

基于改进 UNet++ 的地震断层识别方法研究

张利霞¹, 高俊涛¹, 马强², 杨润湑¹, 王志宝¹, 李菲²

(1. 东北石油大学 计算机与信息技术学院, 黑龙江 大庆 163318;

2. 黑龙江八一农垦大学 信息与电气工程学院, 黑龙江 大庆 163319)

摘要:断层解释是油气勘探开发过程中的重要工作,但是随着勘探规模的增大,传统的人工解释断层的方法已经无法满足实际生产的需要。针对人工标注断层特征费时费力、传统断层识别结果连续性不足的局限,以及地震资料中断层与非断层样本分类不均衡的问题,提出基于 CBAM-UNet++ 模型的地震断层识别方法。采用合成地震数据自动生成地震数据和断层标签,提高断层标注的效率。首先,将 CBAM 注意力模块引入 UNet++,从通道和空间两个维度抑制地震振幅信号干扰,增强地震断层的检测能力,采用 DropBlock 模块抑制网络中产生的过拟合问题;其次,引入 Dice Loss 损失函数用于减小断层识别任务中数据不均衡问题对模型的影响;再次,对断层预测结果进行霍夫变换,提取骨架,使断层预测结果更好地应用于地质目标;最后,在合成地震数据集、北海地区 F3 区块真实地震数据上评估 CBAM-UNet++ 模型,与 UNet++、UNet、SegNet 进行对比。结果表明,基于 CBAM-UNet++ 的断层识别方法在准确率、断层连续性方面表现优异,可自动、有效地识别地震图像中的断层。

关键词:地震断层识别;图像分割;UNet++模型;CBAM 注意力模块;DropBlock

中图分类号: TP18

文献标识码: A

文章编号: 1673-629X(2023)08-0199-07

doi:10.3969/j.issn.1673-629X.2023.08.029

Research on Seismic Fault Identification Methods Based on Improved UNet++

ZHANG Li-xia¹, GAO Jun-tao¹, MA Qiang², YANG Run-tian¹, WANG Zhi-bao¹, LI Fei²

(1. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China;

2. School of Information and Electrical Engineering, Heilongjiang Bayi Agricultural University,
Daqing 163319, China)

Abstract: Fault interpretation is an important task in the exploration and development process of oil and gas. However, as the exploration scale increases, the traditional manual fault interpretation can no longer satisfy the needs of actual production. In light of the limitations of manual fault annotation, such as being time-consuming & laborious, insufficient continuity of traditional fault identification results, and the unbalanced classification of fault and non-fault samples in seismic data, a seismic fault identification method based on CBAM-UNet++ model is proposed, which adopts synthesized seismic data to automatically generate seismic data and fault labels, so as to improve the efficiency of fault annotation. Firstly, we introduce the CBAM attention module into UNet++, which suppresses the signal interference of seismic amplitude from the two dimensions of channel and space to enhance the detectability of seismic fault, and suppresses the over fitting in the network with the use of DropBlock module. Secondly, introduce the Dice Loss function to reduce the impact of data imbalance on the model in fault identification task. Thirdly, perform Hough transform to the fault prediction results for skeleton extracting, so that the fault prediction results can be better applied to geological objectives. Finally, evaluate the CBAM-UNet++ model based on the synthesized seismic data set and the real seismic data of F3 block in the North Sea, and compare with UNet++, UNet and SegNet. The results indicate that the fault identification method based on CBAM-UNet++ model has excellent performance in terms of accuracy and fault continuity, and can identify faults in seismic images automatically and effectively.

Key words: seismic fault identification; image segmentation; UNet++ model; CBAM attention module; DropBlock

收稿日期: 2022-08-16

修回日期: 2022-12-19

基金项目: 古龙页岩油大数据分析系统构建技术研究(DQYT-2022-JS-750); 中国石油天然气集团有限公司重大科技专项(2021ZZ10-05)

作者简介: 张利霞(1997-), 女, 硕士研究生, 研究方向为深度学习、计算机视觉; 通信作者: 高俊涛(1979-), 男, 博士, 副教授, 从事数据分析、过程挖掘、业务过程管理、软件工程等相关研究工作。

0 引言

断层是地下岩层沿破裂面或破裂带发生位移而形成的一种地质构造。它是油气运移和聚集的主要通道。在油气勘探开发过程中,断层解释是地震资料解释的关键,弄清断层的位置及分布对于油气勘探有着十分重要的作用,断层解释的结果直接关系到储层预测的精度。因此,如何从变化多样的地震剖面数据中准确高效地识别断层成为了一项难题,对此,许多国内外学者进行了大量研究。

传统断层解释由解释人员手工拾取地震剖面上的同相轴不连续点,将这些点连接成断层线,逐个地震剖面解释完毕后,将断层线在三维空间中进行组合,得到断层面。人工解释的结果准确度虽然高,但是比较耗时费力,并且主观性强,非常依赖于解释人员的经验。为了解决传统断层识别方法存在的不足,相关学者提出了利用相干体、曲率、方差等地震属性来识别断层的方法,Bahorich 等人^[1]在 1995 年提出 C1 相干体技术,此方法的计算速度很快,但易受噪声的干扰。为了弥补 C1 相干体技术存在的不足,Marfurt 等人^[2]在 1998 年提出了 C2 相干体技术,不仅保证了计算速度,同时提高了抗噪性,但是对于小断层的识别效率比较低。Gersztenkorn 等人^[3]在 1999 年提出了 C3 相干体技术,提高了断层识别的精度,但是计算量较大。印兴耀等人^[4]在 2014 年提出了一种基于离心窗的倾角扫描方法,降低了地震噪声的影响,提高了计算的效率。杨国权等人^[5]在 2015 年提出了使用不同网格提取曲率的方法,但是曲率易受人为因素影响,主观性大,识别准确率较低。汪杰和汪锐^[6]在 2016 年提出了方差相干体技术,改善了噪声影响,对较大断层识别效果较好,但小断层的识别效果较差。马艺璇等人^[7]在 2020 年提出了基于匹配追踪频谱分解的分频相干体技术,改进蚂蚁追踪流程,提高断裂刻画精度。谢清惠等人^[8]在 2021 年根据工区实际情况,引进蚂蚁追踪技术来进行裂缝预测,并通过降噪、增强连续性、突出断层边界、剔除假构造等手段提高裂缝预测的精度。基于地震属性的断层识别算法在不断的优化与改进,但是依赖于算法参数的设置,许多参数需要经过多次测试才能得到理想效果,并且对于地质构造复杂的断层仍然很难有效识别。

近年来,深度学习被广泛应用于各个领域,深度学习通过多层网络可以自动提取图像特征,因其高效、便捷,许多学者提出基于深度学习的断层识别方案。Huang 等人^[9]在 2017 年将多种地震属性作为 CNN 的输入,应用于断层识别。Guo 等人^[10]在 2018 年从三维地震数据中提取出带有断层标签的二维图像用于卷积神经网络模型的训练,再用此模型进行高精度断层

自动识别。H. Di 等人^[11]在 2018 年将 MLP 和 CNN 的实验结果进行对比分析,发现 CNN 在断层识别效率与准确率方面均优于 MLP,证明了 CNN 比传统的机器学习方法好。Chang 等人^[12]在 2019 年提出了用 UNet 网络识别断层,利用合成数据与实际数据相结合,尝试解决泛化能力低的问题。Di 等人^[13]在 2020 年以新西兰塔拉纳基盆地为例用深度卷积神经网络(CNN),高效完成断层的自动解释工作。Augusto Cunha 等人^[14]在 2020 年提出在合成地震数据上利用卷积神经网络(CNN)进行训练和调整,并利用迁移学习预测 F3 地震数据的方法。Liu 等人^[15]在 2020 年提出了 UNet 结合 ResNe-34 的方法,进一步提高了断层自动识别的精度。张政等人^[16]在 2020 年提出了深度残差网络与迁移学习相结合的方法,利用人工合成的样本加上少量的实际样本进行迁移学习,提高了实际数据中断层识别能力。席英杰等人^[17]在 2021 年提出了一种改进的 SPD-UNet 模型,并利用空洞卷积扩大了感受野,更加有效地提高了断层识别的能力。

已有的利用深度学习来识别断层的方法取得了很大的进步,但仍然存在一些不足,如断层识别的结果连续性不足,存在错误识别、漏识别的现象,导致无法较为精准地分割出断层。针对该问题,提出基于 CBAM-UNet++的断层识别方法,在 UNet++模型的跳跃连接处添加注意力模块,提高 UNet++对断层的特征提取能力,从通道和空间两个维度抑制非断层信号的干扰。使用 DropBlock 防止网络过拟合。最终对连续性不足的断层实现准确识别,提高断层识别的准确率。

1 方法技术

1.1 图像分割与 UNet++网络

图像分割是将图像分割成不同的连续像素点的集合,按照图像中如像素值、纹理、颜色等对图像有意义的特征进行识别。在地质勘探中,断层识别可以将地震数据中的断层和非断层看作不同的区域,用图像分割方法提取断层。

UNet++是一种基于深度学习的图像分割方法,使用 UNet++可以直接对地震数据进行特征提取。UNet++^[18]由 Zhou 等人提出,该网络是对 UNet 网络模型的改进,解决了随着 UNet^[19]网络深度的增加,识别效果不一定越好的局限。UNet++由不同层级 UNet 叠加组成,其解码器利用重新设计的跳跃连接以相同的分辨率密集连接,其结构如图 1 所示。在 UNet++中,由浅到深将 2、3、4、5 深度的 UNet 依次叠加,各层互不孤立,通过跳跃连接,依次被连接起来。由于不同层级 UNet 最后得到的特征维度不同,所以在每个 UNet 的右端模块与 $1 * 1$ 卷积核的卷积层连接,降低维度并监

督各层训练,最后将每层特征图相加,得到相加特征。UNet++能够提取来自不同深度的特征,学习到不同深度的特征的重要程度。地震剖面图像中同时存在局

部小断层和全局大断层,UNet++具有考虑不同深度图像特征的特点,因此非常适用于同时识别地震图像中的小断层以及大断层。

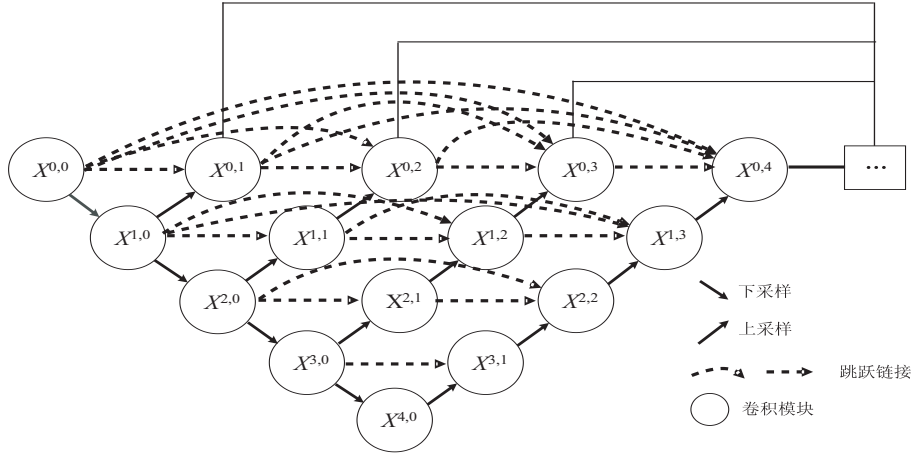


图 1 UNet++ 结构

1.2 CBAM 注意力模型

2018 年, WOO 等人^[20]提出了 CBAM (Convolutional Block Attention Module), 它同时结合了通道注意力和空间注意力, 是一种简单且有效的卷积神经网络注意力模块。CBAM 模块如图 2 所示。CBAM 的运算分为两个部分, 首先将通道注意力 $M_c(F)$ 与输入 F 相乘, 得到特征图 F' ; 然后将空间注意力 $M_s(F')$ 与 F' 按元素相乘, 得到特征图 F'' , 具体流程如图 2, CBAM 的过程可描述为:

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

其中, F 为输入特征图; F' 为输出特征图; $M_c(F)$ 为通道注意力模块; $M_s(F')$ 为空间注意力模块。




图 2 CBAM 模块示意图

(1) 通道注意力模块。

通道注意力主要关注哪些特征为有意义的特征。通道注意力计算过程为:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (3)$$

其中, F 为输入特征图; $M_c(F)$ 为通道注意力模块; σ 为 sigmoid 激活函数; MLP 为多层感知器; AvgPool 为平均池化; MaxPool 为最大池化。

它将输入 F 分别通过最大值池化和平均池化得到两个特征图; 然后将这两个特征图输入到多层感知器

中做降维、升维处理; 之后将从多层感知器中得到两个特征图进行加和; 同时经过 sigmoid 激活函数处理后, 得到通道注意力 $M_c(F)$, 如图 3 所示。




图 3 通道注意力示意图

(2) 空间注意力模块。

空间注意力主要关注哪些地方特征为有意义的特征, 是对通道注意力的补充。空间注意力计算过程可描述为:

$$M_s(F') = \sigma(f([\text{AvgPool}(F'); \text{MaxPool}(F')])) \quad (4)$$

其中, $M_s(F')$ 为空间注意力模块; f 为卷积层运算; σ 为 sigmoid 激活函数; AvgPool 为平均池化; MaxPool 为最大池化。

首先, 将输入 F' 分别通过最大值池化和平均池化, 并将它们连接起来; 然后, 利用卷积网络将其降维为一通道; 之后, 经过 sigmoid 激活函数得到空间注意力模块, 如图 4 所示。




图 4 空间注意力示意图

2 改进的 CBAM-UNet++ 模型

为了便于理解该文的整体思路, 图 5 展示了完整

的工作流程,分为四个步骤。第一步是样本准备阶段,在三维地震图像中裁剪出一定的切片作为训练样本和预测样本。第二步是断层识别网络构建阶段,针对目前断层识别存在的问题,构建 CBAM-UNet++ 模型。

第三步,利用训练后获得的最佳预测模型对预测数据集进行预测。第四步,将预测后的输出图像进行霍夫变换、膨胀腐蚀、骨架提取等后处理,得到最终的预测结果。

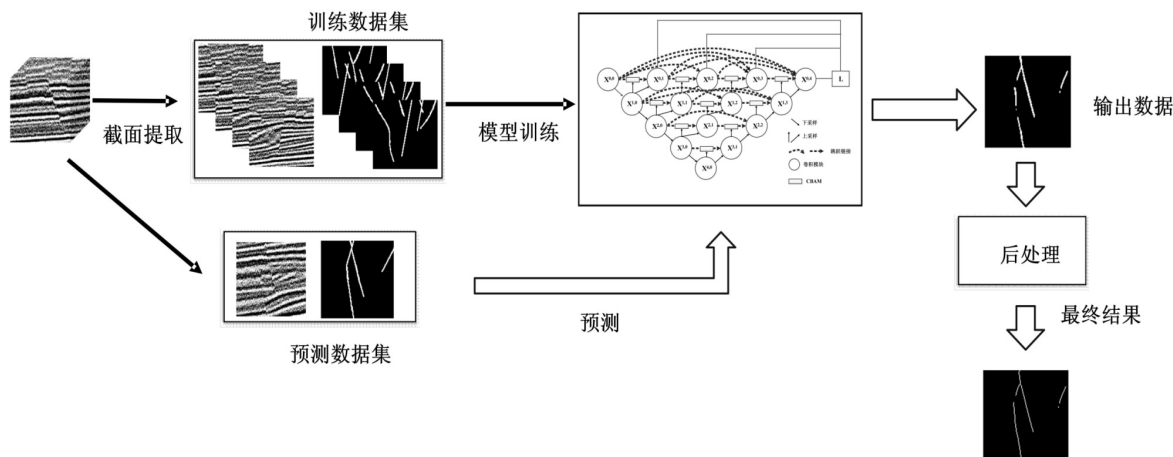


图 5 总体流程

针对深度学习方法在断层识别时存在的断层识别结果连续性不足、地震资料中非断层样本高于断层样本的问题,在 UNet++ 网络的基础上,提出 CBAM-UNet++ 模型,用于地震图像的断层识别,CBAM-UNet++ 模型整体结构如图 6 所示。在 UNet++ 跳跃连接处添加 CBAM 注意力模型,提高断层区域的关注度,同时抑制无关区域的干扰,以提高标签预测的准确性。

它从通道和空间两个维度抑制干扰,增强地震断层的检测能力。同时,采用了 Dropout 卷积块,即每个卷积层后面都有一个 DropBlock,一个批处理归一化(BN)层和一个 ReLU 激活单元,如图 7 所示,来达到防止神经网络过拟合的目的。在神经网络中引入注意力机制可以提高模型的特征表达能力^[21]。

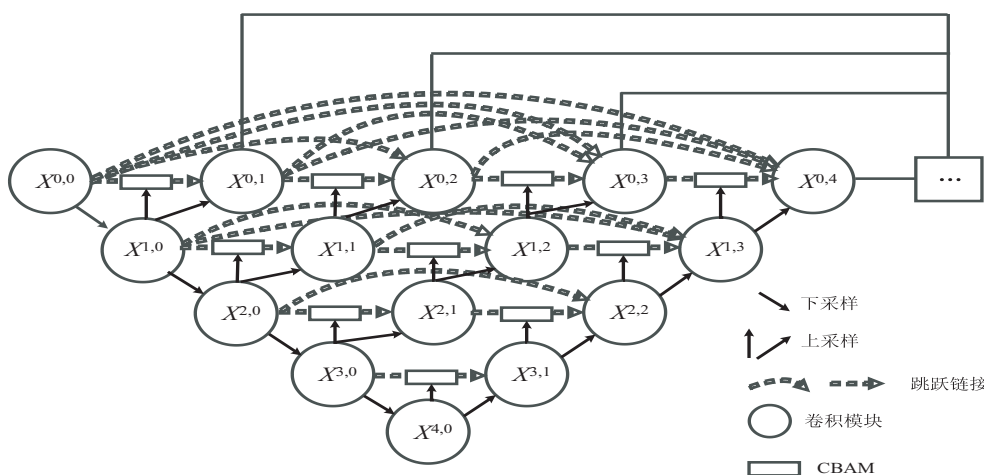


图 6 CBAM_UNet++ 结构




图 7 添加 DropBlock 后的卷积单元

2.1 DropBlock 与损失函数

为避免原始 UNet++ 训练过程中出现的过拟合问题,在网络模型中加入 DropBlock^[22] 来规范卷积架构。

DropBlock 从一个层的特征图中丢弃连续的区域,它是 dropout 的一种结构化形式^[23]。DropBlock 有两个参数,分别为 block_size 和 γ 。

block_size 为 DropBlock 的长宽,当 block_size 为 1 时,DropBlock 类似于 dropout。

γ 为伯努利函数的概率,控制要删除的特征数,计算公式如下:

$$\gamma = \frac{(1 - \text{keep_prob}) * \text{feat_size}^2}{\text{block_size}^2 * (\text{feat_size} - \text{block_size} + 1)^2} \quad (5)$$

在地震剖面图像中,断层线像素区域面积较小,会导致正负样本不平衡,最终影响模型识别效果。采用 Dice 损失函数^[24]缓解样本的不平衡问题。

Dice 系数的计算公式如下:

$$C_{\text{Dice}} = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \quad (6)$$

其中, P 为断层预测结果, G 为断层标签, N 为断层图像的总数, p_i 为 P 中的某一像素, g_i 为相同位置中 G 的某一像素。Dice 损失函数公式如下:

$$f_{\text{Dice_loss}} = 1 - C_{\text{Dice}} = 1 - \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \quad (7)$$

2.2 断层识别后处理

基于 CBAM-UNet++的断层识别模型可以准确提取地震剖面中的断层线,相较于其他深度学习模型,对不连续断层的识别精度更高。但是,由于地震剖面中的断层存在反射特征不明显但属于同一断层的问题以及破裂面破碎严重的问题,因此模型的输出中不可避免有部分不连续断层。

从图像分割的角度看,断层中存在的不连续的现象是正常的,但是模型输出的直接结果降低了应用性,不能真正地被应用于地震解释处理中,需要对输出的初步识别结果进行后处理。方法如下:

首先对断层预测结果进行霍夫变换,连接断开的断层。霍夫变换根据图像空间中共线的点对应在参数空间里相交的线的关系把在图像空间中的直线检测问题转换到参数空间里,在参数空间里进行累加统计完成直线检测任务。

然后对霍夫变换处理后的断层图像进行膨胀、腐蚀、骨架提取处理,填充断层区域,同时将断层细化成一条线。

3 实验与结果分析

3.1 数据集

在地震断层识别实验中,数据集的制作主要通过两种方法,一种是利用人工合成的地震数据及其标签进行训练和测试,另一种是采用真实的地震数据及人工标注的断层标签进行训练。

为了避免不正确的标注数据对网络的学习造成误导的问题,采用 Wu 等人^[25]提出的合成地震断层数据的方法,将合成地震断层数据作为样本集。人工合成的方法可以快速且大量地生成实验数据,有利于实验研究,同时避免手动标记耗时且断层位置主观性大的问题。

合成地震断层数据是由地震正演模拟得到,合成过程如下:

(1)创建一维反射模型;(2)应用高斯函数在模型中增加褶皱构造;(3)添加平面剪切构造;(4)添加断层;(5)同雷克子波褶积;(6)添加随机噪声。

通过此方法生成 7 819 张分辨率为 128 * 128 的合成地震数据和断层标签数据用于模型训练,同时生成 3 150 张用于验证,1 150 张用于预测,生成的合成地震数据及其断层标签如图 8 所示,其中 (a)(c)(e)(g) 为合成地震数据,(b)(d)(f)(h) 分别为 (a)(c)(e)(g) 对应的断层标签。




图 8 合成地震数据及其断层标签

3.2 网络搭建与模型训练

提出的模型在 Pytorch 神经网络框架中完成,使用的硬件环境为 AMD Ryzen 9 3950X 16-Core Processor ~3.49 GHz,搭载了英伟达 2080 Ti GPU。实验过程中 batch_size 设置为 20,epoch 设置为 60,使用学习率 1×10^{-4} 的 Adam 优化器对模型训练过程进行优化。模型的输入尺寸为 128 * 128 * 3 像素。训练平台配置见表 1。

表 1 训练平台配置

参数	配置
CPU	AMD Ryzen 9 3950X
GPU	NVIDIA 2080Ti
语言	Python
训练框架	Pytorch
GPU 加速环境	CUDA10.2

3.3 评估指标

地震断层的分割任务主要是将断层从地震数据中提取出来,将二值黑白图与断层标签做对比,计算出混乱矩阵中的各个数据,用于分割断层的混乱矩阵分布,如表 2 所示。

表 2 混乱矩阵

	被分类为断层的点	被分类为背景的点
分类正确	TP	TN
分类错误	FP	FN

地震断层识别的结果实质上是二分类的结果,同

时也是一个不平衡分类问题,可以采用机器学习中的分类器的评价指标来对地震断层识别进行评价。为了评价提出方法的有效性,采用 IOU、ACC、Dice、Precision、Specificity 多个指标进行综合的比较和分析,每个评估指标计算公式如下:

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

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

$$Dice = \frac{2 * TP}{FP + 2 * TP + FN} \quad (10)$$

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

$$Specificity = \frac{TN}{TN + FP} \quad (12)$$

其中,TP 代表实际是断层且识别结果也为断层的像素点数量,TN 为实际不是断层且识别结果也不是断层的像素点数量,FP 为实际不是断层但是被识别成断层部分的像素点数量,FN 为实际是断层但是没被识别成断层部分的像素点数量。

3.4 不同语义分割网络对比

将设计的 CBAM-UNet++ 与 UNet++、UNet、SegNet 进行比较。由表 3 可以看出,CBAM-UNet++ 算法相比于 UNet++ 方法在 IOU、ACC、Dice、Precision、Specificity 分别提高了 0.73、0.35、0.6、5.5、0.67 百分点,相比于 UNet 方法在 ACC、Precision、Specificity 分别提高了 0.18、3.87、0.5 百分点,这说明加入 CBAM 注意力机制后,新的算法有利于断层的分割,这说明提出的模型具有一定的优越性。

表 3 CBAM-UNet++ 与 UNet、UNet++、SegNet 的结果比较

评价指标	SegNet	UNet	UNet++	CBAM-UNet++
IOU	49.37	55.48	54.36	55.09
ACC	95.28	95.90	95.73	96.08
Dice	66.11	71.36	70.44	71.04
Precision	67.94	71.64	70.01	75.51
Specificity	97.66	97.82	97.65	98.32

不同算法的分割效果如图 9 所示,其中,(a) 表示地震断层原始图像;(b) 表示地震断层实际标注;(c) 表示用 SegNet 模型进行断层识别的结果;(d) 表示用 UNet 模型进行断层识别的结果;(e) 表示用 UNet++ 模型进行断层识别的结果;(f) 表示加入 CBAM 注意力模型的 CBAM-UNet++ 识别结果。从实验结果中可以看出,SegNet 在断层中部位置存在漏识别的现象,同时在断层顶部有部分错误识别;UNet、UNet++ 同样在断层中部位置存在漏识别的现象,但是相对于

SegNet,在中部位置漏识别的区域减少,识别效果有明显提高;CBAM-UNet++ 识别的断层相对于以上三种模型,连续性有明显提升,与实际标注的地震断层形状及位置更接近。




图 9 合成地震数据不同算法对断层识别效果对比

3.5 北海地区 F3 区块地震数据实验结果

为了验证 CBAM-UNet++ 断层识别方法在实际工区地震数据中的有效性,将提出的方法应用于北海荷兰地区 F3 的某工区地震数据。从图 10 中可以看出,SegNet 漏识别的情况比较严重;UNet、UNet++ 同样在剖面的中间位置存在漏识别的现象,但是相对于 SegNet 识别效果有明显提高;而 CBAM-UNet++ 与其他三种方法对比,在断层连续性方面较好,错误识别率较低,能够有效识别出绝大多数断层线,证明了所提方法的有效性。




图 10 F3 区块不同算法的断层识别效果对比

从表4中可以看出,CBAM-UNet++算法在 IOU、ACC、Dice、Precision、Specificity 这几个评价指标上优于 UNet++,同时与其他两个算法相比 CBAM-UNet++获得了较大的提升,得到了更好的识别效果。CBAM-UNet++不仅在合成地震数据中有较好的效果,在实际地震工区中也同样具备较好的效果。

表4 4种语义分割模型在F3地震工区中的断层识别效果比较 %

评价指标	SegNet	UNet	UNet++	CBAM-UNet++
IOU	45.48	63.96	70.27	70.94
ACC	92.54	95.01	95.92	96.28
Dice	62.53	78.02	82.54	82.99
Precision	81.05	84.53	86.56	94.25
Specificity	98.34	98.15	98.29	99.36

用 CBAM-UNet++网络对 F3 地震数据检测断层,断层检测效果如图 10(f) 所示,图中断层仍存在少部分断层断裂,此检测结果降低了应用性,所以对 CBAM-UNet++网络检测的断层结果进行进一步处理。通过霍夫变换、膨胀、腐蚀、骨架提取等方法进行后处理,连接断层断裂的部分。最终后处理的断层效果(图 11)与地震断层标签(图 10(a))进行对比,可以看出所提方法最终的预测效果与地震断层标签基本一致。



图11 F3区块地震数据后处理效果

4 结束语

从地震数据中自动提取断层是地震解释工作中的难点。针对人工标注断层效率低、传统断层识别方法对实际地震断层预测效果不理想的问题,将注意力机制融入到 UNet++算法中,建立 CBAM-UNet++模型,并将其应用地震断层识别中,抑制无关特征的干扰,同时采用 DropBlock 有效地抑制网络中产生的过拟合问题,通过引入 Dice Loss 损失函数以减轻地震断层识别任务中的数据不均衡问题。该方法在合成地震数据集上进行训练和预测,其中,IOU、ACC、Dice、Precision 和 Specificity 指标分别达到了 55.09%、96.08%、71.04%、75.51%、98.32%。CBAM 提高了特征提取能力,为地震断层识别提供了一种很好的识别效果。同时,将该方法应用于真实地震数据 F3 区块进行检验,实验结果表明该网络能够对断层进行精准的提取。该研究展示了从二维的角度解释断层线,在未来的工

作中,将应用深度学习方法进行三维断层解释的研究,直接提取三维断层面并自动连接不连续断层面。

参考文献:

- [1] BAHORICH M, FARMER S. 3-D seismic discontinuity for faults and stratigraphic features: the coherence cube[J]. The Leading Edge, 1995, 14(10): 1053-1058.
- [2] MARFURT K J, KIRLIN R L, FARMER S L, et al. 3-D seismic attributes using a semblance-based coherency algorithm[J]. Geophysics, 1998, 63(4): 1150-1165.
- [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] 印兴耀, 高京华, 宗兆云. 基于离心窗倾角扫描的曲率属性提取[J]. 地球物理学报, 2014, 57(10): 3411-3421.
- [5] 杨国权, 刘延利, 张红文. 曲率属性计算方法研究及效果分析[J]. 地球物理学进展, 2015, 30(5): 2282-2286.
- [6] 汪杰, 汪锐. 基于方差相干体的断层识别方法[J]. 工程地球物理学报, 2016, 13(1): 46-51.
- [7] 马艺璇, 李慧莉, 刘坤岩, 等. 基于分频相干体的蚂蚁追踪技术在塔河油田断裂刻画中的应用[J]. 石油物探, 2020, 59(2): 258-266.
- [8] 谢清惠, 蒋立伟, 赵春段, 等. 提高蚂蚁追踪裂缝预测精度的应用研究[J]. 物探与化探, 2021, 45(5): 1295-1302.
- [9] HUANG L, DONG X, CLEE T E. A scalable deep learning platform for identifying geologic features from seismic attributes[J]. The Leading Edge, 2017, 36(3): 249-256.
- [10] GUO B, LI L, LUO Y. A new method for automatic seismic fault detection using convolutional neural network[M]//SEG technical program expanded abstracts 2018. [s. l.]: Society of Exploration Geophysicists, 2018: 1951-1955.
- [11] DI H, WANG Z, ALREGIB G. Why using CNN for seismic interpretation? An investigation[C]//2018 SEG international exposition and annual meeting. OnePetro, California, USA: [s. n.], 2018.
- [12] CHANG D, YONG X, YANG W, et al. U-Net & residual neural networks for seismic fault interpretation[C]//81st EAGE conference and exhibition 2019. [s. l.]: European Association of Geoscientists & Engineers, 2019: 1-5.
- [13] DI H, TRUELOVE L, LI C, 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.
- [14] CUNHA A, POCHET A, LOPES H, et al. Seismic fault detection in real data using transfer learning from a convolutional neural network pre-trained with synthetic seismic data[J]. Computers & Geosciences, 2020, 135: 104344.
- [15] LIU N, HE T, TIAN Y, et al. Common azimuth seismic data fault analysis using residual U-Net[J]. Interpretation, 2020,

(下转第 213 页)