

石油地球物理勘探
Oil Geophysical Prospecting
ISSN 1000-7210, CN 13-1095/TE

《石油地球物理勘探》网络首发论文

题目：面向地震波初至智能拾取的超分辨率深度残差方法研究
作者：李建平，张硕伟，丁仁伟，麻晓敏，赵俐红，赵硕
DOI：10.13810/j.cnki.issn.1000-7210.2023.02.002
收稿日期：2022-05-09
网络首发日期：2022-12-12
引用格式：李建平，张硕伟，丁仁伟，麻晓敏，赵俐红，赵硕. 面向地震波初至智能拾取的超分辨率深度残差方法研究[J/OL]. 石油地球物理勘探.
<https://doi.org/10.13810/j.cnki.issn.1000-7210.2023.02.002>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

面向地震波初至智能拾取的超分辨率深度残差方法研究

李建平^{1,2}，张硕伟¹，丁仁伟^{*1,3}，麻晓敏¹，赵俐红^{1,3}，赵硕¹

(1. 山东科技大学地球科学与工程学院，山东青岛 266590；2. 山东省物化探勘查院，山东济南 221116；3. 青岛海洋科学与技术国家实验室海洋矿产资源评价与探测技术功能实验室，山东青岛 266237)

摘要 针对常规语义分割网络在初至拾取中存在精度低、泛化能力差等问题，基于 U-Net 网络，结合残差学习模块和亚像素卷积方法，构建了一种超分辨率深度残差网络的初至智能拾取方法 (SD-Net)。该方法使用具有跳跃连接的 U 型网络融合地震数据的多尺度信息，端到端的训练方式简化工作。首先，在 SD-Net 的下采样阶段引入残差学习模块，克服深层网络退化问题，有效提高对地震数据的学习能力；其次，上采样阶段采用亚像素卷积方法，通过卷积和多通道间像素重组实现特征图超分辨率重建，更高精度定位初至；另外，利用迁移学习将模型应用于中、低信噪比模拟数据，仅需少量标注数据即可训练得到最优初至拾取模型。实际算例表明：与 U-Net 方法相比，SD-Net 训练效率明显提高；网络模型具有更高准确率和鲁棒性；迁移学习模型预测的结果验证了 SD-Net 具有较强的泛化能力；该方法对实际生产中实现高效、准确的初至智能拾取具有重要意义。

关键词：初至拾取，U-Net，残差学习模块，亚像素卷积方法，SD-Net，迁移学习

中图分类号：P631 文献标识码：A doi: 10.13810/j.cnki.issn.1000-7210.2023.02.002

Research on depth residuals of super-resolution for seismic wave first arrival intelligent pickup

LI Jianping^{1,2}, ZHANG Shuwei¹, DING Renwei^{*1,3}, MA Xiaomin¹, ZHAO Lihong^{1,3}, ZHAO Shuo¹

(1. College of Earth Sciences and Engineering, Shandong University of Science and Technology, Qingdao, Shandong 266590, China; 2. Shandong Institute of Geophysical & Geochemical Exploration, Jinan, Shandong 221116, China; 3. Functional Laboratory of Marine Mineral Resources Evaluation and Exploration Technology, Qingdao National Laboratory of Marine Science and Technology, Qingdao, Shandong 266237, China)

Abstract Aiming at the problems of low precision and poor generalization ability in the first arrival pickup of conventional semantic segmentation networks, a novel first arrival intelligent pickup method (SD-Net) based on a U-Net network, combined with residual learning module and subpixel convolution method, is proposed. This method uses a U-shaped network with a jump connection to fuse multi-scale information of seismic data and simplifies the complexity of the work through end-to-end training. Firstly, the residual learning module is introduced in the subsampling stage of SD-Net to overcome the deep network degradation problem and effectively improve the learning ability of seismic data. Secondly, the subpixel convolution method is used in the up-sampling stage to achieve the super-resolution reconstruction of the feature map through convolution and multi-channel pixel recombination, and the positioning with higher accuracy is achieved. In addition, transfer learning is used to apply the model to the simulation data of medium and low SNR, and only a small amount of labeled data can be trained to obtain the optimal initial pick-up model. Practical examples show that the training efficiency of SD-Net is improved compared with the U-Net method. The network model has

*山东省青岛市黄岛区前湾港路 579 号山东科技大学地球科学与工程学院，266590。Email:dingrenwei@126.com

本文于 2022 年 5 月 9 日收到，最终修改稿于同年 12 月 1 日收到。

本研究受山东省自然科学基金项目“基于混合模型深度神经网络的多波地震油气藏特征提取与识别”（ZR202103050722）资助。

higher accuracy and robustness. The results predicted by the transfer learning model prove that SD-Net has a strong generalization ability. This method is of great significance for realizing efficient and accurate initial intelligent pickup in actual production.

Keywords: first-arrival,U-Net,deep residual module,sub-pixel convolution,SD-Net,transfer learning

李建平,张硕伟,丁仁伟,等. 面向地震波初至智能拾取的超分辨率深度残差方法研究[J].石油地球物理勘探,2023,58(2).

LI Jianping, ZHANG Shuwei, DING Renwei, et al. Research on depth residuals of super-resolution for seismic wave first arrival intelligent pickup[J]. Oil Geophysical Prospecting, 2023, 58(2).

0 引言

初至拾取质量直接影响后续折射波静校正^[1]、垂直地震剖面解释和地震层析成像^[2-3]等工作的效果。随着地震采集技术的提高及勘探地形的日益复杂,地震资料数据量巨大且信号复杂度较高。传统的初至自动拾取方法对中、低信噪比数据的拾取准确率和精度不高,需大量的人工操作进行调整,耗时耗力、效率低下。因此,对于海量的中、低信噪比数据,亟需找出一种能够同时满足工业化精度标准和效率标准的初至智能拾取方法。

传统的初至拾取方法主要有人工手动拾取和算法自动拾取两种。人工手动拾取方法主要根据工作人员的经验手动标记初至位置,主观性强、一致性差、效率低下^[4];算法自动拾取是根据波形在能量、频率等方面的不同特征进行识别,常用方法有能量比值法^[5-6]、相关法^[7-8]、图像处理法^[9-10]、神经网络法^[11-12]等。这些方法大多是基于单道数据的拾取方法,缺少考虑多道数据之间的相关性,因此对于信噪比较低的地震数据拾取效果不佳。

目前深度学习技术发展迅速,并广泛应用于地震勘探领域^[13-17]。初至拾取原理上可看作是一个二分类问题,高精度的初至拾取方法可结合计算机视觉中的语义分割技术对地震数据的每一个信号时刻进行分类,最终得到初至位置。目前,应用在初至拾取上的神经网络大多是以全卷积网络(Fully Convolutional Networks, FCN)^[18]、SegNet^[19]、U-Net^[20]等为基础进行改进的编码-解码结构^[21-22]。刘佳楠等^[23]提出的基于FCN的地震初至波拾取方法由于网络结构简单,拾取初至的精度有限。陈德武等^[24]提出基于混合网络U-SegNet的地震初至

自动拾取方法,融合了U-Net和SegNet两个网络结构,但为节约时间和内存,去掉通过学习参数上采样的反卷积操作,一定程度上降低了拾取的精度。潘英杰等^[25]提出一种基于地震图像深度语义分割的初至拾取方法,但该方法需先将数据转化为图像并对图像处理后,再转化为数据,过程繁琐,应用效率较低。

针对上述神经网络方法在地震资料初至拾取上存在精度和效率不足的问题,本文在充分分析U-Net结构后,结合残差学习模块及亚像素卷积方法,提出一种面向地震波初至智能拾取的超分辨率深度残差方法(简称SD-Net)。残差学习模块扩展网络深度并克服深层网络退化的问题,提升网络的学习能力以更好的学习目标特征;亚像素卷积方法通过卷积和多通道间的像素重组扩大特征图,实现特征图由低分辨率空间到超分辨率空间的转化,解决反卷积作为上采样运算效率和还原特征图精度低的问题;同时,具有长跳跃连接的编、解码结构结合浅层和深层的特征图,实现了不同尺度的特征融合。本文结合残差学习模块、亚像素卷积方法以及编、解码网络中长跳跃连接的各个优势,使网络具有更好的学习能力及更高的推理效率,另外,结合迁移学习,增强网络泛化能力,实现高精度、高效率、普适性的地震数据初至智能拾取。

1 方法原理

1.1 残差学习模块

神经网络的深度对模型的效果有至关重要的影响,增加神经网络的深度可提高网络的学习能力,使其更好的学习地震数据特征^[26-28]。但是,直接堆叠更多的层数会导致梯度弥散、梯度爆炸、网络退化等

问题，使网络出现更高的训练误差^[29]。

为解决深层网络性能下降的问题，He 等^[30]提出了残差学习模块。如图 1 所示，原始输入为 x ，期望得到的输出为 $F(x)+x$ ， x 经两个卷积层后，其中第一个卷积层后使用修正线性单元（Rectified Linear Unit, ReLU），输出 $F(x)$ ，同时右侧跳跃连接直接将输入的 x 传送给 $F(x)$ ，二者进行加法操作并经过 ReLU，最后的输出结果变为 $H(x)=F(x)+x$ ，而网络需要学习的映射函数由恒等映射函数转化为残差映射函数 $F(x)=H(x)-x$ 。

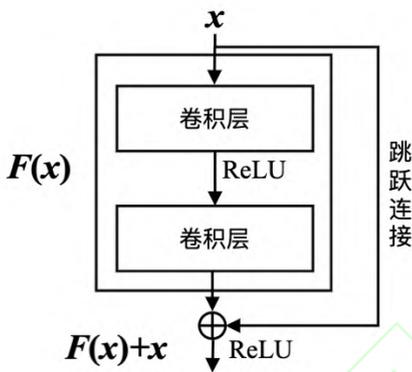


图 1 残差学习模块示意图

He 等^[30]指出，如果网络层数达到了最优深度，残差函数 $F(x)$ 将推理为 0，即通过残差学习后的输出与输入相同，从而变为恒等映射。残差学习方法解决了网络层数加深造成的梯度弥散、梯度爆炸及网络退化的问题，提高了网络的学习能力以及训

练效率。

1.2 亚像素卷积方法

神经网络通过卷积操作提取目标特征后，输出的特征图尺寸会变小，需通过上采样还原特征图分辨率，以达到分割的效果。目前广泛使用的上采样方法有插值法和反卷积法。其中基于插值的上采样方法是一个固定运算，计算复杂度较高；基于反卷积的上采样方法使用带权重的网络层学习参数，但反卷积层具有“非均匀重叠效应”，会导致还原后的特征图带有棋盘纹理。Shi 等^[31]提出的高效亚像素卷积神经网络中使用亚像素卷积方法，具有图像从低分辨率到超分辨率转化的效果(图 2)。该网络通过隐含层对图像进行特征提取，生成 $r \times r$ 通道的特征图，其中 r 为上采样的倍数。使用亚像素卷积层将每个像素的 r^2 个通道重新排列成一个 $r \times r$ 的区域，对应超分辨率图像中一个 $r \times r$ 大小的子块，从而将大小为 $H \times W \times r^2$ 的特征图像重新排列成同样大小的超分辨率图像，其中 H 和 W 分别为特征图的高和宽。

高效亚像素卷积神经网络通过卷积和多通道间的像素重组，使特征图完成由低分辨率空间到超分辨率空间的转化。亚像素卷积层可学习到更好、更为复杂的推理方式提高特征图的分辨率，从而更加精准的定位初至区域，有效降低了计算复杂度，在拾取效果及训练效率上均有很大提升。

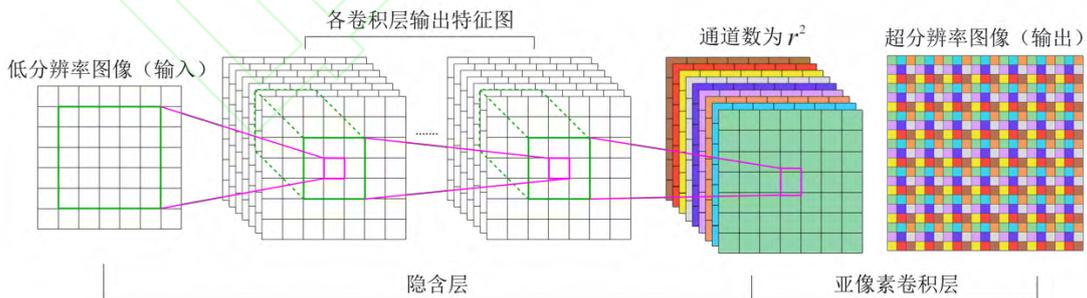


图 2 高效亚像素卷积神经网络流程图(据 Shi 等^[31]修改)

1.3 SD-Net 结构

本文设计的 SD-Net 结构(图 3)与传统语义分割网络 U-Net 结构形状类似，也是由编码器和解码器两部分组成。编码器子网络学习输入的地震数据并提取特征图谱，解码器子网络对得到的特征图谱进行

特征优化和任务处理，逐步实现每一个像素的类别标注。在特征图分辨率相同的层之间建立跳跃连接，将具有空间信息的低级特征和具有语义信息的高级特征进行融合，从而提高初至定位的准确度。

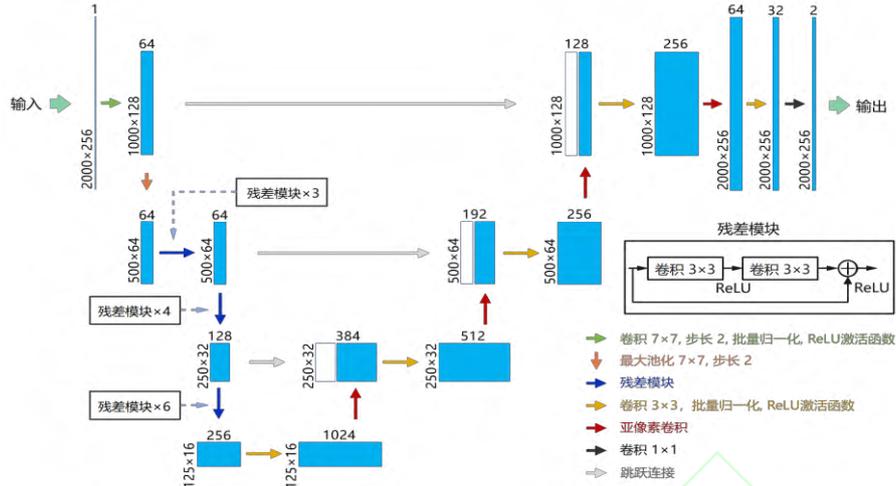


图 3 SD-Net 网络结构图

与 U-Net 不同的是，SD-Net 的编码器部分使用一个尺寸为 7×7 的卷积核和最大池化处理输入数据，大尺寸卷积核具有更大的感受野，有助于提取浅层信息间的相关性；池化操作可缩减特征图尺寸，减少深层网络的计算复杂度；使用残差模块以增加网络深度，通过卷积控制步长代替池化进行下采样操作，保留更多的特征信息。残差模块由两个 3×3 卷积层和一个跳跃连接组成，卷积层后添加批量归一化^[32]和 ReLU 激活函数，提高了模型的训练效率，增强了模型的鲁棒性和泛化能力，编码器具体参数见表 1。残差学习模块的残差函数定义为

$$R(x_i) = F(x_i) + x_i \quad (1)$$

$$x_{i+1} = f[R(x_i)] \quad (2)$$

式中： x_i 和 x_{i+1} 分别表示残差学习模块的输入和输出，其中 $i \in N$ ， N 为卷积层数； $R(x_i)$ 为恒等映射； $F(x_i)$ 为要学习的残差映射； f 为 ReLU 激活函数。

表 1 编码器参数

编码器名称	具体参数
Encoder_1	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$
Encoder_2	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$
Encoder_3	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$

在解码器部分，使用亚像素卷积对多

通道特征图进行像素重组实现上采样，还原特征图尺寸。上采样因子设置为 2，即特征图每次经过上采样后尺寸变为原来的 2 倍。输入特征图首先在顶、底与左、右侧部边缘分别填充 1 行或 1 列零元素；其次经过一个卷积核大小为 3×3 的卷积层，输出特征图尺寸不变，通道数变为原来的 4 倍；最后经过亚像素卷积层进行 4 通道的像素重组，将一个像素的 4 个通道值拼接，形成一个 2×2 大小的新像素块，完成特征图尺寸的 2 倍放大。解码器具体参数见表 2。亚像素卷积方法可表示为

$$I^{SR} = f^l(I^{LR}; W_l, b_l) \quad (3)$$

$$f^l(I^{LR}; W_l, b_l) = \sigma(W_l \times f^{l-1}(I^{LR}) + b_l) \quad (4)$$

式中： I^{SR} 为处理后的特征图； f 为像素重组； W_l 是学习网络的权值， $l \in (1, N-1)$ ，为一大小是 $n_{l-1} \times n_{l-1} \times k_l \times k_l$ 的 2D 卷积张量，其中 n_l 、 k_l 分别是第 l 层的特征数量和卷积大小； b_l 是长度为 n_l 的偏置； σ 为非线性函数。

表 2 解码器参数

解码器名称	具体参数
Decoder_1	特征融合：[3×3 , 512] 特征还原：[2, 128]
Decoder_2	特征融合：[3×3 , 256] 特征还原：[2, 256]
Decoder_3	特征融合：[3×3 , 256] 特征还原：[2, 64]

注：特征融合参数项前一项为卷积核大小，后一项为通道数；特征还原项前一项为还原倍数，后一项为通道数。

具有空间信息的低级特征和具有语义

信息的高级特征对于网络的目标识别能力均起着至关重要的作用。因此，在 SD-Net 的编码器和解码器之间建立 3 个长跳跃连接，将来自编码器浅层低级特征和来自解码器的深层高级特征在通道维度上融合，增强网络的识别能力，提高初至拾取的准确度。网络最后用一个 1×1 的卷积层及 Sigmoid 激活函数输出初至取值范围为[0,1]的概率值。

2 模型训练与测试

2.1 构建样本集

模型训练采用的数据集是经去噪处理后的实际地震资料数据，由于资料数据量过大，无法直接放入网络中训练，因此需对其进行预处理。为保持地震道之间的连续性及炮记录数据中的初至波特征，将 SEG-Y 数据按照连续炮号整体划分，提取单炮记录为单一样本数据，并将其尺寸裁剪为 2000×256 ，其中 256 表示地震道数，2000 表示每一地震道的样本点数，若单炮记录地震道数超过 256，则以炮点为中心进行裁剪，若单炮记录地震道数不足 256，则将其舍弃。采样间隔为 2ms，经处理后，最终得到每道 4000 个样本数据，然后利用这些样本数据制作网络训练所需的样本集，具体过程如下。

(1)使用传统算法如长、短时窗平均比(STA/LTA)法自动拾取 4000 个样本数据的初至，并采用人工修正错误初至。

(2)根据初至时刻生成对应的标签。为避免样本类别不均衡导致网络训练过程中的过拟合或欠拟合问题，采用以初至波为边界的二分类标注方式，将初至之前的样点值设为 0，初至及初至后样点值设为 1。

(3)为加快网络训练过程中梯度下降的求解速度，使用归一化操作将样本的值控制在[0,1]范围内，具体方法为

$$x'_{a,b} = \frac{X_{a,b} - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

式中： $X_{a,b}$ 、 $x'_{a,b}$ 分别表示归一化前、后

第 b 道第 a 个采样点的值； X_{\max} 、 X_{\min} 分别表示样本中的最大值和最小值。

(4)样本集的划分。将所有单炮数据及其对应的标签文件按 8:1:1 的比例划分为训练集、验证集和测试集，供网络模型训练使用。训练集、验证集和测试集所包含数据个数分别为 3200、400、400。

2.2 训练网络模型

训练网络模型参数见表 3，模型训练使用交叉熵损失函数

$$\text{Loss} = -\frac{1}{n} \sum_{m=1}^n [y_m \log(p_m) + (1 - y_m) \log(1 - p_m)] \quad (6)$$

式中： n 表示训练样本的总个数； m 表示当前训练样本批次中的第 m 个样本； y_m 表示样本 m 对应的标签； p_m 表示样本 m 预测为 y_m 的概率。

利用适应性矩估计(Adaptive moment estimation, Adam)算法优化网络参数，最小化损失。为防止训练过程中出现训练数据过拟合的现象，每当训练集完成 4 次迭代训练后，使用优化后参数对验证集进行 1 次验证，训练迭代次数设置为 100，并使用早停机制自动提前终止网络模型的训练，终止条件为：当连续 5 次使用验证集进行验证的结果中，错误率没有下降，则停止训练，并只保存最好的结果。

表 3 模型训练参数表

类型	内容
输入	$2000 \times 256 \times 1$
批处理大小	2
学习率	1×10^{-4}
损失函数	交叉熵损失函数
优化器	Adam
GPU	GTX 1080Ti
训练周期	100 和早停机制
框架	PyTorch

模型效果的评估标准使用语义分割中最常用的均交并比(Mean Intersection over Union, MIoU)，MIoU 是计算真实值和预测值两个集合的交集和并集之比

$$\text{MIoU} = \frac{1}{h+1} \sum_{u=0}^h \frac{p_{uu}}{\sum_{v=0}^h p_{uv} + \sum_{v=0}^h (p_{vu} - p_{uu})} \quad (7)$$

式中： p_{uv} 表示标签值为 u 、被预测为 v 的数量； p_{vu} 表示标签值为 v 、被预测为 u 的数量； p_{uu} 表示预测正确的数量； $h+1$ 为

类别总数。

本文使用样本集分别对 U-Net、SD-Net 训练和验证，并记录训练过程中的损失值 Loss 与 MIoU 值。

使用样本集对 U-Net 进行训练，在 48 次迭代后触发早停机制，总共用时 14.2h，其验证结果如图 4(上)。U-Net 模型在验证集上的 MIoU 达到 99.78%。然而在前期网络模型训练过程中，模型在训练集上的 Loss 及 MIoU 已趋于稳定，但是在验证集上 Loss 曲线和 MIoU 曲线存在抖动现象，

直到第 35 次迭代后才收敛完毕，表明 U-Net 模型对于地震数据特征的学习能力略有不足。

使用样本集对 SD-Net 进行训练，在 26 次迭代后触发早停机制，总共用时 4.5h，其验证结果结果如图 4(下)，模型在验证集上的 MIoU 达到 99.96%，而且 SD-Net 的 Loss 曲线和 MIoU 曲线在训练过程很稳定，网络收敛速度较快，表明 SD-Net 具有更强网络学习能力与更好的初至拾取效果。

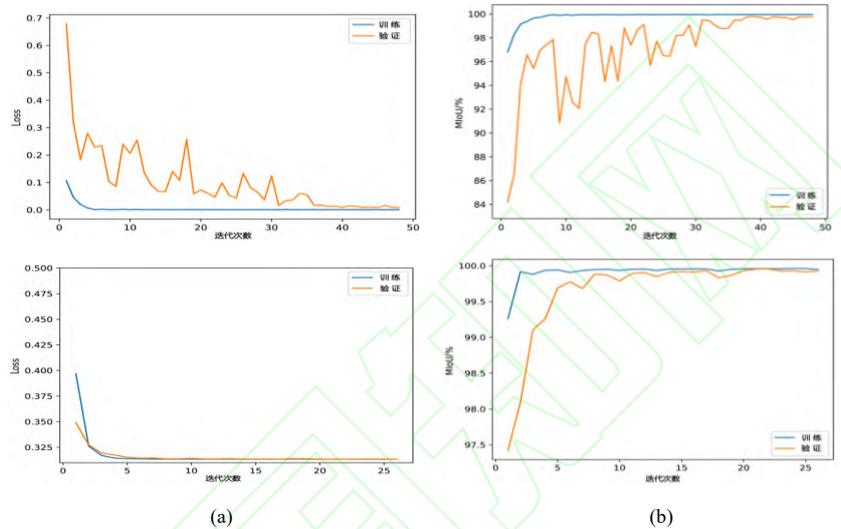


图 4 U-Net(上)与 SD-Net(下)模型训练的 Loss 图(a)和 MIoU 图(b)

2.3 测试网络模型

分别使用 U-Net 和 SD-Net 模型对未参与训练过程的测试集数据进行预测，共 400 个地震数据，每个数据 256 道，共 102400 道。表 4 为 U-Net 和 SD-Net 网络总数量、准确率和训练用时的对比，能够客观的度量网络的性能。由表可见，相较于 U-Net，SD-Net 的参数总数量更少，约为 U-Net 参数总量的 2/5，模型拾取初至准确率更高，训练使用时间更短，推理速度更快。

表 4 U-Net、SD-Net 性能对比表

评价指标	U-Net	SD-Net
网络参数量	34,525,954	13,053,794
训练集准确率/%	99.96	99.96
验证集准确率/%	99.78	99.96
测试集准确率/%	99.35	99.97
训练迭代次数	48	26
训练用时/h	14.2	4.5
预测用时/min	21.4	10.6

为验证 SD-Net 模型鲁棒性，选取 300 个与训练集尺寸、剖面特征、信噪比均不

同的数据制作新测试集，新测试集数据尺寸为 2000×128，数据包含炮点在测线中间以及炮点在测线两端的情况，并对数据添加不同程度的随机噪声、坏道等干扰信号。图 5 为 SD-Net 与 U-Net 对新测试集数据初至拾取的预测结果对比，每 20 个数据为一组共 15 组，取每组准确率的平均值，使用本文方法得到的初至拾取结果平均准确率为 99.75%，而 U-Net 得到的平均准确率为 89.80%；图 6 为两种方法对新测试集数据中单个样本的预测结果，可见 U-Net 受噪声影响较大，将部分初至前类别识别为初至后类别，而 SD-Net 几乎不受影响，可以做到准确分类。

综上所述，SD-Net 法在训练效率、拾取精度以及鲁棒性方面均优于 U-Net 法。

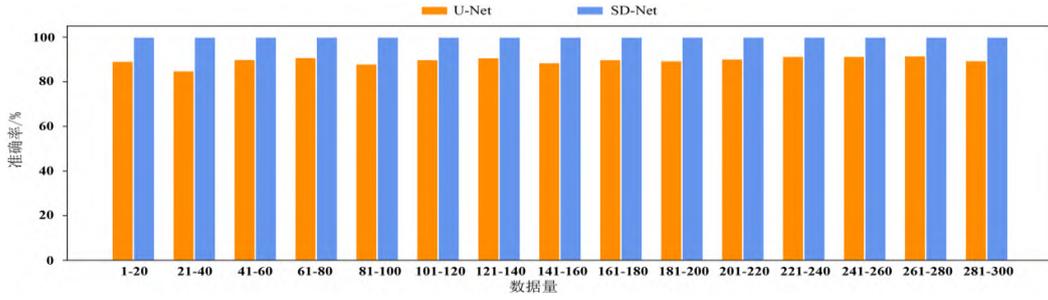


图5 U-Net 和 SD-Net 法预测准确率对比

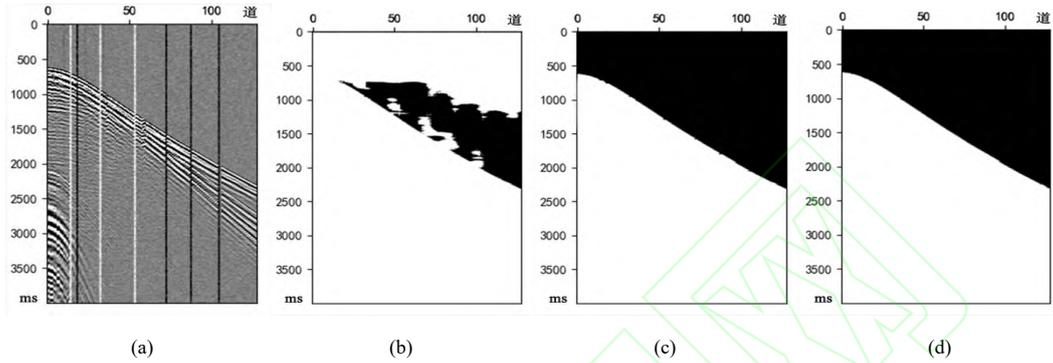


图6 单个样本 U-Net 和 SD-Net 方法预测结果对比

(a)原始地震数据; (b)U-Net; (c) SD-Net; (d)标签值

3 实际应用效果分析

3.1 SD-Net 法与传统方法对比

使用业内常用的 STA/LTA 法拾取初至, STA/LTA 法可表示为

$$SL(t) = \frac{\frac{1}{ns} \sum_{z=t-ns}^t CF(z)}{\frac{1}{nl} \sum_{z=t-nl}^t CF(z)} \quad (8)$$

式中: 分子、分母分别为短、长时窗信号平均值; t 为采样时刻; nl 、 ns 、分别为长、短时窗的长度; $CF(z)$ 为 z 时刻的特征函数值, 表征地震数据的振幅、能量或者其他变化; SL 为设定的触发阈值, 超过该阈值时, 认为出现有效信号。需根据经验设置 ns 、 nl 和 SL 的值, 其值影响地震信号的识别和拾取效果。

图 7 为 STA/LTA 法与 SD-Net 法拾取初至的结果, 由图可见, 当地震数据含有随机噪声和坏道时, STA/LTA 法拾取的初至存在上、下跳变, 拾取精度不高, 而

SD-Net 法拾取的初至不存在跳变问题, 能够精确的拾取初至, 表明 SD-Net 的初至拾取能力优于传统方法。

3.2 泛化能力分析

使用与训练样本集数据特征不同的地震资料试验, 分析初至特征和子波类型的变化对模型拾取初至的影响, 测试 SD-Net 模型的泛化能力。

为分析模型对初至连续性特征的依赖性, 判断模型是否会因初至错断而出现拾取错误的情况, 使用网络模型预测带有地表起伏的地震数据, 预测结果如图 8 所示。由于模型未学习过该类数据的特征信息, 故会出现部分错误分类的现象, 但模型能够基本正确的分割初至边界, 证明模型对初至连续性特征没有依赖性, 初至错断的情况不会影响模型的拾取能力。

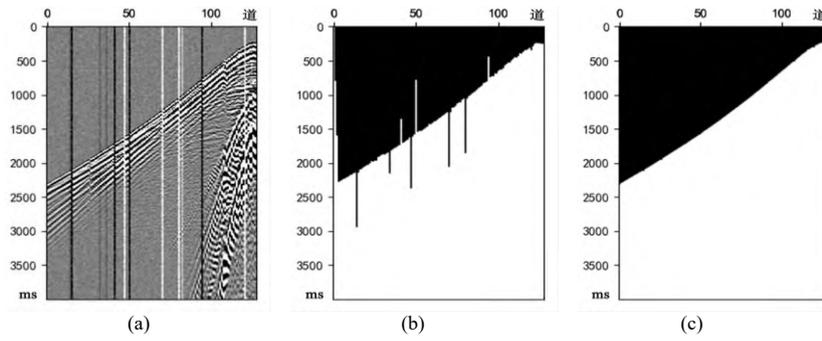


图7 STA/LTA方法与SD-Net方法拾取初至对比

(a)地震数据; (b) STA/LTA; (c) SD-Net

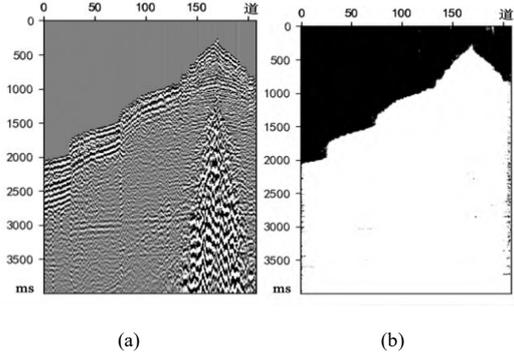


图8 SD-Net对带有地表起伏的地震数据预测结果

(a)带有地表起伏的地震数据; (b)模型分割结果

为分析不同子波类型对模型初至拾取

的影响,以 Marmousi2 模型作为速度场,选用 15Hz 理论 Ricker 子波、Puzirov 子波和 Symmetrical 子波三种不同子波进行正演实验。三种不同子波模型正演结果及预测效果如图 9 所示。由图可见,对于三种不同类别子波正演的地震数据,虽然内部存在部分分类错误的情况,但均可准确的分割初至边界,证明子波类型的改变不会影响模型初至拾取的效果。

上述试验证明,SD-Net 模型具有较强的泛化能力。

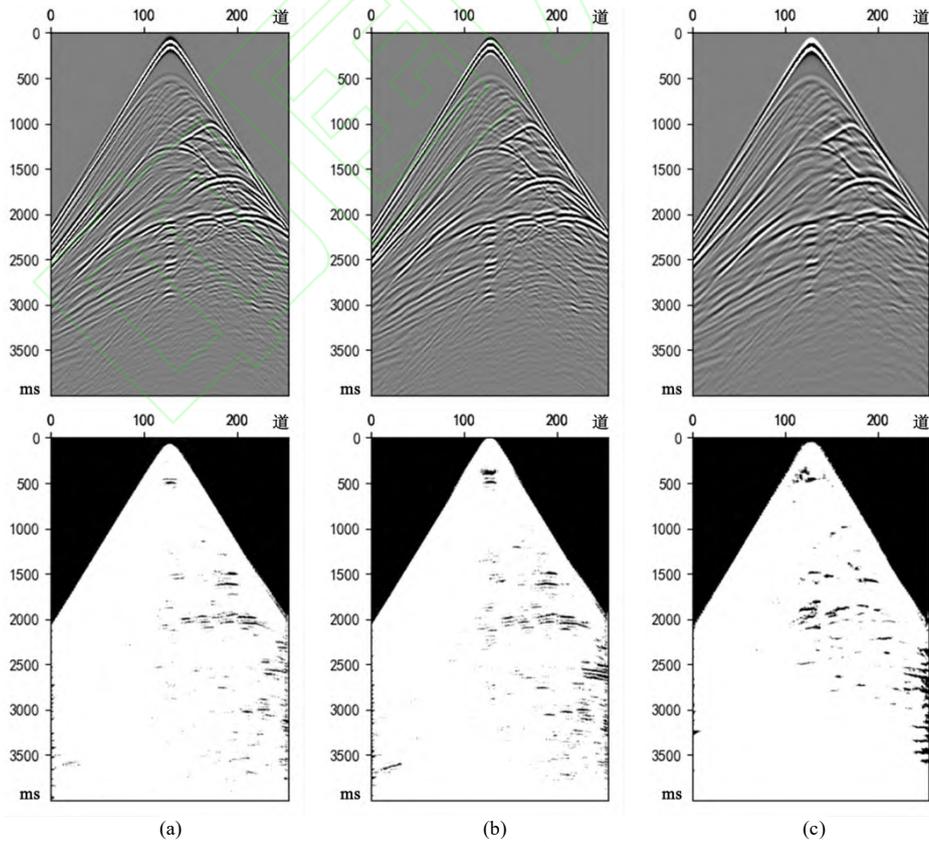


图9 不同子波类型正演(上)与模型分割(下)结果

(a)Ricker 子波; (b)Puzirov 子波; (c)Symmetrical 子波

3.3 迁移学习应用效果分析

实际应用中，因各工区地质环境不同，地震数据也不同，故使用一个工区数据训练好的网络模型，无法有效地对另一个工区数据进行初至拾取。且在勘探环境较为复杂的地区，由于各种噪声干扰，得到的地震数据信噪比较低，通过高信噪比数据训练得到的初至拾取模型也无法很好的适应于低信噪比数据。

迁移学习是利用不同数据之间的相关性，将存储已有问题的解决模型应用在其他不同但有相关性的问题上，以提高网络适应性和泛化能力的方法。使用少量的新数据样本对原有网络模型进行迁移学习，模型即可有效在新数据上进行初至拾取。

为模拟新工区数据，对原始地震数据加噪处理。添加的噪声来源于实际数据的裁切，将实际地震数据中的各类噪声抽取出来组成一个噪声库，然后随机从噪声库

中选择噪声并赋予不同的权重值，添加到原始数据中，得到不同信噪比的新数据，计算信噪比使用的公式如下

$$SNR = 10 \lg \frac{\sum_{a=1}^{M_1} \sum_{b=1}^{M_2} (c_{a,b})^2}{\sum_{a=1}^{M_1} \sum_{b=1}^{M_2} (d_{a,b} - c_{a,b})^2} \quad (9)$$

式中： $c_{a,b}$ 、 $d_{a,b}$ 分别表示加噪前、后的地震数据； M_1 、 M_2 分别代表当前数据的总行数和总列数。

选取 200 个已标注好的样本，其中，160 个作为训练集，40 个作为验证集，使用原始数据训练好的网络模型对新数据进行迁移学习，训练过程中的 Loss 和 MIoU 分别如图 10a、图 10b 所示，网络收敛速度较快，模型经过 55 个训练周期后 Loss 趋于稳定并触发早停机制，总共用时 45min，模型在验证集上的 MIoU 达到 99.69%。

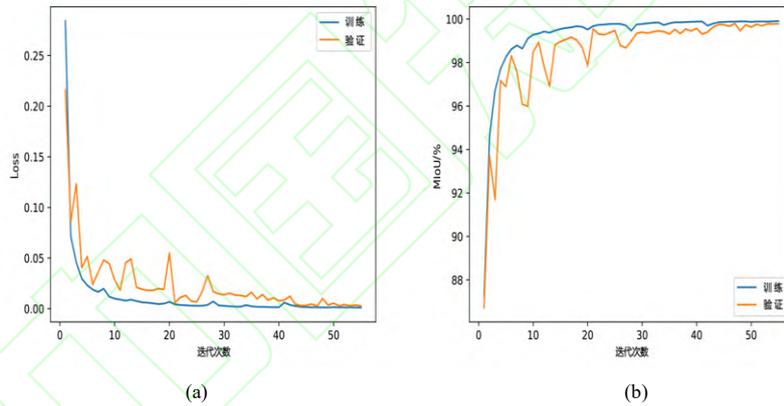


图 10 迁移学习训练过程 Loss 曲线图(a)及 MIoU 曲线图(b)

分别使用迁移学习前、后的网络模型，对未参与训练的加噪数据(不同信噪比)和原始数据做测试，验证迁移学习效果(图 11)，由图可见，随着地震数据信噪比的降低，迁移学习前网络模型的拾取效果逐渐变差，而迁移学习后的网络模型新学习了

低信噪比数据的特征，对不同信噪比的地震数据均可以准确拾取初至。试验表明，经过迁移学习后的模型不仅可以正确拾取之前学习的高信噪比的地震数据初至，同时也能够正确的拾取加噪后的不同信噪比的地震数据初至。

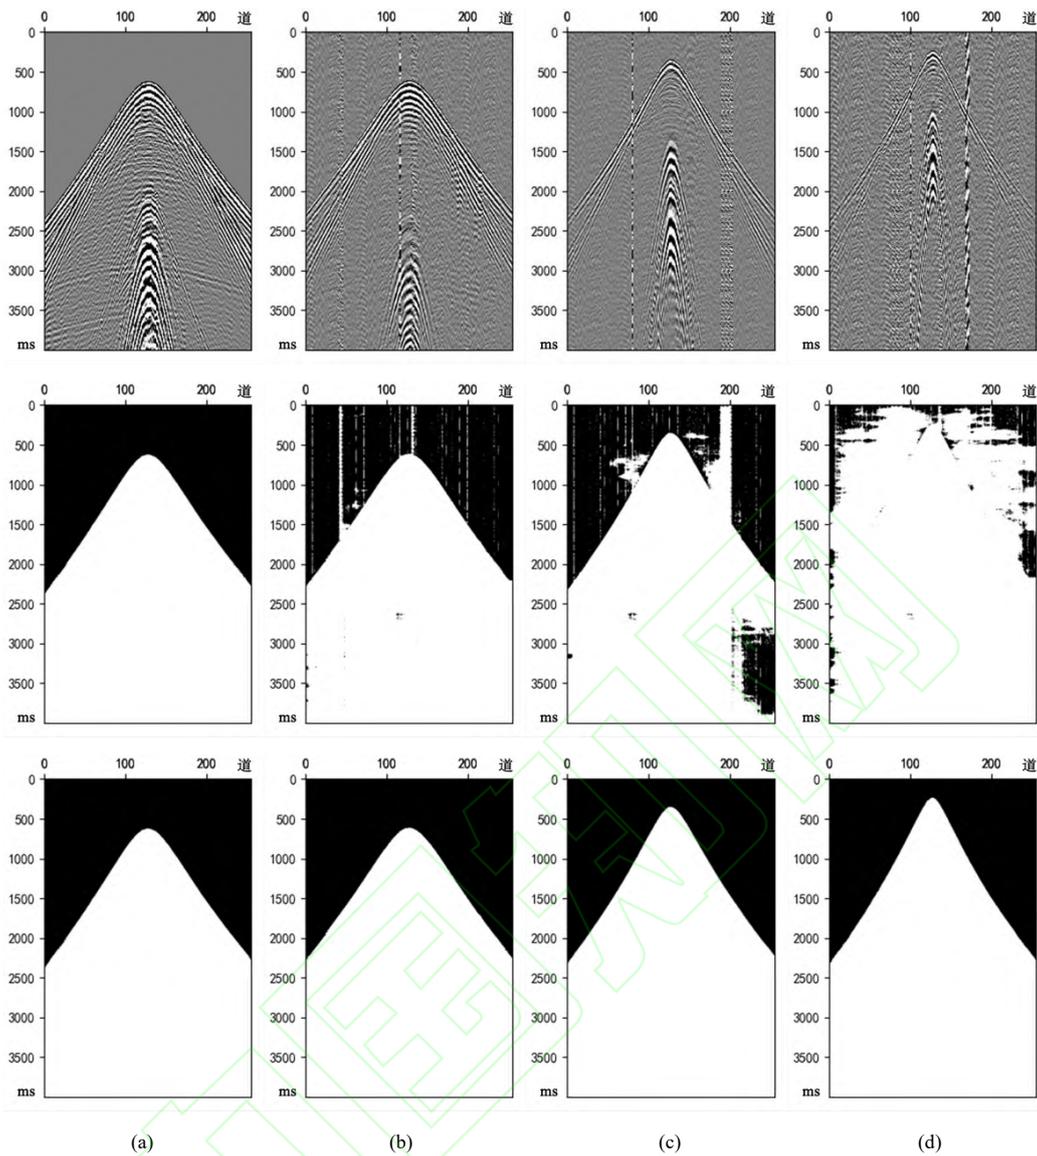


图 11 原始数据及不同信噪比的加噪数据(上)迁移学习前(中)、后(下)模型预测结果

(a)原始数据；(b)信噪比为 3.3582dB 的加噪数据；(c)信噪比为-1.4353dB 的加噪数据；(d)信噪比为-4.1402dB 的加噪数据

为清晰展示初至拾取结果，将预测结果所得分割图中初至位置的坐标信息提取出来，映射到原始地震资料上，并对比分析预测结果与人工拾取的结果(图 12)。图 12a 为提取预测的初至位置映射到地震数据的效果图，图 12b 为网络模型预测初至位置与人工拾取初至位置的误差，平均误差为 0.8906ms。算例结果显示迁移学习后得

到的模型对原始数据和加噪后的数据均具有很好的初至拾取效果，表明该网络可通过迁移学习不断提取新工区的地震数据特征，即只需对新工区数据做少量标注就能训练得到适应该工区的初至拾取模型，证明 SD-Net 具备较好的适应性和泛化能力，易于工业化生产，具有很好的发展前景。

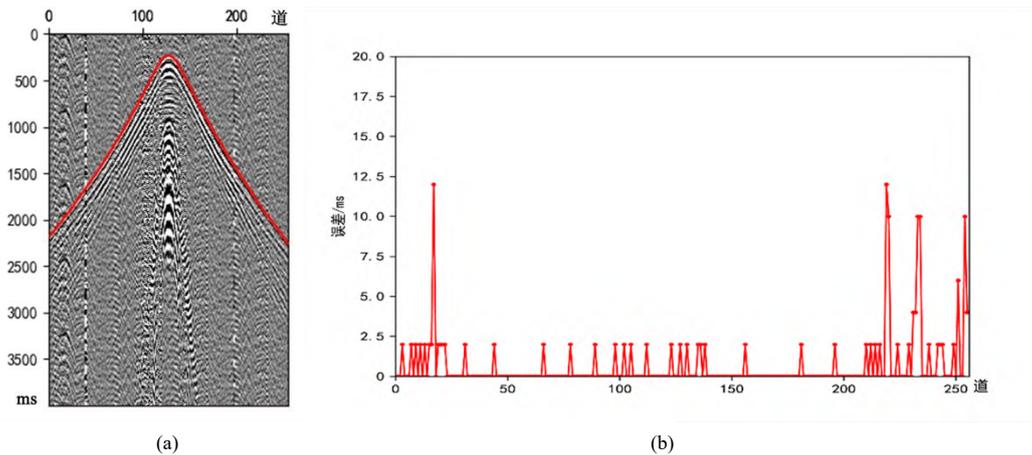


图 12 初至映射地震数据(a)及迁移学习后模型预测与人工拾取误差比较(b)

4 结论

本文基于深度学习中的 U-Net 网络提出了一种面向地震波初至智能拾取的超分辨率深度残差方法(SD-Net), 通过引入残差学习模块增强了网络对地震数据的学习能力, 同时使用亚像素卷积方法提高特征图的分辨率, 从而实现初至精准定位。SD-Net 法的长跳跃连接操作将多尺度特征信息进行融合, 最后使用迁移学习增强了网络泛化能力, 并取得了较好效果。本文获得的主要结论如下:

(1)实际地震资料数据集的训练和测试结果以及量化评估指标表明, U-Net 和本文方法在同一测试集上的预测准确率分别为 99.35%和 99.97%, 且 U-Net 的训练用时约为本文方法的 3 倍, 证明了本文提出的 SD-Net 模型比 U-Net 模型具有更高的初至拾取精度和更快的训练速度;

(2)使用与训练集尺寸、剖面特征、信噪比均不同的数据所构成的新测试集对 U-Net 和 SD-Net 进行试验与分析, 结果表明, U-Net 和 SD-Net 对新测试集数据初至拾取的平均准确率分别为 89.80%和 99.75%, 证明本文提出的 SD-Net 模型比 U-Net 模型具有更强的鲁棒性;

(3)将训练的网络模型分别应用到带有地表起伏的地震数据以及不同子波正演生成的合成数据上, 均可准确的分割初至边界, 得到良好的初至拾取效果, 证明本文提出的 SD-Net 模型具有较强的泛化能

力;

(4)对地震数据进行加噪处理模拟新工区数据, 使用少量标注样本即可训练得到适用于新数据的初至拾取模型, 随机选取的测试集数据与人工标注的初至平均误差表明, 所提方法有效实现了对地震数据初至的准确拾取, 证明了本文方法易于工业化生产, 具有良好的应用前景。

参考文献

- [1] 曾庆才,曾同生,欧阳永林,等.复杂山地层析反演静校正新方法及应用[J].石油地球物理勘探,2017,52(3): 418-425.
ZENG Qingcai,ZENG Tongsheng,OUYANG Yonglin,et al.A new tomographic inversion for static corrections in complex mountain areas[J].Oil Geophysical Prospecting, 2017, 52(3): 418-425.
- [2] 谢春,刘玉柱,董良国,等.基于声波方程的有限频伴随状态法初至波旅行时层析[J].石油地球物理勘探,2015,50(2): 274-282.
XIE Chun,LIU Yuzhu, DONG Lianguo, et al. First arrival tomography with finite frequency adjoint-state method based on acoustic wave equation[J].Oil Geophysical Prospecting, 2015,50(2): 274-282.
- [3] 王立歆,李海英,李弘,等.复杂地质条件下超深层碳酸盐岩断控缝洞体成像及预测技术 [J].石油物探,2022, 61(5): 865-875.
WANG Lixin,LI Haiying,LI Hong,et al.Imaging and prediction technology of fault-karst reservoirs in ultra-dep carbonate

- rocks under complex geological conditions[J]. *Geophysical Prospecting for Petroleum*, 2022,61(5):865-875.
- [4] 林彬华,金星,康兰池,等.基于卷积神经网络的地震震级测定研究[J].*地球物理学报*,2021,64(10):3600-3611.
LIN Binhua, JIN Xing, KANG Lanchi, et al. The research of earthquake magnitude determination based on Convolutional Neural Networks[J].*Chinese Journal of Geophysics*, 2021,64(10):3600-3611.
- [5] 陈金焕,曹永生,孙成龙,等.基于二分法的地震波初至自动拾取算法[J].*地球物理学进展*,2015,30(2): 688-694.
CHEN Jinhuan, CAO Yongsheng, SUN Chenglong, et al. The algorithm for automatic first-breaks picking on seismic traces based on Dichotomy[J].*Progress in Geophysics*, 2015,30(2): 688-694.
- [6] 王议迎,丁仁伟,李建平,等.联合改进 STA/LTA 与 MLoG 算子的微震 P 波到时自动拾取方法[J/OL].*山东科技大学学报(自然科学版)*,2021,40(6): 1-10.
WANG Yiying, DING Renwei, LI Jianping, et al. Automatic pickup of microseismic P-wave arrival based on improved STA/LTA and MLoG operators[J/OL].*Journal of Shandong University of Science and Technology (Natural Science)*,2021,40(6): 1-10.
- [7] 江国明,张贵宾,徐晓.远震相对走时数据快速计算方法及应用[J].*地球物理学报*, 2012, 55(12): 4097-4105.
JIANG Guoming, ZHANG Guibin, XU Yao. A fast method for calculating relative residuals of teleseismic data and its application[J]. *Chinese Journal of Geophysics*, 2012, 55(12): 4097-4105.
- [8] 刘腾蛟,高阳,储仿东,等.最小二乘曲线拟合的微地震初至优化拾取方法及应用[J].*石油地球物理勘探*, 2018, 53(S2):124-129.
LIU Tengjiao, GAO Yang, CHU Fangdong, et al. Microseismic first arrival picking based on least square curve fitting[J].*Oil Geophysical Prospecting*, 2018,53(S2):124-129.
- [9] 李辉峰,邹强,金文昱.基于边缘检测的初至波自动拾取方法[J].*石油地球物理勘探*, 2006(2): 150-155.
LI Huifeng, ZOU Qiang and JIN Wenyu. Method of automatic first breaks pick-up based on edge detection[J].*Oil Geophysical Prospecting*,2006(2): 150-155.
- [10] 牛沛琛,张建中.基于数字图像处理的地震波初至时间检测[J].*计算机与现代化*, 2007(4): 27-30.
NIU Peichen, ZHANG Jianzhong. First Arrival Picking Based on Image Processing Methods[J].*Computer and Modernization*, 2007(4):27-30.
- [11] 宋建国,李赋真,徐维秀,等.改进的神经网络级联相关算法及其在初至拾取中的应用[J].*石油地球物理勘探*,2018,53(1): 8-16.
SONG Jianguo, LI Fuzhen, XU Weixiu, et al. An improved neural-network cascade-correlation algorithm and its application in seismic first break picking[J].*Oil Geophysical Prospecting*,2018,53(1): 8-16.
- [12] 曹晓莉,刘斌,王淑荣,等.综合动量法和可变速学习速度的 BP 神经网络地震初至拾取[J].*石油地球物理勘探*,2020,55(1):71-79.
CAO Xiaoli, LIU Bin, WANG Shurong, et al. Seismic first-break picking based on BP neural network integrated with momentum method and adaptive learning rate method[J]. *Oil Geophysical Prospecting*, 2020, 55(1): 71-79.
- [13] COVA D,刘洋,丁成震,等.人工智能和视速度约束的地震波初至拾取方法[J].*石油地球物理勘探*,2021,56(3): 419-435.
COVA D, LIU Yang, DING Chengzhen, et al. First break picking method based on artificial intelligence and apparent velocity constraint[J]. *Oil Geophysical Prospecting*, 2021, 56(3): 419-435.
- [14] 杨晶,丁仁伟,林年添,等.基于深度学习的地震断层智能识别研究进展[J].*地球物理学进展*,2022,37(1):298-311.
YANG Jing, DING Renwei, LIN Niantian, et

- al. Research progress of intelligent identification of seismic faults based on deep learning[J]. *Progress in Geophysics*, 2022, 37(1):298-311.
- [15] 张岩, 李新月, 王斌, 等. 基于深度学习的鲁棒地震数据去噪[J]. *石油地球物理勘探*, 2022, 57(1):12-25.
ZHANG Yan, LI Xinyue, WANG Bin, et al. Robust seismic data denoising based on deep learning[J]. *Oil Geophysical Prospecting*, 2022, 57(1):12-25.
- [16] 李祺鑫, 罗亚能, 马晓强, 等. 基于深度嵌入网络的地震相聚类技术[J]. *石油地球物理勘探*, 2022, 57(2):261-267.
LI Qixin, LUO Yaneng, MA Xiaoliang, et al. Seismic facies clustering technology based on deep embedding network[J]. *Oil Geophysical Prospecting*, 2022, 57(2):261-267.
- [17] 唐杰, 韩盛元, 刘英昌, 等. 基于去噪卷积神经网络的面波噪声压制方法[J]. *石油物探*, 2022, 61(2):245-252.
TANG Jie, HAN Shengyuan, LIU Yingchang, et al. Seismic surface wave attenuation based on denoising convolutional neural networks[J]. *Geophysical Prospecting for Petroleum*, 2022, 61(2):245-252.
- [18] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015: 3431-3440.
- [19] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2017, 39(12): 2481-2495.
- [20] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015: 234-241.
- [21] 赵明, 陈石, 房立华, 等. 基于 U 形卷积神经网络的震相识别与到时拾取方法研究[J]. *地球物理学报*, 2019, 62(8):3034-3042.
ZHAO Ming, CHEN Shi, FANG Lihua, et al. Earthquake phase arrival auto-picking based on U-shaped convolutional neural network[J]. *Chinese Journal of Geophysics*, 2019, 62(8): 3034-3042.
- [22] 张逸伦, 喻志超, 胡天跃, 等. 基于 U-Net 的井中多道联合微地震震相识别和初至拾取方法[J]. *地球物理学报*, 2021, 64(6):2073-2085.
ZHANG Yilun, YU Zhichao, HU Tianyue, et al. Multi-trace joint downhole microseismic phase detection and arrival picking method based on U-Net[J]. *Chinese Journal of Geophysics*, 2021, 64(6):2073-2085.
- [23] 刘佳楠, 武杰. 基于全卷积神经网络的地震初至波拾取[J]. *信息技术与网络安全*, 2018, 37(11):58-63.
LIU Jianan, WU Jie. Seismic first arrival picking based on fully convolutional networks[J]. *Information Technology and Network Security*, 2018, 37(11):58-63.
- [24] 陈德武, 杨午阳, 魏新建, 等. 基于混合网络 U-SegNet 的地震初至自动拾取[J]. *石油地球物理勘探*, 2020, 55(6):1188-1201.
CHEN Dewu, YANG Wuyang, WEI Xinjian, et al. Automatic picking of seismic first arrivals based on hybrid network U-SegNet[J]. *Oil Geophysical Prospecting*, 2020, 55(6):1188-1201.
- [25] 潘英杰, 许银坡, 倪宇东, 等. 一种基于地震图像深度语义分割的初至拾取方法[J]. *地球物理学进展*, 2022, 37(3):1122-1131.
PAN Yingjie, XU Yinpou, NI Yudong, et al. 2022. First break picking method based on deep learning semantic segmentation of seismic image. *Progress in Geophysics (in Chinese)*, 37(3):1122-1131.
- [26] 王维波, 官强, 高明, 等. 利用残差网络和地震发射层析成像的微地震事件检测[J]. *石油地球物理勘探*, 2022, 57(2):251-260.
Weibo, GUAN Qiang, GAO Ming, et al.

Detection of microseismic events based on residual network and seismic emission tomography[J]. Oil Geophysical Prospecting, 2022,57(2):251-260.

- [27] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 1-9.
- [28] SIMONYAN K, ZISSERMAN A . Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- [29] HE K, JIAN S. Convolutional neural networks at constrained time cost[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 5353-5360.
- [30] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [31] SHI W, CABALLERO J, F HUSZÁR, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 1874-1883.
- [32] OFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. International conference on machine learning. PMLR, 2015: 448-456.

(本文编辑: 石双虎)

作者简介



李建平, 博士, 1980 年生; 2003 年毕业于吉林大学, 获勘查技术与工程专业学士学位, 2008 年或获吉林大学地球探测与信息技术专业博士

学位; 现就职于山东科技大学, 从事地球物理勘探领域的教学与科研工作。