

基于3D U-Net++卷积神经网络的 断层识别方法及应用

李卿武¹, 王兴建^{1,2}, 张永恒¹, 文雪梅¹, 陈阳¹, 王崇名¹, 廖万平¹

(1. 成都理工大学地球物理学院, 成都 610059;

2. 成都理工大学油气藏地质及开发工程国家重点实验室, 成都 610059)

摘要: 断层解释是地震资料解释的基础与关键, 准确合理的断层识别对油气开采有着至关重要的作用。随着油田对断层解释精度需求的日益提高, 单纯通过基于人工的如相干体、曲率等属性的传统断层解释方法, 其精度已无法满足要求。笔者在U-Net++卷积神经网络模型的基础上进行改进, 得出了一种自动断层识别方法, 能够从任意三维地震图像中自动提取断层。文中该模型在足量样本集训练下, 对两区块的实际地震数据进行自动断层识别, 将识别结果进行分析对比。实验结果表明, 该模型能够对任意三维地震数据进行自动断层识别, 基于3D U-Net++网络模型的断层识别结果相比于传统U-Net++网络识别结果准确性有明显提高, 对潜山内部的小断层识别也表现出良好的效果, 明显提高了常规、复杂断层识别的工作效率。

关键词: 断层识别; 三维地震数据; 卷积神经网络; 3D U-Net++

中图分类号: P631.4

文献标志码: A

DOI: 10.3969/j.issn.1001-1749.2024.03.04

0 引言

地震勘探是油气田开发的基础, 油气运移、储集又与地震断层、裂缝密切相关, 故断层识别在地震数据解释和油气勘探开发中有着举足轻重的地位。地震断层在时间剖面上表现为反射波同相轴错断、反射波同相轴突增或突减, 传统断层识别方法需要地震资料解释人员从剖面中手动提取这些断层特征, 这不仅需要花费大量的工作时间, 而且由于受人为主观因素影响, 还造成了研究区断层识别结果极大地依赖资料解释人员主观判断的困扰。

随着行业领域的发展, 诸多学者将常规地震剖面法和地震属性联合起来开展断层解释工作, 也取得了一些效果, 如利用数据体的相干、曲率、方差等地震属性。随着计算机领域的发展, 通过计算机辅助

断层解释的技术也发展得也越来越快, 如Bahorich等^[1]提出了第一代基于互相关相干体特征的算法, 提高了计算速度但该方法受噪声干扰较为严重; Marfurt^[2]等提出了第二代基于多道相似性相干体技术, 相对于第一代相干算法虽然解决了抗噪性低的缺点, 但其对波形和横向振幅的变化敏感, 不利于裂缝体的识别; Gersztenkorn等^[3]提出的C3相干技术进一步提高了相干体技术的分辨率, 缺点是运行速度较慢; 方差体技术是一种不连续性检测, 也是断层识别的常用方法之一, 其原理是通过计算相邻地震道之间的方差, 利用方差值来反映反射特征的差异性, 从而实现了对断层的识别。此外, 除了利用相关地震属性的方法来识别断层, 还有边缘检测、模型正演分析等技术也能在一定程度上提高断层解释的精确度。边缘检测起初源于图像处理领域, 其工作原理是检测图像中的灰度突变。因此, 经过滤波、相

干等一系列处理后的地震数据剖面图进行边缘检测,图像中地震数据同相轴不连续对应处会得到凸显,从而实现裂缝预测和断层识别。

然而地震属性的断层识别方法仍然依赖于人工的数据处理解释,面临着工作量大、效率低的局限性。近年来,随着机器学习的迅速发展,如何尽量克服人工主观影响,实现自动、快速、准确的断层识别,逐渐成为了油气地球物理勘探开发领域的当务之急。目前来看,只有利用深度学习的方法才能实现我们所需要的自动断层识别,该方法主要包括:选取深度学习网络模型,并对选取的模型进行调试和优化;准备足够的训练样本及标签数据集;根据工区数据情况选取合适的损失函数等。

国内外学者已经将多种深度学习网络运用在断层自动识别的方法中,如董守华等^[4]利用 BP 人工神经网络成功实现对断层的自动识别;Goodfellow 等^[5]采用生成对抗网络(GAN)提高了断层识别精度;Huang 等^[6]首次在断层识别中引入卷积神经网络(CNN);Zhao 等^[7]将图像处理与断层识别相结合,使得断层识别的精度有了一定的提升;Wu 等^[8]结合 U-Net,充分利用地震数据的三维空间特征,使模型训练的效率和精确度得到了很大提升;Yang 等^[9]在 Wu 等提出的 U-Net 基础上,引入了 Skip Connections 得到了 U-Net++ 网络使得断层自动识别的精确度进一步提高。

笔者在计算机视觉领域的基础之上结合三维 U-Net++ 全卷积神经网络模型,利用语义分割技术将分类问题转化为图像分割问题,实现了对地震断层自动识别。以胜利油区富台潜山部分工区和 F3 区块地震数据为例,在断层识别技术指导下完成了断层自动识别。结果显示,基于 3D U-Net++ 的断层识别方法识别效果良好,相比于 U-Net 卷积神经网络的断层识别准确性有明显的提升,且能够在一定程度上消除噪声的干扰,进一步验证了基于深度学习的断层识别方法可行性。

1 方法原理

利用卷积神经网络识别断层分为图像分类和语义分割两种方法。将断层识别看作图像分类问题时,程序通过对剖面中心点是否为断层进行判定,接着逐点移动剖面,直接将剖面上的每一个点都进行判断,从而实现整个剖面的断层识别;将断层识别看作语义分割问题时,输入数据和输出数据均为二维

或者三维数据体。比较之下,将断层识别看作语义分割问题具有更高的预测精度且模型训练时间也较短^[10]。故笔者研究的断层自动识别方法是以语义分割的思维进行的。

1.1 搭建网络模型

笔者的研究方法是基于 3D U-Net++ 卷积神经网络模型,U-Net++ 模型与 U-Net 模型结构相似,但不同的是 U-Net++ 是在 U-Net 的基础之上增加了类似于 Dense 结构的卷积层,将相邻卷积层之间的训练集特征信息进行融合,将这个策略用在模型的每一个阶段,就形成了 U-Net++ 模型结构。

在模型结构中通过使用跳跃连接提取训练样本数据集中的空间特征,增强了网络模型的学习能力,适当地引入批量归一化来解决过拟合问题。Focal loss 最初由何恺明^[11]提出,用于图像领域解决数据不平衡造成的模型性能问题,笔者将 Focal loss 作为模型训练的损失函数,可以解决断层和非断层区分困难的问题。

U-Net++ 是一种强大的医学图像分割体系结构,最早由 Zhou 等^[12]提出。该模型在本质上是一个深度监督的编码器-解码器网络,由于编码器和解码器子网络的特征映射在语义上相似时,优化器倾向于去处理更容易的学习任务,因此引入跳跃连接,将编码器和解码器子网络通过一系列嵌套的密集跳跃路径连接便可防止这种现象。

3D U-Net++ 网络是具有三维块的对称编码器-解码器结构组成,其上采样和下采样操作也是三维的,并且网络通过跳跃连接的方式将同一层相同大小的卷积块连接到新的卷积块。根据前人经验,靠近头部的位置卷积块连接到新的卷积块提取图像低级特征,如边缘信息;而靠近尾部位置的卷积块提取图像的高级特征,如对象分类。跳跃连接是一种通过连接操作将底层特征和高层特征结合起来的特征融合方法,3D U-Net++ 用跳跃连接的蜂窝状密集块填充 U 形结构^[13],可以捕获和传输不同级别的图像特征,还可以传播损失函数的误差,从而达到使用反向传播中的梯度下降算法更新神经元参数的目的,其网络模型结构如图 1 所示。

每个密集块均由两个卷积块、一个批量归一化(BN)块和一个串联的 ReLU 块组成,每个卷积块的核尺度均为 $3 \times 3 \times 3$,且卷积块数量随着层数的增加而增加,流程如图 2。

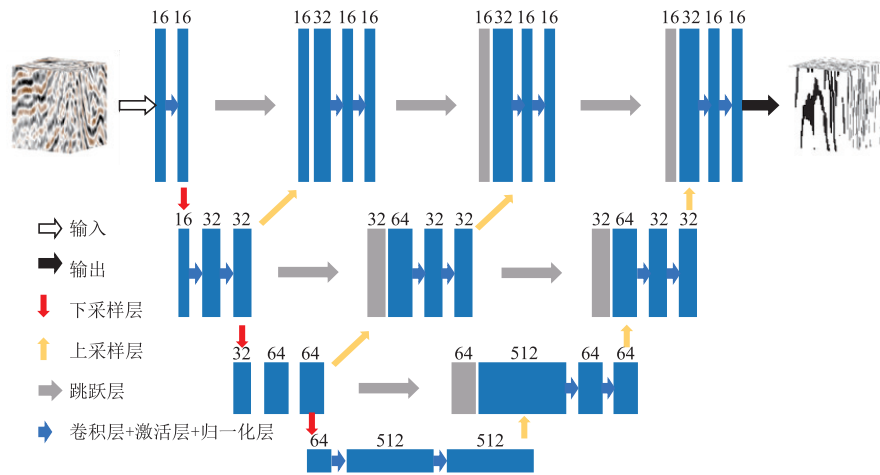


图 1 3D-UNet++网络模型结构

Fig. 1 Structure of 3D-UNet++ network model




图 2 三维密连接块

Fig. 2 Three-dimensional tight connection bloc

地震断层识别是一个分类不平衡问题,常用的损失函数一般都是具有权重的二进制交叉熵损失函数,如下式:

$$L = \left(\alpha \sum_{i=0}^N y \log(\hat{y}) + (1-\alpha) \sum_{i=0}^N (1-y) \log(1-\hat{y}) \right)$$

在深度学习中,损失函数(loss function)用于评估模型的预测值与真实值之间的差异大小,如果在训练中损失函数值越小,则说明模型的鲁棒性越好^[14]。笔者选取的损失函数是 focal loss,它针对样本不平衡问题从 loss 角度提供另一种解决办法,函数形式如下:

$$L = \begin{cases} -\alpha * (1-y)^\gamma * \log(y) & y=1 \\ -(1-\alpha) * y^\gamma \log(1-y) & y=0 \end{cases}$$

在上式中, γ 通常为值为 2 的调整因子,用于控制样品损失。以地震数据体中断层点 Q 的识别为例,假设该点的分类对于神经网络是确定的,那么无论该点是断层点且神经网络的输出预测概率 y 接近 1,还是该点是非断层点且 y 接近 0,损失函数 L

的值都很小。但当该点的分类信息较为模糊时,对于神经网络模型来说该点可能是断层点和非断层点^[15-16]。预测结果 y 和 $(1-y)$ 都趋近于 0.5,且损失函数 L 增加到最大值。总体来说,预测点的分类信息如果趋向于易于检测时,则损失函数值相对较小,而分类信息模糊时,则损失函数值较大。这便使得梯度下降算法在优化损失函数算法时将重点放在更难以区分的训练样本上面。

1.2 准备训练样本集

为实现深度神经网络模型训练,需要提前准备大量的训练数据和标签。在地震断层识别的研究中,常常需要通过在三维数据体中进行手动标记断层,而这类工作十分耗时且主观性很强。为了满足训练所需的大量地震数据和对应的断层标签,靠人工来准备往往是不现实的。

为了提高断层标签的制作效率,提高断层识别模型的识别能力,根据正演模拟的方法自动生成一套训练数据^[17]。该方法是由地震子波与地质模型的反射系数做褶积得到地震记录,表达式如下:

$$f(t) = S(t) * R(t) = \int_0^T s(\tau) R(t-\tau) d\tau$$

式中, S 为地震子波, R 为反射系数, t 为时间。

具体方法是通过 python 研发的一套程序来实现自动生成三维地震数据和断层标签。为了让程序高效运行,使用了 CuPy,CuPy 是 NumPy 兼容多维数组在 CUDA 上实现的开源矩阵库,能够使用 Python 提供的 GPU 加速计算,可以极大地加快实验进程。整体流程如下:

创建一维反射模型,利用函数产生随机数值,使用 tile 函数建立一维反射模型;应用高斯形变,实现

了在模型中增加了折叠结构;应用平面形变,实现整体平面的倾斜,并且使用 Element wise Kernel 函数让程序在 GPU 中运行;添加多形态断层,实现训练集中断层形态的多样化,增加断层的同时确定断层标签的位置;小波卷积反射模型,通过雷克子波与反射模型进行卷积运算,形成了更加近似于地震的数据模型;添加噪声,通过添加随机噪声,可以起到模拟真实干扰环境的作用;建立与合成地震数据体大小相同的元素全为 0 的三维数组,根据插入断层时的断层位置坐标信息,将三维数组中对应位置的元素值替换为 1,就得到了只包含合成数据断层信息的三维数据体;为了使得训练数据大小满足训练网络,同时将合成地震数据与包含断层信息的三维数据体

以相同的方式分割成若干大小为 $128 \times 128 \times 128$ 的数据体,这样地震数据与断层标签就成对出现了,保证了断层标签的完整性;标准化,将振幅值大小切割到了 -1 到 1 之间,增强了剖面的显示效果^[18]。

根据上文的样本集制作方法来制作训练样本集共 220 组,其中包含了 200 组训练样本和 20 组验证样本,每一组数据都包含了大小为 $128 \times 128 \times 128$ 的合成地震数据和与之同等大小的断层标签。训练集中包含了正断层、逆断层和平移断层,大量的包含了多种断层类型的训练样本将更加有利于模型训练效果,使模型在训练中提取到更多的断层特征。完成后的合成地震数据剖面图及对应的断层标签效果如图 3 所示。




图 3 训练集及对应的断层标签

Fig. 3 Training set and corresponding fault label

2 训练及测试

利用训练集将 3D U-Net++ 神经网络模型放入显存为 24 G 的 GPU Quadro P1000 中训练 50 个周期,模型训练参数如表 1。每完成一个周期的训练都将采用 20 个合成地震记录数据集作为验证集对训练效果进行验证。经过 6 h 的训练后,该模型已经达到收敛状态,从验证集的预测结果来看,模型预测的准确率为 96% 左右,损失率为 0.05 左右。准确度和损失率变化曲线如图 4。

训练完成后的模型在验证集中随机选择一条地震剖面的预测结果如图 5,预测结果显示,利用神经网络模型进行自动断层识别的预测结果与断层标签中断层位置几乎完全一致,为后续实际工区中断层识别的准确性提供了坚实的基础。

基于 3D U-Net++ 的断层识别方法在模型训练完成后,即可实现全工区的断层自动识别。相比于传统断层识别方法,本文方法不需要在断层识别工作中持续数天投入人工成本,满足文中计算设备的情况下只需要花费 6~7 h 的时间成本进行模型训练,训练完成后便可在几分钟内进行全工区的断层自动识别工作,显著提升了断层识别效率。

3D U-Net++ 网络模型相对于 U-Net 网络而言,由于加入了 Dense 结构和跳跃连接,所以计算量有所提升,文中改进模型的主要目的是出于对断层识别准确性的提升。断层自动识别准确性的对比验证见第 3 部分。

表 1 模型训练参数表

Tab. 1 Model training parameters

类型	内容
框架	Keras, Tensorflow
输入	$128 \times 128 \times 128$
损失函数	平衡交叉熵函数
批量大小	1
GPU	Quadro P1000
训练周期	50

3 实际数据应用

为验证文中网络模型在断层识别工作中的准确度,先选用荷兰 F3 区块和富台潜山地区的地震数据进行实际应用。荷兰北海区域富含碳氢化合物沉积物,北海大陆架位于荷兰海岸附近,被划分为不同的地理区域,其中的 F3 区块是一个尺寸为 $16 \text{ km} \times 24 \text{ km}$




图4 模型训练的准确率和损失率

Fig. 4 Accuracy and loss function value change curve of training model




图5 合成地震数据、对应断层标签和对应预测结果

Fig. 5 Synthetic seismic data, corresponding fault labels and corresponding prediction results




图6 原始剖面和断层识别效果展示

Fig. 6 Display of original profile and fault recognition effect

的矩形区域,该工区共有测线 512 条,每条测线 384 道,采样间隔 4 ms,采样点 128 个。选用联络线 $xline=50$ 地震剖面进行断层识别效果展示,原始剖面、3D U-Net 网络模型和 3D U-Net++ 网络模型识别结果分别如图 6(a)、6(b)、6(c)。富台潜山的实际工区数据为例进行潜山内幕断层识别,该区

域位于渤海湾盆地济阳坳陷以北,埕南断裂带的下降盘,南部以二台阶断层为界,北部紧邻埕子口凸起部,潜山构造以奥陶系和寒武系地层为主^[19-20]。随着勘探程度的加深,碳酸盐岩潜山储层的油气开发备受关注,潜山内幕断层的识别工作成为重点^[21],同时由于潜山内部断裂情况复杂,地震数据信噪比

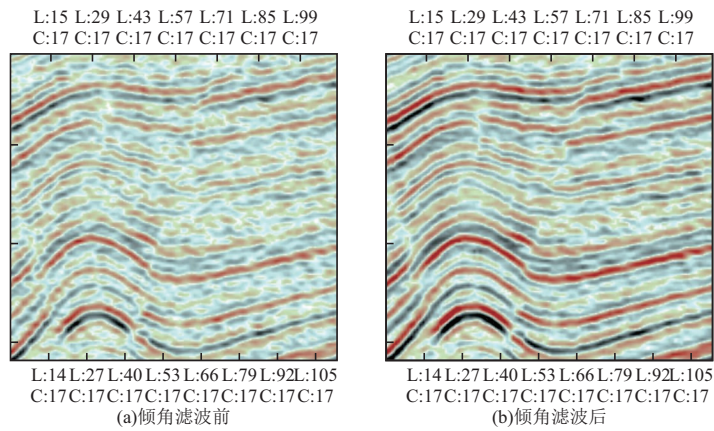


图 7 倾角滤波前后对比

Fig. 7 Comparison of inclination before filtering and after filtering




图 8 富台潜山基于 3D U-Net 和 3D U-Net++网络的断层识别结果对比

Fig. 8 Comparison of fault recognition results of Futai buried hill based on 3D U-Net and 3D U-Net++network

不高,深层地震数据同相轴连续性差^[22],断层识别成为该区域的重难点工作。富台潜山工区共设 364 条测线,每条测线 401 道,采样间隔 2 ms,采样点数 2 000。

由于实验工区中的地震资料信噪比低,为断层识别工作的开展带来极大的挑战,笔者采用倾角导向滤波方法对其进行去噪处理^[23-24]。倾角导向滤波主要是为了提高数据的信噪比,它有两方面的特

点,一是使同相轴连续性好的地方更加连续,二是使连续性不好的地方更加不连续^[25]。在断层处同相轴连续性差,经过构造导向滤波处理后断层显示会更加清楚,能够有效提高断层识别的准确性^[26],处理前后效果对比如图 7 所示。对滤波前后的实验工区地震数据进行基于 3D U-Net++ 网络模型的断层自动识别,分别从主侧线 inline=473,联络线 xline=767 和时间切片 time=2.9s 三个方向展示识别结果,如图 8(a)、8(b)、8(c)。

4 结论

笔者通过利用由正演模拟生成的地震数据集和对应的断层标签数据集训练 3D U-Net++ 卷积神经网络模型,完成了一种自动断层识别方法,并将其运用在不同区域的实际地震数据中,取得了较好的断层识别效果。本次研究所得结论总结如下:

1) 经过不同工区的地震断层自动识别结果比较发现,该神经网络模型能够有效识别常规断层和潜山内部的细小断层,面对不同工区的地震数据仍然表现出良好的断层识别能力。

2) 添加跳跃连接后的 3D U-Net++ 网络在地震断层识别中抗噪性有所提升,断层识别准确率明显高于 3D U-Net 卷积神经网络,证明了文中的深度学习网络模型改进方法的可靠性。

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] 董守华, 石亚丁, 汪洋. 地震多参数 BP 神经网络自动识别小断层[J]. 中国矿业大学学报, 1997, 26(3): 14-18.
DONG S H, SHI Y D, WANG Y. Automatic identification of small faults by seismic multi-parameter BP artificial neural network[J]. Journal of China University of Mining and Technology, 1997, 26(3): 14-18. (In Chinese)
- [5] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. Advances in neural information processing systems, 2014, 27.
- [6] HUANG L, DONG X, CLEE T E. A scalable deep learning platform for identifying geologic features from seismic attributes[J]. Leading Edge, 2017, 36(3): 249-256.
- [7] ZHAO T, MUKHOPADHYAY P. A fault detection workflow using deep learning and image processing[C]//2018 SEG Annual Meeting. 2018, 37: 1966-1970.
- [8] WU X M, LIANG L M, SHI Y Z, et al. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation[J]. Geophysics, 2019, 84(3): IM35-IM45.
- [9] YANG D, CAI Y, HU G, et al. Seismic fault detection based on 3D U-Net++ model[C]//SEG International Exposition and Annual Meeting. SEG, 2020: 1631-1635.
- [10] XIONG W, JI X, MA Y, et al. Seismic fault detection with convolutional neural network[J]. Geophysics, 2018, 83(5): O97-O103.
- [11] LIN T Y, GOYAL P, GIRSHICK R, KHOSLA P, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE international conference on computer vision. 2017: 2980-2988.
- [12] DI H B, ZHAO T, JAYARAM V, et al. Introduction to special section: Machine learning in seismic data analysis[J]. Interpretation, 2019, 7(3): SE1-SE11.
- [13] LI S R, YANG C C, SUN H, et al. Seismic fault detection using an encoder-decoder convolutional neural network with a small training set[J]. Journal of Geophysics and Engineering, 2019, 16(1): 175-189.
- [14] 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 W Y, YANG J R, CHEN S Q, et al. Seismic data fault detection based on U-Net deep learning network[J]. Oil Geophysical Prospecting, 2021, 56(4): 688-697. (In Chinese)
- [15] 范媛媛. 基于卷积神经网络的断层识别方法研究[D]. 荆州: 长江大学, 2021.
FAN Y Y. Research on fault recognition method based on convolutional neural network[D]. Jingzhou: Yangtze University, 2021. (In Chinese)
- [16] 常德宽, 雍学善, 王一惠, 等. 基于深度卷积神经网络的地震数据断层识别方法[J]. 石油地球物理勘探, 2021, 56(1): 1-8.
CHANG D K, YONG X S, WANG Y H, et al. Seismic fault interpretation based on deep convolutional neural networks[J]. Oil Geophysical Prospecting,

- 2021, 56(1): 1-8. (In Chinese)
- [17] WU X M, HALE D. 3D seismic image processing for faults[J]. *Geophysics*, 2016, 81(2): IM1-IM11.
- [18] CAO L. Application of deep learning in seismic data fault recognition[C]. Beijing; CPS/SEG Beijing 2018 International Geophysical Conference and Exhibition, 2018;1780-1783.
- [19] 童亨茂, 郑磊. 三维地震资料在古应力场反演和裂缝预测中的应用: 以胜利油田富台潜山为例[J]. *地质科学*, 2007, 42(1): 45-57.
TONG H M, ZHENG L. Applications of 3d seismic data in paleo-tectonic stress field backward modeling and fissures' prediction: A case study from the futai buried hill, Shengli oilfield[J]. *Chinese Journal of Geology (Scientia Geologica Sinica)*, 2007, 42(1): 45-57. (In Chinese)
- [20] 金强, 毛晶晶, 杜玉山, 等. 渤海湾盆地富台油田碳酸盐岩潜山裂缝充填机制[J]. *石油勘探与开发*, 2015, 42(4): 454-462.
JIN Q, MAO J J, DU Y S, et al. Fracture filling mechanisms in the carbonate buried-hill of Futai Oilfield in Bohai Bay Basin, East China[J]. *Petroleum Exploration and Development*, 2015, 42(4): 454-462. (In Chinese)
- [21] 左中航, 姜利群, 蔡纪琰, 等. 渤中凹陷西南环潜山复杂带断层识别[J]. *石油钻采工艺*, 2018, 40(增刊 1): 17-19.
ZUO Z H, JIANG L Q, CAI J Y, et al. A new fault identification method for complex zones around the buried hill in Southwestern Bozhong Sag[J]. *Oil Drilling & Production Technology*, 2018, 40(Suppl 1): 17-19. (In Chinese)
- [22] 商琳. 富台碳酸盐岩潜山多期裂缝发育规律研究[D]. 东营: 中国石油大学(华东), 2014.
SHANG L. Research on developing regularity of multi-period structural fractures in futai carbonate buried hill[D]. Dongying: China University of Petroleum (Huadong), 2014. (In Chinese)
- [23] 冯琦, 刘池洋, 刘显阳, 等. 小断层识别技术在鄂托克前旗地区的应用[J]. *地球物理学进展*, 2021, 36(4): 1512-1520.
FENG Q, LIU C Y, LIU X Y, et al. Minor faults identification in the Ertuoqeqianqi Area[J]. *Progress in Geophysics*, 2021, 36(4): 1512-1520. (In Chinese)
- [24] 迟红霞. LH盆地西部凹陷中南段潜山储层裂缝预测[J]. *中国石油和化工标准与质量*, 2017, 37(15): 69-70.
CHI H X. Fracture prediction of buried hill reservoir in the south-central section of the western depression of LH basin[J]. *China Petroleum and Chemical Standard and Quality*, 2017, 37(15): 69-70. (In Chinese)
- [25] WANG C, ZHU Z H, GU H M, et al. Hankel low-rank approximation for seismic noise attenuation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(1): 561-573.
- [26] LIU Z N, SONG C Y, CAI H P, et al. Enhanced coherence using principal component analysis[J]. *Interpretation*, 2017, 5(3): T351-T359.

Fault recognition method and application based on 3D U-Net++ convolution neural network

LI Qingwu¹, WANG Xingjian^{1,2}, ZHANG Yongheng¹, WEN Xuemei¹, CHEN Yang¹,
WANG Chongming¹, LIAO Wanping¹

(1. School of Geophysics, Chengdu University of Technology, Chengdu 610059, China;

2. State Key Laboratory of Oil and Gas Reservoir Geology and Development Engineering,
Chengdu University of Technology, Chengdu 610059, China)

Abstract: Fault interpretation is the basis and key to seismic data interpretation, and accurate and reasonable fault identification plays a vital role in oil and gas exploitation. With the increasing demand of oil fields for fault interpretation accuracy, the accuracy of traditional fault interpretation methods based solely on artificial attributes such as coherence, curvature, etc., cannot meet the requirements. Based on the U-Net convolution neural network model, this paper proposes an automatic fault recognition method, which can automatically extract faults from any 3D seismic image. In this paper, the model carries out automatic fault identification on the actual seismic data of two blocks under the training of sufficient sample sets and analyzes and compares the identification results. The experimental results show that the model can automatically recognize faults from arbitrary 3D seismic data, and the fault recognition results based on the 3D U-Net++ network model have significantly improved the accuracy of the recognition results compared with the traditional U-Net network. It also shows a good effect on the recognition of minor faults inside the buried hill and significantly improves the efficiency of conventional and complex fault recognition.

Keywords: fault identification; 3D seismic data; convolution neural network; 3D U-Net++