

基于 LOFUnet 深度卷积神经网络 低序级断层多属性识别方法

马玉歌¹, 苏朝光¹, 丁仁伟², 颜世磊¹, 张玉洁², 韩天娇², 闫绘栋¹

(1. 中国石化胜利油田分公司物探研究院, 东营 257022;

2. 山东科技大学 地球科学与工程学院, 青岛 266590)

摘要: 低序级断层控制圈闭及油气富集, 对油气勘探开发具有重要的意义。但其识别描述难度大、效率低, 严重制约了该类油藏的勘探开发进程。随着人工智能的发展, 深度学习为低序级断层识别提供了新的途径。这里在样本集构建及方法上都有创新之处: 建立了同相轴错动、扭动、微扭动地震响应特征的低序级断层样本集, 为智能识别奠定了良好的样本库; LOFUnet 网络是在 UNet 基础上进行的改进, 可以获取样本中更多低序级断层信息的特征。笔者通过方差属性、倾角属性和振幅属性融合获得新的断层体, 用构建的 LOFUnet 网络进行低序级断层识别。网络通过残差块构建编码器端可以获取更多的低序级断层特征, 解决梯度消失问题, 提高模型的收敛速度, 增强模型的稳定性以及低序级断层检测的精度和效率。选用正演模拟数据和实际地震数据分别对 UNet 模型、LOFUnet 模型进行测试, 结果表明, 基于 LOFUnet 深度卷积神经网络低序级断层多属性识别方法提取的信息更加丰富, 提高了低序级断层识别的准确度。

关键词: 低序级断层; Unet 网络; LOFUnet 网络; 多属性识别; 模型试算

中图分类号: P618.13

文献标志码: A

DOI: 10.3969/j.issn.1001-1749.2024.03.03

0 引言

断层是控制油气分布和聚集的重要因素, 决定着构造的规模和圈闭的形成。三维地震勘探虽然在小断层识别方面已经取得了较好的效果, 但受各种因素和解释技术的约束, 对 5 m~15 m 低序级断层识别效果不明显。目前地震属性技术在构造解释上越来越成熟, 如相干体^[1-5]、方差体^[6-7]、曲率体^[8-11]、蚂蚁体^[12-14]、倾角方位角^[15]、似然度^[16]、相似度^[17]等, 一些地震属性体的研究与应用是为了克服地震数据上噪声的影响和分辨率的限制^[18], 在解释地下地质构造中的断层构造方面发挥着极其重大的作用。

尹成等^[19]联合地震振幅类属性与地震波形类

属性的识别方法在小断层和砂体重叠带得以很好的验证; 张晓岩^[20]采用多属性识别技术对矿井断层构造进行精细识别; 霍丽娜等^[21]融合相干、方差、分频相位以及蚂蚁体等多种属性大大提高了断层的解释精度; 解洁清^[22]利用蚂蚁+RGB 属性融合使断层在数据体上的形态与边界反映清晰, 吻合度更高。Jahan 等^[23]利用 PCA 和多属性融合的方法进行断层识别。随着深度学习的发展^[24-26], 验证了深度卷积神经网络在断层识别方面的进展。Wu 等^[27]提出三维图像处理方法, 自动计算断层相邻图像样本的断层面和倾斜滑动矢量; Wu 等^[28]使用正演合成地震数据, 利用卷积神经网络方法计算断层概率图。张政等^[29]将深度残差网络与迁移学习结合并应用于断层识别。常德宽等^[30]在 UNet 网络结构的基

收稿日期: 2023-02-02

基金项目: 中国石化胜利油田分公司项目(YKY2405)

第一作者: 马玉歌(1975-), 女, 高级工程师, 主要从事物探综合研究工作, E-mail: mayuge_slyt@sinopec.com。

基础上结合 ResUNet 的思想,提出了 SeisFault Net 结构。杨午阳等^[31]提出一种基于 UNet 深度学习网络的地震数据断层检测方法,在网络结构中结合 UNet 和残差模块 ResUNet50,构建了新的 ResUNet 网络。刘宗杰^[32]等提出基于 3D U-Net 全卷积神经网络的低序级断层识别技术。吴吉忠等^[33]提出基于全卷积神经网络(Fully Convolutional Neural Network, FCN)结构的低序级断层识别方法。马玉歌等^[34]进行影响低序级断层识别精度因素的地震正演定量研究,为低序级断层智能识别模型样本库的建立奠定了良好的基础。

对于深度学习而言,选择合适的网络结构能同时提取低序级断层特征,这是深度学习在断层识别方面的优势之一。笔者特别考虑到低序级断层的特征^[34],构建了具有地震同相轴错断、错动、扭动、地震响应特征的样本集,构建了基于 LOFUnet 网络深度学习架构的低序级断层识别网络,通过残差块构建编码器可以获取更多的低序级断层特征,解决梯度消失问题,提高模型的收敛速度,增强模型的稳定性。通过方差、振幅、倾角三种属性效果对比表明总体的断层分布一致,方差属性和振幅属性在断层识别上较清晰。因此笔者融合方差属性、振幅属性、倾角属性来获得一个新的断层体,进而利用 LOFUnet 网络进行训练,模型测试与实际资料表明,相对以往方法,提取的信息更加丰富,表明此方法在识别

低序级断层方面有较好效果。

1 方法

1.1 残差网络

随着网络层数的加深,feature map 包含的特征信息逐层减少,训练集 loss 却饱和甚至增大出现梯度消失、梯度爆炸、过拟合等问题。针对上述问题,残差网络^[35]通过引入跳层连接(图 1),解决了深层网络的退化问题。

残差网络由一系列残差块组成,单一残差块的表示如公式 1 所示,残差块分为直接映射部分和残差部分。 $h(x_L)$ 表示直接映射(图 1(a)左边部分), $f(x_L, W_L)$ 表示残差部分(图 1(a)右边部分)。在卷积网络中, x_L 与 x_{L+1} 的 feature map 数量不一,利用 W'_L ($1 \times 1 \times 1$)卷积升维或降维。此时,残差块表示如公式 2 所示,其中 $h(x_L) = W'_L x_L$ 。

$$x_{L+1} = x_L + f(x_L, W_L) \quad (1)$$

$$x_{L+1} = h(x_L) + f(x_L, W_L) \quad (2)$$

1.2 LOFUnet 结构

LOFUnet 网络(图 2)由编码器和解码器组成。编码器端学习低序级断层特征,解码器端将学习的特征信息进行端到端训练,实现断层分割。LOFUnet 网络在编码器端增加了 3 个残差块(图 2 红色方框),网络由 15 层增加到 18 层。残差块由两个

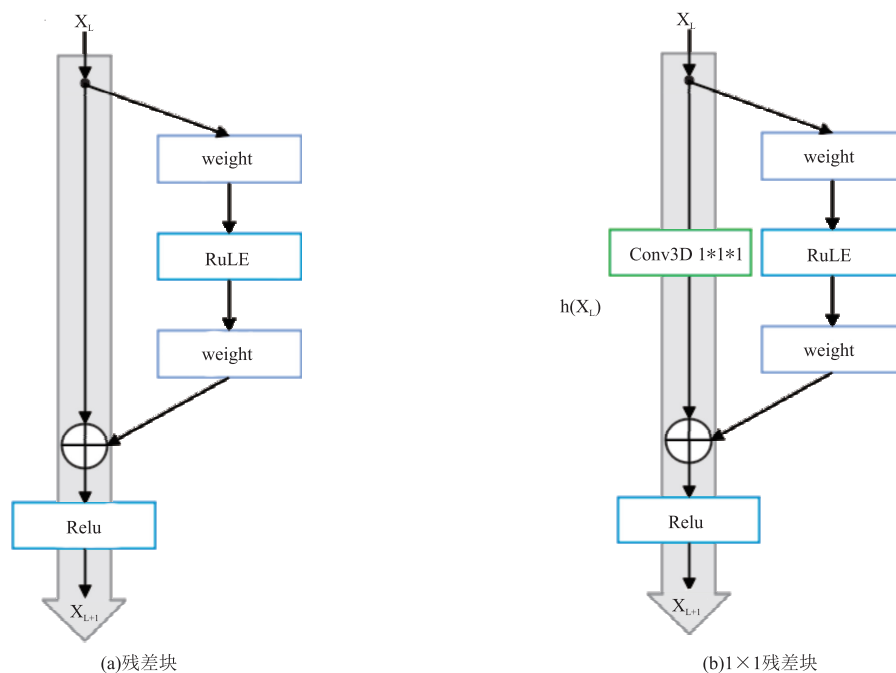


图 1 残差模块

Fig. 1 Residual module

$3 \times 3 \times 3$ 的三维卷积层和一个跳跃连接组成。残差网络增加一个恒等映射,恒等映射基本不会降低网络性能,它可以跳过本层或多层运算,同时后向传播过程中,下一层网络梯度直接传播给上一层,解决深度网络梯度消失的问题。每一层残差块之后采用 $2 \times 2 \times 2$ 的最大池化对数据进行降维,扩大后续卷

积层对低序级断层数据的感受野。解码器端采用 $2 \times 2 \times 2$ 的上采样对数据进行升维后可以准确地重建断层特征。与 U-Net 网络相比,本文网络在编码器端可以获取更多的低序级断层特征,解决梯度消失问题,提高模型的收敛速度,增强模型的稳定性以及断层检测的精度。

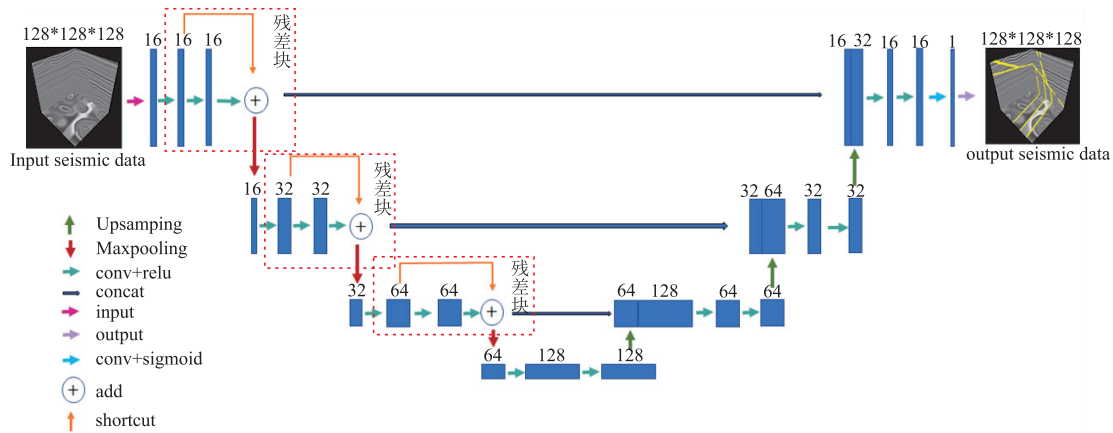


图 2 LOFUnet 网络结构

Fig. 2 LOFUnet network structure

1.3 低序级断层样本集构建

1.3.1 褶积方法

利用网络训练模型预测断层需要大量的样本集。这里的样本集是使用 Wu 等开发的工具包,将地质模型的反射系数与地震子波褶积、正演得到三维合成地震数据,断层样本生成的步骤如下。

1) 首先生成一维水平反射系数模型 $r(x, y, z)$, 其反射系数是在 $[-3, 3]$ 范围内随机生成;

2) 在反射系数模型中添加一些褶皱构造, 通过以下公式(3)、(4)实现:

$$S_1(X, Y, Z) = \frac{1.5Z}{Z_{max}} \sum_{k=1}^N b_k e^{-\frac{(X-c_k)^2 + (Y-d_k)^2}{2\sigma_k^2}} \quad (3)$$

$$S_2(X, Y, Z) = aX + bY + c \quad (4)$$

其中, S_1 表示线性位移场用于倾斜结构; a, b, c 在特定范围内随机选择; S_2 表示高斯位移场; N 个 2D 高斯函数和一个线性缩放函数; 中心点 (c_k, d_k) ; 半宽度 σ_k ; 振幅 b_k , 最终褶皱是在 z 轴方向形成(公式 5)。

$$\begin{bmatrix} \tilde{x} \\ \tilde{y} \\ \tilde{z} \end{bmatrix} = \begin{bmatrix} X \\ Y \\ Z + S_1 + S_2 \end{bmatrix} \quad (5)$$

3) 随机产生一个点 (r_1, r_2, r_3) , 范围是 $((0, n_1), (0, n_2), (0, n_3))$ 。在 $[0^\circ, 360^\circ]$ 之间随机生成断面走向, 在 $[30^\circ, 85^\circ]$ 之间随机生成断面倾角;

4) 两种方法生成断距(线性函数和高斯函数) $f = a_1x_1 + a_2x_2 + a_3x_3$, 随机给定函数的系数 a_1, a_2, a_3, \dots ;

5) 初始模型 P;

6) 在三维体依次给定一个点 (i_1, i_2, i_3) , 范围是 $((0, n_1), (0, n_2), (0, n_3))$ (int 类型), 判断该点是否在断面的上方, 若是, 该点在 n_1 方向根据断距发生位移, 在 n_3 方向断距及倾角发生位移, 得到新的点 (f_1, f_2, f_3) (float 类型), 否则就返回输入的点;

7) 根据新得到的点、初始模型 P、三个方向的采样点等参数, 通过插值, 得到新的有断层的数据体 Q, 设置 nplanar 参数生成多个断面;

8) 将构造完成的模型与雷克子波进行褶积得到地震记录, 最后在合成地震记录中添加随机噪声。

利用上述褶积方法生成 512 对三维地震数据以及对应的标签, 数据和标签的大小为 $128 \times 128 \times 128$ 。二维剖面展示如图 3 所示, 三维显示效果见图 4。

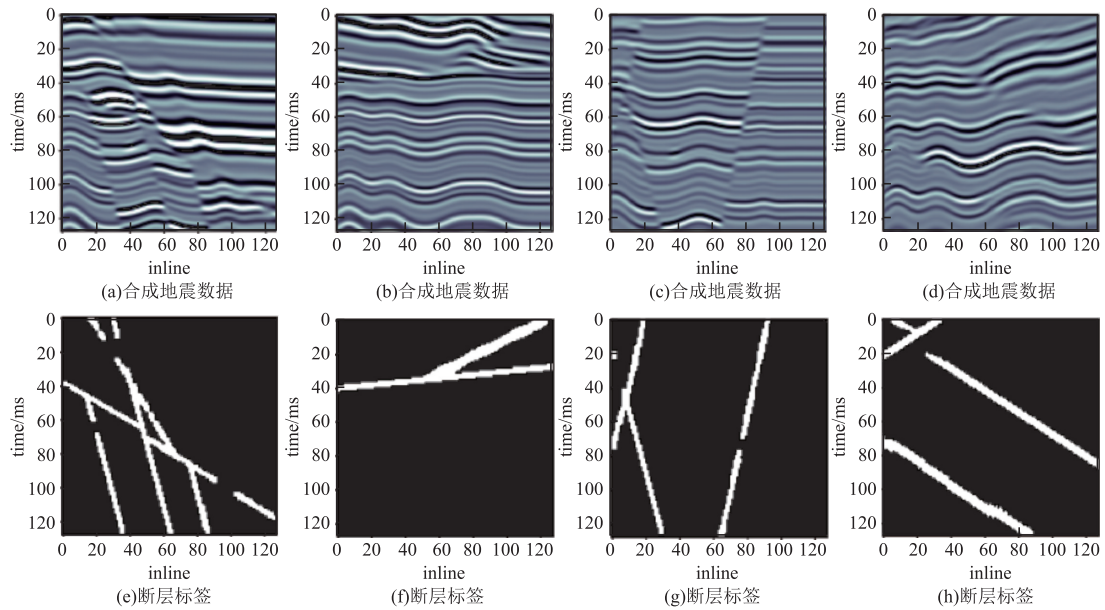


图 3 合成地震数据二维剖面显示图
Fig. 3 2D section display of synthetic seismic data




图 4 合成地震数据三维显示图
Fig. 4 3D display of synthetic seismic data

1.3.2 基于实际数据的断层样本集

针对实际偏移数据,人工解释完成标签标注,进而生成样本集的方法,形成实际数据的低序级断层样本集构建方法。选取目标靶区实际数据,维度为 $1\ 201 \times 401 \times 401$,其中对 207 条测线进行人工标注。由于 207 条带标签的测线不相邻,现将 207 条测线拼接成新数据体,将 $1\ 201 \times 401 \times 207$ 数据体,按照 $128 \times 128 \times 128$ 切割,共切成 170 个小数据体;参与训练的实际数据及标签如下图 5 所示。

1.4 多属性识别

根据地震反射特征,提取振幅属性、蚂蚁属性、倾角属性和方差属性数据体(图 6)。倾角属性可以把落差较大的断层的产状特点清晰表达,对于落差较小的断层不能清晰表达;蚂蚁属性对于地震资料的品质极其敏感,地震资料信噪比低会造成蚂蚁属性得到的断层及裂缝淹没在噪声里;方差属性通过计算相邻地震道之间的方差来表示各个地震道反射特征的差异,从而完成对断层的识别,

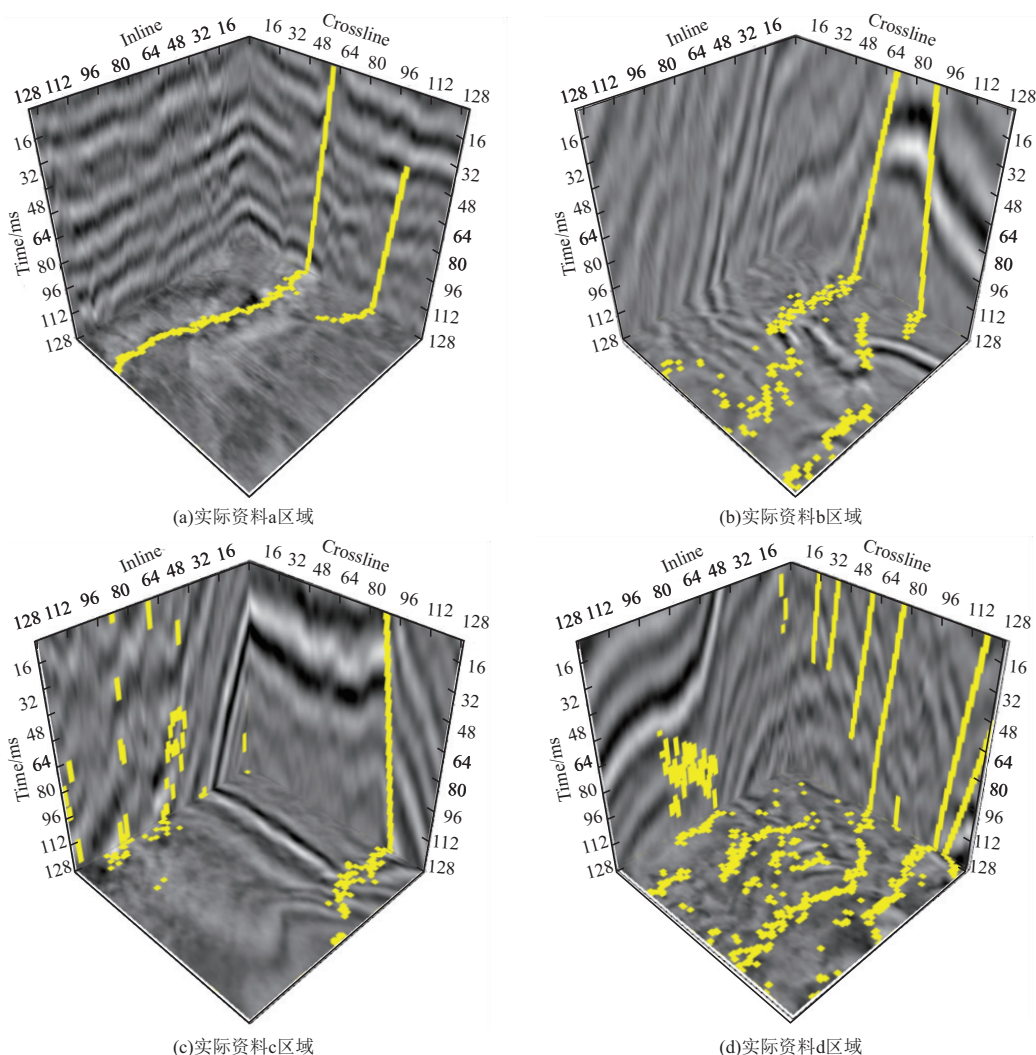


图5 部分实际资料作为样本集展示图
Fig. 5 Part of the actual data as a sample set




图6 四种属性体效果图
Fig. 6 Rendering of four attribute bodies




图 7 模拟数据的属性融合展示图

Fig. 7 Attribute fusion display of simulation data

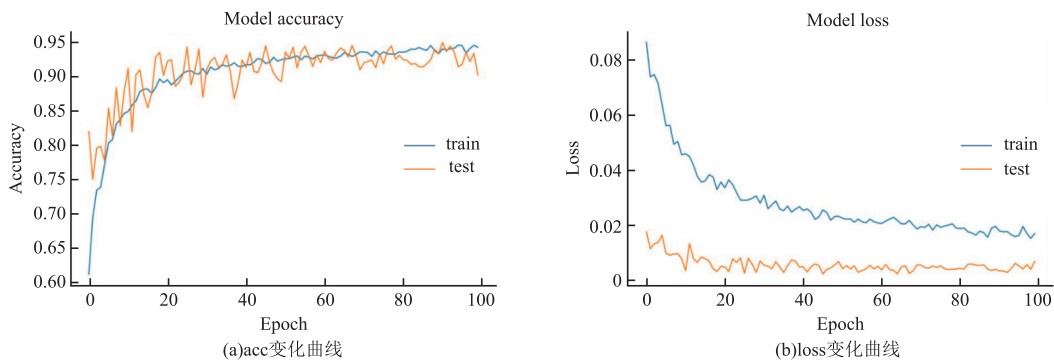


图 8 训练模型变化曲线

Fig. 8 Training model change curve

但方差属性的分辨率较低,对于低序级断层难以很好地识别。

对三维地震数据进行属性融合时,首先将四种属性体进行归一化处理,将数据的值归到 $[0, 1]$;然后在线号方向将多个属性堆叠起来,合并之后的新的数据体维度为 $128 \times 128 \times 128 \times 3$,不区别不同属性的顺序,按照振幅属性、倾角属性和方差属性的顺序将数据堆叠成新的数据体(图 7)。

2 训练及模型测试

2.1 参数设置

笔者使用 512 对三种属性融合(振幅、倾角、方差)的样本集做训练和 20 对验证样本集,每组数据

和标签的大小为 $128 \times 128 \times 128$ 。采用 Adam 优化器,并设置初始学习率为 0.000 1,该学习率随着迭代次数的增加而动态下降。Batchsize 大小设置为 5,训练 100 轮,保存每次训练后的网络模型,训练的准确率提高到 95.7%,损失降到 2%(图 8)。选取最优网络模型进行断层预测。

为了解决断层正负样本不均衡的问题,使用平衡交叉熵损失函数(Xie and Tu, 2015^[35])来优化模型,公式 6 中, N 是三维地震数据点数; y_i 是实际二进制标签; p_i 是 Sigmoid 计算的预测概率, β 表示非断层与总数据的比率; $1-\beta$ 是断层数据点的比率。

$$L = -\beta \sum_{i=0}^{i=N} y_i \log(p_i) - (1-\beta) \sum_{i=0}^{1=N} (1-y_i) \log(1-p_i) \quad (6)$$

2.2 模型试算

2.2.1 LOFUnet 与 UNet 识别效果对比

通过对模型的试算,可以看出,LOF-Unet 网络识别出模型剖面上红色圈中的低序级断层,较 UNet 网络对低序级断层的识别精度得到了提高(图 9 绿圈和红圈处)。

2.2.2 LOFUnet 单属性与多属性识别效果对比

利用 LOFUnet 网络模型分别对单属性(振幅)和多属性(振幅、倾角、方差)训练,使用两种训练得出的网络模型分别预测常规数据(子波主频 20 Hz—噪声 0.3、子波主频 30 Hz—噪声 0.3、子波主频 30 Hz—噪声 0.25)和高精度数据(子波主频 40 Hz—噪声 0.15)。对于高精度数据,基于 LOFUnet 网络单一属性网络模型可以很好地预测;但预测常规数据出现了误预测,且只能预测常规数据的中浅层

(图 10)。图 11 是 LOFUnet 网络多属性网络模型分别对常规数据(子波主频 20 Hz—噪声 0.3、子波主频 30 Hz—噪声 0.3、子波主频 30 Hz—噪声 0.25)和高精度数据(子波主频 40 Hz—噪声 0.15)的预测效果图。

从常规数据和高精度数据预测结果看,基于 LOFUnet 多属性网络模型能够较好的预测常规数据的中浅层,预测出的断层具有较强的连续性;对于高精度数据整体的预测效果较佳,且断层具有较强的延展性。从基于 LOFUnet 多属性网络模型和单一属性网络模型角度看,对于高精度数据,两种网络模型都可以预测出较好的结果;但对于常规数据,单一属性网络模型预测结果中出现了错误预测,而多属性网络模型没有出现错误预测。所以,属性融合的数据拥有更多且更准确的断层特征,能够更好的训练网络模型。




图 9 单属性网络模型预测结果

Fig. 9 Prediction results of single attribute network model

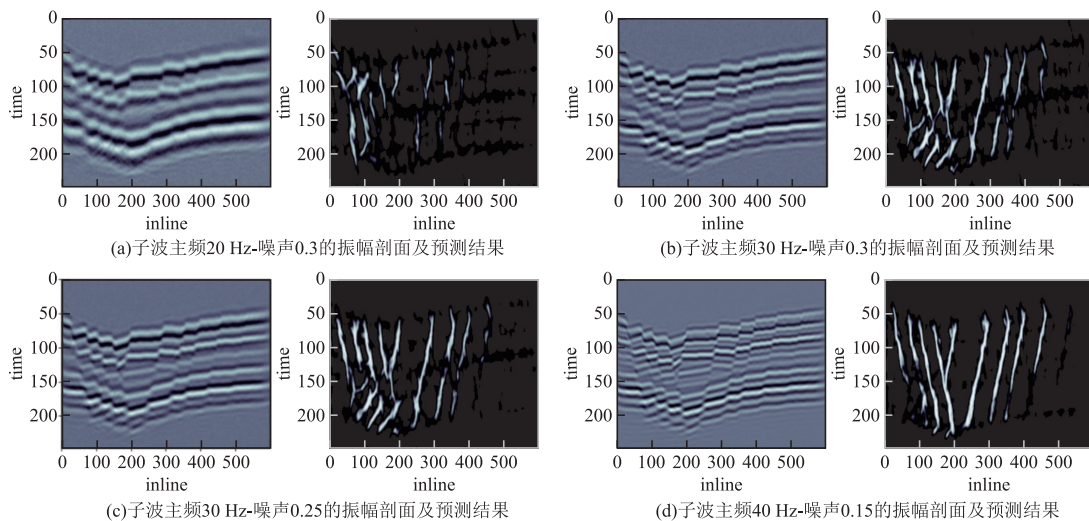


图 10 单属性网络模型预测结果

Fig. 10 Prediction results of single attribute network model

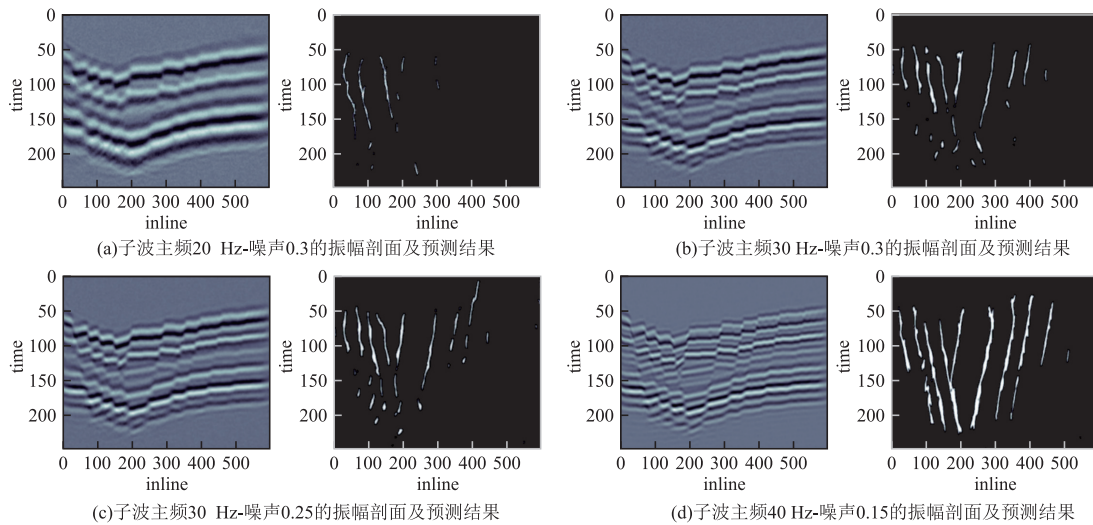


图 11 多属性网络模型预测结果

Fig. 11 Prediction results of multi-attribute network model

3 实际数据应用

实际数据采用胜利油田某靶区的实际地震资料,该实际地震资料的时间范围为[1 000 ms,2 200 ms],CDP 的范围为[3 100,3 500],线号的范围为[3 200,3 600]。

3.1 Unet 网络与 LOFUnet 网络对比

用 512 对训练集(170 对实际数据+342 对模拟数据)分别训练简化版 Unet 网络和自构建的

LOFUnet 网络,用得到的两个模型分别预测实际工区数据(大小为 $1\ 201 \times 401 \times 401$),为了更好地验证 LOFUnet 网络模型的泛化性,笔者通过二维剖面的断层对比,说明 LOFUnet 对于低序级断层预测效果更好,可以识别地震反射特征为同相轴扭动类型的低序级断层以及识别出的断层连续性较好。图 12 是第 3 307 条测线的剖面图以及不同网络结构的预测结果。图 12 红色方框中黄色箭头所示位置,Unet 网络模型并未识别出该位置的断层;LOFUnet 网络模型可以识别出断层。




图 12 Line3307 测线不同网络结构模型预测结果

Fig. 12 Prediction results of different network structure models of Line3307 line

3.2 单属性与多属性网络模型对比

用 512 对振幅属性训练集(170 对实际数据+

342 对模拟数据)和 512 对三属性融合的训练集(170 对实际数据+342 对模拟数据)训练 LOFUnet

网络,得到两个网络模型,用得到的两个模型分别预测实际工区数据(大小为 $1\ 201 \times 401 \times 401$),相比于单属性网络模型,多属性网络模型学习到的特征更多,泛化能力更强,预测效果更好,可以识别出更多微小断裂的位置以及识别出的断层连续性较好。图 13 是第 3 106 条测线的剖面图、基于 LOFUnet 单属性以及多属性网络模型预测结果。图 13 红色方框中黄色箭头所示位置,基于 LOFUnet 单属性网络模型并未预测出该位置是断层,而基于 LOFUnet 多属性的网络模型预测出该位置是断层。图 14 是 1 400 ms 时刻的时间切片平面图、基于 LOFUnet

单属性多、属性网络模型预测结果,图 14 中红色箭头所指的位置,基于 LOFUnet 多属性网络模型预测的结果更加连续,其在地震剖面上表现为同相轴扭动特征,实际钻井也证实该断层的存在,说明基于 LOFUnet 多属性网络模型预测准确度更高,断层的连续性更好,可以帮助解释人员对研究区域的判断,提高钻探成功率。

通过与传统手工解释断层方法对比,传统手工解释该研究工区 11 条断层需要约 60 min,应用该智能解释方法解释 1 条断层 58 s,效率提高 10 倍以上。

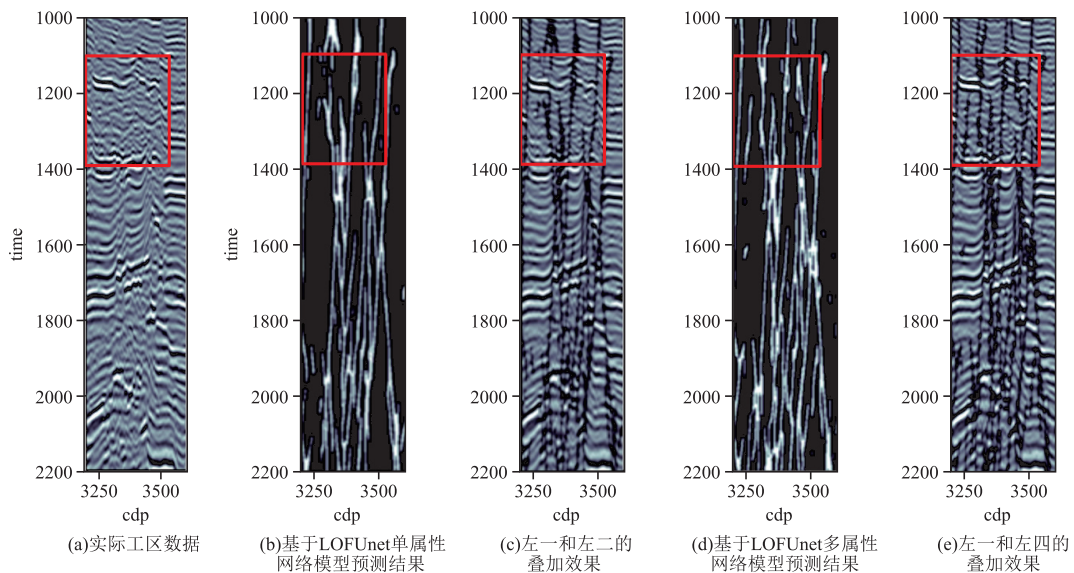


图 13 Line3106 测线基于 LOFUnet 单属性和多属性网络结构模型预测结果

Fig. 13 Prediction results of Line3106 line based on LOFUnet single attribute and multi-attribute network structure model

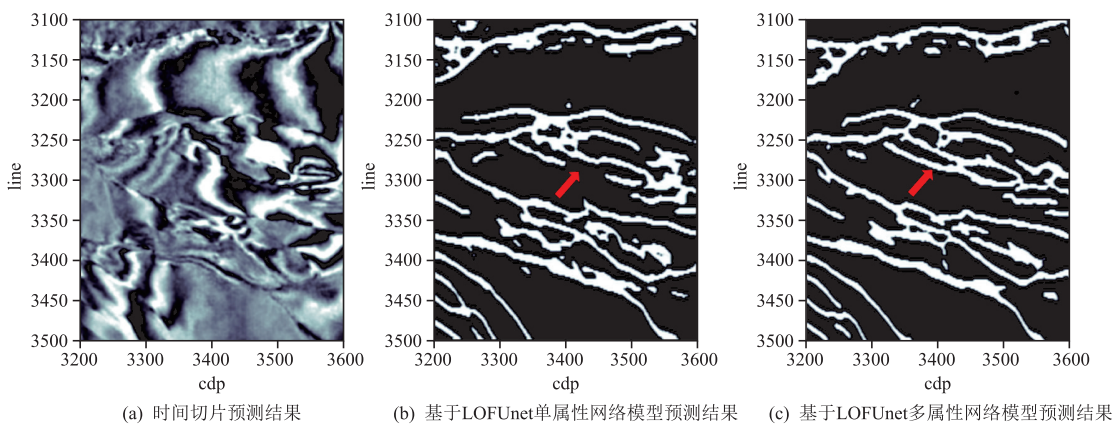


图 14 1 400 ms 水平时间切片基于 LOFUnet 单属性和多属性网络结构模型预测结果

Fig. 14 Prediction results of 1 400 ms horizontal time slice based on LOFUnet single-attribute and multi-attribute network structure model

4 结论

针对低序级断层断距小,识别难等问题,笔者在对低序级断层地震反射特征认识的基础上,提出基于 LOFUnet 网络低序断层多属性识别方法。相比于传统的低序级识别断层具有以下优点:

1) 残差块可以简化网络的学习目标,使神经网络的训练变得更加容易,进一步提高断层识别的准确性。

2) 基于 LOFUnet 多属性网络的低序级断层智能识别模式总体优于 Unet 网络识别模式。振幅、倾角、方差等属性对描述断层各有优势,将多属性融合,增加了网络的学习范围。

3) 训练样本集中断层和非断层的比例严重失衡,为保持二者的比例均衡,采用平衡交叉熵损失函数,使二者比例为 1:1,确保网络的学习能力。

模型测试与实际资料表明,该方法与 Unet 网络对比实验结果表明进一步提升断层的连续性,提高对低序级断层识别的准确度。进而用基于 LOFUnet 多属性网络不仅提高了图像质量,而且在解释地下构造时减少了不确定性。

参考文献:

[1] BAHORICH M S, FARMER S L. 3-D seismic discontinuity for faults and stratigraphic features: The coherence cube[C]//SEG Technical Program Expanded Abstracts 1995. Society of Exploration Geophysicists, 1995: 93-96.

[2] MARFURT K J, KIRLIN R L, FARMER S L, et al. 3-D seismic attributes using a semblance-based coherence algorithm[J]. Geophysics, 1998, 63(4): 1150.

[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] 王西文, 杨孔庆, 刘全新, 等. 基于小波变换的地震相干体算法的应用[J]. 石油地球物理勘探, 2002, 37(4): 328-331.

WANG X W, YANG K Q, LIU Q X, et al. Research on algorithm of seismic coherent cube based on wavelet transform[J]. Oil Geophysical Prospecting, 2002, 37(4): 328-331. (In Chinese)

[5] LI Y D, LU W K, XIAO H Q, et al. Dip-scanning coherence algorithm using eigen structure analysis and

supertrace technique[J]. Geophysics, 2006, 71(3): V61-V66.

[6] YANG L Y, GAO J H, LIU N H, et al. A coherence algorithm for 3-D seismic data analysis based on the mutual information[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(6): 967-971.

[7] CHEN Y P, LIAO Z H, FU L Y, et al. Effect of main frequencies on characterizing fault damage zones using forward modeling and attribute of variance[J]. Interpretation, 2020, 8(4): SP157-SP165.

[8] CHOPRA S, MARFURT K J. Volumetric curvature attributes add value to 3D seismic data interpretation[J]. The Leading Edge, 2007, 26(7): 856-867.

[9] CAO L T, YAO Y B, LIU D M, et al. Application of seismic curvature attributes in the delineation of coal texture and deformation in Zhengzhuang field, southern Qinshui Basin[J]. Bulletin of the American Association of Petroleum Geologists, 2020, 104(5): 1143-1166.

[10] 张晓琦, 文晓涛, 张超铭, 等. 基于坐标变换的三维旋转曲率属性计算方法[J]. 物探化探计算技术, 2021, 43(5): 544-553.

ZHANG X Q, WEN X T, ZHANG C M, et al. Three-dimensional rotation curvature attribute method based on coordinate transformation[J]. Computing Techniques for Geophysical and Geochemical Exploration, 2021, 43(5): 544-553. (In Chinese)

[11] PEDERSEN S I, RANDEN T, SONNELAND L, et al. Automatic fault extraction using artificial ants[C]//SEG Technical Program Expanded Abstracts 2002. Society of Exploration Geophysicists, 2002: 512-515.

[12] 李宏伟, 白雪莲, 崔京彬, 等. 蚂蚁属性优化断层识别技术[J]. 煤田地质与勘探, 2019, 47(6): 174-179.

LI H W, BAI X L, CUI J B, et al. Fault identification technology of ant attribute optimization[J]. Coal Geology & Exploration, 2019, 47(6): 174-179. (In Chinese)

[13] 马玉歌. 产状控制蚂蚁追踪技术在 p57 井区断层解释中的应用[J]. 物探化探计算技术, 2019, 41(5): 601-605.

MA Y G. Application of occurrence control ant tracking technology in fault interpretation in well p57 area[J]. Computing Techniques for Geophysical and Geochemical Exploration, 2019, 41(5): 601-605. (In Chinese)

[14] 钟学彬, 刘军, 王鹏, 等. 基于多属性的断层综合解

- 释技术研究[J]. 新疆地质, 2013, 31(增刊 1): 87—90.
- ZHONG X B, LIU J, WANG P, et al. The study of fault interpretation technology based on multi attribute [J]. Xinjiang Geology, 2013, 31(Suppl 1): 87—90. (In Chinese)
- [15] TINGDAHL K M, PPM D GROOT. Post—stack dip— and azimuth processing[J]. Journal of Seismic Exploration, 2003, 12(2): 113—126.
- [16] 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.
- [17] WU X M, HALE D. 3D seismic image processing for faults[J]. Geophysics, 2016, 81(2): IM1—IM11.
- [18] 马玉歌, 苏朝光, 张健, 等. 低序级断层结构导向坎尼属性边缘检测识别方法[J]. 物探与化探, 2020, 44(3): 698—703.
- MA Y G, SU C G, ZHANG J, et al. Low—order fault structure—oriented Canny property edge detection and recognition method[J]. Geophysical and Geochemical Exploration, 2020, 44(3): 698—703. (In Chinese)
- [19] 尹成, 彭浩, 赵虎, 等. 薄砂体重叠带与小断层的地震多属性联合识别方法研究[J]. 石油物探, 2022, 61(4): 625—634.
- YIN C, PENG H, ZHAO H, et al. Identifying small fault and overlap strip of thin sand body based on seismic multi—attribute analysis [J]. Geophysical Prospecting for Petroleum, 2022, 61(4): 625—634. (In Chinese)
- [20] 张晓岩. 地震多属性融合技术在煤矿隐蔽断层构造识别中的应用研究[J]. 煤炭与化工, 2022, 45(6): 73—75.
- ZHANG X Y. Research on the application of seismic multiple attribute fusion technology in coal mine concealed fault structure identification [J]. Coal and Chemical Industry, 2022, 45(6): 73—75. (In Chinese)
- [21] 霍丽娜, 张建军, 郑良合, 等. 多属性断层解释技术在煤层气储层解释中的应用[J]. 石油地球物理勘探, 2014, 49(增刊 1): 221—227.
- HUO L N, ZHANG J J, ZHENG L H, et al. Fault interpretation with multiple attributes in coalbed methane interpretation [J]. Oil Geophysical Prospecting, 2014, 49(Suppl 1): 221—227. (In Chinese)
- [22] 解洁清. 蚂蚁+RGB 属性融合技术在淮北 QD 矿断层解释中的应用[J]. 中国煤炭地质, 2017, 29(5): 65—68.
- XIE J Q. Application of ant colony plus RGB attribute fusion technology on fault interpretation in QD coalmine, Huaibei [J]. Coal Geology of China, 2017, 29(5): 65—68. (In Chinese)
- [23] JAHAN I, CASTAGNA J, MURPHY M, et al. Fault detection using principal component analysis of seismic attributes in the Bakken Formation, Williston Basin, North Dakota, USA [J]. Interpretation, 2017, 5(3): T361—T372.
- [24] DI H B, SHAFIQ M, ALREGIB G. Patch—level MLP classification for improved fault detection [C]//SEG Technical Program Expanded Abstracts 2018. Anaheim, California. Society of Exploration Geophysicists, 2018: 2211—2215.
- [25] GUITTON A. 3D convolutional neural networks for fault interpretation [C]//80th EAGE Conference and Exhibition 2018. June 11—14, 2018. Copenhagen, Denmark. Netherlands: EAGE Publications BV, 2018: 1—5.
- [26] GUO B, LI L, LUO Y. Automatic seismic fault detection with convolutional neural network [C]. SEG Technical Program Expanded Abstracts, 2018: 1951—1955.
- [27] WU X M, SHI Y Z, FOMEL S, et al. Convolutional neural networks for fault interpretation in seismic images [C]//SEG Technical Program Expanded Abstracts 2018. Anaheim, California. Society of Exploration Geophysicists, 2018: 1946—1950.
- [28] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 770—778.
- [29] 张政, 严哲, 顾汉明. 基于残差网络与迁移学习的断层自动识别[J]. 石油地球物理勘探, 2020, 55(5): 950—956.
- ZHANG Z, YAN Z, GU H M. Automatic fault recognition with residual network and transfer learning [J]. Oil Geophysical Prospecting, 2020, 55(5): 950—956. (In Chinese)
- [30] 常德宽, 雍学善, 王一惠, 等. 基于深度卷积神经网络的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)
- [31] 杨午阳, 杨佳润, 陈双全, 等. 基于 U—Net 深度神经网络的震数据断层检测[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)
- [32] 刘宗杰, 贺锡雷, 张祖豪, 等. 基于 3D U-Net 全卷积神经网络的低序级断层识别技术[J]. 地球物理学进展, 2021, 36(6): 2519-2530.
LIU Z J, HE X L, ZHANG Z H, et al. Low-order fault identification technique based on 3D U-NET full Convolutional Neural Network(CNN)[J]. Progress in Geophysics, 2021, 36(6): 2519-2530. (In Chinese)
- [33] 吴吉忠, 何书梅, 杨倩倩, 等. 基于全卷积神经网络(FCN)的低序级断层识别方法研究[C]. SPG/SPE 南京 2020 年国际地球物理会议论文集, 2020, 1010-1012.
WU J Z, HE S M, YANG Q Q, et al. Research on low order fault recognition method based on full convolutional neural networks [C]. Proceedings of SPG/SPE Nanjing 2020 International Geophysical Conference, 2020, 1010-1012. (In Chinese)
- [34] 马玉歌, 苏朝光, 乐友喜. 影响低序级断层识别精度因素的地震正演定量研究[J]. 地球物理学进展, 2020, 35(2): 616-622.
MA Y G, SU C G, YUE Y X. Quantitative study of seismic forward modeling affecting the accuracy of low-order fault identification[J]. Progress in Geophysics, 2020, 35(2): 616-622. (In Chinese)
- [35] XIE S N, TU Z W. Holistically-nested edge detection[J]. International Journal of Computer Vision, 2017, 125(1): 3-18.

Multi-attribute recognition method for low-order faults based on LOFUnet deep convolutional neural network

MA Yuge¹, SU Chaoguang¹, DING Renwei², YAN Shilei¹,
ZHANG Yujie², HAN Tianjiao², YAN Huidong¹

- (1. Geophysical Research Institute, Shengli Oilfield Company, SINOPEC, Dongying 257022, China;
2. College of Earth Sciences and Engineering, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: Low-order faults control traps and hydrocarbon enrichment, which are significant for oil and gas exploration and development. However, its identification and description are complicated and inefficient, which seriously restricts such reservoirs' exploration and development process. With the development of artificial intelligence, deep learning provides a new way to identify low-order faults. LOFUnet network is an improvement based on UNet, which can obtain more features of low-order fault information in the sample. In this paper, a new fault body is obtained through the fusion of variance attribute, dip attribute, and amplitude attribute, and the LOFUnet network is constructed to identify low-order faults. The network in this paper can obtain more low-order fault features at the encoder end, solve the problem of gradient disappearance, improve the model's convergence speed, enhance the model's stability, and improve the accuracy and efficiency of low-order fault detection. The forward simulation and actual seismic data are used to test the UNet and LOFUnet models, respectively. The results show that the multi-attribute recognition method of low-order faults based on the LOFUnet depth convolution neural network can extract more information and improve the accuracy of low-order fault recognition.

Keywords: low-order fault; Unet network; LOFUnet network; multi-attribute identification; model calculation