2026 年第 41 卷 第 5 期
2026,41(5):2078-2091

地球物理学进展 Progress in Geophysics
http://www.progeophys.cn

ISSN 1004-2903
CN 11-2982/P

王雨,张军华,于景强,等.2026.基于 DCAS-UNet++ 3D 网络的断层识别方法.地球物理学进展,41(5):2078-2091,doi:10.6038/pg2026JJ0412.

WANG Yu, ZHANG JunHua, YU JingQiang, *et al*. 2026. Seismic fault identification method based on the DCAS-UNet++ 3D network. *Progress in Geophysics* (in Chinese), 41(5):2078-2091, doi:10.6038/pg2026JJ0412.

基于 DCAS-UNet++ 3D 网络的断层识别方法

Seismic fault identification method based on the DCAS-UNet++ 3D network

王雨[1,3],张军华[1*],于景强[2],冯德永[2],李红梅[2],王树刚[2]

WANG Yu[1,3], ZHANG JunHua[1*], YU JingQiang[2], FENG DeYong[2], LI HongMei[2], WANG ShuGang[2]

1. 中国石油大学(华东)地球科学与技术学院,山东青岛 266580
2. 中国石化胜利油田分公司物探研究院,山东东营 257022
3. 中国石油天然气股份有限公司西南油气田分公司重庆气矿,重庆 400021

1. *School of Earth Science and Technology, China University of Petroleum (East China), Qingdao Shandong* 266580, *China*
2. *Geophysical Research Institute of Sinopec Shengli Oilfield Branch, Dongying Shandong* 257022, *China*
3. *Chongqing Gas District, PetroChina Southwest Oil & Gasfield Company, Chongqing* 400021, *China*

摘 要 针对断控河道砂体储层,小断裂发育、砂体薄、资料信噪比不高等问题,提出了一种基于改进 DenseASPP 模块增强、CBAM 注意力优化和深度可分离卷积的改进三维 ResU-Net++网络,以集中解决复杂断控河道砂体低序级断层的识别问题.首先,在 ResU-Net++主干网络引入基于 DCNv2 改进的 DenseASPP 模块,通过密集连接多尺度 DCNv2 卷积分支,显著扩展网络感受野并提升对细粒度断层和薄层砂体的多尺度上下文感知能力;其次,结合 CBAM 对特征图进行通道与空间注意力权重重新标定,进一步突出断层纹理和结构边界;此外,用深度可分离卷积替换常规卷积以提高模型解析力和运算速度,最后实际应用中采用迁移学习的方法提高模型的泛化能力.方法应用于通 61 断块,IoU、Dice 分割指标提升至 85.6% 和 92.2%,井震对比和案例分析表明,本文方法可精确刻画复杂断裂结构,提高薄砂体储层描述精度,为构造—岩性一体化解释及油气精细勘探开发提供高效、有效的技术手段.

关键词 DCNv2;DenseASPP;CBAM;深度可分离卷积;改进 3D ResU-Net++;断层精细识别

中图分类号 P631

文献标识码 A

doi:10.6038/pg2026JJ0412

CSTR:32085.14.pg2026JJ0412

Abstract For fault-controlled channel sandbody reservoirs, where small faults are prevalent, sandbodies are thin, and the data have a relatively low signal-to-noise ratio, we propose an improved 3D ResU-Net++ network that integrates an enhanced DenseASPP module, CBAM based attention optimization, and depthwise separable convolutions to address the identification of low-order faults in complex settings. First, a DCNv2-enhanced DenseASPP module is introduced into the ResU-Net++ backbone. By densely connecting multi-scale DCNv2 convolution branches, the network's receptive field is markedly expanded, improving multi-scale contextual awareness of fine-grained faults and thin-layer sandbodies. Second, CBAM recalibrates channel and spatial attention weights to further highlight fault textures and structural boundaries in addition, standard convolutions are replaced with depthwise separable convolutions to boost the model's resolving power and computational efficiency. Finally, transfer learning is employed to enhance generalization. Applied to the Tong-61 fault block, the method achieved segmentation metrics of IoU and Dice up to 85.6% and 92.2%. Well-seismic comparisons and case studies indicate that the proposed approach can accurately delineate complex fault structures and finely depict the distribution of thin sandbody reservoirs, providing an efficient and effective technique for integrated structural-lithologic interpretation and high-resolution hydrocarbon exploration and development.

Keywords DCNv2; DenseASPP; CBAM; Depthwise separable convolution; Improved 3D ResU-Net++; Fine fault detection

收稿日期 2025-12-04; **修回日期** 2026-05-26. **投稿网址** http://www.progeophys.cn

基金项目 新型油气勘探开发国家科技重大专项"复杂地质目标勘探关键技术"(2024ZD1400102)资助.

第一作者简介 王雨,硕士研究生,主要从事深度学习智能解释、地震解释和高精度正演建模研究.E-mail:2025707628@qq.com

***通讯作者** 张军华,男,1965 年生,教授,博士生导师,从事油气地球物理勘探方法研究,现在中国石油大学(华东)从事地球物理领域的教学和科研工作.E-mail:zjh_upc@163.com

0 引　言

断层识别是油气勘探开发的重要工作(邸希和刘洋,2025;李凤磊等,2026;王俊等,2026).以往识别方法主要是属性分析和相干体算法(Bahorich and Farmer,1995;Gersztenkorn and Marfurt,1999;柏冠军等,2011),能够识别出断层面和地层不连续面;此外还包括图像熵各向异性扩散滤波(李军等,2019)、最大似然属性(王静等,2020,2021)、曲率属性(霍志周等,2020)以及蚂蚁体属性(李楠等,2019).这些方法具有一定的减噪效果和突显断层边界的作用,可以在一定程度上提高预测精度,但在复杂断裂系统、信号微弱或低序级断层的场景下仍存在困难.

在深度学习的飞速发展下,先是出现了以卷积神经网络 CNN(Convolutional Neural Network)为基础的断层识别方法.Li 等(2019)提出基于 encoder-decoder(U-Net 类)架构的断层检测方法,在样本有限的条件下仍能实现高精度断层分割并取得良好效果;Xiong 等(2018)基于卷积神经网络的断层检测研究将 CNN 应用于三维地震数据,证明了卷积网络在自动断层定位与高效预测中的有效性,Wu 等(2019)通过 FaultSeg3D 框架实现了三维 U-Net 在体素级断层分割中的端到端应用.此外还有合成数据预训练与迁移学习策略(Pochet *et al.*,2019;Kim *et al.*,2022),以及解释约束网络,此网络可以将地质先验和解释规则并入 CNN,可显著提高结果的一致性与地质合理性(Di *et al.*,2022).通过合适的数据增强、跨域预训练或注意力和多尺度结构设计,CNN 网络也能在不同地质背景下能保持良好的断层检测性能(Gao *et al.*,2022).以上方法通过改进标签样本制作,或者深度学习网络架构提高了深度学习断层预测方法的泛化能力.

关于断层预测深度学习架构,深层特征提取以及多尺度信息融合依旧是目前的研究热点.基于 ResU-Net 的轻量级双向解码网络能够提高深度学习断层预测网络训练的速度和效果(Tang *et al.*,2024);基于上采样的架构(比如 SegNet)能够从整体提升端到端像素级语义分割的效果(Badrinarayanan *et al.*,2017);基于 U-Net 网络使用编码—解码结构、多级跳跃连接等可以实现断层的高精度分割,在医学领域有着比较优秀的性能(Ushinsky *et al.*,2021;Liu *et al.*,2021).何涛等(2023)利用多层深度监督的方式,把多层的中间结果监督加入到 ResU-Net 网络,以增强网络对特征的提取能力;杨午阳等(2021)在 U-Net 基础上加入了注意力机制,并且证明在神经网络中加入注意力机制可有效提高网络对细节裂缝的预测效果.稠密空洞金字塔池化模块 DenseASPP(Dense Atrous Spatial Pyramid Pooling)通过在 ASPP 内部采用密集连接的多尺度空洞卷积分支,一方面可以让网络的感受野更大,另一方面也可以保留更多的断层细节,网络从不同的尺度中提取了更多的上下文信息,实验证明了该模块非常适合应用在城市景物以及遥感图像语义分割上(Wang *et al.*,2019;Pang *et al.*,2024;Lü *et al.*,2024;Tan and Jin,2025).

在深度学习网络中加入轻量级注意力模块可以自适应地选择最优的空间或通道特征,进而使网络更好地对断裂处的纹理信息及边界进行捕获,提高断层预测准确性(Park *et al.*,2020;Zhang *et al.*,2023;Xu *et al.*,2023).比如利用 CBAM(Convolutional Block Attention Module)提取通道和空间注意力,对中间特征图做自适应加权可增强深度学习网络中关键断层纹理特征的提取能力(Woo *et al.*,2018;Zhao *et al.*,2024);利用 BAM(Bottleneck Attention Module)对网络中的瓶颈处设计分层的通道注意力和空间注意力,可在不同尺度语义上加强网络的表达能力(Park *et al.*,2020).大量实验表明,用 CBAM 或 BAM 等注意力模块融入 U-Net、ResU-Net 等网络中能够提升断层预测准确性同时保留断层边界细节(Xu *et al.*,2023).

DCNv2(Deformable ConvNetsv2)是一种调制型可形变卷积,它在 Deformable ConvNetsv1 的基础上引入了可学习偏移和调制掩码来替代固定规则采样网格,并使空洞卷积的规则采样网格适应于输入的自适应采样(Zhu *et al.*,2019;Chen *et al.*,2021),还可以在 xyz 三轴上自适应采样.如果把 DCNv2 加入到 DenseASPP 模块中代替空洞卷积,那么可以得到"自适应膨胀率"来提高断层预测精度,而且深度可分离卷积能以较小的成本获得更好的性能,使得精度损耗非常低的同时大大减少模型的训练时间,优于传统卷积(Liu *et al.*,2024).

总而言之,已有的深度学习断层预测网络在扩大感受野、保留边界细节、通用性及性能上都有各自的优点,但是在低序级断层以及噪声干扰较强的条件下无法更好地解决断层预测问题.为此,本文以东营南坡 T61 断块为例,根据砂体薄、叠置严重、信号弱的复杂储层条件,提出了一种基于 DCAS-UNet++ 3D

(DeformableDenseASPP + CBAM + depthwiseseparable)新的网络结构,有效预测了研究区复杂的断层结构.应用结果表明:本方法可将 IoU、Dice 指标分别提升至 85.6% 和 92.2%,结合油气分布验证,可有效预测与油气开发相关的小微断层,实现油气精细勘探开发.

1 问题分析

1.1 断控河道砂体的地质特征

本研究选取的工区为东营凹陷通王断裂带的通 61 断块,断块位于王家岗鼻状构造的北部高点上,是一个北东~南西向延伸的狭长地垒块.目的层段为沙二上段,包含 Es21~Es26 共 6 个砂组,储层多为 10 m 以下的薄砂体.断块内东营组-沙三中断层-河道油藏地质特征复杂,两者多样的组合模式使本就复杂的油藏进一步破碎化.另外,该区地震资料同相轴连续性差,波形杂乱,低序级断点与岩性变化点响应相似,地震分辨率低,仅靠人工来解释低序级和小微断层有很大的困难,所以需要基于深度学习的高精度断层识别技术以解决低序级断层的预测问题.

1.2 常规方法断层识别能力分析

本文采用了两种常规方法识别断层,分别是相干和曲率属性,图中横向坐标为线号,纵向为道号,黑色"+"字符为井位点.图 1a 为沙二段 5 砂组 Es25 沿层相干体切片,图中黑色色标代表相干性好的地层背景,白色代表断层等相干性差的异常.可以看到,常规相干体能识别尺度较大的大断层,但小微断层连续性差,断点也不明确;另外,砂体特征也无法通过相干体进行表征.图 1b 为最大正曲率属性,黑色代表高曲率区域,可以发现曲率属性能够一定程度上反映断层边界信息,但是连续性和对小微断层识别能力仍然不足,需要通过精细的断层识别与属性融合技术来改进描述手段.

2 方法原理

2.1 改进 DenseASPP 和深度可分离卷积和 CBAM 模块

DenseASPP 以 ASPP 模块为基础,增加了多尺度特征融合的能力,最早由 MaokeYang 等人提出,主要用于解决 ASPP 模块在尺度上存在分辨率稀疏的现象,在保证模型大小相近的情况,实现不同层之间的高斯特征聚合;方法不会提高网络训练和预测的代价,并能够使得预测结果更加准确,预测分辨率更高.

设模块输入特征映射为 X,共有 K 个串联的空洞卷积层,膨胀率依次为 $\{r_1,r_2,\cdots,r_K\}$,第 i 层的输出 H_i 定义为:

$$H_i = BN(Conv_{3\times3\times3}^{\text{rate}=r_i}([X,H_1,\cdots,H_{i-1}])),\quad i=1,\cdots,K, \tag{1}$$

式中[·]表示通道维度上的拼接操作,BN 为批量归一化,所有级联输出与输入再度拼接后,通过一个 1×1×1 卷积瓶颈融合,得到模块最终输出:

$$Y = Conv_{1\times1\times1}([X,H_1,\cdots,H_K]). \tag{2}$$

如图 2a 所示,稠密空洞空间金字塔池化能从不同尺度提取出信息."输入特征 X"是 DenseASPP 模块最初的输入值,是从上一网络层中获得的三维特征,其含有 rate=3、6、12、18 和 24 这 5 种膨胀率为 3×3×3 的空洞卷积层,在每个卷积层后附加 BN+ReLU 空洞卷积能在很大程度上增大感受野,且不会丧失空间分辨率,能覆盖多种地层的信息.再进行空洞卷积前"通道拼接"输入 X 以及每级 BN+ReLU 之后的输出,将这 6 组特征拼接在一起,再在拼接之后的大尺寸特征图中用 1×1×1 卷积进行"瓶颈"式通道压缩和融合,即可得到不损失参数且含有多种尺度信息的结果."输出特征 Y"为 DenseASPP 模块输出的结果,进入之后的解码器层也可以进入深度监督分支中,用来提供完整的多尺度的上下文信息,提高复杂的断层识别精度.

不过,由于 DenseASPP 模块中空洞卷积的膨胀率是固定的,同时断层的尺度大小并不一致,并且各个断层的位置也是不一样的,因而固定的膨胀率无法兼顾小的目标细节以及大的目标的整体信息;另外,DCNv2 可以通过学习偏移来让各个分支能在它的原始尺度的基础上进行伸缩变化、各向异性的变化,从而更好的使断层的细节轮廓和整体轮廓相配.故本文将所有空洞卷积均替换成调制型可形变卷积,其核心计算公式如下所示:

$$y(p) = \sum_{k=1}^{K} w_k \cdot x(p+p_k+\Delta p_k)\cdot \Delta m_k, \tag{3}$$

其中:$\Delta p_k \in \Re^3$ 是对第 k 个采样点的三维偏移(通过插值在连续坐标上取样);$\Delta m_k \in [0,1]$ 是调制掩码,控制该采样点的有效权重;w_k 为卷积核权重.因此我们把 DenseASPP 的第 i 个空洞卷积替换成"以 r_i 为基础网格、再叠加 $(\Delta p,\Delta m)$ 形变"的 DCNv2,设 $G_{r_i}=\{p_k\}_{k=1}^{K}$ 替换为以膨胀率 r_i 生成的规则采样网格(3×3×3 核),式(1)相应地变为:

$$H_i = BN\left(\sum_{k=1}^{K} W_k^{(i)} \cdot X(\cdot+p_k+\Delta p_k^{(i)})\cdot \Delta m_k^{(i)}\right),$$

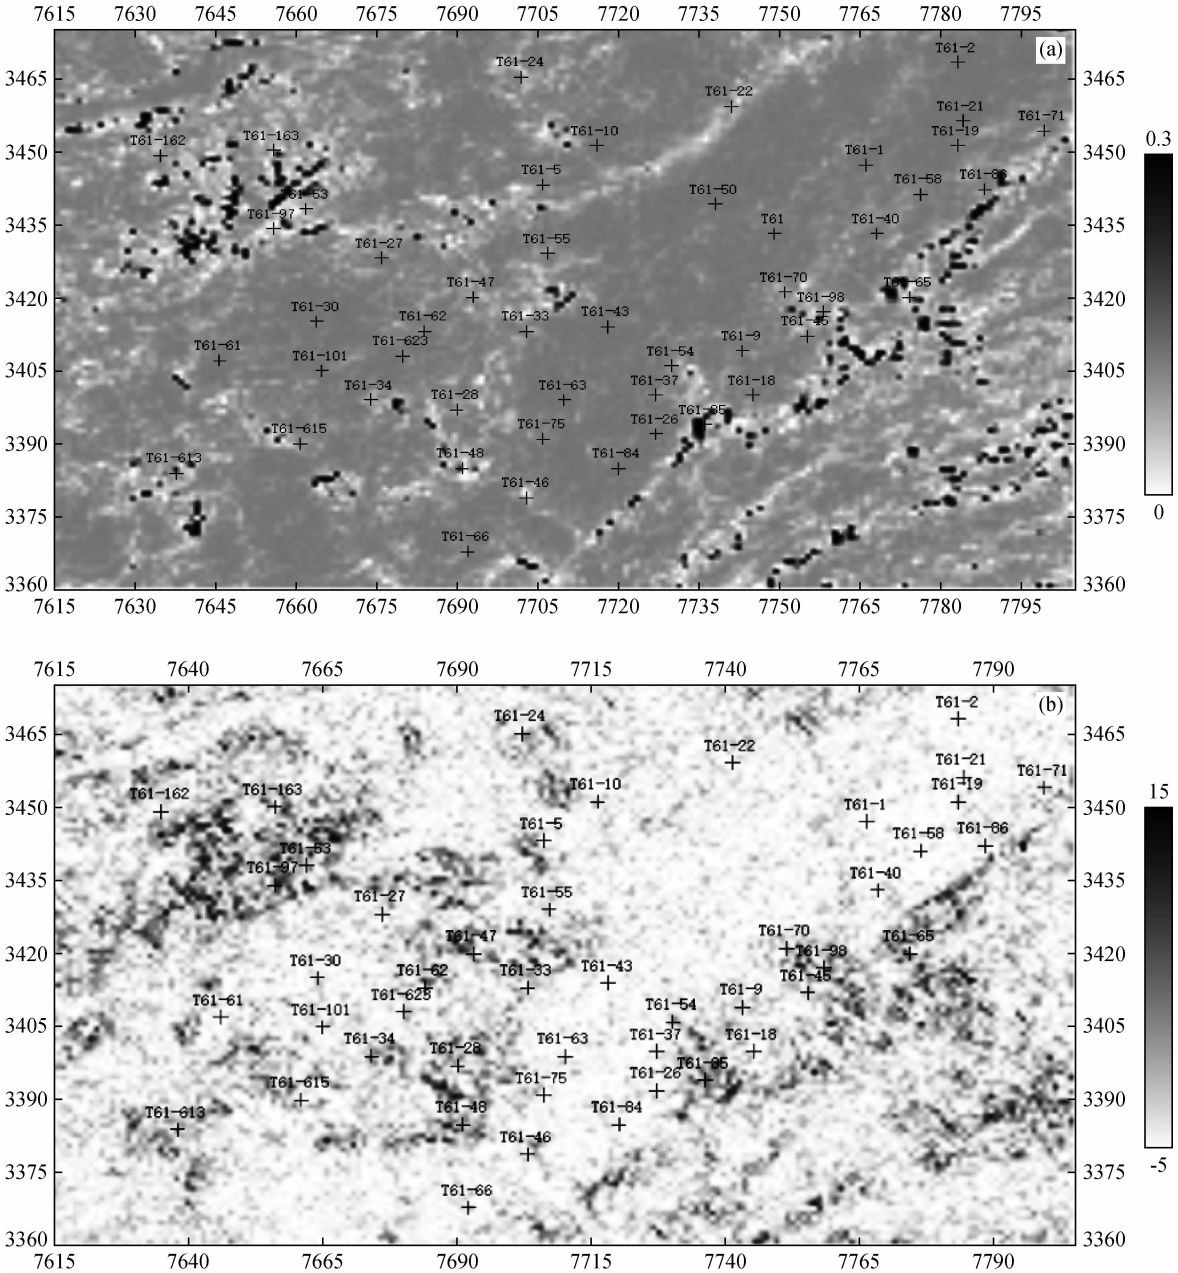


图 1　Es25 沿层相干体切片(a)和最大正曲率属性(b)

Fig. 1　Es25 horizon coherence slice (a) and maximum positive curvature attribute slice (b)

$$i = 1,\cdots,K, \tag{4}$$

其中$\{\Delta p_k^{(i)},\Delta m_k^{(i)}\}$由与本层同步的偏移和掩码头从$[X,H_1,\cdots,H_{i-1}]$预测得到. 瓶颈融合式(2)保持不变. 简单来说:r_i 决定"基础尺度"的网格骨架,$\Delta p_k \Delta m_k$ 让该网格对输入自适应地弹性形变与重加权,从而在相当于学习到了"自适应的膨胀率".

自适应膨胀率的具体学习机制主要包括偏移与调制掩码产生、可微采样与损失回传、端到端更新三个步骤. 首先从级联特征$[X,H_1,\cdots,H_{i-1}]$生成偏移与调制掩码:

$$\Delta P^{(i)} = Conv_{\text{off}}^{(i)}([X,H_1,\cdots,H_{i-1}]) \in \Re^{K\times 3}, \tag{5}$$

$$\Delta M^{(i)} = \sigma(Conv_{\text{mask}}^{(i)}([X,H_1,\cdots,H_{i-1}])) \in [0,1]^K. \tag{6}$$

然后在连续坐标 $u = p + p_k + \Delta p_k^{(i)}$ 处进行可微插值,使损失能回传到 $\Delta p,\Delta m$,从而可学习偏移:

$$X(u) = \sum_{q\in N(u)} \left(\prod_{d\in\{x,y,z\}} \max(0,1 - |q_d - u_d|) \right) X(q). \tag{7}$$

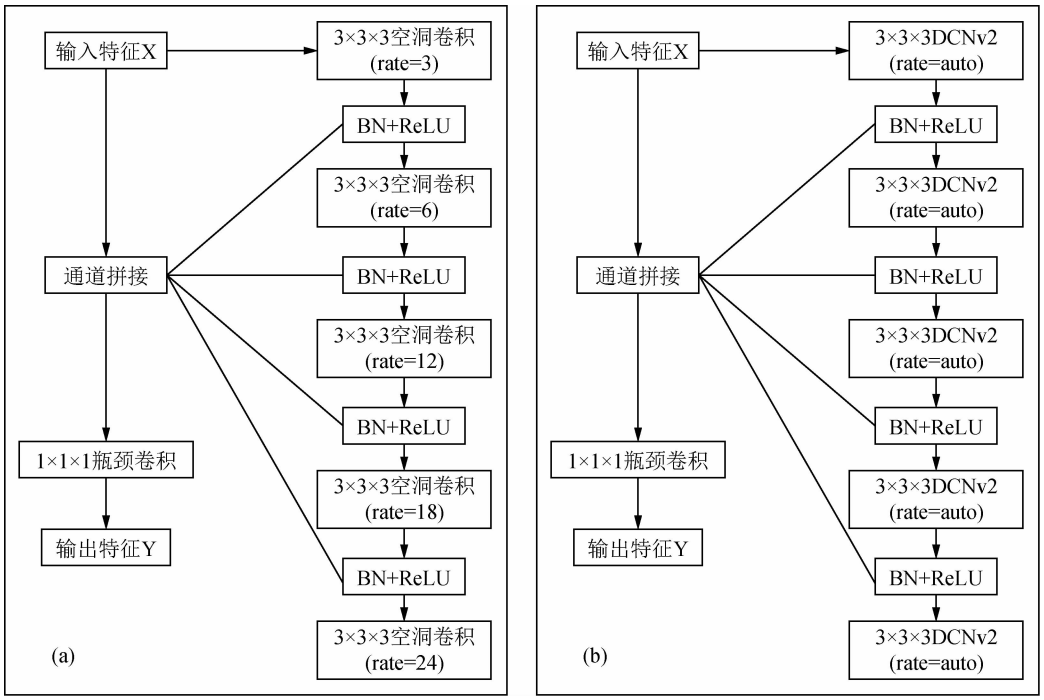


图 2 (a)稠密空洞空间金字塔池化;(b)DCNv2 稠密空洞空间金字塔池化

Fig. 2 (a) Dense atrous spatial pyramid pooling; (b) DCNv2-based dense atrous spatial pyramid pooling

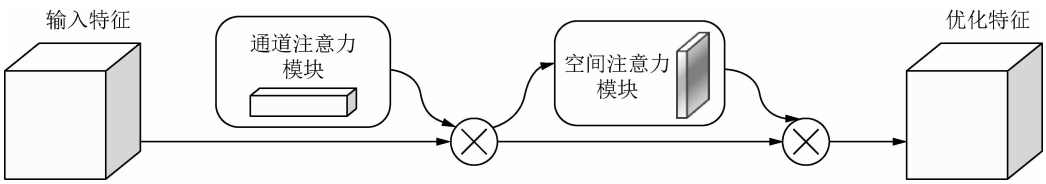


图 3 CBAM 模块优化特征流程

Fig. 3 Feature refinement process using the CBAM module

最后在端到端目标下与卷积核一起更新,下面给出 Δp,Δm 的关键梯度,以分支 i 的单点输出 $y^{(i)}(p)$ 为例:

$$\frac{\partial \mathcal{L}}{\partial \Delta m_k^{(i)}} = \sum_p \frac{\partial \mathcal{L}}{\partial y^{(i)}(p)} W_k^{(i)} X(p + p_k + \Delta p_k^{(i)}), \tag{8}$$

$$\frac{\partial \mathcal{L}}{\partial \Delta p_k^{(i)}} = \sum_p \frac{\partial \mathcal{L}}{\partial y^{(i)}(p)} W_k^{(i)} \Delta m_k^{(i)} \nabla X(p + p_k + \Delta p_k^{(i)}), \tag{9}$$

其中∇X 来自式(9)插值核对坐标的导数;整体采用标准反向传播端到端训练.

本文初始 Δp 为 0,Δm 取 0.5,起步等价于“固定膨胀率”的空洞卷积. 再由任务损失逐步学习到位置相关的有效膨胀,符合 DCN“由目标任务端到端学习偏移”的原则和 DCNv2 的调制机制.

DenseASPP 提供上下文信息 X,而我们通过调整 DCNv2 的 Δp,Δm 参数,实现对小裂缝倾向“收拢采样、提高边界点权重”,对大断层和地层倾向“外扩采样、提高远域上下文权重”,即学习到位置相关的有效膨胀率,提高断层预测性能,得到图 2b 所示 DCNv2 稠密空洞空间金字塔池化.

深度可分离卷积相比常规卷积拥有更好性能的同时,可以大幅压缩模型参数量和计算量,因此本文主干网络的编码器将采用深度可分离卷积模块替代传统标准卷积模块,进行特征提取.

常规卷积计算量:

$$\mathrm{MACs}_{\mathrm{std}} = D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F, \tag{10}$$

深度可分离卷积计算量(两部分相加):

$$\mathrm{MACs}_{\mathrm{DSC}} = D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F, \tag{11}$$

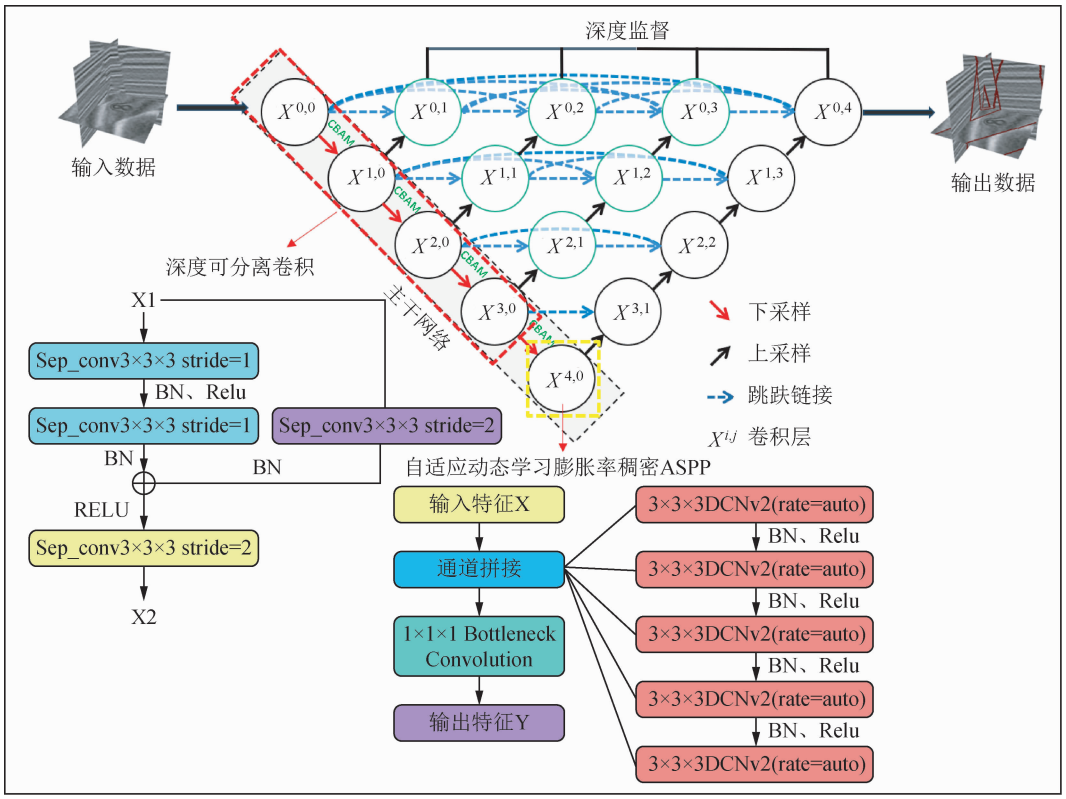


图 4　DCAS-UNet++ 3D 网络

Fig. 4　DCAS-UNet++ 3D Network

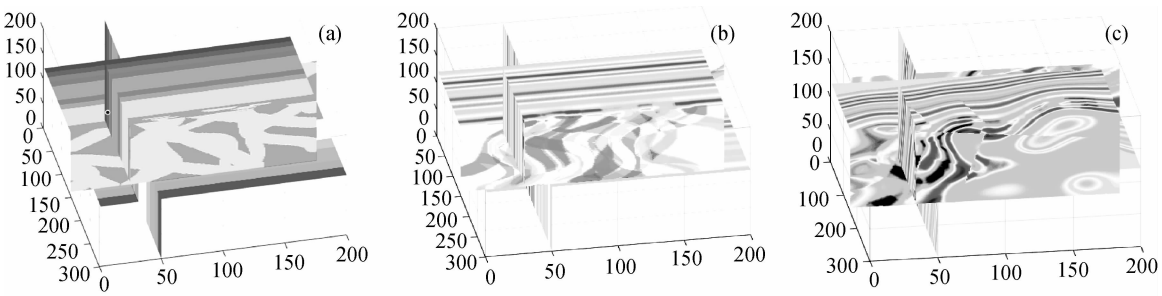


图 5　断层样本生成流程

(a)速度模型;(b)合成地震记录;(c)加入断层、褶皱、倾斜.

Fig. 5　Fault sample generation workflow

(a) Velocity model; (b) Synthetic seismic records; (c) Add faults, folds, and tilts.

因此,相对常规卷积的计算量理论比值为:

$$\frac{\mathrm{DSC}}{\mathrm{Std}}=\frac{1}{N}+\frac{1}{D_K^2}\ , \tag{12}$$

可见用深度可分离卷积替换常规卷积块效率可以提高数倍.

图 3 为 CBAM 模块优化特征流程,首先给定输入特征 $F\in R^{C\times H\times W}$,CBAM 首先计算通道注意力映射 $M_c(F)$并与输入相乘得到 $F'=M_c(F)\otimes F$,再计算空间注意力映射 $M_s(F')$并与 F'相乘得到最终输出 $F''=M_s(F')\otimes F'$. 本文将 CBAM 模块加入下采样以提高特征提取能力.

2.2　三维深度监督改进网络的构建

图 4 是本文提出的改进网络,其基础网络架构为深度监督的 ResU-Net++,嵌入了基于 DCNv2 的 DenseASPP 模块,并在主干网络引入 CBAM 模块进行通道与空间注意力重标定,同时网络编码器的第

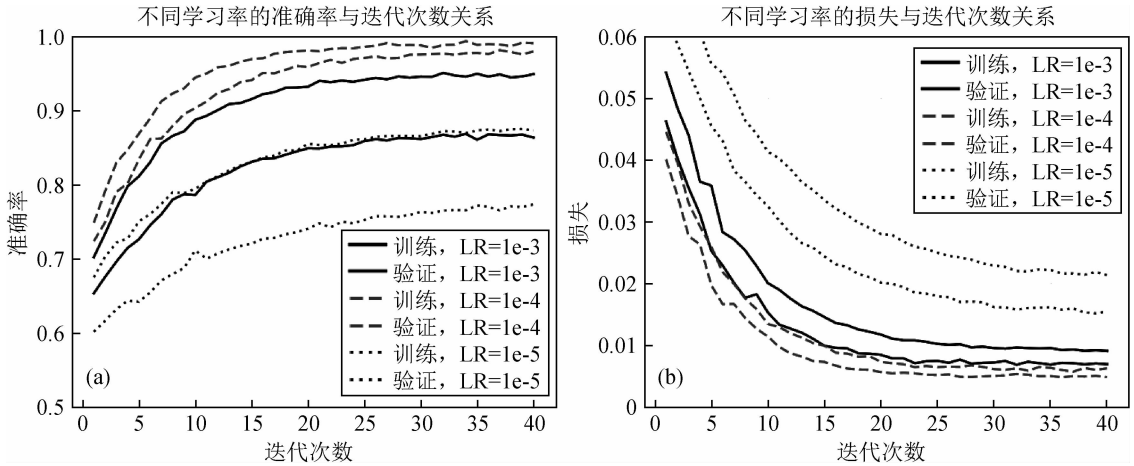


图 6 不同学习率计算得到的准确率(a)和损失(b)

Fig. 6 Accuracy (a) and loss (b) curves obtained with different learning rates

1~4 层($X^{0,0}$,$X^{1,0}$,$X^{2,0}$和$X^{3,0}$)采用基于深度可分离卷积的残差结构,以深度可分离卷积替换常规卷积以降低计算量并提升解析力.

3 网络训练和模型测试

3.1 训练样本生成

本文网络的有效训练依赖于海量、准确的断层样本,借鉴 Wu 等(2019)的方法,采用合成三维地震体生成技术,批量构建包含多种断层形态的训练与验证样本. 如图 5 所示,由于 T61 工区主要储层为砂体,主要岩性参数为:干层 2300 m/s,2.23 g/cm^3;砂岩(河道砂)3100 m/s、2.63 g/cm^3;薄层均为 2 m;河间砂:2900 m/s,2.41 g/cm^3. 设计合成了尺寸不同的 300×200×200 三维速度模型. 河道厚度 3 m 到 9 m 不等,砂体速度 3100 m/s 左右,围岩速度 2600 m/s 左右. 合成地震记录采用 30 Hz 雷克子波,1 ms 采样.

为增强多样性,还对每个数据体进行 90°、180°、270°三种旋转增广,切取输入 128×128×128 大小的三维数据,加入不同程度断层、褶皱、倾斜,加上 Wu 合成的常见断层数据共得 1000 对样本,并在增广后统一做标准化处理,数据 80% 划分为训练集、10% 验证集和 10% 测试集.

3.2 网络训练参数设置

损失函数选用二进制交叉熵(Binary-Cross-Entropy)L_{BCE}为断层检测常用的损失函数之一,即:

$$L_{BCE} = -\frac{1}{N_s}\sum_{i=1}^{N_s}[y_i \ln p_i + (1-y_i)\ln(1-p_i)], \tag{13}$$

式中:N_s 为三维输出或者标签图像中总的样本数;y_i 和 p_i 分别表示第 i 个图像样本的断层二进制标签值和预测值.

引入 FocalLoss 损失函数能修正断层检测正负样本比例问题,并且在网络中根据难易样本调整它们的权重,从而提高断层特征的识别精度:

$$L_{Focal} = -\frac{1}{N_s}\sum_{i=1}^{N_s}[\alpha(1-p_i)^{\gamma} y_i \ln p_i + (1-\alpha)(1-y_i)p_i^{\gamma}\ln(1-p_i)], \tag{14}$$

式中:α 是平衡系数取值为 0.5;γ 为调节因子;通常取值为 2.

本文进行了不同的试验,通过调整参数以选择合适的学习率(Learning Rate,LR). 经试验,迭代次数取 40 时准确率与损失已基本收敛. 由图 6 可见,学习率为 1×10^{-4}时,训练的损失最小,说明模型可以很好学习到断层特征,同时学习率为 1×10^{-4}时准确率也是最高,所以本文设置学习率为 1×10^{-4}.

3.3 评价指标

在深度学习中,对模型预测效果和准确度一般通过不同的指标来衡量. 针对断层识别这一二分类任务,除损失值外,通常还采用准确率、精确率、召回率、Dice 系数与交并比(IoU)等性能指标. 表 1 列出了这些评价指标所对应的符号与计算公式. 准确率(Accuracy)用于衡量模型正确预测的样本占总样本的比例,其值越高,表明模型的整体判别能力越强. 精确率(Precision)反映在被模型判定为断层的样本中,实际为断层的比例,该值越大,说明预测结果越可靠. 召回率(Recall)表示模型能够正确识别出的

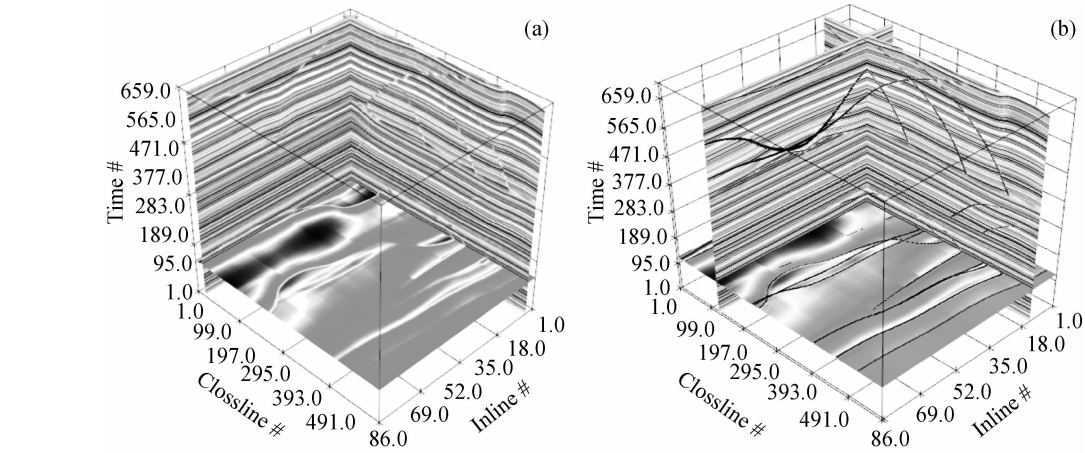


图 7　合成地震记录及其对应断层标签

Fig. 7　Synthetic seismic records and their corresponding fault labels

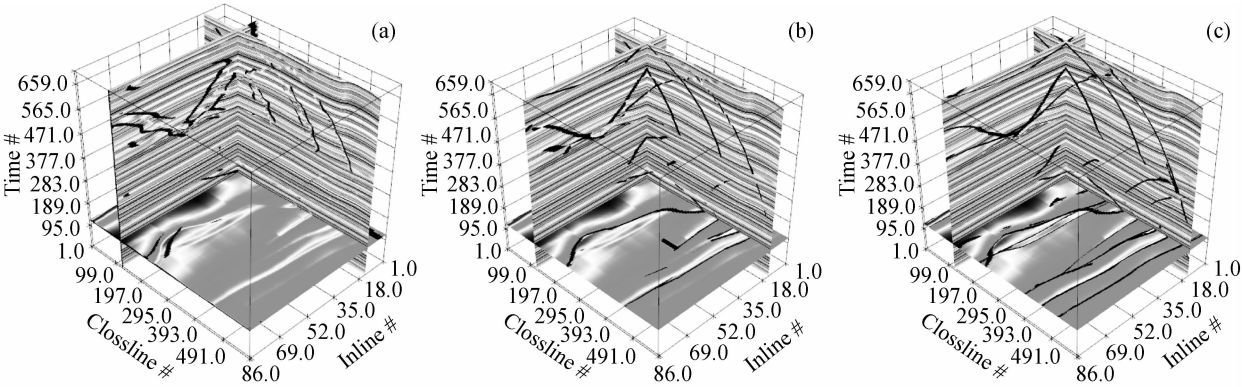


图 8　不同网络预测结果

(a) ResU-Net;(b) ResU-Net + CBAM + ASPP;(c)本文网络.

Fig. 8　Comparing the prediction results of different networks

(a) ResU-Net;(b) ResU-Net + CBAM + ASPP;(c)This article is online.

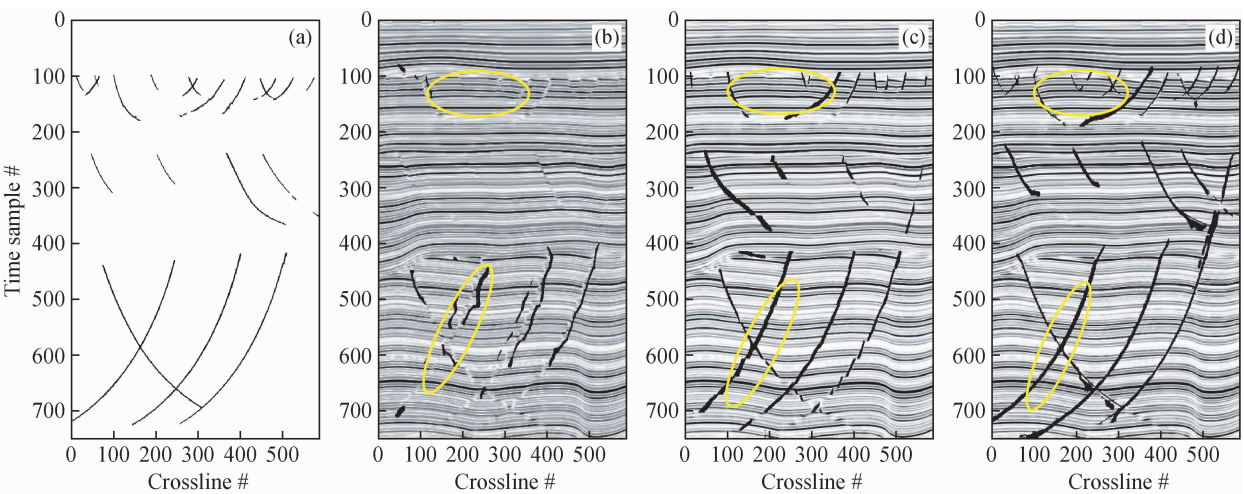


图 9　三种不同网络预测结果剖面对比

(a)标签;(b) ResU-Net 网络;(c) ResU-Net + CBAM + ASPP 网络;(d)本文网络.

Fig. 9　Comparison of slices from three different network prediction results

(a) Labels; (b) ResU-Net network; (c) CBM→CBAM、ResU Net→ResU-Net; (d) This article is online.

真实断层样本所占的百分比.Dice 系数(又称 F1-score)是精确率与召回率的调和平均,用于综合评价两类性能的平衡性,模型整体性能越好其值越接近 1.交并比(Intersectionover Union,IoU)通常用面积来表示,分子是断层和预测为断层的样本数量交集,即 TP;分母是断层和预测为断层的样本数量并集,即 FP、TP 和 FN.断层重叠面积越大越接近 1,识别效果也就越好.

表 1 评价指标及其符号和计算公式

Table 1 Evaluation metrics, symbols, and calculation formulas

指标	符号	计算公式
准确率	ACC	$ACC=\frac{TP+TN}{TP+TN+FP+FN}$
精度	P	$P=\frac{TP}{TP+FP}$
召回率	R	$R=\frac{TP}{TP+FN}$
Dice 系数	Dice	$Dice=\frac{2TP}{2TP+FP+FN}$
交并比	IoU	$IoU=\frac{TP}{TP+FP+FN}$

为了验证本文模型的优化效果,将 ResU-Net 网络、加入 ASPP 和 CBAM 模块的 ResU-Net 网络、本文网络,分别应用于未经训练的测试集中,并分析其断层预测结果.表 2 展示了三种模型在测试集上的评价指标结果.根据表 2 的数据,本文模型的评价指标结果要优于 ResU-Net 模型和加入 ASPP 和 CBAM 模块的 ResU-Net,最主要的指标 Dice 和 IOU 分别提高到 0.922 和 0.856.

表 2 三种不同模型在测试集上的评价指标

Table 2 Evaluation metrics of three different models on the test set

模型类型	ACC	R	P	Dice	IoU
ResU-Net	0.971	0.829	0.791	0.809	0.682
ResU-Net + CBAM + ASPP	0.988	0.948	0.834	0.888	0.798
本文网络	0.988	0.958	0.911	0.922	0.856

3.4 模型检验

如图 7 所示为制作的合成地震记录和对应的标签,低序级断层,有利于后续模型性能检验.

分别使用三个不同网络对带标签的非训练地震合成记录进行断层预测检验其预测性能,只保留和显示断层预测概率大于 90% 的结果,如图 8 所示.

图 9 为剖面图,可看出 ResU-Net 网络断点和伪影较多(黄色标出),连续性不及本文网络;同时本文网络与标签最一致,证明该改进网络可以极大地提高感受野、特征提取能力,断层预测的准确性和连续性都有提高,接下来对两个网络以及本文改进网络在实际工区预测结果进行比较.

4 实际资料应用

4.1 迁移学习

由于预训练的合成数据和实际地震资料断层存在差异,且实际数据受噪声干扰影响,难以发挥模型完整性能,所以在预训练模型基础上进行迁移学习能够解决这种差异,改善模型性能.迁移学习(Transfer Learning)能使一个模型经过训练后,将学到的特征、参数或结构信息应用到目标领域中,从而减少目标任务对大量标注数据的依赖,并提高模型的泛化能力.针对实际工区断裂需重新建立人工标签进行迁移学习,需要涵盖工区不同断层特征,本文在 Es21-Es26 层段分层设置人工标签,同时基于相干体属性和工区概况根据经验给出例如图 10b 对应的人工标签,图 10b 为人工标签,模型为本文改进模型(DCAS-UNet++ 3D).本文将人工解释标签分为训练集和验证集两部分,为了防止过拟合的情况,在训练时采用了交叉验证的训练方法.迁移学习使用的人工标签有一定的主观性,所以每次迁移学习后根据预测结果判断更新人工标签,补齐之前遗漏区域标签,然后输入到模型重新训练,不断更新模型,直到预测结果满足研究需求.

从图 10d 中第二次迁移学习结果可以发现图中黄色标记处断层预测效果有所提升,可见迁移学习能够使断层预测模型在不同地震数据上发挥其应有的性能.

4.2 数据体整体对比

为了更好的预测断层形态,解决常规方法断层预测不准确清晰的问题,如图 11 是利用三种不同深度学习网络得到的断层数据体和本文改进网络得到断层预测数据体.可以发现本文网络在实际三维地震数据中预测的细小断层更多且更细,与地层重合更少,更加符合断层的真实展布特征,能够更好地预测断层.

但是仅从整体的三维数据体上难以说明本文方法对断层预测的合理性和准确度,接下来将从主要井和油气富集区域的切片来验证本文方法在深度学

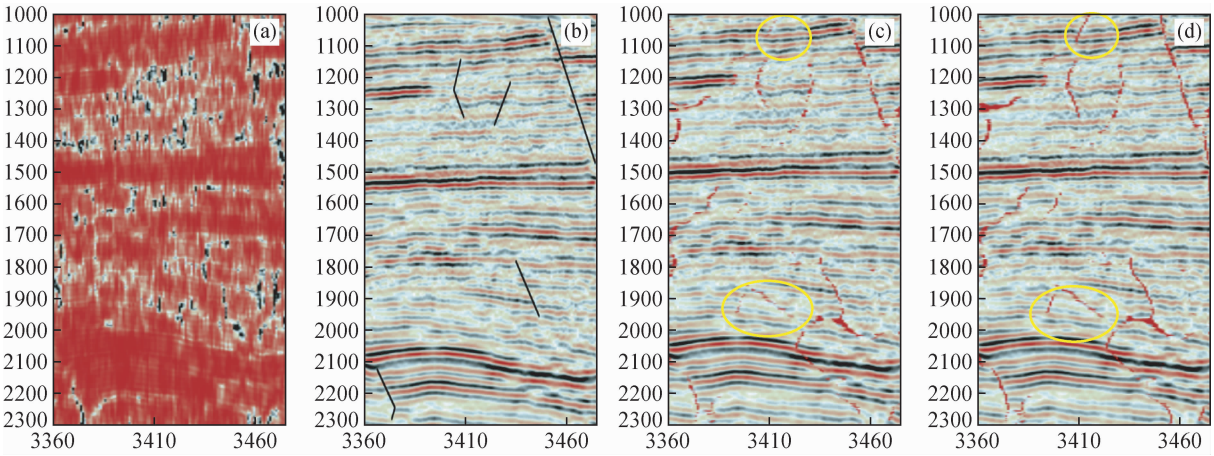


图 10　迁移学习

(a)相干数据体;(b)人工标签;(c)第一次迁移学习;(d)第二次迁移学习.

Fig. 10　Transfer learning

(a) Coherent data volume; (b) Manual labeling; (c) The first transfer learning; (d) Second transfer learning.

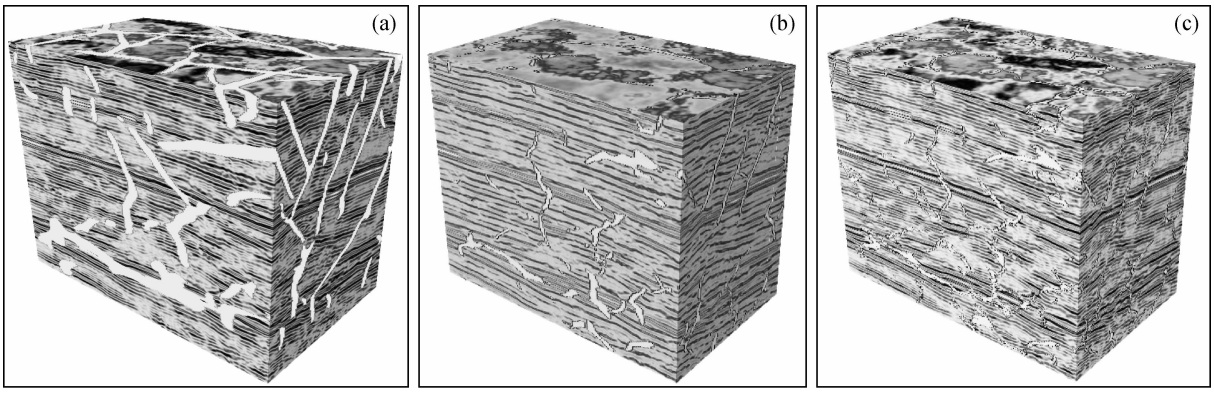


图 11　(a)ResU-Net 断层数据体;(b)ResU-Net + CBAM + ASPP 数据体;(c)本文方法数据体

Fig. 11　(a) ResU Net fault data volume; (b) ResU Net + CBM + ASPP dataset;
(c) This article presents the method data body

习断层预测上的实用性.

4.3　沿层切片和剖面对比

通过沿层切片和剖面对比可以发现,除本文网络外,其他两个模型在 Es25 层位的断层预测结果与相干属性和最大正曲率属性切片存在明显偏差,而本文所提出的改进模型,不仅能够准确提取薄层断层与次生孔隙带特征,其预测分布与相干切片在空间形态和油气富集区位置上高度一致,表明新方法有效结合了局部微弱断层信号与全局上下文信息,提升了模型对实测地震属性的契合度和解释可靠性.

图 12 为 Es25 断层预测的沿层切片比较. 从三个网络预测结果可以看到本文改进网络的预测结果更清晰,连续性更好,也能够预测出主干断裂和低序级断层.

提取过 T61-162 井 7634 主测线和过 T61 井 7749 主测线进行剖面对比分析. 粉色线段为 Es25 主要砂体储层区域,图 13a、d 为 7634 与 7749 主测线 ResU-Net 网络预测结果,图 13b、e 为 7634 与 7749 主测线 ResU-Net + CBAM + ASPP 预测结果,图 13c、f 为 7634 与 7749 主测线本文网络预测结果,从蓝色框选区域可以发现本文网络能够识别出其他网络无法识别的细小断裂信息且连续性更好.

4.4　断裂预测结果与油气关联性分析

将 ES25 断层预测结果与油气储层预测区域融合,可以发现断裂走向和油气区域整体一致性非常

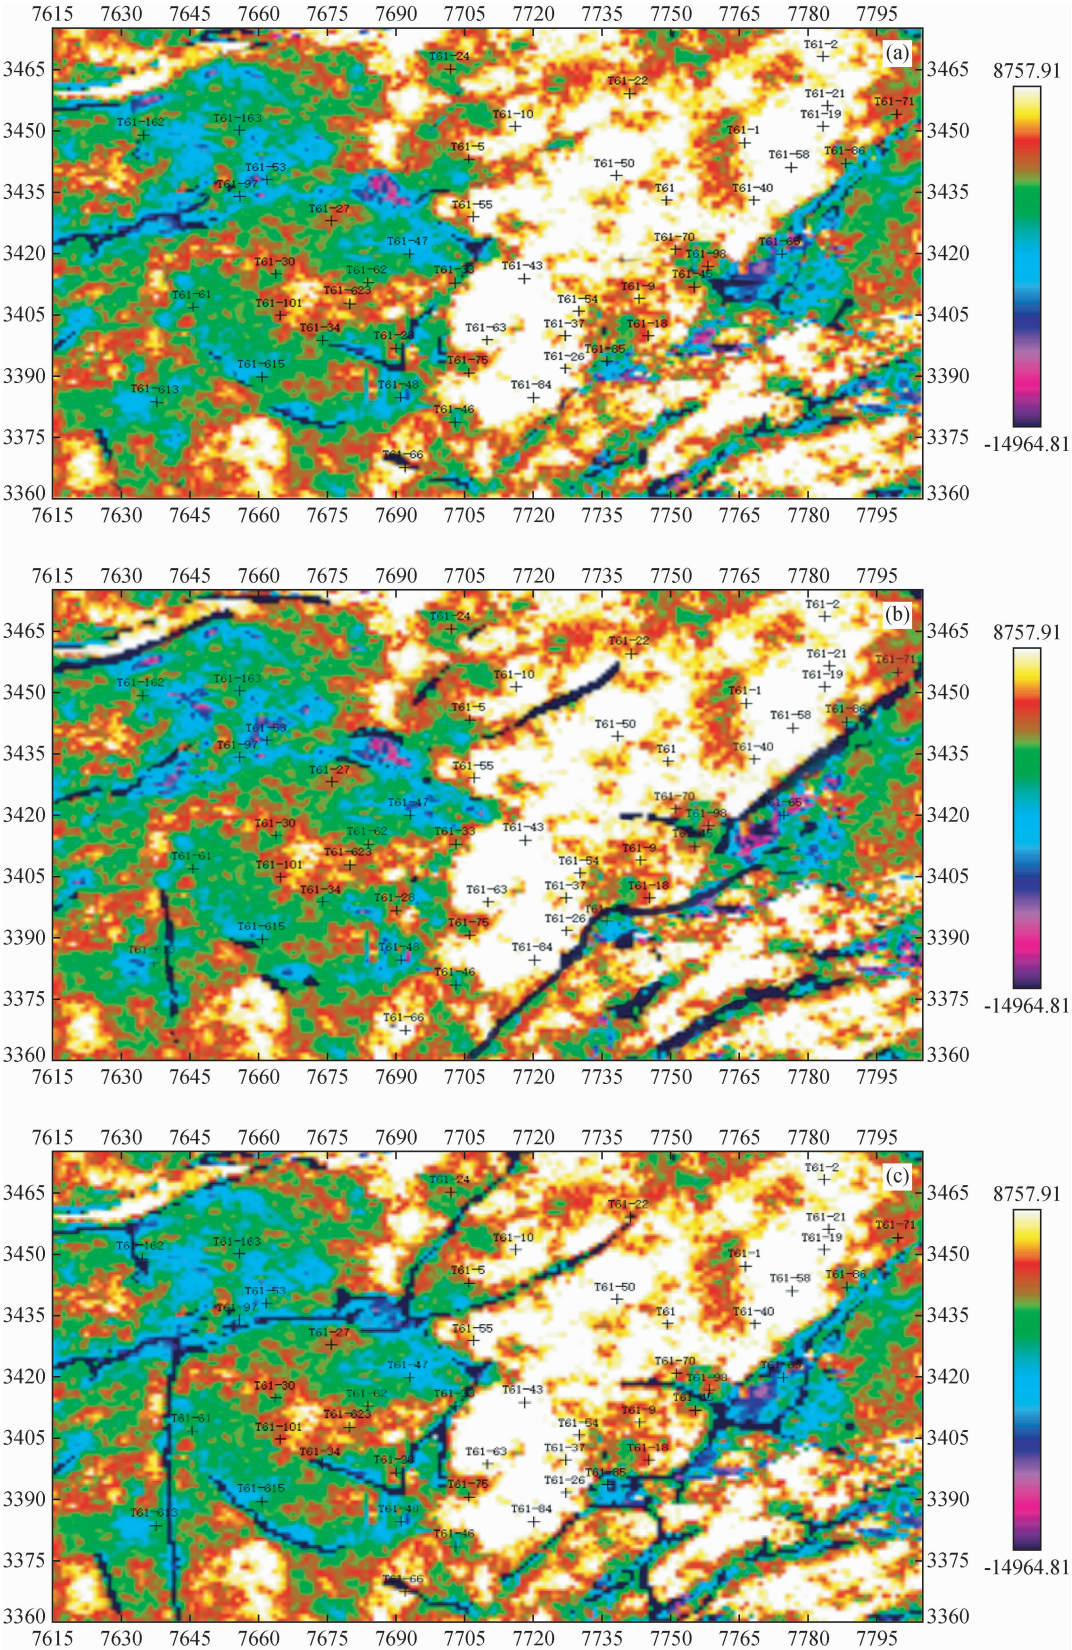


图 12 Es25 断层预测沿层切片比较

(a) ResU-Net 预测结果;(b) ResU-Net + CBAM + ASPP 网络预测结果;(c) 本文改进网络预测结果.

Fig. 12 Comparison of Es25 fault predictions on horizon slices

(a) ResU Net prediction results; (b) ResU Net + CBM + ASPP network prediction results; (c) This article improves the network prediction results.

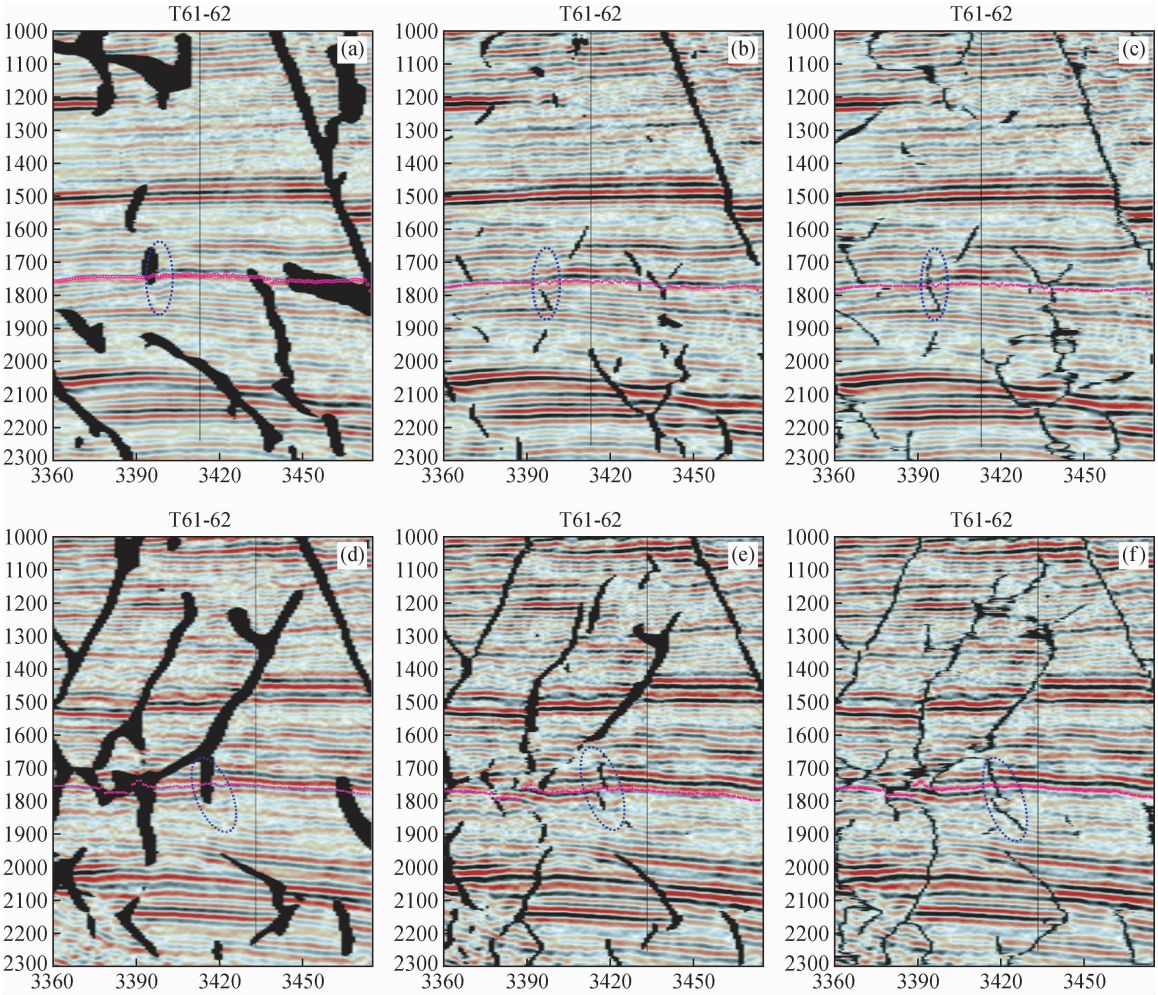


图 13　不同过井测线识别效果对比

(a) ResU-Net 预测结果;(b) ResU-Net + CBAM + ASPP 预测结果;(c) 本文改进网络预测结果;(d) ResU-Net 预测结果;(e) ResU-Net + CBAM + ASPP 预测结果;(f) 本文改进网络预测结果.

Fig. 13　Recognition effect comparison for the different inlines crossing wells

(a) ResU Net prediction results; (b) ResU Net + CBM + ASPP prediction results; (c) This article improves the network prediction results; (d) ResU Net prediction results; (e) ResU Net + CBM + ASPP prediction results; (f) This article improves the network prediction results.

好. 图 14 还给出了过 T61-162 井的细小断裂分析(左上黄色框选区域),以及 T61-62 井圈闭、T61 井断裂发育区的断裂预测井震关系,说明本方法能预测出其他网络无法预测出的小微断层,为精细勘探开发提供支持.

5　结论与认识

5.1　本文方法的优势

(1)将基于 DCNv2 改进后的 DenseASPP 模块、CBAM 模块加入到 ResU-Net++ 网络,实现了自适应膨胀率下多尺度卷积密集连接,极大地扩大了网络的感受野,同时利用多层深度监督机制来提升解码端对断层边界细小部分的识别,并引入深度可分离卷积使得模型计算速度更快,效率更高,在薄层断层及复杂交错体系下也能实现在高精度断层识别的基础上模型计算量更小;实际应用中采用迁移学习的方法提高模型泛化能力,在噪声背景条件下发挥模型应有性能.

(2)在测试集上的定量评估结果表明,本方法在 Dice 系数和 IoU 等关键指标上,分别提升至 92.2% 和 85.6%,并在断层预测的连续性与细节完整性上表现最佳.

(3)本文改进模型对低序级断层预测效果有明显提升,合理预测出了油气区域细小断裂特征并依据断裂特征可进一步精细描述油气储集区域,展示了方法在油气精细勘探开发中的应用价值.

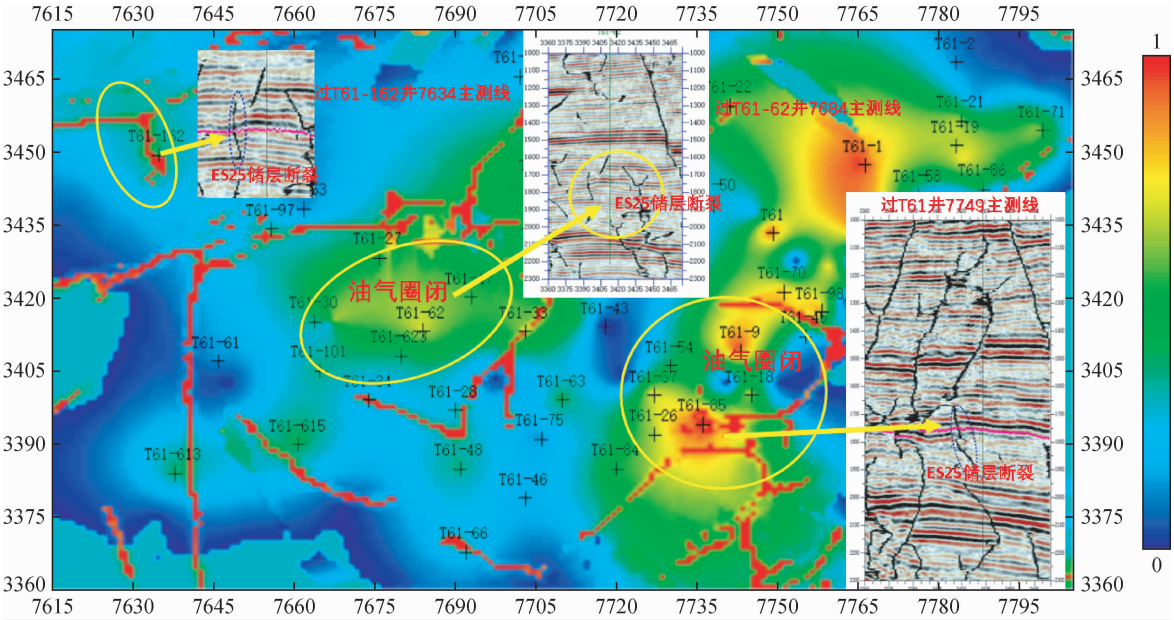


图 14 断裂预测与油气分布融合图

Fig. 14 Integrated map of fault and oil and gas distribution

5.2 存在的问题及改进方向

(1)迁移学习所用的人工标注具有较大的主观性,受到人的地质知识的影响,在低信噪比区断层预测网络容易出现过拟合问题,后续可以尝试使用相干属性或者其他特征属性代替人为的地球物理人工标签做弱监督来减小过拟合风险.

(2)可以继续利用 DCAS-UNet++ 3D 来加入 Transformer 的长距离上下文建模能力、RGT 等方法中相关的地质先验知识,提升断层预测的全局一致性、地质合理性和可解释性;结合地质认识评价预测结果的准确程度,进一步增强本文的科学性、合理性,为将来工程化应用提供研究依据.

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

Badrinarayanan V, Kendall A, Cipolla R. 2017. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(12): 2481-2495, doi: 10.1109/tpami.2016.2644615.

Bahorich M S, Farmer S L. 1995. 3-D seismic discontinuity for faults and stratigraphic features: the coherence cube. The Leading Edge, 14(10): 1053-1058, doi: 10.1190/1.1437077.

Bai G J, Zhao R M, Yang S L, *et al*. 2011. Seismic curvature attributes and their application to seismic interpretation. Engineering Sciences (in Chinese), 13(5): 23-27.

Chen F, Wu F, Xu J, *et al*. 2021. Adaptive deformable convolutional network. Neurocomputing, 453: 853-864, doi: 10.1016/j.neucom.2020.06.128.

Di H B, Li Z, Abubakar A. 2022. Using relative geologic time to constrain convolutional neural network-based seismic interpretation and property estimation. Geophysics, 87(2): IM25-IM35, doi: 10.1190/geo2021-0257.1.

Di X, Liu Y. 2025. Research progress of deep learning in seismic fault interpretation. Progress in Geophysics (in Chinese), 40(4): 1688-1716, doi: 10.6038/pg2025II0204.

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, doi: 10.1190/geo2020-0945.1.

Gersztenkorn A, Marfurt K J. 1999. Eigenstructure-based coherence computations as an aid to 3-D structural and stratigraphic mapping. Geophysics, 64(5): 1468-1479, doi: 10.1190/1.1444651.

He T, Liu N H, Wu B Y, *et al*. 2023. ResU-Net based three-dimensional fault identification method and application. Chinese Journal of Engineering Mathematics (in Chinese), 40(1): 1-19.

Huo Z Z, Liu X W, Mo L, *et al*. 2020. Application of high-precision structural curvature extracting on the structural interpretation of Jianghan-Qianjiang Depression. Geophysical Prospecting for Petroleum (in Chinese), 59(6): 961-969.

Kim S, Seol S J, Byun J, *et al*. 2022. Extraction of diffractions from seismic data using convolutional U-net and transfer learning. Geophysics, 87(2): V117-V129, doi: 10.1190/geo2020-0847.1.

Li F L, Wang J, Wang J, *et al*. 2026. Research and application of fault identification method based on four-channel deep supervised network. Progress in Geophysics (in Chinese), 41(1): 355-371, doi: 10.6038/pg2026HH0389.

Li J, Zhang J H, Liu Y, *et al*. 2019. Anisotropic diffusion edge-preserved filter based on image entropy and application in fault identification. Oil Geophysical Prospecting (in Chinese), 54(2): 365-370, doi: 10.13810/j.cnki.issn.1000-7210.2019.02.015.

Li N, Wang L Y, Huang S B, *et al*. 2019. 3Dseismic fine structural interpretation in complex fault zones based on the high-definition ant-tracking attribute volume. Oil Geophysical Prospecting (in Chinese), 54(1): 182-190, doi: 10.13810/j.cnki.issn.1000-7210.2019.01.021.

Li S R, Yang C C, Sun H, *et al*. 2019. Seismic fault detection using an encoder-decoder convolutional neural network with a small training set. Journal of Geophysics and Engineering, 16(1): 175-189, doi: 10.1093/jge/gxy015.

Liu X, Sun Z N, Han C, *et al*. 2021. Development and validation of the 3D U-Net algorithm for segmentation of pelvic lymph nodes on diffusion-weighted images. BMC Medical Imaging, 21(1): 170, doi: 10.1186/s12880-021-00703-3.

Liu Z, Hao M, Zhang W Z, *et al*. 2024. Optimizing depthwise separable convolution on DCU. CCF Transactions on High Performance Computing, 6(6): 646-664, doi: 10.1007/s42514-024-00200-3.

Lü J W, Zhang Y T, Guo J T, *et al*. 2024. Attention-based monocular depth estimation considering global and local information in remote sensing images. Remote Sensing, 16(3): 585, doi: 10.3390/rs16030585.

Pang Z J, Hu R M, Zhu W, *et al*. 2024. A building extraction method for high-resolution remote sensing images with multiple attentions and parallel encoders combining enhanced spectral information. Sensors, 24(3): 1006, doi: 10.3390/s24031006.

Park J, Woo S, Lee J Y, *et al*. 2020. A simple and light-weight attention module for convolutional neural networks. International Journal of Computer Vision, 128(4): 783-798, doi: 10.1007/s11263-019-01283-0.

Pochet A, Diniz P H B, Lopes H, *et al*. 2019. Seismic fault detection using convolutional neural networks trained on synthetic poststacked amplitude maps. IEEE Geoscience and Remote Sensing Letters, 16(3): 352-356, doi: 10.1109/lgrs.2018.2875836.

Tan G X, Jin Y Y. 2025. A semantic segmentation method for road sensing images based on an improved PIDNet model. Electronics, 14(5): 871, doi: 10.3390/electronics14050871.

Tang Z X, Wu B Y, Ma D B. 2024. Fault3DNnet: a lightweight 3D seismic fault detection network with bidirectional decoding. Geophysics, 89(6): IM91-IM103, doi: 10.1190/geo2023-0712.1.

Ushinsky A, Bardis M, Glavis-Bloom J, *et al*. 2021. A 3D-2D hybrid U-Net convolutional neural network approach to prostate organ segmentation of multiparametric MRI. American Journal of Roentgenology, 216(1): 111-116, doi: 10.2214/ajr.19.22168.

Wang J, Zhao Y, Gao G X. 2026. Automatic identification method for earthquake fault interpretation based on CBAM-UNet. Progress in Geophysics(in Chinese), 41(4): 1776-1785, doi: 10.6038/pg2026JJ0410.

Wang J, Zhang J H, Feng D Y, *et al*. 2020. Fault identification based on a discontinuous anisotropic diffusion filter. Oil Geophysical Prospecting (in Chinese), 55(6): 1349-1357, doi: 10.13810/j.cnki.issn.1000-7210.2020.06.020.

Wang J, Zhang J H, Lu F M, *et al*. 2021. Research on fault detection method based on 3D deeply supervised network. Oil Geophysical Prospecting (in Chinese), 56(5): 947-957, doi: 10.13810/j.cnki.issn.1000-7210.2021.05.002.

Wang Y H, Liang B X, Ding M, *et al*. 2019. Dense semantic labeling with atrous spatial pyramid pooling and decoder for high-resolution remote sensing imagery. Remote Sensing, 11(1): 20, doi: 10.3390/rs11010020.

Woo S, Park J, Lee J Y, *et al*. 2018. CBAM: Convolutional block attention module. //Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 3-19, doi: 10.1007/978-3-030-01234-2_1.

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, doi: 10.1190/geo2018-0646.1.

Xiong W, Ji X, Ma Y, *et al*. 2018. Seismic fault detection with convolutional neural network. Geophysics, 83(5): O97-O103, doi: 10.1190/geo2017-0666.1.

Xu Y, Hou S K, Wang X Y, *et al*. 2023. A medical image segmentation method based on improved UNet 3+ network. Diagnostics, 13(3): 576, doi: 10.3390/diagnostics13030576.

Yang W Y, Yang J R, Chen S Q, *et al*. 2021. Seismic data fault detection based on U-Net deep learning network. Oil Geophysical Prospecting (in Chinese), 56(4): 688-697, doi: 10.13810/j.cnki.issn.1000-7210.2021.04.002.

Zhang Y F, Feng W, Wu Z Y, *et al*. 2023. Deep-learning model of ResNet combined with CBAM for malignant-benign pulmonary nodules classification on computed tomography images. Medicina, 59(6): 1088, doi: 10.3390/medicina59061088.

Zhao L, Zhang H L, Sun X D, *et al*. 2024. Application of ResUNet-CBAM in thin-section image segmentation of rocks. Information, 15(12): 788, doi: 10.3390/info15120788.

Zhu X Z, Hu H, Lin S, *et al*. 2019. Deformable ConvNets V2: More deformable, better results. //2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 9300-9308, doi: 10.1109/CVPR.2019.00953.

附中文参考文献

柏冠军, 赵汝敏, 杨松岭, 等. 2011. 地震曲率技术在地震资料解释中的应用. 中国工程科学, 13(5): 23-27.

邸希, 刘洋. 2025. 深度学习在地震断层解释中的研究进展. 地球物理学进展, 40(4): 1688-1716, doi: 10.6038/pg2025II0204.

何涛, 刘乃豪, 吴帮玉, 等. 2023. 基于 ResU-Net 的三维断层识别方法及应用. 工程数学学报, 40(1): 1-19.

霍志周, 刘喜武, 莫莉, 等. 2020. 高精度结构曲率提取方法在潜江凹陷构造解释中的应用. 石油物探, 59(6): 961-969.

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): 355-371, doi: 10.6038/pg2026HH0389.

李军, 张军华, 刘杨, 等. 2019. 图像熵各向异性扩散保边滤波方法及在断层识别中的应用. 石油地球物理勘探, 54(2): 365-370, doi: 10.13810/j.cnki.issn.1000-7210.2019.02.015.

李楠, 王龙颖, 黄胜兵, 等. 2019. 利用高清蚂蚁体精细解释复杂断裂带. 石油地球物理勘探, 54(1): 182-190, doi: 10.13810/j.cnki.issn.1000-7210.2019.01.021.

王静, 张军华, 冯德永, 等. 2020. 利用不连续性的各向异性扩散滤波方法识别断层. 石油地球物理勘探, 55(6): 1349-1357, doi: 10.13810/j.cnki.issn.1000-7210.2020.06.020.

王静, 张军华, 芦凤明, 等. 2021. 构建三维深度监督网络的断层检测方法. 石油地球物理勘探, 56(5): 947-957, doi: 10.13810/j.cnki.issn.1000-7210.2021.05.002.

王俊, 赵岩, 高郭翔. 2026. 基于 CBAM-UNet 的地震断层解释自动识别方法. 地球物理学进展, 41(4): 1776-1785, doi: 10.6038/pg2026JJ0410

杨午阳, 杨佳润, 陈双全, 等. 2021. 基于 U-Net 深度学习网络的地震数据断层检测. 石油地球物理勘探, 56(4): 688-697, doi: 10.13810/j.cnki.issn.1000-7210.2021.04.002.