

# 基于 M-Net 的微地震信号初至拾取方法

王向雨<sup>1,2</sup>

WANG Xiangyu

## 摘要

高效精准地对微地震信号进行初至拾取工作是微地震监测技术中重要环节, 由于微地震信号通常存在震级微弱, 噪声复杂等问题, 导致微地震信号初至拾取工作十分困难。目前对微地震信号初至拾取的方法普遍存在拾取速度慢、拾取精度低的问题, 针对这些问题, 文章提出了一种基于多尺度特征提取的方法来构建的网络模型 M-Net, 首先将微地震信号训练集输入到 M-Net, 通过反向传播算法最小化损失函数, 更新 M-Net 权重参数, 得到拾取效果最优的 M-Net。M-Net 和其他网络在微地震信号验证集进行对比, 实验结果表明, M-Net 在微地震信号初至拾取效率和精度方面均优于其他网络, 验证网络模型 M-Net 的优越性。

## 关键词

微地震信号; 初至拾取; 多尺度特征提取; 跳跃连接; 信噪分离

doi: 10.3969/j.issn.1672-9528.2025.03.001

## 0 引言

在油气藏资源勘探、开采过程中, 微地震监测技术是一种快速、高效的技术手段<sup>[1-2]</sup>。通过在地面或井中设置多个检波器, 长时间监测由井下水力压裂产生的微小地震事件, 来分析确定地下油气藏资源储层情况, 是对油气藏资源安全高效地开采开发的保障<sup>[3]</sup>。其中对采集到的微地震信号进行初至拾取是微地震监测技术中的关键步骤<sup>[4]</sup>, 也是后续对油气藏资源定位、地下裂缝预测工作的前提。实际采集到的微地震信号, 往往其中的有效微地震信号占比较低, 导致对微地震信号进行初至拾取的工作十分困难。因此, 一种能够高效、精准地对微地震信号进行初至拾取的方法具有重要意义<sup>[5]</sup>。

目前针对微地震信号进行初至拾取有许多相关方法研究<sup>[6]</sup>。例如传统拾取方法有长短时窗平均值比(STA/LTA)法<sup>[7]</sup>、Akaike 信息准则(AIC)法<sup>[8]</sup>、小波变换法<sup>[9]</sup>等, 上述这些方法相较于人工拾取方法, 大幅提高了微地震信号初至拾取效率, 但是这些方法需要人为设置具体的特征参数, 往往只适应于某一种特定的微地震信号, 对不同的微地震信号进行初至拾取的泛化性仍有待提高。

随着深度学习的快速发展, 基于深度学习拾取方法逐渐开始应用。神经网络模型对于海量数据可以快速处理学习并提取特征信息, 与传统拾取方法相比, 神经网络模型不仅

对微地震信号数据处理速度更快, 同时不需要人为设置特征参数, 可以通过海量的数据进行训练, 自动更新权重参数, 使拾取效果最优。基于深度学习拾取方法有 UNet<sup>[10]</sup>, UNet++<sup>[11]</sup>等, 这些方法初至拾取的泛化性和精准性均优于传统拾取方法, 但上述拾取方法对低信噪比的微地震信号拾取精度仍有待提高。针对这些拾取方法存在的不足, 本文提出了一种基于多尺度特征提取的网络模型 M-Net 来对微地震信号进行初至拾取。在实验部分将 M-Net 和 UNet 拾取结果进行了对比, M-Net 拾取精度达到了 94.99%, UNet 为 87.50%, 实验说明 M-Net 初至拾取效果和精度均优于 UNet 网络。

## 1 模型结构和原理

### 1.1 M-Net 模型结构

M-Net 模型由编码器、解码器、中间跳跃连接层三部分组成。编码器部分由 5 个 M-Block 模块组成, 每个 M-Block 模块之间通过下采样连接, 对微地震信号逐层提取浅层到深层信号特征; 解码器部分由 4 个 M-Block 模块组成, 之间通过上采样连接, 逐层将编码器得到的信号特征复原为原微地震信号特征大小; 中间跳跃连接层部分负责连接编码器和解码器, 避免 M-Net 在编码器提取特征时丢失有效信号特征信息。M-Net 模型结构图如图 1 所示, M-Block 结构图如图 2 所示。M-Block 模块通过将 3×3、5×5、7×7 不同尺度的卷积层融合, 获取不同感受野下的微地震信号特征, 提取更全面丰富微地震信号初至特征, 提高 M-Net 对微地震信号初至拾取结果的精度。

1. 湖北省水电工程智能视觉监测重点实验室 湖北宜昌 443002

2. 三峡大学计算机与信息学院 湖北宜昌 443000

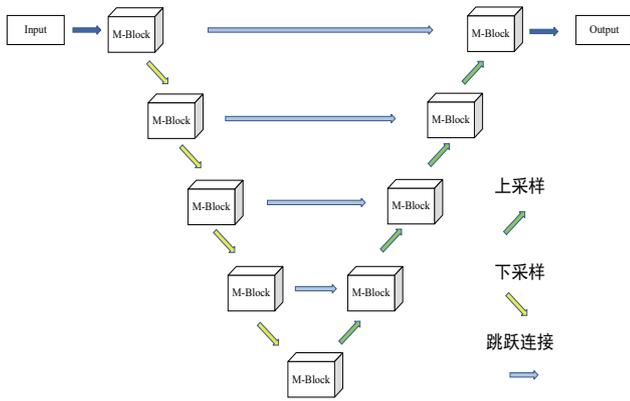


图1 M-Net 模型结构图

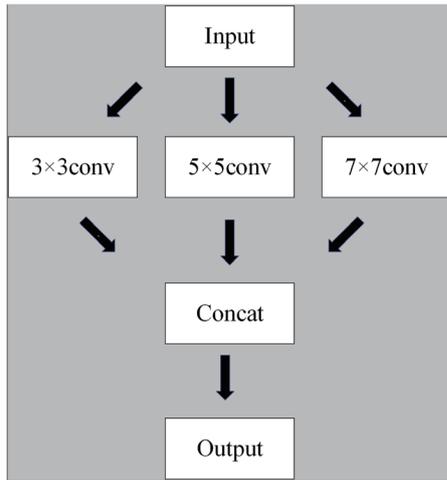


图2 M-Block 结构图

### 1.2 M-Net 模型原理

将微地震信号训练数据输入到 M-Net，首先经过 M-Net 编码器部分，M-Block 模块对输入的微地震信号数据进行多尺度的初至信号特征提取，然后通过下采样逐层提取浅层到深层的初至信号。编码器中 5 层 M-block 通道数分别设置为 32、64、128、256、512，在编码器最后一层得到序列长度为  $L/16$  的微地震信号初至特征（ $L$  是微地震信号序列长度）。

M-Net 解码器部分对编码器提取的微地震信号特征中解码通过上采样，将编码器提取的序列长度为  $L/16$  的微地震信号初至特征逐层恢复，解码器中 4 层 M-block 通道数分别设置为 32、64、128、256，在 M-Net 最后输出序列长度为  $L$  的微地震信号特征。

M-Net 中间跳跃层连接编码器和解码器，避免编码器对微地震信号进行特征提取时丢失有效信息细节，使 M-Net 模型输出更准确地微地震信号初至拾取结果。同时将编码器提取的浅层特征和经过解码器得到的深层特征融合，从而 M-Net 提取更全面丰富的微地震信号特征信息，进一步提高微地震信号初至拾取结果精度。

M-Net 最后结果输出将序列长度为  $L$  的微地震信号特征

经过 Softmax 函数<sup>[12]</sup>，输出微地震信号序列上是否为初至点的概率曲线，取输出概率曲线中概率最大值对应的微地震信号序列为微地震信号初至点。

M-Net 中 Softmax 函数计算公式为：

$$y_i(x) = \frac{\exp(x_i)}{\sum_{i=1}^n \exp(x_i)} \quad (1)$$

式中： $x$  是微地震信号； $n$  是微地震信号采样点个数； $i$  是微地震信号序列位置； $x_i$  是微地震信号序列点为  $i$  时，该点微地震信号特征； $y_i$  是地震信号序列点为  $i$  时，该点是否为初至点的概率。

M-Net 通过最小化损失函数，反向传播<sup>[13]</sup>来更新模型权重参数，使 M-Net 可以高效、精准地完成微地震信号初至拾取。M-Net 中损失函数<sup>[14-15]</sup>用公式表示为：

$$L = \min \frac{1}{N} \sum_{i=1}^N - [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (2)$$

式中： $L$  是 M-Net 损失函数； $N$  是微地震信号采样点个数； $i$  是微地震信号序列位置； $y_i$  是微地震信号序列点为  $i$  时的标签值（若该点是初至点，取值为 1，否则为 0）； $p_i$  是地震信号序列点为  $i$  时，该点是否为初至点的概率。

M-Net 微地震信号初至拾取精度定义为：

$$\text{accuracy} = \frac{T}{S} \quad (3)$$

式中： $\text{accuracy}$  是 M-Net 微地震信号初至点准确拾取百分比； $T$  是初至点准确的微地震信号拾取数目； $S$  是所有微地震信号数目总和。

### 2 微地震信号拾取流程

M-Net 网络模型用于微地震信号初至拾取任务时，拾取流程分为三个步骤完成：微地震信号数据集预处理、微地震信号数据集训练、微地震信号数据集拾取。

微地震信号数据集预处理阶段，将微地震模拟信号通过加入信噪比为 -10 dB 高斯噪声<sup>[16]</sup>，和真实微地震信号一起组成 M-Net 训练数据集。添加的高斯噪声定义为：

$$\frac{S}{N} = 10 \log_{10} \frac{\sigma_S}{\sigma_N} \quad (4)$$

式中： $S$  是微地震信号； $N$  是噪声； $\sigma_S$  是微地震信号标准差； $\sigma_N$  是噪声标准差。

微地震信号数据集训练阶段，将微地震信号训练数据集输入到 M-Net，通过最小化损失函数，反向传播算法更新 M-Net 权重参数，完成 M-Net 对微地震信号训练数据集的训练步骤，得到训练好的 M-Net。

微地震信号数据集拾取阶段，将待拾取的微地震信号数据集样本输入到经过微地震信号数据集训练阶段后的 M-Net，

M-Net 可以自动对待拾取的微地震信号数据集样本输出微地震信号特征和微地震信号初至拾取结果，微地震信号初至拾取流程完成。M-Net 拾取流程图如图 3 所示。

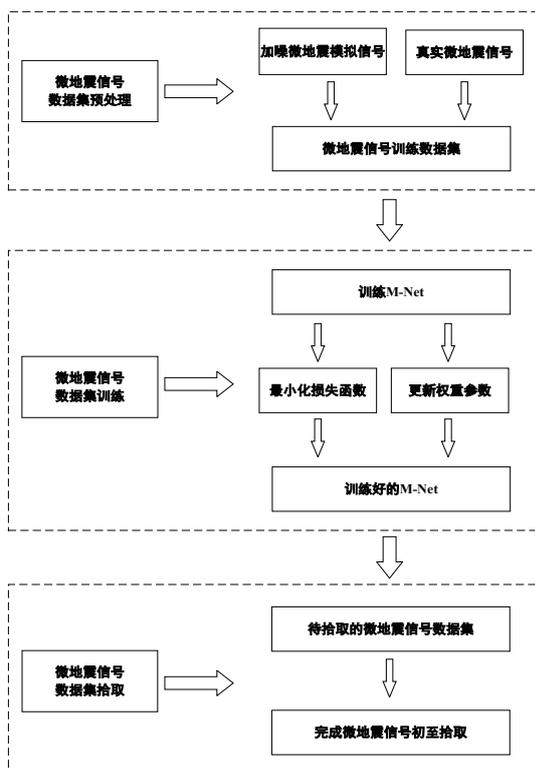


图 3 M-block 拾取流程图

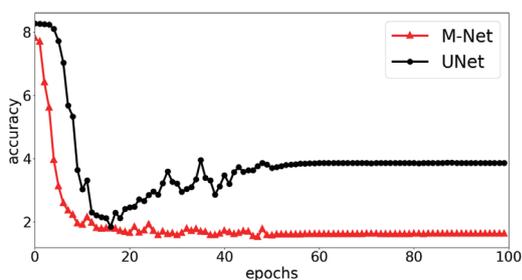
### 3 实验设置

#### 3.1 实验环境和超参数选择

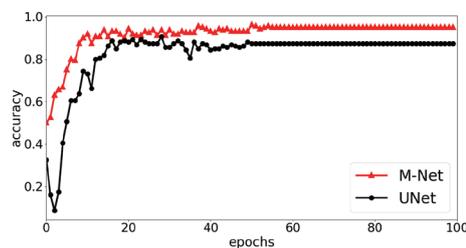
本文实验编程环境实验 Tensorflow2.6，在 Ubuntu 7.5.0 操作系统的 GPU 服务器上训练，硬件设备配有 6 个 NVIDIA GeForce RTX3090 GPU 和 24 GB RAM。M-Net 网络模型 epoch 设置为 100，批次大小为 16，学习率为 0.001，优化器为 Adam，标签平滑化参数为 0.01，Dropout 设置为 0.5，防止 M-Net 在训练阶段出现过拟合现象。

#### 3.2 模型结果对比

为验证 M-Net 较于其他深度学习网络在微地震信号初至拾取的优越性，本文对 M-Net、UNet 模型在微地震信号初至拾取结果上进行对比实验，实验结果如图 4 所示。



(a) 微地震信号拾取 Loss 对比图



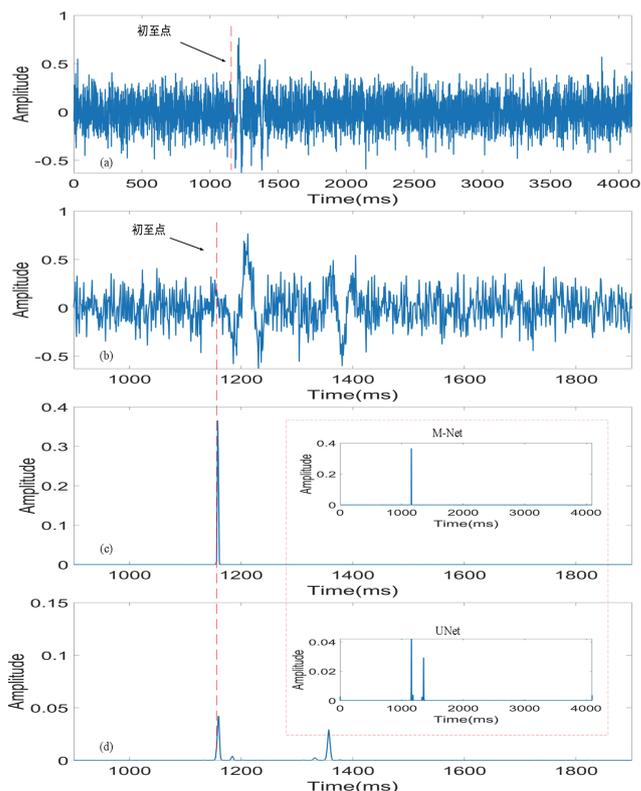
(b) 微地震信号拾取 accuracy 对比图

图 4 不同网络模型结果对比图

图 4 (a) 可以看到 M-Net loss 值比 UNet 更小、更稳定，这说明 M-Net 比 UNet 在对微地震信号数据集的拟合能力更好，更能有效提取微地震信号初至特征；由图 4 (b) 可知，M-Net 微地震信号拾取精度达到了 94.99%，UNet 微地震信号初至拾取精度为 87.50%，M-Net 拾取精度优于 UNet 拾取精度，进一步说明 M-Net 比 UNet 在微地震信号初至拾取的优越性，可以更好地提取微地震信号特征，更有效实现微地震信号和噪声分离，更精准地对微地震信号完成初至拾取工作。

#### 3.3 初至拾取结果对比

本实验利用正演模型生成模拟信号，其中模拟信号的采样点均为 4 096，采样间隔为 1 ms，对添加 -10 dB 高斯噪声的微地震模拟信号进行初至拾取实验。M-Net、UNet 模型的信号初至拾取结果对比图如图 5 所示。



(a) 微地震模拟信号图；(b) 微地震模拟信号图 900 ms 到 1900 ms 局部放大图；(c) M-Net 拾取结果图；(d) UNet 拾取结果图

图 5 添加 -10 dB 高斯噪声的微地震模拟信号拾取结果图

从图 5 对比拾取结果可以看到, 图 5 (a) 是添加 -10 dB 高斯噪声的微地震模拟信号, 图 5 (b) 是模拟信号 900 ms 到 1900 ms 局部放大图。对图 5 中 (c) (d) M-Net、UNet 拾取结果分析可知, M-Net 可以精准找到信号初至点并准确拾取, 而 UNet 初至拾取结果和真实初至点存在较大偏差。结果表明 M-Net 拾取效果和精准性优于 UNet。

上述实验结果表明, UNet 对于低信噪比的微地震信号不能准确进行初至拾取, M-Net 可以准确对低信噪比的微地震信号进行初至拾取, 说明 M-Net 相较于 UNet 在初至拾取效果和精准性更优。

#### 4 结语

本文提出了一种基于多尺度特征提取的方法来构建的网络模型 M-Net。M-Net 和其他深度学习网络模型相比, 在低信噪比微地震信号条件下, M-Net 初至拾取速度和精度均优于其他网络。M-Net 可以很好地解决低信噪比的微地震信号拾取精度低的问题, 通过多尺度特征提取, 获取了更全面更丰富的特征信息, 避免丢失了微地震信号有效特征, 更好地实现微地震信号和噪声分离, 从而精准地完成微地震信号初至拾取工作。在后续研究阶段, 将结合微地震信号去噪网络和微地震信号初至拾取网络, 进一步提升模型的拾取精度, 同时优化网络模型, 高效精准地完成微地震信号初至拾取任务。

#### 参考文献:

- [1] SHU H M, DAWOD A Y. Microseismic monitoring signal waveform recognition and classification: review of contemporary techniques[J]. Applied sciences, 2023, 13(23): 12739.
- [2] FENG G L, YOSHIDA S, LACIDOGNA G. Special issue on new advances in acoustic emission and microseismic monitoring technologies in civil engineering[J]. Applied sciences, 2023, 13(2): 969.
- [3] MENG L B, ZHENG J, YANG R Z, et al. Microseismic monitoring technology developments and prospects in CCUS injection engineering[J]. Energies, 2023, 16(7): 3101.
- [4] QIAN Y N, LI Q G, LIANG Y P, et al. Evaluation of hydraulic fracturing in coal seam using ground microseismic monitoring and source location[J]. Rock mechanics and rock engineering, 2024, 57(10): 679-694.
- [5] ANIKIEV D, BIRNIE C, WAHEED U B, et al. Machine learning in microseismic monitoring[J]. Earth-science reviews, 2023, 239: 104371.
- [6] XIAO Y X, CHEN S J, LIU L, et al. Determining s-wave arrival times for microseismic monitoring in tunnels based on instantaneous phase difference of sensors[J]. Rock mechanics and rock engineering, 2023, 57: 1781-1797.
- [7] 邱磊, 李彩华. STA/LTA 方法拾取天然地震波初至及其改进分析[J]. 地球物理学进展, 2023, 38(4): 1497-1506.
- [8] 胡慧江, 李利平, 靳昊, 等. 基于高阶统计量偏斜度和赤池信息准则的突涌水微振信号初至拾取方法[J]. 工业建筑, 2023, 53(5): 132-136.
- [9] 巩佳琦. 基于 Shearlet 变换与 AIC 的微地震初至提取[D]. 吉林: 吉林大学, 2018.
- [10] 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): 251-262.
- [11] 刘志文, 王进强, 王广鑫. 基于 UNet++ 的地震 P 波初至拾取研究[J]. 太原理工大学学报, 2023, 54(1): 65-72.
- [12] HAN D C, YE T Z, HAN Y Z, et al. Agent attention: on the integration of softmax and linear attention[DB/OL]. (2024-07-15)[2024-09-09]. <https://doi.org/10.48550/arXiv.2312.08874>.
- [13] 王子华, 叶莹, 刘洪运, 等. 基于脉冲序列标识的深度脉冲神经网络时空反向传播算法[J]. 电子与信息学报, 2024, 46(6): 2596-2604.
- [14] 李伟, 黄鹤鸣. 基于双交叉熵的自适应残差卷积图像分类算法[J]. 计算机工程与设计, 2023, 44(12): 3670-3676.
- [15] 王振, 杨宵晗, 吴楠楠, 等. 基于生成对抗网络的序列交叉熵哈希[J]. 吉林大学学报(工学版), 2023, 53(12): 3536-3546.
- [16] 肖莉. 通信系统中高斯白噪声的性能研究[J]. 传感器世界, 2023, 29(2): 32-36.

#### 【作者简介】

王向雨(1999—), 男, 湖南株洲人, 硕士研究生, 研究方向: 微地震信号处理等。

(收稿日期: 2024-11-14)