漏

浆46.4 m³,该漏失段岩屑未返出。此两段漏失在PS16的录井综合柱状图中可见,两个漏失段分别标注为1和2(图11a)。将漏失段标定在地震剖面上,结果显示在两段漏失的位置,相干和曲率属性均未出现明显的异常响应(图11b和11c)。而2段漏失正好位于U-CNNformer深度学习预测的断层发育位置,且井筒恰好穿过了这些断层(图11d)。因此分析2段漏失均是钻遇断层引起的。综上所述,PS9井和PS16井的漏失段与U-CNNformer深度学习预测的断层位置高度吻合,验证了该方法预测断层的可靠性。

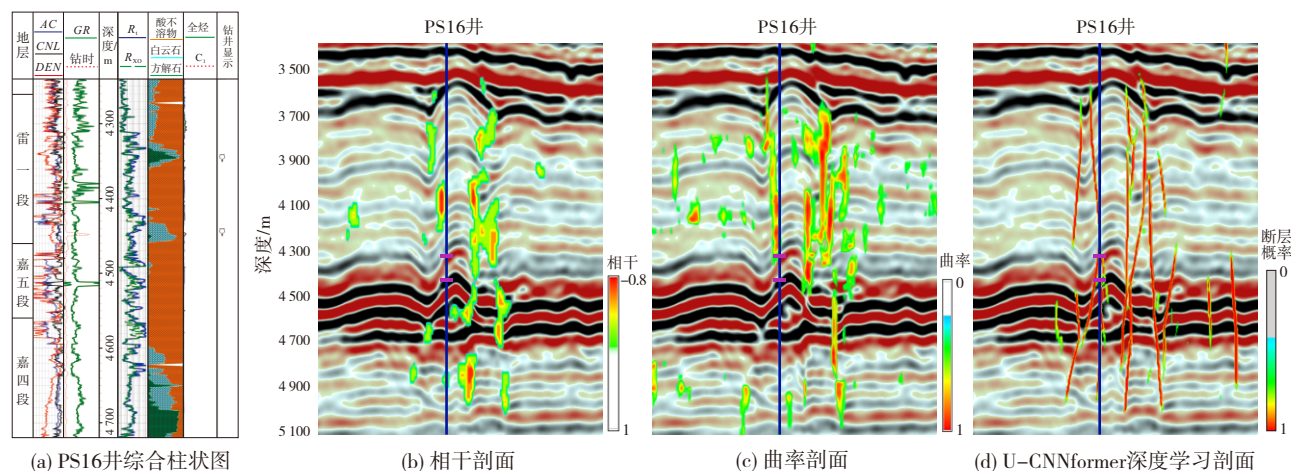


图11 PS16井综合柱状图及不同方法识别的断裂与漏失段的关联性分析

Fig. 11 Comprehensive column of Well PS16, and correlation of faults identified by different methods and the location of leakage occurrences

断层识别作为构造解释与储层表征的核心环节,其识别精度直接影响勘探开发成效与钻井安全。本文提出的基于U-CNNformer深度学习的智能断层识别技术,不仅能够精细刻画断层展布特征,为复杂地质条件下的油气藏勘探与开发提供更加精细的断层预测结果,而且实现了从井位部署到钻后评估的全流程工程风险管控:在井位部署阶段,通过高精度预测断层欠发育区,为优化井位设计提供科学依据;在钻进阶段,可对钻头前方可能发育的断层进行精准预测,并及时向工程部门发出风险提示,有助于规避潜在的工程风险,确保钻井操作的安全性和高效性;在钻后阶段,该方法还能够通过对已经发生的漏失进行检测和复核分析漏失原因。这种全方位的分析 and 检测,为事后的工程评估和问题溯源提供了科学依据,有助于更好地了解漏失的根本原因,进而优化未来的钻井策略。综上所述,这项技术不仅可以在井位部署期降低钻探风险,还在钻进期和钻后期提供了全面的支持。

4 结 论

本文提出了一种基于U-CNNformer网络的断层智能识别方法。首先,通过CNN的卷积运算提取高分辨率的地震数据空间信息,进而利用Transformer的自注意力机制,使模型更关注图像中的关键区域与有效信息,实现了对断层特征的增强学习。然后,引入了特征耦合单元(FCU)桥接CNN和Transformer网络模型,考虑不同模型提取的地震断层特征的不对称性,以交互的方式融合不同尺度的特征信息,提高局部特征的全局感知能力和全局表示的局部细节,最终提高了断层识别的精度。

北海F3数据测试展示了本文提出的断层智能识别方法的可行性和有效性。四川盆地某实际数据的应用表明,该方法相较于相干和曲率属性取得了更为精细的断层预测结果,且与平面地质解释结论高度一致。通过工程评估的验证,发现断层智能预测结果与实际钻井显示高度一致,这不仅为断层

的高效解释提供了一种关键的智能化工具,而且在井位部署、钻进期以及钻探后期提供了全面的技术支持,从而在提升钻井操作的安全性和效率的同时,为地质勘探和油气开发带来了更高的效益。

本文中所采用的训练数据主要以大断层为主,模型未能充分学习到不同复杂地质条件下中小断裂的有效特征。为了提升该方法的适用性,未来研究将考虑采用迁移学习策略,将训练好的U-CNNformer模型中蕴含的断层识别特征迁移到不同工区的实际数据中。通过使用少量目标工区的断裂解释结果作为标签,可以更进一步地识别断裂,提升精度和可靠性。

参考文献

- [1] ROBERTS A. Curvature attributes and their application to 3D interpreted horizons[J]. *First break*, 2001, 19(2): 85–100.
- [2] AL-DOSSARY S, MARFURT K J. 3D volumetric multispectral estimates of reflector curvature and rotation[J]. *Geophysics*, 2006, 71(5): P41–P51.
- [3] GERSZTENKORN A, MARFURT K J. Eigenstructure-based coherence computations as an aid to 3-D structural and stratigraphic mapping[J]. *Geophysics*, 1999, 64(5): 1468–1479.
- [4] HALE D. Methods to compute fault images, extract fault surfaces, and estimate fault throws from 3D seismic images[J]. *Geophysics*, 2013, 78(2): O33–O43.
- [5] WU Xinming, HALE D. 3D seismic image processing for faults[J]. *Geophysics*, 2016, 81(2): IM1–IM11.
- [6] PEDERSEN S I, RANDEN T, SØNNELAND L, et al. Automatic fault extraction using artificial ants[C]//2002 SEG Annual Meeting. Salt Lake City: SEG, 2002: SEG–2002–0512.
- [7] LAVIALLE O, POP S, GERMAIN C, et al. Seismic fault preserving diffusion[J]. *Journal of applied geophysics*, 2007, 61(2): 132–141.
- [8] WU Xinming, FOMEL S. Automatic fault interpretation with optimal surface voting[J]. *Geophysics*, 2018, 83(5): O67–O82.
- [9] 王喜鑫, 倪雪儿, 李少华, 等. 基于深度学习地震多属性融合的海上少井条件下河道型砂体构型解释: 以西湖凹陷X气田为例[J]. *海相油气地质*, 2023, 28(3): 261–268.
WANG Xixin, NI Xueer, LI Shaohua, et al. Architecture interpretation of channel sand body under offshore few well conditions based on deep learning seismic multi-attributes fusion: a case of X gas field in Xihu Sag, Donghai Shelf Basin[J]. *Marine origin petroleum geology*, 2023, 28(3): 261–268.
- [10] 张杰, 沈安江, 胡安平, 等. 基于深度学习的碳酸盐岩薄片人工智能鉴定方法研究[J]. *海相油气地质*, 2023, 28(4): 337–348.
ZHANG Jie, SHEN Anjiang, HU Anping, et al. Research on artificial intelligence identification approach for carbonate thin sections based on deep learning[J]. *Marine origin petroleum geology*, 2023, 28(4): 337–348.
- [11] 侯宇, 刘定锦, 雷开强, 等. 优化的AI断裂识别技术在川中北斜坡的应用[J]. *天然气勘探与开发*, 2024, 47(4): 55–62.
HOU Yu, LIU Dingjin, LEI Kaiqiang, et al. Optimized AI identification for faults in northern slope, central Sichuan Basin[J]. *Natural gas exploration and development*, 2024, 47(4): 55–62.
- [12] 董守华, 石亚丁, 汪洋. 地震多参数BP人工神经网络自动识别小断层[J]. *中国矿业大学学报*, 1997, 26(3): 16–20.
DONG Shouhua, SHI Yading, WANG Yang. Automatic recognition of small fault by BP artificial nervous network from multiple seismic parameters[J]. *Journal of China University of Mining & Technology*, 1997, 26(3): 16–20.
- [13] 崔若飞, 许东. 利用分形技术和人工神经网络技术检测小断层[J]. *中国矿业大学学报*, 1999, 28(3): 258–261.
CUI Ruofei, XU Dong. Detection of minor faults using both fractal and artificial neural network techniques[J]. *Journal of China University of Mining & Technology*, 1999, 28(3): 258–261.
- [14] TINGDAHL K M, DE ROOIJ M. Semi-automatic detection of faults in 3D seismic data[J]. *Geophysical prospecting*, 2005, 53(4): 533–542.
- [15] DI Haibin, SHAFIQ M A, ALREGIB G. Seismic-fault detection based on multiattribute support vector machine analysis[C]//2017 SEG International Exposition and Annual Meeting. Houston: Society of Exploration Geophysicists, 2017: SEG–2017–17748277.
- [16] LU Ping, MORRIS M, BRAZELL S, et al. Using generative adversarial networks to improve deep-learning fault interpretation networks[J]. *The leading edge*, 2018, 37(8): 578–583.
- [17] YASIN Q, DING Yan, BAKLOUTI S, et al. An integrated fracture parameter prediction and characterization method in deeply-buried carbonate reservoirs based on deep neural network[J]. *Journal of petroleum science and engineering*, 2022, 208(Part A): 109346.
- [18] HUANG Lei, DONG Xishuang, CLEE T E. A scalable deep learning platform for identifying geologic features from seismic attributes[J]. *The leading edge*, 2017, 36(3): 249–256.
- [19] WU Xinming, SHI Yunzhi, FOMEL S, et al. Convolutional neural networks for fault interpretation in seismic images[C]//2018 SEG International Exposition and Annual Meeting. Anaheim: SEG, 2018: SEG–2018–2995341.
- [20] XIONG Wei, JI Xu, MA Yue, et al. Seismic fault detection with convolutional neural network[J]. *Geophysics*, 2018, 83(5): O97–O103.
- [21] 段艳廷, 郑晓东, 胡莲莲, 等. 基于3D半密度卷积神经网络的断裂检测[J]. *地球物理学进展*, 2019, 34(6): 2256–2261.
DUAN Yanting, ZHENG Xiaodong, HU Lianlian, et al. Fault detection based on 3D semi-dense convolutional neural network[J]. *Progress in geophysics*, 2019, 34(6): 2256–2261.
- [22] WU Xinming, GENG Zhicheng, SHI Yunzhi, et al. Building realistic structure models to train convolutional neural networks for seismic structural interpretation[J]. *Geophysics*, 2020, 85(4): WA27–WA39.
- [23] DI Haibin, TRUELOVE L, LI Cen, et al. Accelerating seismic fault and stratigraphy interpretation with deep CNNs: a case study of the Taranaki Basin, New Zealand[J]. *The leading edge*, 2020, 39(10): 727–733.
- [24] LIU Naihao, HE Tao, TIAN Yajun, et al. Common azimuth seismic data fault analysis using residual U-net[J]. *Interpretation*, 2020, 8(3): SM25–SM37.

- [25] 杨午阳, 杨佳润, 陈双全, 等. 基于U-Net深度学习网络的地震数据断层检测[J]. 石油地球物理勘探, 2021, 56(4): 688–697.
YANG Wuyang, YANG Jiarun, CHEN Shuangquan, et al. Seismic data fault detection based on U-Net deep learning network [J]. Oil geophysical prospecting, 2021, 56(4): 688–697.
- [26] 王作乾, 芦凤明, 王静, 等. 基于特征压缩激活U-Net网络的断层识别[C]//中国石油学会2021年物探技术研讨会论文集. 成都: 中国石油学会石油物探专业委员会, 2021: 1008–1010.
WANG Zuoqian, LU Fengming, WANG Jing, et al. Fault recognition based on feature compression activated U-Net network [C]//Proceedings of the 2021 Geophysical Exploration Technology Symposium of the China Petroleum Society. Chengdu: Petroleum Geophysical Exploration Professional Committee of China Petroleum Society, 2021: 1008–1010.
- [27] 陈继兴, 路鹏飞, 袁兆林, 等. CUNet断层智能识别方法及其在断层识别中的应用研究[J]. 地球物理学进展, 2024, 39(2): 561–571.
CHEN Jixing, LU Pengfei, YUAN Zhaolin, et al. CUNet deep learning method and its application in fault recognition [J]. Progress in geophysics, 2024, 39(2): 561–571.
- [28] 刘贵鑫, 马中华. 改进Unet网络对叠后地震数据的断层识别[J]. 计算物理, 2023, 40(6): 742–751.
LIU Guixin, MA Zhonghua. Fault identification of post stack seismic data by improved Unet network [J]. Chinese journal of computational physics, 2023, 40(6): 742–751.
- [29] 张利霞, 高俊涛, 马强, 等. 基于改进UNet++的地震断层识别方法研究[J]. 计算机技术与发展, 2023, 33(8): 199–205, 213.
ZHANG Lixia, GAO Juntao, MA Qiang, et al. Research on seismic fault identification methods based on improved UNet++ [J]. Computer technology and development, 2023, 33(8): 199–205, 213.
- [30] 张红波, 李忠权. 川中地区南充构造成因机制探讨[J]. 科学技术与工程, 2020, 20(20): 8113–8121.
ZHANG Hongbo, LI Zhongquan. Genesis mechanism of the Nanchong structure in central Sichuan Basin [J]. Science technology and engineering, 2020, 20(20): 8113–8121.
- [31] 张本健, 周刚, 宋泽章, 等. 川中古隆起北斜坡蓬莱气区上震旦统一寒武统海相碳酸盐岩天然气多层系立体成藏[J]. 海相油气地质, 2023, 28(4): 401–412.
ZHANG Benjian, ZHOU Gang, SONG Zezhang, et al. Multi-layers three-dimensional natural gas accumulation of the Upper Sinian–Lower Cambrian marine carbonate rocks in Peng-lai gas area, north slope of central Sichuan paleo-uplift [J]. Marine origin petroleum geology, 2023, 28(4): 401–412

编辑:刘江丽

Intelligent seismic fault identification method based on U-CNNformer network

AN Hongyi¹, WEN Xin¹, LI Juzheng¹, ZHANG Jingzhe¹, ZHANG Linzhi¹,
FANG Pingchao¹, DU Tianwei², ZHANG Kui³, WANG Qunwu³

1. Exploration Department, PetroChina Southwest Oil & Gasfield Company;
2. Kunlun Digital Technology Co., Ltd; 3. Beijing Precise Energy Technology Co., Ltd

Abstract: Fault interpretation is one of the core tasks in oil and gas exploration and development. However, with the increase of exploration scale, traditional artificial fault interpretation and conventional fault detection methods are unable to meet practical needs. Deep learning methods provide an important approach for intelligent seismic fault recognition, among which deep network models represented by Unet have achieved many successful cases in this type of task. However, due to the particularity of convolution operations, this method loses some information in the feature extraction process, resulting in the need for further improvement in the accuracy and robustness of fault recognition. In this paper, we design a CNN-Transformer hybrid module and embed it into the Unet network framework, proposing a hybrid network model based on U-CNNformer. The hybrid network model improves the mining ability of both global features and local details in the sample set, overcomes the limitations of the conventional Unet network in weak information correlation in fault recognition, and improves the robustness of the model while ensuring the accuracy of fault recognition. Testing on the publicly available North Sea F3 data and applying with actual data in a certain area of Sichuan Basin in China demonstrate that the proposed hybrid network model not only accurately detects fault features but also provides a more detailed characterization of fault distribution, achieving high-precision intelligent fault recognition with excellent application effectiveness.

Key words: fault recognition; deep learning; Unet; CNN; Transformer; model training; data test

AN Hongyi, First author: Engineer, mainly engaged in oil and natural gas exploration technology. Add: No 12, North Section of Tianfu Avenue, Wuhou District, Chengdu, Sichuan 610095, China. E-mail: anhongyi@petrochina.com.cn

DU Tianwei, Corresponding author: MSc, Engineer, mainly engaged in research related to reservoir prediction and fracture detection. Add: China Petroleum Science and Technology Park, No. 1 Courtyard, Huanghe North Street, Changping District, Beijing 102206, China. E-mail: 1984055727@qq.com