

基于改进 AlexNet 模型的断层识别方法

李辉

(成都理工大学 地球物理学院,四川 成都 610059)

摘要:从地震数据中识别断层在地震资料解释中至关重要,但随着勘探规模的扩大,传统的人工解释断层已满足不了实际生产需要。如何研究出一种能满足断层识别高精度需求并能提升运算速度的方法是急需解决的问题。为此,基于改进的 AlexNet 模型,把自动识别断层的方法看作图像识别二分类问题。首先将批量归一化代替局部响应归一化,加快模型收敛;其次引入平衡交叉熵损失,解决在地震数据中断层与非断层高度不平衡问题,使模型朝着正确的方向收敛;最后用卷积层代替全连接层,极大缩减了训练参数,加快了训练速度。训练的模型对理论数据和实际数据预测结果表明,改进的 AlexNet 模型充分学习了断层特征,具有可以从地震数据中识别断层的能力。

关键词:AlexNet 模型;断层识别;模式识别;批量归一化;平衡交叉熵损失

中图分类号:TE319

文献标识码:A

Fault recognition method based on improved AlexNet

LI Hui

(College of Geophysics, Chengdu University of Technology, Chengdu City, Sichuan Province, 610059, China)

Abstract: Fault recognition from seismic data is crucial to the seismic data interpretation, but with the expansion of exploration scale, the traditional artificial fault interpretation cannot meet the actual production needs. How to develop a high-precision fault recognition method and improve the operation speed of the method is an urgent problem for those skilled in the art. Therefore, an automatic fault recognition method based on the improved AlexNet model is proposed to treat fault recognition as binary classification of image recognition. First, instead of local response normalization (LRN), batch normalization is used to accelerate the model convergence. Then, the balanced cross entropy loss is introduced to solve the problem of unbalanced height between the fault and the non-fault in seismic data, which makes the model converge in the right direction. Finally, the convolution layer is adopted to replace the full connection layer, which greatly reduces the training parameters and speeds up the training. The prediction results of the theoretical data and actual data of the training model show that the improved AlexNet model fully learns the fault features and has the ability to identify faults from seismic data.

Key words: AlexNet model; fault recognition; pattern recognition; batch normalization; balanced cross entropy loss

断层识别在地震解释过程中起着至关重要的作用^[1-6]。人工识别断层的方法,易受人主观意识以及地震资料分辨率影响,断距较小的断层难以精确识别,通常在地震剖面上无法准确识别断距小于5 m的断层^[7-10]。通过方差体技术识别断层,尽可能减少了人为因素或其他外界因素对断层识别的影响,进一步提升了断层识别的精度,但也出现了一系列的问题,比如参与的运算量巨大,运算速度稍慢^[11]。参与运算的道数根据预测断层来确定,太多太少都会影响结果^[12]。因此,如何研究出一种能满

足断层识别高精度需求并能提升运算速度的方法是急需解决的问题^[13-16]。

近几年,卷积神经网络(Convolutional Neural Networks,简称CNN)在图像识别方面大放异彩^[17-19],由于卷积神经网络可以直接对二维图像进行处理,不需要在训练之前对图像进行复杂的预处理^[20],因此在图像处理方面得到了广泛的应用^[21],并取得了较多的研究成果。关于卷积模型的设置,目前较热门的模型包括LetNet-5, AlexNet, ZFNet, VGG-16, GoogLenet 和 ResNet 等。其中在2012年的

ImageNet 竞赛中, AlexNet 模型相对于使用传统的人工提取特征的方法, 错误率降低了将近 10%, 由此可以看出, AlexNet 模型在图像识别领域具有独特的优势^[22]。AlexNet 模型作为深度学习中的一种经典模型, 目前在图像分类任务中仍被大量使用^[23-24]。与其他大型模型相比, AlexNet 模型复杂度低、参数量少, 比轻量级模型深度深, 训练难度小, 表征能力强, 可以节省大量模型训练时间, 预测速度快。因此更适合于地震数据断层自动识别。

为此, 笔者提出一种基于改进的 AlexNet 模型自动识别断层的方法, 在经典的 AlexNet 模型基础上, 对其进行改进, 把断层识别看作是图像识别二分类问题, 断层识别为 1, 非断层识别为 0。

1 经典 AlexNet 模型

经典 AlexNet 模型分为上、下 2 部分, 分别利用 2 块 GPU 来提高运算效率, 共有 8 层深度神经网络, 其中包括 5 层卷积和 3 层全连接层, 不计激活层和池化层。

第 1 层: 输入尺寸为 $224 \times 224 \times 3$ 的图像, 卷积核数量为 96 个, 2 块 GPU 分别计算 48 个核; 卷积核尺寸 (kernel_size) 为 $11 \times 11 \times 3$; 步长 (stride) 为 4, 不扩充边缘; 经过卷积后的图像宽度和高度表达式分别为:

$$w = (224 + 2 \times \text{pad} - \text{kernel_size}) \text{stride} + 1 = 54 \quad (1)$$

$$h = (224 + 2 \times \text{pad} - \text{kernel_size}) \text{stride} + 1 = 54 \quad (2)$$

然后进行局部响应归一化 (Local Response Normalized, 简称 LRN), 接着进行池化作用, 池化尺寸 (pool_size) 为 3×3 , 步长为 2, 填充值 (pad) 为 0, 最终获得第 1 层卷积层的特征映射。

第 2 层: 输入为上一层卷积层的特征映射, 卷积核数量为 256 个, 2 块 GPU 分别有 128 个卷积核。卷积核尺寸为 $5 \times 5 \times 48$; 填充值为 2, 步长为 1; 然后做 LRN, 最后进行最大池化作用, 池化尺寸为 3×3 , 步长为 2。

第 3 层: 输入为第 2 层的输出, 卷积核数量为 384, 卷积核尺寸为 $3 \times 3 \times 256$, 填充值为 1, 不进行 LRN 和池化作用。

第 4 层: 输入为第 3 层的输出, 卷积核数量为 384, 卷积核尺寸为 3×3 , 填充值为 1, 和第 3 层一样, 不进行 LRN 和池化作用。

第 5 层: 输入为第 4 层的输出, 卷积核数量为 256, 卷积核尺寸为 3×3 , 填充值为 1。然后直接进行最大池化作用, 池化尺寸为 3×3 , 步长为 2。

第 6, 7 和 8 层为全连接层, 每一层的神经元数量为 4 096, 最终使用 Softmax 作为分类函数, 因为 ImageNet 比赛的分类数量为 1 000, 最后输出为 1 000。全连接层中使用 RELU 激活函数。

2 AlexNet 模型改进

考虑到经典 AlexNet 模型耗费的训练时间较长, 为了进一步提升识别精度, 笔者对此模型做出了以下改进。

2.1 批量归一化

改进的模型分别使用 64 个和 32 个尺寸为 3×3 和 5×5 的卷积核, 保留最大池化层来减少模型大小, 提高计算精度, 同时提高所提取特征的鲁棒性。采用批量归一化 (BN) 层代替原来的 LRN 层。LRN 使得局部较大的响应值更大, 而小的会变得更小, 从而抑制了小的神经元, 增强了模型的泛化能力。在此基础上, BN 加快了模型收敛, 打乱了训练数据, 大大减少了训练时间。在每一层输入 x 时, 先做一个归一化处理 (归一化至均值为 0、方差为 1), 然后进入下一层。设输入 x 是 d 维, 对每一维进行归一化, 则:

$$\hat{x}^k = \frac{x^k - E[x^k]}{\sqrt{\text{Var}[x^k]}} \quad (3)$$

为使模型学习到更多断层的特征, 进行变换重构, 引入可学习参数, 也是该算法的关键, 可表示为:

$$y^k = \gamma^k \hat{x}^k + \delta^k \quad (4)$$

$$\gamma^k = \sqrt{\text{Var}[x^k]} \quad (5)$$

$$\delta^k = E[x^k] \quad (6)$$

在训练过程中除了正常的前向传播和方向求导之外, 还要记录每一个批量的均值和方差, 以便训练完成之后计算整个数据集的均值和方差。所以, 均值和方差不再是某一个批量, 而是整个数据集。

2.2 引入 Sigmoid 和平衡交叉熵损失函数

考虑到地震数据识别断层是一个二分类问题, 即断层和非断层, 所以在模型最后一层采用 Sigmoid 替代 Softmax 作为分类函数, 同时将平衡交叉熵损失作为损失函数。Sigmoid 函数是针对两点分布提出的, 神经模型的输出经过转换, 可以将数值压缩至 $(0, 1)$, 得到的结果可以理解为分类目标类别的概率为 P , 而不分类该目标类别的概率为 $1-P$, 这也是

典型的两点分布的形式。Sigmoid 函数公式为：

$$S(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

二分类交叉熵损失在二值分类问题研究中被广泛应用,该函数在平常的图像二值分类问题中有着较好的效果,因为在普通的图像中,零和非零样本的分布或多或少是均衡的,但在断层识别问题中,因为在一张地震数据图像中,断层和非断层高度不平衡,如果在断层识别问题中使用此损失函数训练模型,易造成模型朝着错误的方向收敛,容易将预测结果判定为非断层,从而误判率较高。在此基础上,引入平衡交叉熵损失来解决样本的高度不平衡问题。主要是通过增加惩罚系数,对数量少的类别增加权重,对数量多的类别减少权重,以减少样本之间的不平衡。从而使模型朝着正确的方向收敛。

平衡交叉熵损失公式为：

$$L = -\beta \sum_{i=0}^{i=N} y_i \log P_i - (1 - \beta) \sum_{i=0}^{i=N} y_i \log (1 - P_i) \quad (8)$$

其中：

$$\beta = ml(m + n) \quad (9)$$

2.3 1×1 卷积层代替全连接层

在模型中使用全连接层存储开销大且计算效率低下。为了进一步减少模型的计算量,将最后的3层全连接层用1×1的卷积层替代,在很大程度上减少了神经网络的参数,让模型更易训练。同时因为全连接层的输入尺寸是固定的,替换全连接层为卷积层之后,对于输入图片的大小是没有任何限制的,大图小图一样都经过卷积池化激活。因为卷积核的参数个数与图像大小无关。而且全连接层会破坏图像的空间结构,而使用1×1卷积层替代全连接层后,不会破坏图像的空间结构。

3 神经网络训练

3.1 数据增强

神经网络训练结果很大程度上取决于训练数据,考虑到实际数据中可能有其他的地质特征影响神经模型对断层的识别,同时,在对实际数据标签的过程中依赖人的主观判断,一方面工作量巨大,另一方面可能产生错误的识别标签。所以,本文采用的训练数据集是人工合成理论数据集,此数据集包含200个样本的三维训练数据集和20个样本的三维测试数据集。因为训练需要输入二维数据,所以对每个样本进行垂直切片,从每个三维数据体中

获得一个二维数据。由于训练样本的数据有限,容易使模型过拟合,从而影响识别效果,为了增强样本的多样性,包含更多类别的地震断层,增加样本数量,对数据采取了水平翻转、垂直翻转和水平、垂直同时翻转处理。考虑到旋转会产生垂直和水平断层,从而导致断层和层位的区别不清楚,且这也不符合地质规律,故未对数据进行旋转处理,仅进行翻转。由N30°W走向的断层,通过数据增强,可以得到N30°E,S30°E,S30°W走向的断层。由原始数据(图1a)可以看出,断层的模式比较单一,经过数据增强后(图1b,1c,1d),训练数据可以包含更多的断层模型,增加了样本数量。

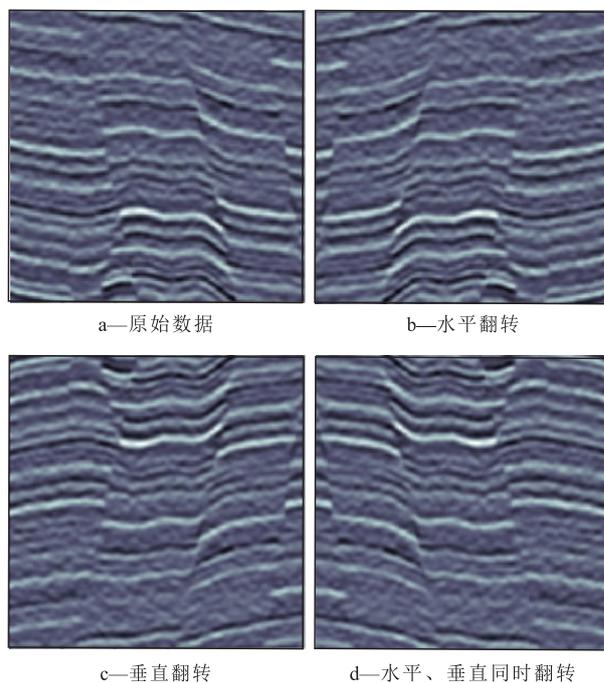


图1 数据增强

Fig.1 Data enhancement

原始理论地震数据(图2a)没有噪声的干扰,但实际的地震数据都会存在一定的噪音,如果直接用其训练可能会使得模型预测理论地震数据效果较好,但对于实际数据效果可能不理想。为了使理论数据尽可能的接近实际数据,同时进一步扩大数据量,在理论数据的基础上,加入方差为0.005的高斯噪声的理论地震数据(图2b),噪声较少。加入方差为0.05的高斯噪声的理论地震数据(图2c),噪声比较多。加入噪声数据后更加接近真实数据,使得训练更充分,更能从地震数据中学习断层特征。

3.2 输入数据训练

分类任务中最常用的评估指标包括错误率、准确率、查准率、查全率、损失值等,笔者优选了准确率与损失值。损失函数的作用是用来衡量一组参

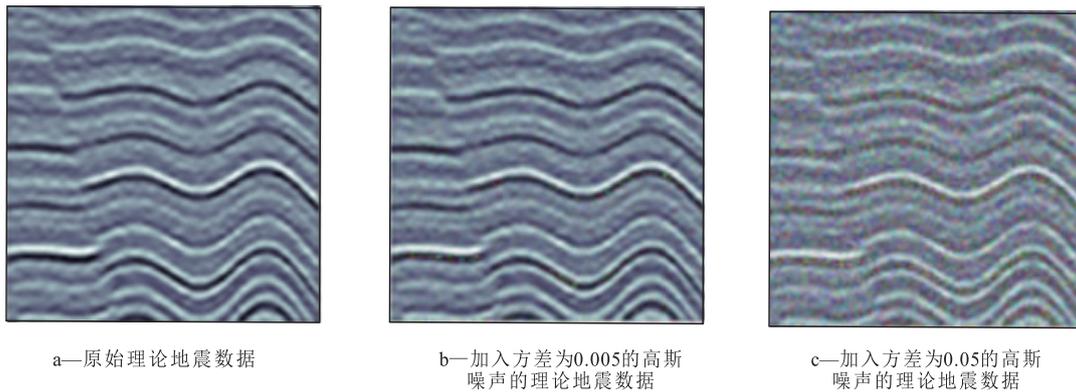


图2 原始理论地震数据与加入噪声后的理论地震数据
Fig.2 Theoretical seismic data before and after adding noise

数好坏,其衡量方式是比较模型输出和真实输出的差异。损失函数在模型的最后一层接收两个参数作为输入值,一个是模型预测结果,一个是真实断层标签。损失函数是在前向传播计算中得到的,同时也被作为反向传播的起点。损失函数并不使用测试数据来衡量模型的性能,而是用来指导训练过程,使得模型的参数向损失值降低的方向改变。当模型的计算预测断层结果和真实断层标签一致时,损失值为0,预测断层结果和真实断层标签越不一致时值越大。从模型准确率曲线和模型损失值曲线(图3,图4)可以看出,经过25次迭代训练之后,模型的准确率由85%增加至96.5%,损失值也由

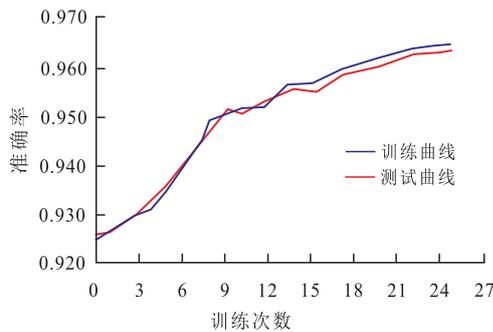


图3 模型准确率曲线
Fig.3 Accuracy curve of model

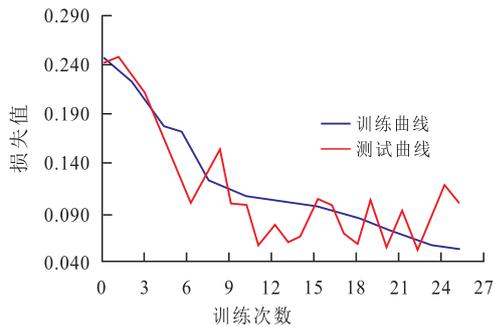


图4 模型损失值曲线
Fig.4 Loss value curve of model

0.21降至0.055,达到够接受的范围。

4 实例分析

优化前后模型的准确率、损失值和模型趋于稳定时的训练次数均有了很大的改进,优化后的模型比优化前准确率有了较大的提升,减少了训练时间,节约了资源。

优化前的模型将许多断层位置预测成了非断层(图5a),错误率较高。而优化后的模型在理论数据中表现良好,基本上识别出了断层位置(图5b),具有从理论地震数据中识别断层的能力,证实该模型所做优化的有效性。

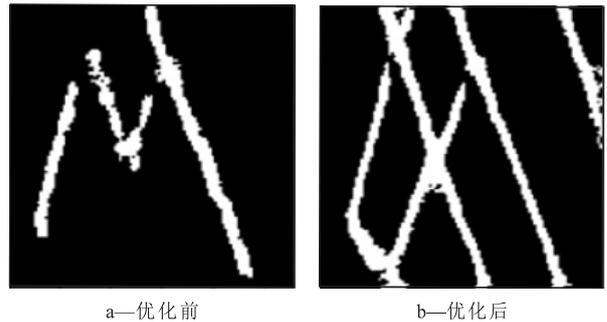


图5 理论数据预测结果(白色为断层位置)
Fig.5 Prediction results of theoretical data (white refers to fault locations)

为进一步验证模型的泛化能力,使用实际地震剖面进行测试。实际地震剖面具有更复杂的地质构造,且存在各种噪音,对于模型的泛化能力与抗噪能力产生较大考验。从实际地震剖面及断层预测结果(图6)可以看出,该模型较好地预测了断层位置,验证了模型的泛化能力。此外,实际地震剖面中有一定噪声,预测结果也证实了此模型具有一定抗噪能力。

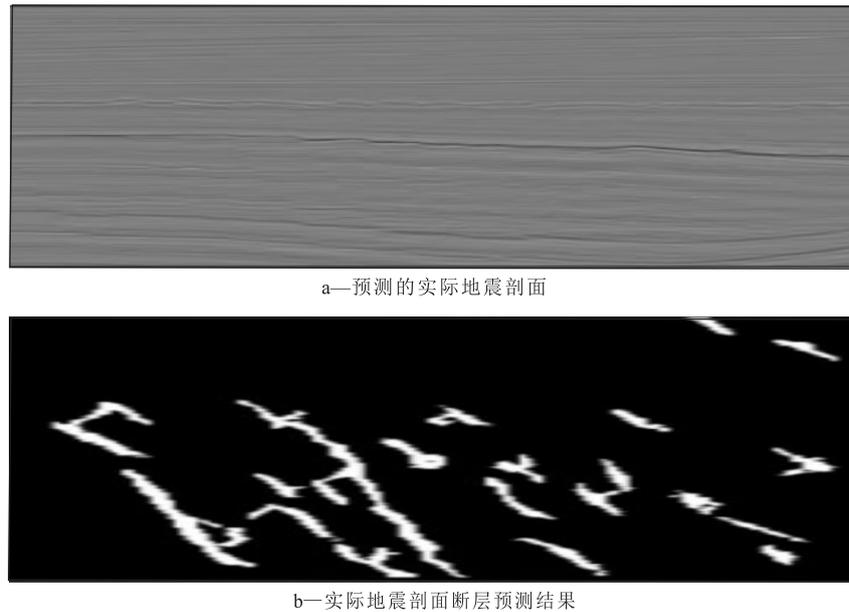


图6 实际地震剖面与断层预测结果(白色为断层位置)

Fig.6 Prediction results of actual seismic profile and faults(white refers to fault locations)

5 结束语

随着地震数据采集的规模不断扩大,从地震数据中精确地识别断层变得越来越困难。基于改进的 AlexNet 模型,实现了对地震数据断层的自动识别。将批量归一化代替 LRN, BN 能够加快模型收敛,打乱训练数据,大大减少了训练的时间。为解决地震数据正负样本(断层与非断层)数量高度不平衡问题,引入了平衡交叉熵损失函数,平衡了正负样本权重,使模型朝着正确的方向收敛。最后用卷积层代替全连接层,极大缩减了训练参数,加快了训练速度。优化后的模型 25 次迭代后,准确率和损失值均达到能够接受的范围。使自动识别断层的能力得到较大提高。

从整体上看,本文训练采用的理论数据,是否可以采用实际数据来训练模型,采用实际数据训练的模型能否提升预测精度,是否存在更好的模型结构、模型参数,以及模型性能能否提升等,仍需不断探索与尝试。

符号解释

- d ——输入数据的维度;
- E ——均值运算;
- h ——卷积后图像的高度;
- i ——地震剖面中第 i 个像素点;
- k ——在 d 维输入数据 x 中的第 k 维;

- L ——平衡交叉熵损失值;
- m ——地震剖面中断层的像素点数;
- n ——地震剖面中非断层的像素点数;
- N ——地震剖面的总像素点数;
- P ——分类正确的概率;
- P_i ——地震剖面中第 i 个像素点为断层的概率;
- $S(x)$ —— x 经过 Sigmoid 函数转换后的值;
- Var——方差运算;
- w ——卷积后图像的宽度;
- x —— d 维的输入数据;
- x^k ——在 d 维输入数据 x 中第 k 维的数据;
- \hat{x}^k —— x^k 归一化后的数据;
- y_i ——第 i 个像素点的标签值;
- y^k ——第 k 维数据的线性变换;
- β ——惩罚系数,表示地震剖面中断层像素点个数占总像素点的比例;
- γ, δ ——学习参数;
- γ^k ——第 k 维数据的方差开根号;
- δ^k ——第 k 维数据的均值。

参考文献

- [1] 李玲,冯许魁.用地震相干数据体进行断层自动解释[J].石油地球物理勘探,1998,33(增刊1):105-111.
LI Ling, FENG Xukui. Automatic fault interpretation using seismic coherence data volume [J]. Oil Geophysical Prospecting, 1998, 33(Supplement1):105-111.
- [2] SOLIVA R, BENEDICTO A.A linkage criterion for segmented normal faults[J].Journal of Structural Geology, 2004, 26(12): 2 251-2 267.

- [3] TINGDAHL K M, DE ROOIJ M. Semi-automatic detection of faults in 3D seismic data [J]. *Geophysical Prospecting*, 2005, 53 (4): 533-542.
- [4] 方芹. 微断层发育特征及封闭性评价——以塔河IX区下油组油藏为例[J]. *大庆石油地质与开发*, 2020, 39(5): 40-50.
FANG Qin. Development characteristics and its sealing evaluation for the micro-fault: A case study of Lower Oil Group in Block IX of Tahe Oilfield [J]. *Petroleum Geology & Oilfield Development in Daqing*, 2020, 39(5): 40-50.
- [5] 柳永军, 赵弟江, 李正宇, 等. 走滑-伸展断裂叠合特征及其控藏作用[J]. *特种油气藏*, 2019, 26(2): 45-51.
LIU Yongjun, ZHAO Dijiang, LI Zhengyu, et al. The superposition patterns of strike-slip-extension faults and its effects on hydrocarbon accumulation [J]. *Special Oil & Gas Reservoirs*, 2019, 26 (2): 45-51.
- [6] 彭光荣, 张向涛, 许新明, 等. 南海北部珠江口盆地阳江凹陷油气勘探重要发现与认识[J]. *中国石油勘探*, 2019, 24(3): 267-279.
PENG Guangrong, ZHANG Xiangtao, XU Xinming, et al. Important discoveries and understandings of oil and gas exploration in Yangjiang sag of the Pearl River Mouth Basin, northern South China Sea [J]. *China Petroleum Exploration*, 2019, 24(3): 267-279.
- [7] GERSZTWNKORN A, MARFURT K J. Eigenstructure-based coherence computations as an aid to 3-D structural and stratigraphic mapping [J]. *Geophysics*, 1999, 64(5): 1 468-1 479.
- [8] LAVIALLE O, POP S, GERMAIN C, et al. Seismic fault preserving diffusion [J]. *Journal of Applied Geophysics*, 2006, 61 (2): 132-141.
- [9] ASHRAF H, MOUSA W A, AI DOSSARY S. Sobel filter for edge detection of hexagonally sampled 3D seismic data [J]. *Geophysics*, 2016, 81(6): 41-51.
- [10] 左宗鑫, 陆建林, 王苗, 等. 松辽盆地长岭断陷断层特征及其控油气作用[J]. *石油实验地质*, 2019, 41(2): 200-206.
ZUO Zongxin, LU Jianlin, WANG Miao, et al. Fault characteristics and controls on hydrocarbon accumulation in Changling Faulted Depression, Songliao Basin [J]. *Petroleum Geology & Experiment*, 2019, 41(2): 200-206.
- [11] 王洪宇, 陈沫, 孟令东. 塔木察格盆地反向断层与反转断层控藏机理[J]. *油气地质与采收率*, 2020, 27(2): 72-79.
WANG Hongyu, CHEN Mo, MENG Lingdong. Controlling mechanism of antithetic fault and reverse fault on hydrocarbon accumulations in Tamsag Basin [J]. *Petroleum Geology and Recovery Efficiency*, 2020, 27(2): 72-79.
- [12] HUS R, ACOCELLAB V, FUNICIELLO R, et al. Sandbox models of relay ramp structure and evolution [J]. *Journal of Structural Geology*, 2005, 27(3): 459-473.
- [13] WU X M, HALE D. 3D seismic image processing for faults [J]. *Geophysics*, 2016, 81(2): 1-11.
- [14] WU X M, HALE D. Automatically interpreting all faults, unconformities, and horizons from 3D seismic images [J]. *Interpretation*, 2016, 4(2): 227-237.
- [15] 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): 35-45.
- [16] 刘巍, 刘威, 谷建伟, 等. 利用卡尔曼滤波和人工神经网络相结合的油藏井间连通性研究[J]. *油气地质与采收率*, 2020, 27 (2): 118-124.
LIU Wei, LIU Wei, GU Jianwei, et al. Research on interwell connectivity of oil reservoirs based on Kalman filter and artificial neural network [J]. *Petroleum Geology and Recovery Efficiency*, 2020, 27(2): 118-124.
- [17] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1 229-1 251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural networks [J]. *Chinese Journal of Computers*, 2017, 40(6): 1 229-1 251.
- [18] 青晨, 禹晶, 肖创柏, 等. 深度卷积神经网络图像语义分割研究进展[J]. *中国图像图形学报*, 2020, 25(6): 1 069-1 090.
QING Chen, YU Jing, XIAO Chuangbai, et al. Deep convolutional neural network for semantic image segmentation [J]. *Journal of Image and Graphics*, 2020, 25(6): 1 069-1 090.
- [19] 覃晓, 黄呈铨, 施宇, 等. 基于卷积神经网络的图像分类研究进展[J]. *广西科学*, 2020, 27(6): 587-599.
QIN Xiao, HUANG Chengcheng, SHI Yu, et al. Research progress of image classification based on convolutional neural network [J]. *Guangxi Sciences*, 2020, 27(6): 587-599.
- [20] 胡正平, 郭增洁, 王蒙, 等. 基于深度卷积神经网络 End-to-End 模型的亲属关系认证算法[J]. *模式识别与人工智能*, 2018, 31 (6): 554-561.
HU Zhengping, GUO Zengjie, WANG Meng, et al. Kinship verification based on deep convolutional neural network end-to-end model [J]. *Pattern Recognition and Artificial Intelligence*, 2018, 31(6): 554-561.
- [21] 吴帅, 徐勇, 赵东宁. 基于深度卷积网络的目标检测综述[J]. *模式识别与人工智能*, 2018, 31(4): 335-346.
WU Shuai, XU Yong, ZHAO Dongning. Survey of object detection based on deep convolutional network [J]. *Pattern Recognition and Artificial Intelligence*, 2018, 31(4): 335-346.
- [22] 任楚岚, 孙佳楠, 张阳. 基于 AlexNet 的注意力机制网络研究 [J]. *网络安全技术与应用*, 2021, 18(1): 16-18.
REN Chulan, SUN Jianan, ZHANG Yang. Research on attention mechanism network based on Alexnet [J]. *Network Security Technology and Application*, 2021, 18(1): 16-18.
- [23] 任意平, 夏国强, 李俊丽. 基于优化 AlexNet 的花卉识别[J]. *电子测量技术*, 2020, 43(19): 94-98.
REN Yiping, XIA Guoqiang, LI Junli. Flower recognition based on optimized alexnet [J]. *Electronic Measurement Technology*, 2020, 43(19): 94-98.
- [24] 杨旭, 尚振宏. 基于改进 AlexNet 的人脸表情识别[J]. *激光与光电子学进展*, 2020, 57(14): 235-242.
YANG Xu, SHANG Zhenhong. Facial expression recognition based on improved Alexnet [J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 235-242.