



李凤磊, 王静, 王蛟, 等. 2026. 基于四通道深度监督网络的断层识别方法研究及应用. 地球物理学进展, 41 (1): 0355-0371, doi:10. 6038/pg2026HH0389.

LI FengLei, WANG Jing, WANG Jiao, et al. 2026. Research and application of fault identification method based on four-channel deep supervised network. *Progress in Geophysics* (in Chinese), 41 (1): 0355-0371, doi:10. 6038/pg2026HH0389.

基于四通道深度监督网络的断层识别方法研究及应用

Research and application of fault identification method based on four-channel deep supervised network

李凤磊^{1,2}, 王静³, 王蛟^{1,2}, 王志强⁴, 韩长城⁵, 李师吉⁴, 翁燕飞⁴

LI FengLei^{1,2}, WANG Jing³, WANG Jiao^{1,2}, WANG ZhiQiang⁴, HAN ChangCheng⁵, LI ShiJi⁴, WENG YanFei⁴

1. 山东石油化工学院, 东营 257000

2. 油气藏高效勘探开发与地质工程一体化山东省工程研究中心, 东营 257000

3. 中国石化胜利油田分公司勘探开发研究院, 东营 257015

4. 中国石化胜利油田分公司河口采油厂, 东营 257200

5. 新疆大学地质与矿业工程学院, 乌鲁木齐 830000

1. Shandong Institute of Petroleum and Chemical Technology, Dongying 257000, China

2. Shandong Engineering Research Center for Integrated Geological Engineering and Efficient Exploration & Development of Oil and Gas Reservoirs, Dongying 257000, China

3. Exploration and Development Research Institute, Shengli Oilfield Company, SINOPEC, Dongying 257015, China

4. Hekou Oil Production Plant, Shengli Oilfield Company, SINOPEC, Dongying 257200, China

5. College of Geology and Mining Engineering, Xinjiang University, Ürümqi 830000, China

摘要 人工识别断层耗时费力,且人为因素增加了断层解释结果的不确定性,随着人工智能的发展,多种基于卷积神经网络的算法在断层识别中得到广泛应用,提高了断层解释的效率,为了进一步提高断层识别的准确性,本文构建了四通道的深度监督网络识别断层.首先在三维UNet中引入残差模块替换传统的编码器和解码器,简化网络学习目标,降低训练难度;然后引入扩张卷积模块以及多层深度监督机制,使解码器子网络能够学习到不同尺度的断层特征信息,提高网络训练的精度;最后借助优选出的三种地震多属性构建四通道的网络架构训练模型,使其学习到断层的多种响应特征,提高断层识别的准确度.理论模型测试和实际地震资料的应用表明,与常规UNet相比,该网络可以有效识别断层的断点位置,减少了小断层的漏识别和错误识别,明显提高了断层识别的准确性.

Abstract Manual fault interpretation is time-consuming and the experience of the interpreters tends to increase the uncertainty of the fault interpretation. With the development of computers and artificial intelligence, varieties of algorithms based on convolutional neural networks are more widely used in fault recognition. In order to further improve the accuracy of fault identification, a multi attribute convolutional neural network is proposed to identify faults. First, the residual block is introduced to replace the convolutional block in 3D UNet to simplify the learning goal and reduce the difficulty of training. Then the dilated convolution module and multi-layer deep supervision mechanism are introduced to take advantage of multi-scale information more effectively and further improve the accuracy of fault recognition. Finally, the four-channel network is constructed with multiple seismic attributes to learn various

关键词 断层识别;深度学习;四通道;扩张卷积;深度监督机制

中图分类号 P631

文献标识码 A

doi:10. 6038/pg2026HH0389

CSTR:32085.14.pg2026HH0389

response characteristics of faults. The synthetic model test and the application of real seismic data show that this method can effectively identify the fault location, reduce the missed and wrong identification of small faults, and significantly improve the accuracy of fault identification.

Keywords Fault identification; Deep learning; Four channel; Dilated convolution; Deeply supervised mechanism

0 引言

在油气田的勘探开发中,断层的准确识别起到至关重要的作用,对油气藏的井位部署及产量的提升都非常关键.目前在计算机辅助断层解释领域,应用于断层识别方面的方法及技术非常多,包括保边滤波方法(Lavialle *et al.*, 2007; 刘洋等, 2014)、属性类方法(Chopra and Marfurt, 2007; 印兴耀等, 2014; Qi *et al.*, 2017; Duan *et al.*, 2018)、边缘检测算法(Ashraf *et al.*, 2016; Di and Gao, 2014)、蚂蚁体属性(刘财等, 2016)等,然而,这些方法在实际应用中,通常会因为计算参数的设置以及解释人员的经验导致断层识别的准确性受到影响.特别是某些区块中,地震资料分辨率不高,低序级断层发育,常规的断层解释方法(如倾角、方差、相干等)对断距较大的断层应用效果较好,但断距较小的断层由于地震反射的隐蔽性,难以准确识别,因此需要研究新的方法高效率、准确地识别断层.

近年来,人工智能技术发展迅速,深度学习方法开始越来越多地应用于地球物理领域,多种基于卷积神经网络的算法也广泛应用于断层识别中.在人工解释断层的工作中,数据的信噪比、解释的流程以及解释人员的经验都会影响到断层的准确识别,而且常规方法的参数调试工作繁琐,整个断层解释工作耗时、费力;利用深度学习的方法识别断层,能够减少人工因素的影响,减少参数选择的过程,利用训练数据生成模型后可以应用到不同的地震工区中进行断层的预测,且预测断层所需时间很少,模型的泛化能力也较好,能够有效提高断层识别的准确性以及断层解释的效率,因此基于深度学习的断层识别方法研究具有深远的研究意义和实用价值.

在基于卷积神经网络的断层识别方面, Dahlke 等(2016)、Araya-Polo 等(2017)将卷积神经网络应用到原始地震数据上进行断层的识别;Wu 和 Hale (2016)提出基于图像处理的方法自动检测断层和不整合面等;Lu 等(2018)将生成对抗网络的深度学

习方法应用到断层识别中,能够增强断层边缘检测能力;Wu 等(2019)提出了基于三维 U-Net 断层识别方法,并首次利用多个理论合成的地震数据体进行模型训练,进而应用于实际地震数据的断层预测中;Cunha 等(2020)利用合成的地震数据训练端对端的网络模型,并采用调整模型输出层的方法实现迁移学习,应用到实际地震资料中,可提高断层识别的准确性;Qi 等(2020)对比了三维 UNet 和常用的属性类方法识别断层的效率、应用效果以及存在的问题;Wang 等(2021)引入知识蒸馏机制识别断层,提升了网络性能;Di 等(2021)在卷积神经网络中应用解释性约束条件,提高了断层识别的准确性;An 等(2021)利用真实的地震数据集训练网络,并对比了多种方法识别断层的效果,证明了边缘检测网络的优越性;Zhou 等(2021)引入对抗性神经网络并结合迁移学习机制,设置了渐进式框架降低合成地震数据与真实地震数据之间的差异,提高断层预测精度;唐杰等(2021)提出一种基于多分辨率 UNet 的地震数据断层检测方法,在三维实际地震数据应用中取得了较好的效果;Yan 等(2021)利用微调 UNet 识别断层,提升网络性能;刘乃豪等(2022)提出了基于整体嵌套边缘检测的断层识别技术,为地震断层智能识别提供了一条可靠途径;Wei 等(2022)通过冻结部分参数,实现了卷积神经网络从简单断层到复杂断层的迁移学习;Gao 等(2022)提出多尺度注意力机制以及嵌套型密集 UNet 识别断层;Hu 等(2022)利用人工解释的断层数据作为样本进行网络训练,能够较好识别断层,但效率较低;芦凤明等(2022)提出了 UNet ++ 和迁移学习相结合的方法,减少了小断层的漏识别和错误识别;陈继兴等(2024)结合 UNet 和 VNet 两种网络提处 CUNet 进行断层识别,在提高断层识别效率的同时,能够更准确刻画断层特征.上述这些方法都具有较强的学习和表征能力,但对于信噪比较低的地震数据或者断层较复杂的数据,识别效果可能达不到预期效果,因此本文引入深度监督机制,并将多种地震属性加入




图 1 地震属性重要性排序

A1-特征值相干属性;A2-方差体属性;A3-最大正曲率属性;
A4-Chaos 属性;A5-最小负曲率;A6-极大曲率属性;A7-倾角属性;
A8-Sobel 边缘检测;A9-相似度属性;A10-GST 相干;
A11-极小曲率属性;A12-平均曲率;A13-走向曲率;
A14-相似系数属性;A15-GLCM 纹理属性.

Fig. 1 The order of importance of seismic attributes

A1-Coherence attribute;A2-Variance cube;A3-Most positive curvature;
A4-Chaos;A5-Most negative curvature;A6-Maximum curvature;A7-Dip;
A8-Sobel edge detection attribute;A9-Similarity;A10-GST coherence;
A11-Minimum curvature;A12-Mean curvature;A13-strike curvature;
A14-Semblance;A15-GLCM texture.




图 2 残差学习模块结构示意图

Fig. 2 The diagram of residual block

到网络训练中,能够使网络学习更多的断层特征,提高断层的识别精度.

原始的 UNet 网络结构最初由 Ronneberger 等人提出 (Ronneberger *et al.*, 2015), Wu 等对其进行修改简化使其用于三维地震数据的断层识别问题 (Wu *et al.*, 2019). UNet 的基本结构包含编码器和解码器两部分,并融合了跃层连接的特点 (Drozdal *et al.*, 2016). 编码器部分是一个经典的 CNN,通过重复堆叠卷积层和池化层来提取特征;解码器部分是进行反卷积上采样的过程,只在最后一层进行输出,没有利用不同层级解码器输出的特征. 在网络训练过程中,神经网络越深识别效果越好,但网络加深会出现梯度消失现象,导致网络的训练效果不佳,但是浅层




图 3 本文所用残差块结构

Fig. 3 The residual block used in this article

的网络对效果提升又起不到明显的作用. 为了解决这一问题,He 等 (2016) 提出了残差学习模块的概念.

针对 UNet 解码器部分的不足,同时简化网络训练难度,提高网络训练对断层特征的学习能力,本文首先将三维 UNet 和残差模块结合形成新的网络,该网络结构用残差块替换 UNet 编码器和解码器部分的所有卷积层增强特征提取能力,可以充分结合两个网络的优势,一是残差结构会简化网络的训练,二是在残差单元内的跳跃连接以及网络的低层次和高层次之间将促进信息传播而不会出现梯度消失,从而简化网络学习目标,降低网络训练难度;在此基础上,分别在 UNet 的瓶颈层和解码部分引入扩张卷积和多层深度监督机制,更有效地结合断层的多尺度信息,提高网络训练的准确度. 通过上述步骤构建了新的卷积神经网络,然后将地震数据和多个地震属性相结合,建立四通道深度监督网络架构训练深度学习模型预测断层. 多地震属性的应用有助于网络训练学习到断层的不同响应特征,从而提高断层预测的准确性. 相比于 Wu 等提出的三维 UNet 的断层识别结果,本文构建的四通道深度监督网络识别断层的精度有了明显提高.

1 属性评估与选择

在进行网络训练前,首先要优选出合适的地震




图4 连续扩张卷积示意图(Yu and Koltun,2016)
(a)扩张率为1的空洞卷积;(b)扩张率为2的空洞卷积;(c)扩张率为4的空洞卷积.
Fig.4 The diagram of continuous dilated convolution (Yu and Koltun, 2016)
(a) Expansion rate is 1;(b) Expansion rate is 2;(c) Expansion rate is 4.




图5 本文构建的深度监督网络结构
Fig.5 Schematic of deep supervised network




图6 扩张卷积模块
Fig.6 Structure of continuous dilated convolution




图 7 四通道深度监督网络预测断层流程

Fig. 7 Process of fault identification with four-channel deep supervised network

属性用于断层识别. 本文首先计算出了 15 种常用的识别断层的地震属性, 包括倾角、方差体、相干类属性、曲率类属性等; 经过标准化处理后利用随机森林方法评估地震属性的重要性, 选择重要程度最高的三种地震属性输入到深度监督网络中进行训练. 下面详细介绍属性评估与选择的过程.

1.1 地震属性标准化处理

在网络训练过程中, 输入数据的分布需要保持一致, 否则会导致网络训练的难度增加. 四通道深度监督网络需要用到不同的地震属性, 而不同属性体的生成方法是不一样的, 因此各属性体之间的数值差别较大. 为了确保网络训练的有效性, 首先要对所有的地震属性数据进行标准化处理. 本文采取了标准差标准化方法(印兴耀和周静毅, 2005), 其数学定义为:

$$y_i = \frac{x_i - \mu}{\sigma}, \tag{1}$$

式中, x_i 为原始地震属性某样点 i 处的值, y_i 表示该地震属性标准化处理后在样点 i 处的值, μ 和 σ 分别表示原始属性数据的均值和标准差.

标准差标准化修改了地震属性的振幅值, 但是没有改变其几何特征或结构模式, 而且标准化处理后的数据分布是一致的, 这一步对于网络训练来说非常必要.

1.2 地震属性评估与选择

地震属性评估就是对多种地震属性进行相关性

分析, 选取能够反映断层分布状况, 并且互不相关的属性特征. 由于地震属性与断层概率之间的非线性关系比较复杂, 因此在断层预测前必须在属性优选, 避免不敏感的地震属性对断层识别造成干扰, 减少预测断层的多解性, 提高断层识别的精度(Hotelling, 1933; Tipping and Bishop, 1999). 本文采用随机森林方法评估地震属性的重要性, 选择重要程度最高的三种属性输入到网络中用于断层预测.

随机森林是一种集成学习方法, 通常用于解决分类或回归问题(Breiman, 1996), 它是在 Bagging (Bootstrap aggregating) 学习框架的基础上提出的(Breiman, 2001), 随机森林由多棵决策树构成, 这些决策树之间互不相关. 在构建决策树模型时, 需要用到许多子数据集, 这些子数据集一般利用 Bagging 算法从整个训练数据集中随机抽取. 在 Bagging 的每次随机采样中, 训练样本中约有 63.2% 数据会被选取到用于决策树模型的训练, 而 36.8% 的数据不会被选取到(未被选取的数据通常称为袋外数据, 简称为 OOB, 袋外数据可以用于评估决策树的性能). 每次随机采样的数据不尽相同, 也在一定程度上保证了随机森林模型中的各个决策树模型的相互独立.

随机森林除了可以用于分类和回归, 另一个比较广泛的应用是进行特征重要性度量, 因此可以用来对地震属性进行重要性排序, 选择重要性最高的三个属性用于网络训练. 随机森林度量特征重要性的具体步骤为:

(1) 对于随机森林的每一棵决策树, 可以利用袋外数据(OOB)计算模型分类的错误率, 称之为袋外数据误差, 记为 errorOOB1.

(2) 对袋外数据的所有样本特征加入随机噪声, 进而随机改变样本在某个特征 X 处的值, 然后计算袋外数据误差, 记为 errorOOB2.

(3) 通过如下公式计算某个数据特征 X 的重要性:

$$\text{importance} = \frac{\sum_{i=1}^N (\text{errorOOB2}_i - \text{errorOOB1}_i)}{N}, \tag{2}$$

式中, N 表示决策树的数目.

采用公式(2)计算某个特征 X 重要性的原因在于, 如果加入一定量的随机噪声后, 袋外数据 OOB 的准确率大幅下降, 即 errorOOB2 的值变大, 说明该特征对于数据样本的预测结果影响较大, 从而说明

了该特征的重要性较高。

对某个合成地震数据(下文 3.1 节生成的三维断层样本)分别提取 15 种地震属性进行标准化处理,然后按照上述流程对地震属性的重要性进行排序,得到图 1 的结果。从图中可以看出,特征值相干的重要性最高,其重要性因子为 0.139952,其次分别为方差体属性和最大正曲率属性,重要性因子分别为 0.122917 和 0.101197,最终选择这三种地震属性数据用于网络训练。

2 四通道深度监督网络构建

2.1 残差模块基本原理

增加神经网络的深度可以增加网络的参数种类,以便更好地学习目标特征。但是,简单地增加网络层数会出现梯度消失、梯度爆炸、过拟合等问题,造成网络退化。其具体表现为训练精度与测试精度的下降,残差模块可以解决深层网络的退化问题,其基本结构如图 2 所示。

假设某神经网络的输入为 x ,期望输出为 $H(x)$,而在残差网络中,“shortcut connections(捷径连接)”的方式,直接把输入 x 传到输出作为初始结果,输出结果为 $H(x) = F(x) + x$ 。残差块相当于将学习目标改变了,不再是学习一个完整的输出,而是目标值 $H(x)$ 和 x 的差值,即残差 $F(x) = H(x) - x$ 。He 等(2016)指出,如果网络层数超过最佳层数,残差网络会将多余层训练为 $F(x) = 0$,即这些层的输入与输出相同,变为恒等映射,这样网络层数加深就不会造成网络退化。残差学习模块不仅解决了网络层数增加造成的退化问题,还使得网络的学习目标简化,难度降低,使深度神经网络的训练变得更加容易。

本文使用如图 3 所示的残差块替代三维 UNet 中的卷积层,每个残差块由两个 $3 \times 3 \times 3$ 的卷积层、BatchNorm 批量归一化层和 LeakyRelu 激活层组成,卷积层后紧跟 BatchNorm 批归一化操作。图中的 x_l 和 x_{l+1} 分别为第 l 层残差单元的输入和输出, $F(x_l) = 0$ 为残差函数。

残差模块中的激活函数选取带泄露整流函数(Leaky Relu),这是一种非线性激活函数,对于解决梯度消失问题具有很好的效果,不仅可以缩短神经网络训练周期,提升对应模型的收敛速度,而且能够增强模型的鲁棒性及稳定性(Gu et al., 2017)。其对应的函数表达式如下所示:

$$f(x) = \begin{cases} x & x > 0 \\ \lambda x & x \leq 0 \end{cases}, \quad (3)$$

式中, λ 为 Leaky Relu 函数的非零斜率,是取值范围在 (0,1) 的常数。

2.2 扩张卷积基本原理

将局部信息和全局信息结合分析对断层的识别非常重要,然而在传统的 UNet 中,网络的最低层,即前文所说的瓶颈部分,局部感受野非常小,这不利于网络分析捕获非局部信息的特征(Tipping and Bishop, 1999),从而导致对具有相似特征的区域进行断层的错误分类,而扩张卷积(dilated convolutions)为这个问题提供了一个合适的解决方案。

扩张卷积(Yu and Koltun, 2016),又可称之为空洞卷积(atrous convolution),最初是为了解决图像分割问题而提出的,目前用于图像分割的网络一般是利用卷积或者池化操作增加感受野,这些运算过程会缩小特征图的尺寸,因此需要利用上采样将图像尺寸进行还原,特征图在缩小还原的过程中往往会造成图像精度的损失。为了解决这一问题,使得图像感受野在增大的同时保持特征图的尺寸不发生变化,可以引入扩张卷积的操作。在扩张卷积的实现过程中,需要定义一个非常重要的超参数——扩张率,它也可以被称为是空洞数。关于扩张率的含义和扩张卷积的应用效果可以通过图 4 加以说明。

如果相邻多层连续进行扩张卷积,当前层感受野的计算公式为:

$$\begin{cases} RF_{i+1} = RF_i + (k' - 1) \times S_i \\ k' = k + (k - 1) \times (r - 1) \end{cases}, \quad (4)$$

式中, k' 为等效卷积核大小, k 为卷积核大小(图 4 中卷积核均为 3×3), r 代表扩张率, RF_{i+1} 代表当前层的感受野, RF_i 表示上一层的感受野, S_i 代表之前所有层的步长的乘积(当前层除外),其计算公式为:

$$S_i = \prod_{n=1}^i \text{Stride}_n. \quad (5)$$

图 4 中初始卷积核大小为 3×3 ,即 $k = 3$,步长为 1,根据公式(5),可以分别计算出每一层的感受野大小。

扩张卷积可以通过设置不同的扩张率任意扩大感受野,而且不会降低图像的分辨率,应用到断层预测的任务中,有助于捕获多尺度的断层特征信息,提高网络训练的精度和准确性。

2.3 网络构建

根据上文对残差模块和扩张卷积的分析,利用

残差模块替换原始 UNet 中的编码和解码部分的卷积操作,并用扩张卷积替换瓶颈部分的卷积模块,同时引入深度监督的机制,最终构建了图 5 所示的网络,瓶颈层的扩张卷积结构如图 6 所示。

如图 5 所示,本文构建的深度监督网络包括四层结构,即由四个编码器和四个解码器组成,每个编码器、解码器均包含一个残差学习模块。批量标准化对每个层的输入数据作标准化处理,可以有效提高模型训练的效率。

在编码器部分,每一层残差模块之后采用最大池化运算缩小特征图的尺寸;与之对应的是,解码器每一层残差模块之后采用上采样操作,逐层恢复特征图尺寸。瓶颈层采用四个连续的扩张卷积(图 6),扩张率分别为 1~4,随后将每个扩张卷积的输出相加并作为解码器分支的输入。

在本文所提网络的编码器子网络部分,浅层结构可以学习到断层的简单特征;随着网络的加深,多次卷积池化操作可以捕获到断层的抽象特征。浅层特征和深层特征对于断层的检测都起着至关重要的作用。通过引入多层深度监督机制,对解码器子网络的每一层均进行输出,每个解码器阶段的最后一层通过一个 $3 \times 3 \times 3$ 的卷积操作和一个步幅为 2 的 $2 \times 2 \times 2$ 上采样操作,用以匹配不同层级解码器输出的尺寸;将每一层解码器的输出逐层相加,最终利用 Sigmoid 激活函数输出断层概率值,取值范围为 $[0, 1]$ 。

本文构建的深度监督网络,通过残差模块、扩张卷积和多层深度监督的引入,能够降低网络训练的难度,并能学习不同尺度的断层语义信息,在网络训练过程中充分利用不同尺度的断层特征,从而提高断层细分的准确性以及断层检测的精度。

2.4 四通道深度监督神经网络训练流程

结合地震多属性构建四通道深度监督网络,建立图 7 所示的工作流程进行网络训练和断层预测,具体步骤如下:

(1)利用下文 3.1 小节所述步骤生成断层训练样本,计算三种地震属性,然后对所有输入数据进行标准化处理。

(2)将每一个训练数据和对应的三种地震属性进行整合,生成四通道的训练数据集,即四个通道对应的输入数据分别为合成地震数据、特征值相干、方差体和最大正曲率属性大小为 $[128, 128, 128, 4]$ 。

(3)将四通道的训练数据集以及对应的断层标签数据输入到图 5 所示的网络中进行网络训练,训

练完成后输出模型。

(4)对实际地震数据求取三种地震属性,按照步骤(1)和(2)进行数据标准化处理以及整合,然后利用训练模型进行断层识别,输出最终的断层预测概率值。

3 网络训练与模型测试

3.1 训练样本建立

足够的断层标签数据可以保证卷积神经网络预测断层的准确性和有效性,因此将应用 Wu 和 Hale (2016)提出的计算方法生成包含不同断层类型的三维合成地震记录以及相对应的断层标签,以训练和验证本文所用的网络结构。







根据所要应用的实际地震资料的断层特征设置参数,定义断层断距的范围为 $[5, 50]$,断层倾角范围为 $[50^\circ, 80^\circ]$ 和 $[-80^\circ, 50^\circ]$ (正角度代表正断层,负角度代表逆断层);子波频率的预设范围为 $[25, 35]$ Hz,信噪比的取值范围为 $[3, 6]$ 。利用断层模型计算流程最终生成 300 对大小为 $256 \times 256 \times 256$ 的合成地震数据和相对应的断层标签数据用网络模型训练,并随机生成 30 对数据集用于模型验证。在生成断层样本数据过程中,尽可能考虑了多种断层样式,图 8 展示了 6 种典型的合成地震数据及对应的断层标签剖面,包括阶梯状断层、“X”型断层、“Y”型断层以及“λ”型断层等。

3.2 网络训练及模型测试

在网络训练过程中需要确定优化算法、学习率、迭代次数等,本文所提网络在训练时选用的损失函数定为 Focal Loss 损失函数(Lin *et al.*, 2020),对于学习率和迭代次数,进行了多次实验加以确定,最终设置学习率为 1×10^{-4} ,迭代次数为 40,然后利用合成的断层样本数据和求取的三种地震属性数据在 Google Colab 平台上训练四通道的深度监督网络,训练完成后保存模型,200 个训练数据迭代 40 次大约需要半个小时的训练时间。分别应用三维 UNet 和本文所提出的网络在 30 个验证数据集上进行测试(验证数据集未参与网络训练,大小为 $128 \times 128 \times 128$),并按照量化评价标准对断层预测结果进行评价。

三维 UNet:准确率、召回率、F1-score 以及 IOU 的范围为分别为 $0.943 \sim 0.965$ 、 $0.678 \sim 0.815$ 、 $0.667 \sim 0.853$ 、 $0.530 \sim 0.701$ 。

本文提出的四通道深度监督网络:准确率、召回率、F1-score 以及 IOU 的范围为分别为 $0.972 \sim 0.995$ 、






图 8 典型合成地震数据(左)和断层标剖面(右)
(a) 反向阶梯状断层;(b)“X”式断层;(c)“Y”式断层;(d)“λ”式断层;(e) 正向阶梯状断层;(f) 地垒式断层。
Fig.8 Typical synthetic seismic images (left) and the corresponding fault label (right)
(a) Reverse-type step fault;(b)“X” type fault;(c) “Y” type fault;(d) “λ” type fault;(e) Forward-type step fault;(f) Horst-type fault.




图9 理论模型及地震属性
(a)合成地震数据;(b)相干属性;(c)方差体属性;(d)最大正曲率属性.

Fig. 9 Synthetic data and the corresponding seismic attributes
(a) Synthetic seismic data;(b) Coherence;(c) Variance cube;(d) Most positive curvature.

0.770~0.928,0.730~0.942,0.700~0.890.

图9所示为某个验证数据及提取的三种地震属性,图10为应用三维UNet和本文提出的四通道深度监督网络得到的断层识别结果.由图10可以看出,三维UNet不能准确识别断层交叉位置(图10b中黄色箭头所示),断层识别结果与断层标签相差较大,但本文所建网络预测断层在断点位置分辨率更高(图10c中黄色箭头所示).

上述理论模型所加随机噪声为平稳随机噪声,但实际地震勘探中的噪声并不是传统意义上的平稳随机过程,其平稳性与采样时间、采集环境等都有关

系,因此本文在理论模型中加入非平稳随机噪声验证断层预测效果.非平稳随机噪声可以定义为时间和空间方向上不稳定的高斯噪声(钟铁等,2017),假设平稳高斯随机噪声序列为 $S_1(t)$,对其部分取值的特征进行放大或者改变便可得到非平稳随机噪声 $S_2(t)$ (刘璐等,2021),其表达式如下:

$$S_2(t)=\begin{cases} 2S_1(t),k\leq t\leq k+50\\ S_1(t),t\in\text{else} \end{cases},\tag{6}$$

式中,为噪声序列中取值改变的开始位置,不同地震道上K的取值不同.按照上述方法分别加入不同信噪比的噪声并进行断层预测,得到图11所示结果.




图 10 理论模型利用两种网络得到的断层预测结果
(a)断层标签;(b)三维 UNet 预测断层;(c)四通道的深度监督网络预测的断层.

Fig. 10 Fault detection results of synthetic data

(a) Fault label;(b) Fault predicted by 3D UNet;(b) Fault predicted by the proposed network.

从图中可以看出,随着信噪比降低,断层识别精度有所下降(图 11c、d 中黄色箭头所示),但模型中断层位置基本能准确识别,证明了本文创建的网络抗噪性较好.

通过理论模型的验证结果可以发现,本文构建的四通道深度监督网络的各项指标均由于三维 UNet 网络,下面重点讨论四通道的深度监督网络在实际地震资料中的应用效果.

4 实际地震资料应用

为了验证四通道的深度监督网络在实际地震资料中的应用效果,首先从 F3 演示数据 (Wu 等,

2019, F3 演示数据由荷兰政府通过 dGB Earth Sciences 提供)中截取了一小块进行测试,Inline 范围:200 ~ 583, Crossline 范围:300 ~ 812, Time 范围 1340 ~ 1848,采样间隔 4 ms,网络训练参数同前文一致.图 12 所示为该数据体及提取的特征值相干属性体、方差体以及最大正曲率属性体,图 13a、b 分别为采用三维 UNet 和本文所构建的四通道深度监督网络得到的断层预测结果.

由图 13a 可以看出,三维 UNet 方法识别的断层精度较低,断层连续性较差,且背景区域(非断层区域)干扰较多;采用四通道的深度监督网络识别的断层,断层连续性有了明显提高,分辨率更高,减少




图 11 不同信噪比的理论模型利用本文网络识别断层结果

(a) 未加噪声理论模型; (b) 信噪比为 10.6; (c) 信噪比为 7.8; (d) 信噪比为 4.4.

Fig. 11 Fault detection results of synthetic data with different SNR by the proposed network

(a) Synthetic data without noise; (b) SNR is 10.6; (c) SNR is 7.8; (d) SNR is 4.4.

了断层漏识别(图 13b 蓝色箭头所示)以及错误识别(图 13b 黄色箭头所示)的情况,断层识别的准确性有了提高.图 14a 为利用方差体属性得到的蚂蚁体自动追踪结果,图 14b 为本文创建网络识别的断层结果,对比两图可以发现,深度学习识别的断层背景噪声干扰较少,连续性也要更强.对比断层的识别效率,首先属性体和蚂蚁体自动追踪的实现涉及到多个参数的设置(比如蚂蚁体自动追踪,需要设搜索步长、自动追踪的步长、停止追踪的阈值等),而

且为了确保断层识别效果更好,这些参数都需要解释人员手动进行调整,人为影响因素较大;而多属性的三维深度网络在实现断层的自动识别时,确定网络训练参数后可以直接利用大量合成的断层样本进行训练,减少了人为的参与,大大提高了断层解释的效率.

除了在 F3 区块的地震数据体上进行测试,又将四通道的深度监督网络训练得到的模型应用于东部某油田的三维地震资料中,选取的三维地震数据纵




图 12 F3 工区实际地震资料及提取的三种地震属性
(a) 实际地震数据;(b) 特征值相干属性;(c) 方差体属性;(b) 最大正曲率属性.
Fig. 12 The field data in F3 area and the corresponding seismic attributes
(a) The filed data;(b) Coherence;(c) Variance cube;(d) Most positive curvature.




图 13 F3 实际地震资料利用两种网络的断层预测结果
(a) 三维 UNet 预测断层;(b) 本文构建的网络预测断层.
Fig. 13 Fault detection results of the filed data in F3 area
(a) Fault predicted by 3D UNet;(b) Fault predicted by the proposed network.

测线范围为 1975 ~ 2230,横测线范围为 1100 ~ 2124,时间为 1000 ~ 1800 ms,采样间隔为 1 ms.工区内断层比较发育.

图 15 所示为该数据体及提取的特征值相干属性体、方差体以及最大正曲率属性体,将其输入到四通道深度监督网络模型中进行断层预测,得到




图 14 F3 工区实际地震资料蚂蚁体自动追踪和深度学习识别断层结果比较

(a) 蚂蚁体自动追踪结果;(b) 多属性三维监督网络预测的断层结果.

Fig. 14 Fault detection results of the filed data in F3 area

(a) Fault predicted by 3D UNet;(b) Fault predicted by the proposed network.




图 15 东部某油田实际地震资料及地震属性

(a) 实际地震数据;(b) 特征值相干属性;(c) 方差属性;(d) 最大正曲率属性.

Fig. 15 The field data of some oilfield in the East area and the corresponding seismic attributes

(a) The filed data;(b) Coherence;(c) Variance cube;(d) Most positive curvature.

图 16c 的结果,图 16a、b 分别为该数据体的相干属性和采用三维 UNet 得到的断层预测结果. 如图 16a 所示,相干体可以指示大断层的位置以及断层的基

本展布形态,但连续性交叉,且小断层较杂乱,难以有效识别;图 16b 所示为三维 U-Net 的断层识别结果,相比相干属性来说,断层形态清晰,断层连续性




图 16 实际地震资料利用两种网络的断层预测结果
(a) 相干属性结果;(b) 三维 UNet 预测的断层结果;(c) 四通道的深度监督网络预测的断层结果。
Fig. 16 Fault detection results of the filed data in East area
(a) Coherence attribute;(b) Fault predicted by 3D UNet;(c) Fault predicted by the proposed network.

有了提高,但小断层的识别较差(图 16b 中黄色箭头所示),且干扰较多(图 16b 中蓝色框所示);图 16c 中四通道深度监督网络预测断层背景干扰减少(图 16c 蓝色框所示),且断层错误识别的情况得到了改善(图 16c 中蓝色箭头所示),除此之外,利用该网络检测到的小断层特征更为明显(图 16c 黄色箭头所示).由此可知,利用四通道的深度监督网络识别的断层效果更优,也证明了本文所提方法的有效性.

5 结论与认识

本文构建了四通道的深度监督网络识别断层,该网络将三维 UNet 和残差学习模块结合在一起,并引入扩张卷积和多层深度监督的机制,将地震属性应用到四通道的网络训练中.理论模型的测试以及多个工区实际地震资料的应用表明,与常规的三维

UNet 网络相比,本文提出的网络能够更加准确地识别断层,预测的断层连续性更好,特别是对于低序级的断层,识别准确率也更高,而且该网络的泛化能力较好,识别出的断层断点位置与井曲线上真实的断点位置基本能对应上,这也说明了该方法识别断层的准确性

在四通道深度监督网络的实际应用中,以下三点需要重点关注:

(1)四通道深度监督网络的层数可以选择三层或四层(本文设为四层网络).通过多次实验证实,在实际地震数据的断层特征较为简单的情况下,三层网络也可以满足实际的断层识别要求.

(2)在生成断层训练样本时,尽量根据实际地震资料的断层特征设置参数,特别是断层倾角、断距、子波频率和信噪比这几个参数对对网络模型适用性的影响较大.

(3)关于迭代次数的选择,多组随机选择的断层样本训练证明迭代次数选择40的时候,验证数据的断层预测准确率可以达到0.96,继续增加迭代次数后,准确率的提高程度有限,对实际数据的断层检测影响较小。考虑到网络训练的时间成本和计算效率,迭代次数不必选择太大。

致 谢 感谢审稿专家提出的修改意见和编辑部的大力支持!

References

- An Y, Guo J L, Ye Q, *et al.* 2021. Deep convolutional neural network for automatic fault recognition from 3D seismic datasets. *Computers & Geosciences*, 153: 104776, doi: 10.1016/j.cageo.2021.104776.
- Araya-Polo M, Dahlke T, Frogner C, *et al.* 2017. Automated fault detection without seismic processing. *The Leading Edge*, 36(3): 208-214.
- Ashraf H, Mousa W A, Al Dossary S. 2016. Sobel filter for edge detection of hexagonally sampled 3D seismic data. *Geophysics*, 81(6): N41-N51.
- Breiman L. 1996. Bagging predictors. *Machine Learning*, 24(2): 123-140.
- Breiman L. 2001. Random forests. *Machine Learning*, 45(1): 5-32.
- Chen J X, Lu P F, Yuan Z L, *et al.* 2024. CUNet deep learning method and its application in fault recognition. *Progress in Geophysics (in Chinese)*, 39(2): 561-571, doi: 10.6038/pg2024HH0023.
- Chopra S, Marfurt K J. 2007. Volumetric curvature attributes add value to 3D seismic data interpretation. *The Leading Edge*, 26(7): 856-867.
- Cunha A, Pochet A, Lopes H, *et al.* 2020. Seismic fault detection in real data using transfer learning from a convolutional neural network pre-trained with synthetic seismic data. *Computers and Geosciences*, 135: 104344, doi: 10.1016/j.cageo.2019.104344.
- Dahlke T, Araya-Polo M, Zhang C Y, *et al.* 2016. Predicting geological features in 3D Seismic Data. //3D Deep Learning Workshop at NIPS. Barcelona, Spain, 1-4.
- Di H B, Gao D L. 2014. Gray-level transformation and Canny edge detection for 3D seismic discontinuity enhancement. *Computers and Geosciences*, 72: 192-200.
- Di H B, Li C, Smith S, *et al.* 2021. Imposing interpretational constraints on a seismic interpretation convolutional neural network. *Geophysics*, 86(3): IM63-IM71.
- Drozdzal M, Vorontsov E, Chartrand G, *et al.* 2016. The importance of skip connections in biomedical image segmentation. //1st International Workshop, LABELS 2016, and Second International Workshop, DLMIA 2016. Athens: Springer, 179-187.
- Duan Y T, Wu C D, Zheng X D, *et al.* 2018. Coherence based on spectral variance analysis. *Geophysics*, 83(3): O55-O66.
- Gao K, Huang L J, Zheng Y C, *et al.* 2022. Automatic fault detection on seismic images using a multiscale attention convolutional neural network. *Geophysics*, 87(1): N13-N29.
- Gu J X, Wang Z H, Kuen J, *et al.* 2017. Recent advances in convolutional neural networks. <https://arxiv.org/pdf/1512.07108>.
- He K M, Zhang X Y, Ren S Q, *et al.* 2016. Identity mappings in deep residual networks. <https://arxiv.org/abs/1603.05027>.
- Hotelling H. 1933. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24(6): 417-441.
- Hu G, Hu Z W, Liu J P, *et al.* 2022. Seismic fault interpretation using deep learning-based semantic segmentation method. *IEEE Geoscience and Remote Sensing Letters*, 19: 7500905, doi: 10.1109/LGRS.2020.3041301.
- Lavialle O, Pop S, Germain C, *et al.* 2007. Seismic fault preserving diffusion. *Journal of Applied Geophysics*, 61(2): 132-141.
- Lin T Y, Goyal P, Girshick R, *et al.* 2020. Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 42(2): 318-327.
- Liu C, Liu H Y, Peng C, *et al.* 2016. Application of the ant colony algorithm based on weighted coherence to fault detection. *Chinese Journal of Geophysics (in Chinese)*, 59(10): 3859-3868, doi: 10.6038/cjg20161029.
- Liu L, Liu Y, Liu C, *et al.* 2021. Iterative seismic random noise suppression method based on compressive sensing. *Chinese Journal of Geophysics (in Chinese)*, 64(12): 4629-4643, doi: 10.6038/cjg2021P0045.
- Liu N H, Li S Z, Huang T, *et al.* 2022. Seismic fault interpretation based on improved holistically-nested edge detection. *Oil Geophysical Prospecting (in Chinese)*, 57(3): 499-509.
- Liu Y, Wang D, Liu C, *et al.* 2014. Structure-oriented filtering and fault detection based on nonstationary similarity. *Chinese Journal of Geophysics (in Chinese)*, 57(4): 1177-1187, doi: 10.6038/cjg20140415.
- Lu F M, Meng R G, Zhang J H, *et al.* 2022. Research of complex fault recognition method based on UNet++ network and transfer learning technique. *Progress in Geophysics (in Chinese)*, 37(3): 1100-1111, doi: 10.6038/pg2022FF0122.
- Lu P, Morris M, Brazell S, *et al.* 2018. Using generative adversarial networks to improve deep-learning fault interpretation networks. *The Leading Edge*, 37(8): 578-583.
- Qi J, Li F Y, Marfurt K. 2017. Multiazimuth coherence. *Geophysics*, 82(6): O83-O89.
- Qi J, Lyu B, Wu X M, *et al.* 2020. Comparing convolutional neural networking and image processing seismic fault detection methods. //SEG Technical Program Expanded Abstracts. SEG, 1111-1115.
- Ronneberger O, Fischer P, Brox T. 2015. U-Net: convolutional neural networks for biomedical image segmentation. <https://arxiv.org/pdf/1505.04597>.
- Tang J, Meng T, Han S Y, *et al.* 2021. A fault detection method of seismic data based on multiResU-Net. *Oil Geophysical Prospecting (in Chinese)*, 56(3): 436-445.
- Tipping M E, Bishop C M. 1999. Mixtures of probabilistic principal component analyzers. *Neural Computation*, 11(2): 443-482.
- Wang J, Zhang J H, Zhang J L, *et al.* 2021. Research on fault recognition method combining 3D Res-UNet and knowledge distillation. *Applied Geophysics*, 18(2): 199-212.
- Wei X L, Zhang C X, Kim S W, *et al.* 2022. Seismic fault detection using convolutional neural networks with focal loss. *Computers & Geosciences*, 158: 104968, doi: 10.1016/j.cageo.2021.104968.
- Wu X M, Hale D. 2016. Automatically interpreting all faults, unconformities, and horizons from 3D seismic images. *Interpretation*, 4(2): T227-T237.
- Wu X M, Liang L M, Shi Y Z, *et al.* 2019. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84(3): IM35-IM45.
- Yan Z, Zhang Z, Liu S Y. 2021. Improving performance of seismic fault detection by fine-tuning the convolutional neural network pre-trained with synthetic samples. *Energies*, 14(12): 3650, doi: 10.3390/en14123650.
- Yin X Y, Zhou J Y. 2005. Summary of optimum methods of seismic attributes. *Oil Geophysical Prospecting (in Chinese)*, 40(4): 482-489.
- Yin X Y, Gao J H, Zong Z Y. 2014. Curvature attribute based on dip scan with eccentric window. *Chinese Journal of Geophysics (in Chinese)*, 57(10): 3411-3421, doi: 10.6038/cjg20141027.
- Yu F, Koltun V. 2016. Multi-scale context aggregation by dilated convolutions. <https://arxiv.org/pdf/1511.07122>.
- Zhong T, Li Y, Yang B J, *et al.* 2017. Statistical features of the random noise in land seismic prospecting. *Chinese Journal of Geophysics (in Chinese)*, 60(2): 655-664, doi: 10.6038/cjg20170219.

Zhou R S, Yao X M, Wang Y J, *et al.* 2021. Seismic fault detection with progressive transfer learning. *Acta Geophysica*, 69(6): 2187-2203.

附中文参考文献

陈继兴,路鹏飞,袁兆林,等. 2024. CUNet 断层智能识别方法及其在断层识别中的应用研究. *地球物理学进展*, 39(2): 561-571, doi: 10.6038/pg2024HH0023.

刘财,刘海燕,彭冲,等. 2016. 基于加权一致性的蚁群算法在断层检测中的应用. *地球物理学报*, 59(10): 3859-3868, doi: 10.6038/cjg20161029.

刘璐,刘洋,刘财,等. 2021. 地震随机噪声压缩感知迭代压制方法. *地球物理学报*, 64(12): 4629-4643, doi: 10.6038/cjg2021P0045.

刘乃豪,李时桢,黄腾,等. 2022. 改进的整体嵌套边缘检测地震断

层识别技术. *石油地球物理勘探*, 57(3): 499-509.

刘洋,王典,刘财,等. 2014. 基于非平稳相似性系数的构造导向滤波及断层检测方法. *地球物理学报*, 57(4): 1177-1187, doi: 10.6038/cjg20140415.

芦凤明,孟瑞刚,张军华,等. 2022. UNet ++ 和迁移学习相结合的复杂断裂识别方法研究. *地球物理学进展*, 37(3): 1100-1111, doi: 10.6038/pg2022FF0122.

唐杰,孟涛,韩盛元,等. 2021. 基于多分辨率 U-Net 网络的地震数据断层检测方法. *石油地球物理勘探*, 56(3): 436-445.

印兴耀,周静毅. 2005. 地震属性优化方法综述. *石油地球物理勘探*, 40(4): 482-489.

印兴耀,高京华,宗兆云. 2014. 基于离心窗倾角扫描的曲率属性提取. *地球物理学报*, 57(10): 3411-3421, doi: 10.6038/cjg20141027.

钟铁,李月,杨宝俊,等. 2017. 陆地地震勘探随机噪声统计特性. *地球物理学报*, 60(2): 655-664, doi: 10.6038/cjg20170219.