

中国科学技术大学
硕士学位论文



基于 CNN 的地震断层检测定量评价
与优化策略研究

作者姓名: 李游

学科专业: 地球物理学

导师姓名: 伍新明 教授

完成时间: 二〇二四年五月二十三日

University of Science and Technology of China
A dissertation for master's degree



Quantitative Evaluation and Optimization Strategies for CNN-based Seismic Fault Detection

Author: You Li

Speciality: Geophysics

Supervisor: Prof. Xinming Wu

Finished time: May 23, 2024

中国科学技术大学学位论文原创性声明

本人声明所呈交的学位论文，是本人在导师指导下进行研究工作所取得的成果。除已特别加以标注和致谢的地方外，论文中不包含任何他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的贡献均已在论文中作了明确的说明。

作者签名： 李冲

签字日期： 2024年5月23日

中国科学技术大学学位论文授权使用声明

作为申请学位的条件之一，学位论文著作权拥有者授权中国科学技术大学拥有学位论文的部分使用权，即：学校有权按有关规定向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅，可以将学位论文编入《中国学位论文全文数据库》等有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。本人提交的电子文档的内容和纸质论文的内容相一致。

控阅的学位论文在解密后也遵守此规定。

公开 控阅 (____ 年)

作者签名： 李冲

导师签名： 任永明

签字日期： 2024年5月23日

签字日期： 2024年5月23日

摘 要

地震断层检测是地质构造解释、构造建模和储层建模的关键步骤，断层检测结果不仅可以帮助评估地震危险性，还可以揭示油气藏的形成和分布，为能源勘探和开发提供重要依据。目前，卷积神经网络（CNN）已经被广泛应用于地震断层检测，与传统的基于属性的方法相比，其能获得更加低噪声且更连续的断层分割结果，显示出更加稳定、强大的性能。然而，基于 CNN 断层检测方法在实际地震数据上的泛化能力仍有待提高。同时，影响 CNN 断层检测的因素也未得到深入且系统的研究。此外，目前对断层检测结果的评估大多使用来自于自然图像分割领域中常用的基于像素计算的评价指标，这些评价指标并不适合于断层检测这类地质问题，无法提供在地质上更公平、合理的断层分割结果。

为了解决上述问题，本文进行了如下的研究和测试：

首先，我们提出一个基于距离的断层检测评价指标，其能为断层检测提供在地质上更合理的定量评价。然后，我们使用在 CNN 断层检测中最常用的 U-Net 网络作为研究对象，设计了一系列实验，从训练数据、网络的超参数、以及推理阶段的数据增广等方面，来探究影响 CNN 断层分割效果的影响因素。

我们得出了以下的实验结论：对于训练数据集，通过模拟更真实的断面反射波和扩充多种采样率，可以丰富数据集在结构以及波形特征上的变化，从而显著地提高断层分割的效果。此外我们提出了一个新的损失函数，有效的解决了断层数据正负样本分布极为不均衡的问题，提高了断层检测的精度。对于模型的参数设置，更深的网络以及更多的通道数都能在一定程度上提高 U-Net 断层检测的效果。在推理过程中，提出了多尺度和多角度的预测流程，克服 CNN 缺失变换不变性的缺点，提升断层检测的稳定性和连续性。

基于上面的研究，我们优化并训练了一个重新设计的 U-Net，将其应用于多个实际数据工区，获得了准确、干净、连续的断层检测。同时，基于手动标注构建了一个实际数据验证集，用于断层检测模型的定量评估与对比，证明了其在实际数据中的泛化性。

最后，为了进一步解决深部大尺度断层的检测问题，我们基于具有可提示引擎的 SAM 大模型，使用手动标注和生成的深部断层标签以及提示词，基于 Adapter 的方式进行了 SAM 模型的微调，实现了深部断层的可交互式识别。

关键词：断层检测；深度学习；评价指标；卷积神经网络；地震解释

ABSTRACT

Earthquake fault detection is a key step in geological structure interpretation, structural modeling, and reservoir modeling. The results of fault detection can not only help assess earthquake but also reveal the formation and distribution of oil and gas reservoirs, providing an important basis for energy exploration and development. Currently, convolutional neural networks (CNNs) have been widely employed for seismic fault segmentation and show more powerful performance than conventional attribute-based methods to obtain a fault map with noise-free and continuously trackable fault features. However, CNN-based methods face the potential problem of poor generalization in field seismic images. At the same time, the factors affecting CNN fault detection have not been deeply and systematically studied. In addition, Moreover, the existing pixel-wise metrics, borrowed from the natural image segmentation tasks, cannot fairly or reasonably evaluate the fault segmentation results.

To address the aforementioned challenges, this study undertook the following investigations and experiments: we firstly propose to use a distance-based metric to provide a geologically more reasonable evaluation on fault interpretation. We then use the most commonly used U-Net architecture as an example to study how the CNN-based fault segmentation is affected by some significant factors such as training data, all kinds of network hyperparameters, and scaling and rotation in the inference step.

We draw the following experimental conclusions: For the training dataset, more realistic reflection features and multiple sampling rates can enrich the dataset variations in both the structure and waveform signatures, thus significantly enhancing the fault segmentation. For the loss function, we propose a new loss function, which effectively solves the problem of extremely unbalanced positive and negative sample distribution in fault data, and improves the accuracy of fault detection. For the model parameter settings, deeper networks and more channels can improve the effect of U-Net fault detection to a certain extent. In the inference process, it is necessary to apply a multi-scale and multi-angle prediction process to overcome the lack of transformation invariance of CNN, and improve the stability and continuity of fault detection.

Based on the studies, we optimally train a properly designed CNN and apply it to multiple field examples, where we obtain accurate, clean, continuous fault detections and quantitatively evaluate them with manual interpretations, proving its generalization in field seismic data.

Finally, to further address the challenge of detecting deep, large-scale faults, we have refined the SAM large model, which is equipped with a promptable engine, by fine-tuning it through the Adapter approach using manually annotated deep fault labels along with corresponding prompts. This workflow enables the interactive recognition of deep faults.

Key Words: Fault detection; Deep learning; Evaluation metrics; Convolutional neural network; Seismic interpretation

目 录

第 1 章 绪论	1
1.1 研究背景及意义	1
1.2 国内外研究现状	2
1.2.1 断层检测的传统方法研究现状	2
1.2.2 断层检测的人工智能方法研究现状	3
1.3 论文创新点与主要内容	5
1.3.1 本文研究内容	5
1.3.2 本文研究创新点	6
第 2 章 断层检测定量评价指标对比研究	8
2.1 语义分割评价指标的分析和对比	8
2.1.1 基于像素点的评价指标	8
2.1.2 常用的评价指标的缺点和不足	9
2.1.3 基于距离的评价指标	10
2.2 断层评价指标的对比和优选	11
2.2.1 断层预测模拟实验	11
2.2.2 评价指标的对比	13
2.3 人工标注的地震断层检测验证集	15
2.4 本章小结	16
第 3 章 基于卷积神经网络的断层检测优化	18
3.1 基于 U-Net 的断层检测模型设计	18
3.1.1 卷积神经网络基本理论	18
3.1.2 U-Net 模型结构与超参数	20
3.2 断层训练样本对模型效果的影响	21
3.2.1 断层反射特征	21
3.2.2 背景噪声	23
3.2.3 数据采样率	25
3.3 网络模型超参数对模型效果的影响	29
3.3.1 损失函数对模型效果的影响	30
3.3.2 网络特征数对模型效果的影响	34
3.3.3 网络层数对模型效果的影响	35

3.4	FaultSeg3D Plus 模型介绍	36
3.4.1	网络结构和超参数	36
3.4.2	多尺度数据训练	37
3.5	模型推理阶段的多尺度融合增强	38
3.5.1	卷积神经网络的等变性和不变性	38
3.5.2	多尺度和多角度预测流程	41
3.6	实际工区地震数据验证	45
3.6.1	工区一概况和检测结果	45
3.6.2	工区二概况和检测结果	46
3.6.3	工区三概况和检测结果	47
3.6.4	工区四概况和检测结果	47
3.6.5	检测结果对比与分析	48
3.7	本章小结	48
第 4 章	基于可提示引擎的交互式深部断层检测	54
4.1	基于 CNN 的深部断层检测现状	54
4.1.1	深部断层的特点	54
4.1.2	深部断层检测的现存问题	55
4.2	基于可提示引擎的分割网络	56
4.2.1	Transformer 模型原理	56
4.2.2	SAM 网络结构	58
4.2.3	提示信息的常见形式	59
4.3	训练数据集的标注和提示信息生成	60
4.3.1	深部断层的人工标注	60
4.3.2	断层检测提示信息的生成	61
4.4	基于 Adapter 的 SAM 模型微调	61
4.4.1	大模型微调的研究现状	61
4.4.2	深部断层微调工作流程	62
4.5	实际数据预测	64
4.6	本章小结	65
第 5 章	总结与展望	68
5.1	本文内容总结	68
5.2	未来展望	69
	参考文献	70

目 录

致谢 ····· 75

在读期间发表的学术论文与取得的研究成果 ····· 77

第1章 绪 论

1.1 研究背景及意义

断层是地应力作用于地下结构并使其出现破碎并发生相对移动后的一种常见的构造现象，这一构造在地震图像中表现为反射波的同相轴不连续。断层是油气运移和聚集的通道，同时断层的构造解释也能作为地球内部运动和演化的证据，所以在地震资料解释中，断层检测扮演着基础性和不可或缺的关键角色。

首先，断层在油气的运移和聚集过程中起到了关键性的作用，对于油气的勘探开发有着不可或缺的意义。所以，在油气储存的预测流程中，精细的地震断层解释是其中的重要步骤。因此，为了进一步提高断层检测的效果，优化勘探和开发的策略和流程，提高资源的探明率并适应日益提高的数据体量和解释精度的要求，将基于数据驱动的深度学习引入地震断层的检测是必要且重要的。

其次，地震资料的断层解释不仅对油气勘探和开发有意义，还对构造和地球动力学分析具有重要作用。通过对断层构造的解释，我们可以由此了解地壳中的断层分布和特性，进一步探究地球内部的构造和运动机制。因此，对于高精度的断层的解释也对地球内部科学的研究以及城市的建设规划有着重要意义。

地球物理勘探中的地震数据图像通过数据解释，能直观的揭示地下地质结构、构造特征以及资源分布情况。地震断层检测在地球科学领域是一个重要的研究方向，具有重要的意义和应用前景。

传统的断层检测方法主要分为人工手动标注和基于属性的方法。手工标注的方法存在着效率低、成本高且主观性强的问题。如今不断发展的地震数据采集技术，也使得目前的我们获取的数据精度越来越高，体量越来越大，维度也从二维扩展到更高维度。传统的人工解释方法更加难以兼顾解释的速度和精度。为了解决手动标注的问题，很多研究使用基于属性的方法，通过计算各类属性体来刻画断层同相轴不连续的特征。基于属性的方法在一定程度上解决了手动标注的效率问题，但是其检测效果很容易受到地震数据中噪声以及一些和其他非断层的不连续特征的影响。

随着人工智能技术的迅猛发展以及深度学习在各个领域的广泛应用，为了解决传统断层检测方法的上述问题，更好地适应目前对断层检测的高精度、高效率要求，结合深度学习的地球物理勘探技术被用于解决断层检测任务。

基于深度学习的断层解释方法能更好地被应用于大工区数据的处理和解释，提高 workflows 的效率，并端到端地输出更高精度的解释结果，减轻人工解释的主观性问题和时间负担，克服了传统的地震断层解释方法存在着效率低、计算成本高的问题。深入且系统地研究基于深度学习的断层检测，对实现更高效、更高精

度的断层检测有着深刻意义。

尽管人工智能技术在断层检测领域得到了广泛的应用和研究，但目前的研究仍然面临着困难和挑战。由于目前主流模型训练都是在合成的地震数据上进行有监督的训练，虽然模型能较好的拟合于这些合成数据。但是，当深度神经网络模型被应用于复杂的实际地震数据时，模型常常会出现泛化性差的问题，尤其是对于跨工区、跨采样率的数据上，断层的检测结果并不够准确且连续。此外，在模型效果的评价阶段，目前常用的评价指标也无法提供在地质上更加合理的评估。这是由于这些评价指标大多是基于像素点来计算，而这样的标准对于数据采集、地震数据处理中的误差以及实际断层的不唯一确定的位置，这些需要考量的因素并不够鲁棒。此外，由于合成数据的尺度和目前所能模拟的断层模式有限，同时 CNN 缺乏更为全局的感受能力，基于目前合成数据集训练的 CNN 模型在大尺度深部断层的检测上泛化性不够，难以达到好的检测效果。

上面的这些问题，都限制了目前深度学习在断层检测领域的应用，为了解决上面的问题，本课题进行了如下研究：我们首先提出了一种基于距离的断层检测评价指标，能更加客观且准确地评估断层检测结果的好坏，并手动标注了一个断层检测的验证集，用于不同模型效果的定量评估和对比。同时，我们以 U-Net 网络为例，从多个方面探究了影响深度神经网络在断层检测任务的因素。最后，我们基于目前的分割基础大模型，在我们手动标注的少量二维深部断层数据上进行微调，实现了可交互的深部大尺度断层检测。

1.2 国内外研究现状

1.2.1 断层检测的传统方法研究现状

断层检测是地震解释的基础和重要步骤，基于断层检测结果的研究对地下构造建模以及石油勘探具有重要意义。传统上，对地震图像进行手动地断层解释需要丰富的地质理解和专业背景知识 (Hamzeh, 2021)。而且，手动的断层解释可能是主观的，并且非常耗时。随着地震数据的采集技术的进步，地震数据的大小和维度也在增加，这显著增加了手动断层解释的工作量和工作周期，对一个三维地震工区的人工断层解释时间可长达几天到几个月 (Giba et al., 2012; Mohammadpoor et al., 2020)。

为了使断层解释的效率提高，涌现出各种基于属性的方法，通过刻画地震图像中反射波的同相轴的不连续这一特征来突出地震断层 (Hamzeh, 2021)。这些地震属性包括相似属性 (Marfurt et al., 1998)、相干属性 (Marfurt et al., 1999; Li et al., 2014; Wu, 2017)、方差属性 (Van Bemmelen et al., 2000; Randen et al., 2001)、曲率 (Roberts, 2001)、梯度幅度 (Aqrabi et al., 2011) 和倾角/方位角。然而，上述的大

多数属性算法对一些和断层类似的地层特征或不连贯的数据噪声等特征较为敏感,使得在提取地震属性时会得到不够准确的检测结果,无法满足高精度的断层检测要求 (Hale, D., 2013)。

随着计算机技术的不断革新,许多自动化和计算机辅助的方法已经为地震断层解释任务带来了新的思路。蚂蚁跟踪算法 (Pedersen et al., 2005, 2003) 和最优面投票算法 (Wu et al., 2018a) 可以在增强地震属性的同时抑制噪音。Jacquemin et al. (2005) 应用双霍夫变换实现了断层的自动提取。Yan et al. (2019) 利用主成分分析 (PCA) 结合正向和反向的扩散算法来增强断层特征。为了准确区分断层和其他不相关特征, Hale, D. (2013); Wu et al. (2016) 在所有的倾向和倾角的组合情况下,通过对相似度属性体进行由断层构造导向的平滑来计算断层似然体。

为了解决算力的约束并简化断层检测的工作流程,很多研究开始尝试使用图像处理技术来进行地震图像的断层检测。为了识别网格化的断层, Hale et al. (2003) 建议使用传统的图像分割方法,如归一化切割 (Shi et al., 2000) 和随机聚类 (Gdalyahu et al., 2001)。考虑到断层特征类似于人类毛细血管, Zhang et al. (2014) 采用了生物识别方法来获得断层检测结果。基于最优边缘检测, Canny (1986) 出了边缘检测技术来检测地震图像上的灰度突变,以此揭示地震数据中反射波同相轴的不连续性特征。然而这些方法的缺点是它们大多数都是在地震属性体而不是直接地震数据上执行断层的检测,也正因如此,它们的检测效果也高度依赖于属性体的检测质量。

1.2.2 断层检测的人工智能方法研究现状

人工智能在各个行业的蓬勃发展和广泛应用使得将机器学习和深度学习引入地震断层解释任务成为可能 (Hamzeh, 2021)。各种机器学习算法如人工神经网络 (ANN) (Hamzeh, 2021)、支持向量机 (SVM) (Di et al., 2017)、主成分分析 (PCA) (Yan et al., 2019) 被用于分析地震断层属性体,以获得自动化的断层解释结果。尽管这些基于传统机器学习的算法在一定程度上提高了断层解释的智能化和自动化程度,但这些方法的效果高度依赖于解释者对地震属性的选择,具有一定的主观性,且训练过程无法做到端到端进行。

深度学习是一种端到端的、由数据驱动的方法。这样,在进行训练和断层解释的过程中,我们无需预先计算断层检测属性,可以直接端到端地从输入的地震数据体输出对应的断层检测结果。理论上,具有足够参数数量的卷积神经网络 (CNN) 可以逼近任何数学函数并不断迭代优化,最终得到最适合的模型 (LeCun et al., 1998; Hinton et al., 2006; LeCun et al., 2015)。Di et al. (2018) 将机器学习方法:多层感知机 (MLP) 和深度学习的 CNN 模型应用于相同的实际地震数据工区以比较它们的性能。结果表明,从断层检测效率和准确性两方面来看, CNN

均优于 MLP，进一步证明了基于 CNN 的方法比传统的机器学习方法如 MLP 更好。

在深度学习在断层检测领域的效果和前景得到证明和认可之后，越来越多断层检测的研究者，将注意力聚焦到深度学习方法和卷积神经网络（CNNs）上。总的来说，基于深度学习的地震断层检测可分为二分类和语义分割两种方法。第一类，通过将检测任务视为一个二分类问题，CNN 模型被训练以滑动窗口来扫描整个地震或属性体，对每个窗口的中心点像素进行断层或是非断层的分类。Huang et al. (2017) 将地震数据体与相应的地震属性体融合作为 CNN 模型的输入。Xiong et al. (2018) 将相干属性用作训练数据集的断层标签，再基于这个数据集进行 CNN 模型的训练，获得了比相干算法更高分辨率的断层检测结果。Wu et al. (2018b) 提出了一种基于 CNN 的断层检测方法，使用各向异性的高斯函数，是模型在得到断层的检测结果的同时，还能获得对应的断层方向信息。上述的基于分类思想的断层检测算法的优点是：使用一个较为简单的网络模型架构，可以在较短的时间内完成模型的训练；并且这些分类方法的训练数据集的断层标签相对容易获得。但是，基于分类的方法也存在着很多局限和问题。由于在预测的步骤中，这些方法必须在以像素为中心的滑动窗口或立方体中预测每个像素，这样对逐个像素点的预测推理显然是非常耗时的，特别是在三维地震数据的断层检测中。此外，有限的预测窗口大小使模型难以捕捉更为全局的地震结构信息，也在一定程度上限制了模型断层检测的效果和稳定性。

相比之下，基于语义分割思想的断层检测方法，提供了一种更有效的由地震图像直接到断层图像的检测方式，直接计算输入地震图像的所有像素的断层概率图。Di et al. (2019) 使用 CNN 同时分割 12 多个地震构造模式，但由于每个构造模式的类别分布高度不平衡，该方法的分割效果未能获得令人满意的性能。具有编码器-解码器架构的 U-Net(Ronneberger et al., 2015) 是一种经典且高效的语义分割网络，该模型通过权重共享和多次下采样，降低了模型的计算成本并提高了收敛的速度。Li et al. (2019) 将 U-Net 应用于一个小规模的，由真实地震数据构建的二维训练集的训练中，进行端到端的断层检测。

为了解决三维数据标签难获取，标注成本高的问题，使 U-Net 模型能够在三维地震数据体上进行端到端地训练和预测，Wu et al. (2019a) 提出了一种自动工作流程，自动地生成具有多种构造模式和多样性的合成地震数据及其相应的断层标签，并训练了一个简化后的 U-Net 模型，以减少模型对 GPU 内存的消耗并缩短模型的训练时间。选择平衡损失函数来处理非断层和断层样本之间的不均衡分布。这一工作相较于其他传统方法，展现出了更高效和更准确的断层检测性能。基于多任务学习，Wu et al. (2019b) 训练了一个 CNN 模型，其能同时完成包括断层检测、构造定向平滑和反射定向估计在内的三项地震图像处理任务。为

了进一步改进和完善基于深度学习的断层分割的效果，更多的研究 (Zheng et al., 2020; Liu et al., 2020; Gao et al., 2021) 在 CNN 中使用残差块。除了上述的断层分割模型，还有许多研究 (Dou et al., 2021a; Wei et al., 2022; Dou et al., 2021b; An et al., 2021; Yu et al., 2022) 将新技术引入到这个领域，推进了断层检测的领域研究。

尽管目前基于深度学习的断层检测方法显示出了巨大潜力并取得了令人期待的成果，但它们通常面临以下挑战和不足：(1) 常用的基于像素的评估指标无法合理评估断层分割。(2) 现有模型仍然无法在具有复杂结构的某些断层上表现良好，并且无法很好地泛化到具有各种采样率的实际地震数据。(3) 目前缺少对于模型性能的影响因素的深入系统研究。

综上所述，在我们在断层检测领域进行进一步的研究前，有必要先提出一个更适合地震断层检测任务的评价指标，并详细探讨 CNN 模型的训练策略以及可能的影响因素。

1.3 论文创新点与主要内容

1.3.1 本文研究内容

本文主要解决了断层检测任务存在的几个问题：首先是目前断层检测常用的评价指标无法客观地反映模型效果。其次，目前的模型大多存在着泛化性差的问题，深度学习模型性能的影响因素仍有待深入研究。本文共有五个章节，其组织架构和研究内容如下：

第一章：绪论。主要介绍了本课题的研究背景和研究意义。阐述了断层智能检测对油气勘探、地球演化研究以及国家发展的重要意义。调研并梳理了传统的和基于深度学习的断层检测算法的研究和发展；最后，总结了本文的主要内容以及创新点。

第二章：断层检测评价指标的优选。本章首先对目前图像分割领域的评价指标进行了调研和分类，主要对比和探讨了基于像素点计算和基于距离计算的评价指标在断层检测任务的效果。为了选出最适合断层检测问题的评价指标，本研究设计了一组在实际情况下可能出现的断层检测情况，然后对所研究的两类评价指标进行了测试和对比。通过定量的对比，最终选择了最能体现断层检测效果的双向倒角距离作为更适合断层检测任务的评价指标。

第三章：基于卷积神经网络的断层检测优化。本章以最为常用的 U-Net 模型为例，探究了可能影响 CNN 断层检测的诸多因素，包括数据集的构建的逼真度、合成数据纵向采样率的增广、模型训练的损失函数、模型的卷积核个数、网络的深度以及模型的推理预测阶段。通过设计一系列对比实验，最终给出整个断层检

测工作流程可借鉴的模型优化策略，并提出一个改进后的工作流程。

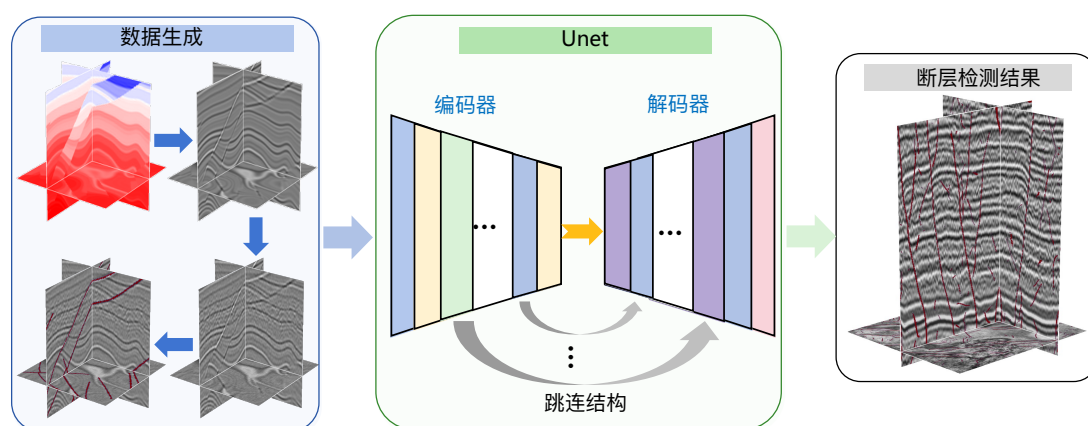


图 1.1 基于深度学习的断层检测工作流程

第四章：基于可提示引擎的深部断层检测。为了解决模型在深部断层上泛化性不佳的问题，本部分首先介绍了目前基于可提示引擎的分割模型的原理。然后，介绍了将可提示引擎引入断层检测领域的一些准备工作和训练流程：包括训练数据集的标注以及提示信息的生成、模型的微调等。最后将微调后的模型应用于具有深部断层的实际工区，测试了模型的效果。

第五章：总结与展望。本部分对全文的内容进行了总结，梳理了对断层检测模型重要的几个影响因素。同时，基于本文的研究结果和目前的研究现状和趋势，提出了本研究中的不足和可以改进的方向，并对今后该领域的研究提出了建议。

1.3.2 本文研究创新点

(1) 通过定量的对比实验，我们推荐双向倒角距离这一基于距离计算的评价指标来进行断层检测结果的评估。相较于基于像素点计算的评价指标，双向倒角距离对标签的不确定性有更强的容忍度，能给出更加稳定且符合地质认识的评估结果。同时，为了定量地评估断层检测方法在实际地震工区上的效果和泛化能力，我们在精选的几个实际数据上进行了精细的断层标注，构建了一个实际数据断层验证集。

(2) 基于如图 1.1 所示的工作流程，我们设计了一系列对比实验，从训练数据集、损失函数、网络超参数、推理阶段后处理等方面，来探究可能影响 CNN 断层检测模型性能的因素。通过上述的对比实验，我们优化了训练数据的合成算法，增强了合成数据的逼真度；选择了更适合断层检测任务的损失函数以及网络模型超参数，对断层检测的整个流程进行了优化，进一步提高了断层检测的准确性和泛化能力。为了克服 CNN 在预测阶段缺乏对输入数据变换的不变性，增强模型断层检测的稳定性和准确性，我们在推理预测阶段提出了多尺度和多角度

的预测后处理流程，并通过融合与增强操作，获得一个更好的断层检测结果。

(3) 提出了一个基于可提示引擎的可交互式深部断层检测的工作流程，解决了目前断层检测模型在深部大尺度断层泛化性不佳的问题。

第2章 断层检测定量评价指标对比研究

2.1 语义分割评价指标的分析和对比

2.1.1 基于像素点的评价指标

在语义分割领域，常用的像素级度量包括准确率 (Accuracy)、F1 分数 (F1-score)、精确度 (Precision) 和召回率 (Recall) (Fawcett, 2006; Powers, 2020; Sokolova et al., 2009)。这些评价指标可以基于混淆矩阵 (Confusion Matrix) 中的四个基本量来计算，混淆矩阵通常用于二元分类任务的评估，如断层分割，它由四个基本量组成：真正例 True Positive (TP)、真负例 True Negative (TN)、假正例 False Positive (FP) 和假负例 False Negative (FN)。在我们断层检测的任务中，TP 指的是正确预测为断层样本的正样本数量。TN 是准确预测为非断层样本的样本数量。FP 是预测为断层但实际上是非断层的样本数量，而 FN 是预测为非断层但实际上是断层的样本数量。

由于混淆矩阵中的这几个变量主要表现为具体标准下的样本数量，而数量这一指标很难提供在同一标准下的比较。于是，我们通过计算混淆矩阵中这四个基本量的一些二级结果，获得了如下所述的四个被广泛使用的评价指标，使其的值域被约束在 0-1 内，以此进行更为客观、定量的结果对比。

1. 准确率 (Accuracy)

代表了正确的预测样本与总样本数的比例，可以体现出模型的准确度，是最直观的性能指标。通过以下公式计算：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}. \quad (2.1)$$

根据其定义，当应用于正负样本严重不平衡的数据集时，准确率可能会提供误导性的评估，我们无法通过准确率这一指标进行模型的性能评估。就地震数据而言，断层标签的数量只占总样本的一小部分，即使所有样本都被预测为非断层，准确率仍然可以超过 90%。

2. 精确度 (Precision)

精确度代表了预测为正样本的样本中被正确预测的比例，其公式如下：

$$Precision = \frac{TP}{TP + FP}. \quad (2.2)$$

在那些对错误正类预测 (假正例) 有更高的重要度的情况中，比如诈骗电话的检测中，高精度是十分重要的。

3. 召回率 (Recall)

召回率 (Recall)，又被称为灵敏度，其代表了所有的实际为证样本的类别中，被正确预测为正样本的比例，其计算公式如下：

$$Recall = \frac{TP}{TP + FN}. \quad (2.3)$$

对于未检出正类样本（假负例）的代价非常高的应用场景中，如疾病的检查、感染者的筛查等场景，高比例的召回率尤其重要。

4. F1 分数 (F1-score)

F1 分数 (F1-score) 被定义为精确度和召回率的调和平均值，表达了精确度和召回率之间的平衡，可以通过下面的公式计算得出：

$$F1 - score = \frac{2 * Precision * Recall}{Precision + Recall} = \frac{2 * TP}{2 * TP + FP + FN}. \quad (2.4)$$

F1 分数是精确度和召回率的权重同等重要时的计算结果，由于它同时考虑了精确度和召回率，因此 F1 分数可以是一个比单独的精确度或召回率更好的模型评价指标，特别是在类别不平衡的数据集中，其可以在一定程度上克服评价不够全面的问题。

2.1.2 常用的评价指标的缺点和不足

对断层检测任务而言，客观有效的模型评价指标对于定量验证模型性能和评估分割结果的质量是不可或缺的。目前，像精确度、准确率、召回率和 F1 分数这样的基于像素点计算的指标被广泛地用于地震图像的断层分割效果评估。

在实际应用中，这些基于像素点的评价指标的核心关注于预测结果和断层标签是否能逐像素地得到匹配，然而这种形式的计算并不符合断层在地质上的特性，无法提供较为客观合理的评价。

事实上，在地震断层解释中断层标签的位置存在着多方面的不确定性。

第一，专家的手动断层标注存在主观和不确定性。手动标注断层的过程依赖于解释者的经验和对地质数据的理解，这导致了标注结果之间的差异。每个解释者可能会根据自己的专业知识、经验以及对地质特征的理解有所不同，从而在断层的识别和标注上存在主观性。这种主观性和解释者之间的不一致性增加了断层标签位置的不确定性 (Bond et al., 2007)。

第二，在地震数据的采集、数据处理、数据成像过程中也存在一定的误差 (Yilmaz, 2001)。地震数据采集和处理的技术限制导致了数据本身的不确定性。从地震波的传播、反射、到接收，每个环节都可能引入误差。此外，数据处理过程中使用的算法和模型假设也会影响最终成像的准确性。这些因素共同作用，使得断层的识别和定位存在不确定性。

第三, 断层是一个具有一定厚度的破坏区, 而不是以一个单纯的线或是平面构成。断层不是一个简单的几何线或平面, 而是一个具有一定厚度的复杂地质体。这个破坏区可能包含多种岩石类型和不同的物理特性, 这也增加了在地震图像上识别和定位断层的难度。此外, 断层区的复杂性使得在不同的解释和建模方法中, 对其准确描述存在挑战 (Fossen, 2016)。

综上, 断层标签位置的不确定性是由多种因素导致的, 包括人工标注的主观性、数据处理的技术限制, 以及断层本身的复杂性。考虑到上述因素, 针对断层检测任务的评估, 我们需要一种能够对于不可避免的轻微位置偏差有更高容忍度和鲁棒性的评价指标。为此, 我们提出了一种基于距离的评价指标, 称为双向倒角距离 (BCD)。该方法对预测结果与实际标签之间轻微的不匹配表现出较高的鲁棒性, 并能够提供更准确和稳定的结果评估。

2.1.3 基于距离的评价指标

双向倒角距离 (Bidirectional Chamfer Distance, BCD) 是一种用于评价两个点云之间相似度的指标。在计算机视觉和计算机图形学中被广泛应用, 特别是在物体的三维重建、模型的匹配与形态分析等领域。




图 2.1 倒角距离计算示意图

作为一种基于距离的度量方法, 双向倒角距离 (BCD) 常用于衡量两组点云的相似度, 它被证明对于异常点和小的位置不准确性具有鲁棒性 (Fan et al., 2017)。该指标通过测量两个点云中每个点到对方点云中最近点的距离, 来量化两个点云之间的差异, 标签 X 和预测结果 \hat{Y} 之间的 BCD 被定义为如下的计算公式:

$$d(X, \hat{Y}) = \sum_{x \in X} \min_{\hat{y} \in \hat{Y}} \|x - \hat{y}\|^2 + \sum_{\hat{y} \in \hat{Y}} \min_{x \in X} \|x - \hat{y}\|^2 \quad (2.5)$$

在上述公式中, X 和 \hat{Y} 分别代表标签和预测结果的两组点云。 x 和 y 分别代表点云 X 和 \hat{Y} 中的元素 (图 2.1)。 $\|x - y\|$ 代表了点 x 与 y 之间的欧式距离。第一个项 $\sum_{x \in X} \min_{\hat{y} \in \hat{Y}} \|x - \hat{y}\|^2$ 代表从 X 中的任意点 x 到 \hat{Y} 的最小距离之和, 第二个项 $\sum_{\hat{y} \in \hat{Y}} \min_{x \in X} \|x - \hat{y}\|^2$ 代表从 \hat{Y} 中的任意点 y 到 X 的最小距离之和。

BCD 是这两个方向距离的总和，为了方便，在我们的论文中，我们将从标签到预测结果的单向倒角距离称为 L2P-CD，从预测结果到标签的单向倒角距离称为 P2L-CD。

具体来说，双向倒角距离的计算分为两个步骤。首先，从第一个点云中的每个点出发，计算它到第二个点云中所有点的欧氏距离，并找出最小值；然后，反过来，从第二个点云中的每个点出发，执行相同的操作。最后，将这两个步骤中计算出的所有最小距离值取平均，得到的结果就是双向倒角距离。BCD 距离越大，说明两个点云之间的差距越大，反之，则说明两个点云相似程度更高。

由于断层点的数量因不同地震数据而异，会造成具有更多断层发育的地震数据在计算 BCD 时会得到更大的距离总和，这对于模型的比较来说是不公平且不合理的。因此，我们对原来的计算方式进行了修改来计算平均的距离，其公式如下：

$$d(X, \hat{Y}) = \frac{1}{N_X} \sum_{x \in X} \min_{\hat{y} \in \hat{Y}} \|x - \hat{y}\|^2 + \frac{1}{N_{\hat{Y}}} \sum_{\hat{y} \in \hat{Y}} \min_{x \in X} \|x - \hat{y}\|^2, \quad (2.6)$$

其中 N_X 和 $N_{\hat{Y}}$ 分别代表标签和预测结果中断层的数量。

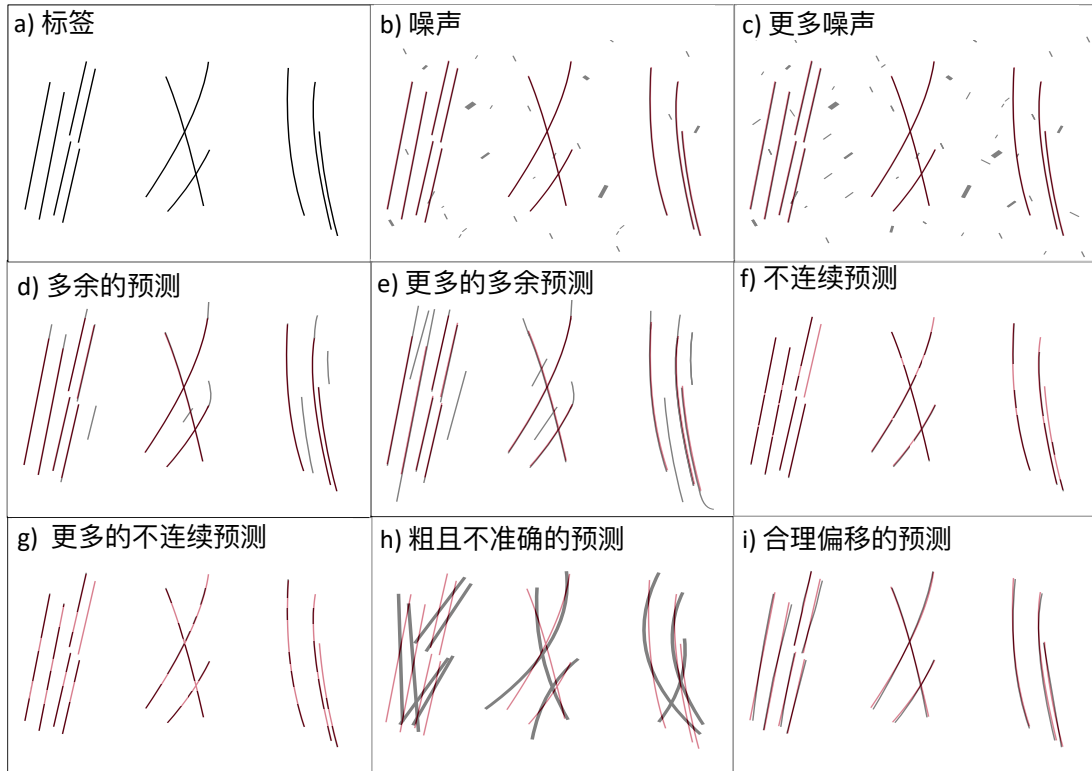
在实际的应用中，断层属性体的每个样本点的值通常在 0 到 1 之间，而断层的标签是由 0 和 1 组成的一个二值图像。为了简化 BCD 计算，我们使用了一个阈值来对断层概率体进行后处理，从而将原始的断层概率体转换为和标签一致的二值体。在我们的研究中，我们将这个阈值设定为 0.5，大于 0.5 的样本点，我们将其赋值为 1，小于 0.5 的点，我们将其赋值为 0。

2.2 断层评价指标的对比和优选

为了验证我们提出的评价指标在断层检测模型评估中的有效性，我们模拟了通常会在模型的预测结果中出现的各种情况，如断不连续的预测、带有噪点的预测、额外的预测等，并进行了上述指标之间的比较实验。

2.2.1 断层预测模拟实验

为了评估我们的指标，我们设计了断层的标签 (Figure 2.2a)，并模拟了其 8 种可能的断层预测结果 (Figures 2.2b~ 2.2i)。图 Figures 2.2 b 和 c 模拟了断层检测结果含有噪点的情况。图 Figures 2.2 d 和 e 模拟了断层检测结果出现多余预测的情况。图 Figures 2.2 f 和 g 模拟了断层检测结果预测不连续的情况。为了测试和对比，基于像素和基于距离计算的评价指标对上述三种断层预测可能出现的情况的敏感度，我们使图 Figures 2.2 c、e、g 中的预测结果比图 Figures 2.2 b、d、f 中的更糟。



断层检测评价结果

断层检测的情况	基于像素点的评价指标				基于距离的评价指标		
	Precision ↑	Recall ↑	F1 Score ↑	Accuracy ↑	L2P-CD ↓	P2L-CD ↓	BCD ↓
b	0.8423	1	0.9144	0.9937	0	3.3636	3.3636
c	0.7678	1	0.8687	0.9898	0	4.4201	4.4201
d	0.8010	1	0.8894	0.9907	0	1.5087	1.5087
e	0.6560	1	0.7923	0.9817	0	2.9688	2.9688
f	1	0.7969	0.8870	0.9931	0.9226	0	0.9226
g	1	0.6313	0.7740	0.9875	1.7661	0	1.7661
h	0.1765	0.3276	0.2294	0.9255	2.0323	2.5180	4.5503
i	0.2232	0.2261	0.2246	0.9472	0.4342	0.4357	0.8729

图 2.2 断层检测评价指标模拟实验与定量对比

注：图 2.2a 是我们设计的一个断层标签，图 2.2b~i 代表八种可能的检测结果。下表展示了上述八种检测结果分别在基于像素点的和基于距离的评价指标下的评估结果。

此外，在实践中，我们发现使用不同损失函数训练的神经网络模型，在模型预测时，预测的断层粗细（横向分辨率）会有所不同。在某些损失函数下，模型的断层检测结果会呈现出较粗的情况，如图 Figures 2.2 h 所示，其分辨率较低。

最后，图 Figures 2.2 i 模拟了一种情况，该情况下的断层预测结果并不是和断层标签在像素上一一对应，但是，其是以上所有检测结果中，更符合地质认知，最满足断层形态和准确性的合理预测结果。

有了上述的模拟断层标签和几种情况下的断层检测结果，我们分别使用前面介绍的几种基于像素点计算的评价指标和我们提出的基于距离的双向倒角距

离计算多种情况下的模型评估结果，分数显示在图 Figures 2.2中的表格里。

2.2.2 评价指标的对比

从地质上看，图 Figures 2.2 i 中的断层预测最符合标签，在定量评估中得分应该最高。图 Figures 2.2 h 应该是最差的结果，因为其分辨率低且预测不准确。然而，从表格中的结果上看，基于像素的指标都显示出不可靠的评估，甚至图 Figures 2.2i 的得分比其他案例都低。

对于精确度 (Precision) 的评估而言，即使某些模型预测的断层结果未被检测出来，且结果是不连续的，例如图 Figures 2.2 f 和 g 也获得了 100% 的准确率。

同样不合理的评估结果也出现在召回率 (Recall) 的评估结果中，案例 b、c、d 和 e，召回率获得了 100% 的完美得分，但是这些检测结果中存在着明显的噪点和错误预测的情况。

对于 F1 分数 (F1-score) 的评估结果，由于它可以被视为召回率和精确度的调和平均数，其对模型的评价更加的合理，对图 Figures 2.2 b-g 的断层检测的评估比较合理，对于不正确的预测能很好的体现在的得分中。但是，当 F1 分数应用于最后两种情况时，仍然存在异常情况。根据我们之前的分析，图 Figures 2.2 i 中的预测远远优于图 Figures 2.2 h 中的预测，并且应该获得更高的评估分数，而图 Figures 2.2 h 得到了更高的 F1-分数。

当准确率 (Accuracy) 应用于所有情况下的检测结果时，它们之间的得分没有明显的差距，都高达 90% 以上。造成这种敏感度不高的评价的原因是由于地震数据中断层像素和非断层像素的数量分布不平衡导致的。即使模型在地震数据中没有检测到断层，它也可以获得高于 90% 的准确率。毫无疑问，准确率无法提供可信赖和精细的结果评价。

相比之下，使用我们提出的基于距离的指标 BCD 来对图 Figures 2.2中的结果进行评估时，相比基于像素的几个评价指标，具有更稳定与合理的评估。双向 Chamfer 距离的关键方面是考虑了两个方向上的距离。这种双向方法确保了更稳健和对称的距离测量，因为它考虑了两组中的最近邻距离。

为了获得更详细和全面的评估，除了双向倒角距离 (BCD) 之外，我们还额外计算了从标签到预测的单向倒角距离 (L2P-CD) 和从预测到标签的单向倒角距离 (P2L-CD)。从下表的结果中，我们发现 P2L-CD 类似于精确度，而 L2P-CD 类似于召回率，这也可以通过它们的公式和定义证明。与 F1 分数相比，BCD 提供了更现实的评估。特别是，对图 Figures 2.2 h 进行评估时，即使由于其断层检测结果较粗，使其预测结果和标签更多的重叠像素，这种横向上的低分辨率也受到 BCD 评价指标的惩罚。预测图 Figures 2.2i 时，是唯一一个给出最高分数和最公正的评价指标。




图 2.3 断层检测结果和对应的 L2P-CD 可视化图

注：图 2.3a 展示的是断层检测结果（红色）和标签（白色）的叠加显示图，图 2.3b 展示的是标签到预测结果的倒角距离的可视化

除了其稳定性外，通过绘制每个标签点到预测结果的最小距离的距离图（图 2.3b），BCD 还能够更直观地刻画断层检测结果的好坏。在图 2.3b 中，彩色区域与预测未能匹配标签的地方一致，这有助于我们找出模型预测机构在哪里以及在多大程度上与标签不匹配。根据色标，数值较高的区域意味着更糟糕的预测性能，这可以为我们的进一步对模型进行改进和优提供更具体的指导。

从上述实验中，我们可以得出结论，在评估模型性能时，我们不能单纯参考单一的指标。就准确率而言，对于正负像素分布不均衡的数据来说，并不适用。准确率（Accuracy）对于正负样本分布不均衡的数据，会出现评估结果区分度不大，无法客观描述模型效果的问题。召回率（Recall）显示了预测与标签的匹配程度，但不能指示预测是否包含噪点或不真实的断层预测。精确度（Precision）可以揭示我们所预测的断层点是否被正确预测，但无法度量检测的连续性和完整性。在一定程度上，F1-分数（F1-score）通过计算召回率和精确度的平均值，可以较为公平地衡量模型的性能。然而，当断层预测结果与标签无法逐像素地对应时，F1-分数仍然不能提供客观的评估。相比之下，双向倒角距离是基于距离来刻画预测的好坏，可以很好地适应断层检测任务的特征，并提供合理且客观的评估。

在我们的模拟实验中，我们假设断层标签完全准确。但实际上，在上面我们所分析的多个因素可能会导致断层标签的不确定性。当考虑断层标签的不确定性时，这些基于像素的指标将表现得更差。由于双向倒角距离是通过距离定义的，它可以容忍标签的不确定性，仍然可以获得稳定的评估结果。

2.3 人工标注的地震断层检测验证集

1. 实际地震数据验证集的重要性

由于实际地震数据的断层标签无法直接获得，这造成目前断层检测领域，缺少实际地震数据的验证集。通常情况下，地震数据的断层标签需要专家详细地手工标注，这一工作流程不仅需要很大的时间成本，也需要相关的专业知识。但是，构建一个来自于实际地震数据的断层检测验证集，对于地球物理断层检测方法的定量评估与效果对比有着重要的意义。

首先，与计算机视觉领域丰富且成熟的公开标准验证集相比，目前地球物理勘探领域，包括断层检测任务，都普遍缺乏一个公开的，标准的验证集。这一情况，限制了目前断层检测的各类算法和模型之间定量的性能比较。一个公开的、有代表性的实际数据验证集，不仅可以促进现有断层检测算法的发展，也为研究人员提供了一个对比的基准。

此外，虽然目前有大量开源的合成地震数据和对应的断层标签，但是这些数据是通过正演地下的地质活动，再模拟地球物理过程得到的合成数据，其断层的形态、构造类型等方面，无法完全地模拟实际地下结构的特征。只有在实际数据上进行模型验证，才能真正评估模型的泛化能力和实际应用效果。实际数据通常比人为生成的数据集更为复杂和多变，涵盖了更广泛的不确定情况和可能性。因此，在实际地震数据集上进行测试和验证模型，更能够为科研人员提供模型之间更准确的性能指标和对比，并确保现有的算法能够很好地泛化于实际复杂的实际地震工区。

总之，构建一个由实际数据组成的、具有专业标注的断层检测验证集，对于更为客观且定量的进行目前断层检测技术的评估、对比有着重大的意义。这不仅完善模型的性能评估流程，也能方便对目前技术进行对比和分析，进一步促进断层检测领域的发展。

2. 验证集人工标注

为了解决地球物理断层检测任务，缺乏实际地震数据的标准验证集的问题，我们进行了实际地震数据的筛选、地震断层的标注等一系列流程，构建了一个由实际地震数据组成的断层检测验证集。

首先，我们对目前可以获得的实际地震数据进行了严格的分析和筛选，最终选择了四个具有代表性的实际地震数据集。这些数据集被认为在数据质量、断层构造和复杂性方面具有足够的多样性，能够全面考验断层检测模型的性能。其次，为了确保验证数据集内来自于不同工区数据的一致性和可比性，我们对选定的四个地震数据进行了统一的数据归一化处理。通过这一过程之后，我们通过切片和筛选，我们最终得到了 70 个维度为 128×128 的二维地震数据切片。最




图 2.4 专家标注的断层标签验证集

注：图 2.4展示的是从 70 个专家标注的二维断层验证集中选取的六个数据的地震图像和断层标签的叠加显示图

后，利用标注软件，由领域专家对每个地震数据切片中的断层特征进行了仔细的人工标注，确保了标注的精确性和一致性。通过这种方式，我们为每个切片提供了准确的断层标签（图 2.4），为模型训练和验证提供了宝贵的标签数据。

本研究中，我们经过实际地震数据的精选和预处理，以及后续专家级的人工标注，构建了一个高质量的断层检测验证集。这一验证集不仅为评估断层检测模型在实际地震数据上的性能提供了必要的基础，而且也为地质勘探领域的研究人员提供了一个共享的资源，促进了领域研究的进步。

2.4 本章小结

在本章中，我们深入探讨了断层检测的定量评价指标，通过对比分析基于像素点计算的评价方法的局限性，并提出一个基于距离计算的评价指标——双向倒角距离（BCD）。本章节内容的详细分点总结如下：

1. 基于像素点计算的评价指标我们从每个指标的定义、计算方法等方面详细介绍和讨论了准确率、精确度、召回率和 F1 分数这些基于像素点计算的评价指标。这些指标基于混淆矩阵计算，广泛应用于语义分割和断层检测任务中。我们通过定量的实验和分析，揭示了基于像素点的评价指标在评估断层检测结果

的不足。由于实际地震数据的断层标签存在着不确定性，如专家标注的主观性、地震数据处理的误差，以及断层构造本身的复杂性，传统的基于像素计算的评价指标往往不能提供准确和客观的性能评估。

2. 基于距离的评价指标

由于传统基于像素点计算的断层检测评价指标存在着局限性，我们设计了双向倒角距离这一基于距离计算的评价指标，并详细展示了 **BCD** 的计算公式。双向倒角距离通过测量两组点集之间的倒角距离来评估双方的相似度，对于标签和预测结果之间小的位置不匹配显示出较好的容忍度和稳定性。此外，通过可视化标签点到预测结果的倒角距离，我们能更为直观地刻画出预测结果与实际断层标签之间的差异，为模型的改进提供更具体的指导。

3. 模拟实验与评价指标对比

通过模拟实验，本章定量地展示了不同预测情况下基于像素点和基于距离的评价指标的得分。我们设计了包括了存在噪点的预测、出现多余的预测、不连续的预测等各种可能的断层预测情况，并对比了这些情况下传统基于像素点计算的评价指标与 **BCD** 的敏感度和合理性。

综上，本章的研究成果，揭示了在断层检测任务中，传统的基于像素点的评价指标可能不足以提供准确和客观的模型性能评估。相比之下，**BCD** 作为一种基于距离的评价指标，能够有效克服这些局限性，为地震数据分析中的断层检测提供了一种更可靠的评估方法。

第3章 基于卷积神经网络的断层检测优化

3.1 基于 U-Net 的断层检测模型设计

为了深入探讨影响基于 CNN 的断层检测模型效果的影响因素，并得出在断层检测领域更为普遍且适用的结论，我们分析了目前基于深度学习的断层检测研究，梳理并调研了一些系统性的综述 (An et al., 2023)。我们选择了在图像分割中广受欢迎的 U-Net 模型，以及 Wu et al. (2019a) 提出的合成断层数据集作为我们的实验基础模型和数据集，因为 U-Net 模型在地震断层检测领域中的使用非常普遍（占 86.1%），并且 Wu et al. (2019a) 的开源合成训练数据集也被广泛使用于目前的断层检测研究（超过 80%）。

3.1.1 卷积神经网络基本理论

卷积神经网络（CNN）是深度学习中一种高效且主流的基于卷积层构建的深层神经网络，被广泛的应用于图像处理、自然语言处理等各种领域。本节将介绍卷积神经网络的几个基础的概念包括：卷积层和池化层的概念和计算，几个常见的激活函数，损失函数与优化器。

1. 卷积层和池化层

卷积层是 CNN 的核心与基础结构，通过卷积核对输入的特征进行多次的卷积计算，来进行数据特征的提取和过滤。不同的卷积核设计，可以起到对不同特征的提取，例如边缘提取，色彩提取等。卷积核对于输入数据的卷积计算，通过权值共享，起到了减少模型参数数量的作用。

卷积的具体计算过程，如下图 3.1 所示：

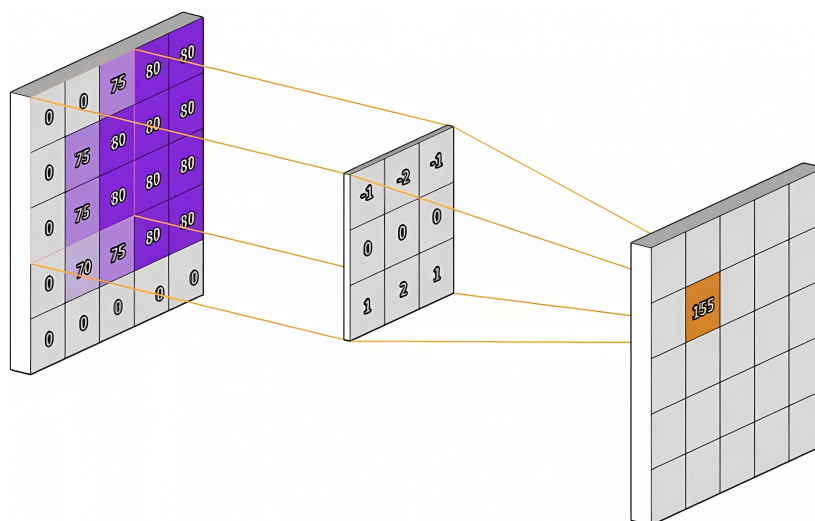


图 3.1 卷积过程示意图

如上图展示的是一个二维卷积的过程，紫色方框代表的输入数据是一个 5×5 的矩阵，灰色矩阵代表的卷积核的尺寸为 3×3 ，最后的输出矩阵用橙色方框代表。确定了卷积核的大小之后，步长（stride）和填充（padding）也是卷积运算中的重要参数。填充操作通过在矩阵周围补零或复制临近值，可以保证卷积之后的特征图的尺寸不变。我们按照设定的步长和填充，进行滑动的卷积计算，将卷积核的中心依次对准输入特征的像素点，计算卷积核覆盖区域的元素的加权后的和，也就得到了图中红色框所示的输出结果。上述的卷积计算公式如下：

$$O_{i,j} = \sum_m \sum_n I_{i+m,j+n} \cdot K_{m,n} \quad (3.1)$$

其中， $O_{i,j}$ 是输出矩阵中的元素， I 是输入矩阵， K 是卷积核矩阵， m 和 n 分别是卷积核的行和列索引。

和卷积操作类似，池化层也是 CNN 的重要结构之一。池化层可以起到降低特征图的大小，减少参数量，并提高模型表现能力的作用。常用的池化操作有最大池化（Max Pooling）和平均池化（Average Pooling）两种。最大池化是提取卷积核区域内的最大值作为卷积结果，而平均池化则是通过计算卷积核区域内的平均值来作为卷积的结果。其具体的实现，可以参考下面的图示 3.2：

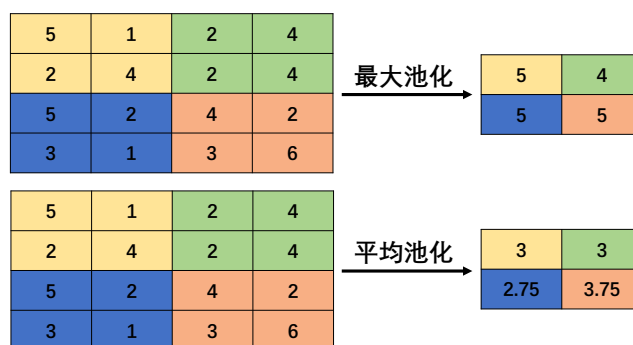


图 3.2 池化过程示意图

2. 激活函数

激活函数在 CNN 模型中也起着十分重要的作用，其决定着神经元的非线性输出，通过激活函数才能将非线性的结构引入到模型中，使模型的表现力和复杂度得到增强。目前，激活函数这一领域得到了广泛的研究，下面我们介绍一些常用的激活函数：

(1) ReLU (Rectified Linear Unit) 函数：ReLU 函数又称为修正线性单元，其公式如下：

$$\text{ReLU}(x) = \max(0, x) \quad (3.2)$$

其作用是，使小于 0 的输出结果被赋值为 0，能在一定程度上加快模型梯度的计算和训练的速度，克服梯度消失的影响 (Nair et al., 2010)。

(2) **Sigmoid** 函数：本激活函数用于将输入函数的值投射到 $(0, 1)$ 的区间内，其公式如下：

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$

由于 **Sigmoid** 函数可以将输出结果控制在 0 到 1 之间，通常被用在网络的最后几层，来作为而分类模型的输出 (Han et al., 1995)。

(3) **Softmax** 函数：**softmax** 函数和 **sigmoid** 函数类似，可以将一个 n 维的输入映射到 k 个类别的概率分布，对于第 i 类，**softmax** 的定义如下：

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.4)$$

softmax 可以确保多类的输出结果的和为 1 ，很好的作用于多分类任务 (Bridle, 1990)。

3. 损失函数与优化器

损失函数 (Loss Function) 是模型训练的核心，其控制着模型收敛的方向。在模型的训练过程中，我们通过损失函数来计算模型预测结果和真实标签之间的差异，并通过迭代不断地最小化损失函数的值，来优化模型效果。

优化器 (Optimizer) 则在训练过程中起到了控制模型权重，以最小化损失函数值的作用。优化器的算法很多，其核心是通过计算损失函数的梯度，通过梯度参与到模型权重的更新。目前常用的优化算法包括梯度下降 (Gradient Descent)、随机梯度下降 (SGD)、Adam 等。Adam 优化器结合了动量和自适应学习率的特点，能够在不同的参数更新方向上动态调整学习率，因其高效而被广泛使用。

3.1.2 U-Net 模型结构与超参数

U-Net 网络是图像分割领域被广泛使用的经典模型，其名称来源于其 U 型的编码器-解码器结构。U-Net 通过端到端的训练，可以直接输出和输入的图像同尺寸的分割结果。其多尺度的特征提取与跳跃连接 (skip connections) 操作，使得模型可以获得不同空间尺度下的图像特征，同时保留更为细节的语义信息。

Wu et al. (2019a) 基于 U-Net 设计了一个断层检测的网络模型，我们接下来的实验和测试，都将以这个模型 (图 3.3) 作为基线模型。具体地，U-Net 由收缩支路 (contracting path) 和扩展支路 (expansive path) 两个部分构成。在收缩支路这一部分，网络对输入的图像进行了三次池化操作，每次池化后，模型的特征图大小缩小一倍，同时特征通道数增加一倍。在扩展支路这一部分，网络通过三次上采样的操作，将特征图还原至原尺寸。同时，模型采用跳跃连接的策略，将收缩路径的特征图 and 对应扩展支路的特征图进行组合。在网络的输出层，模型使用 **Sigmoid** 激活函数，将通道数为 16 的特征图转化为一个和输入图像维度一




图 3.3 U-Net 断层检测网络图 (Wu et al., 2019a)

致的断层概率图。在模型的训练中，使用平衡交叉熵损失函数进行训练，采用了 Adam 优化器来优化模型的权重，学习率设置为 0.0001。

3.2 断层训练样本对模型效果的影响

作为一个有监督的深度学习任务，地震断层检测模型通常需要大量的训练数据集和对应的断层标签。然而地震图像中的断层标签是很难获取的，而人工标记地震数据中的断层，尤其是在三维地震数据中，是一项艰巨且耗时的工作。

为了解决断层标签难以获得的这个问题，Wu et al. (2019a) 提出了一个工作流程，可以自动生成大量的地震数据及其相应的具有各种结构模式的断层标签。基于此工作流程生成的数据集，该工作训练了一个 U-Net 断层检测模型，其在大多数的实际地震数据中有着不错的效果，这一数据的合成流程也被证明是可行且有效的。

然而，由于实际地震数据的断层模式和数据采集参数多样，使得基于上述合成数据训练的模型在实际工区中的泛化能力存在局限和不足。为了提高 CNN 断层检测的性能，本工作从以下三个方面来优化合成数据集：地震数据中的断层特征、背景噪声、合成数据集的采样率和频率。

3.2.1 断层反射特征

在断层检测模型实际应用时，我们观察到，在一些实际地震工区数据中，一些具有较小倾角的断层，在地震图像对应的位置会出现一个很明显的断面反射特征，这些断面波特征在图 3.4 中被黄色箭头标示出来。

然而，这种断面反射波的特征，在之前的合成数据生成的算法下是无法模拟的。由此产生的问题是，使用原来工作流程（图 3.5）得到的数据集训练的断层检测模型，在识别这类断层时表现不佳，这一点在图 3.8 c 和 d 中得到了明显的体现。




图 3.4 地震数据断面波

注：图 3.4 a 和 b 展示了分别来自于两个工区的地震图像，其中箭头所指示的是断层的断面波特征

为了提升合成地震数据的真实性，我们根据图 3.5 蓝色箭头展示的工作流程，我们对数据生成流程进行了调整和优化。

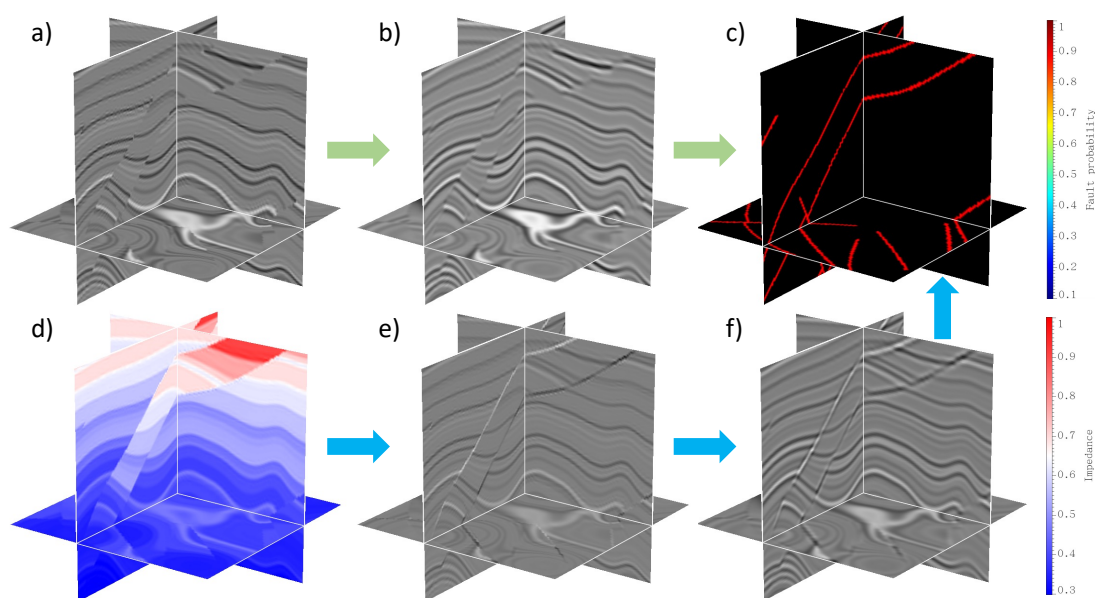


图 3.5 新、旧数据集生成的工作流程对比

注：三维合成地震数据集及其标签的生成流程对比。在Wu et al. (2019a) 的工作流程中（绿色箭头），首先生成一个反射率模型 (a)，该模型使用-1~1 范围内的随机值，然后与 Ricker 小波褶积，获得合成地震图像 (b)，其中断层表现为锐利的反射不连续性，其对应的断层标签显示在 (c) 中。在我们优化的工作流中，首先生成一个阻抗模型 (d)，从中我们计算出一个反射率模型 (e)，在断层处由于断层上盘和下盘之间具有高阻抗差异，使得在断面上能获得一个高反射率值。这些在断层处的高反射率在与 Ricker 小波卷积后产生明显的反射特征，这与图 3.4 中的断层特征更加一致。

在这个新的工作流程中，我们的第一步是生成一个初始的阻抗模型，标记为 $p(x, y, z)$ 。接下来与之前的流程一致，我们在 p 模型中加入了一些褶皱结构和平面剪切结构。紧接着，我们在模型中引入断层结构，通过这一步骤，得到了一个包含褶皱和断层的阻抗，如图 3.5 (d) 的结果所示。在此波阻抗模型的基础上，

我们计算对应的反射率模型 $r(x, y, z)$ 。这与原先直接生成反射率模型的流程是不同的，通过改进后的工作流程，我们在断层平面上会得到特定的反射系数，这些反射系数在与雷克子波褶积时，能够形成我们所需要的明显的断面波的特征。

需要指出的是，我们并不是在所有断层模式中都选择生成这样的断层断面波的反射特征。我们的合成地震数据中是否存在这样强烈的断层断面波特征，取决于断层的上盘和下盘之间的波阻抗差异，以及断层的倾斜角度。这样，也使得我们合成数据集的断层特征更加符合实际且具有多样性。

3.2.2 背景噪声

为了提升合成训练数据集的真实性，我们对原有数据集合成流程中的背景噪声进行了进一步的改进。在之前的合成数据生成流程中，背景噪声通常是通过随机生成的高斯噪声来模拟，这种方法简便易行，但却忽略了一个关键问题：高斯噪声与实际工作环境中存在的噪声模式相比，往往差异甚远。这种差异可能会导致合成数据与真实地震数据之间存在偏差，进而影响到数据集在实际应用中的效果和可靠性。




图 3.6 获取实际地震数据背景噪声流程图

注：图 3.6 a 展示的是一个三维地震图像，图 3.6 b 展示的是对三维地震数据做沿着构造导向的平滑处理后的结果，图 3.6 c 展示的是将原地震数据和平滑后的地震数据做差得到实际地震数据背景噪声。

鉴于此，我们采取了一种如图 3.6 所示的方法来获取更加真实的地震数据背景噪声。我们直接从实际地震数据（图 3.6 a）中提取噪声，而不是依赖于理论模型的随机生成。首先，我们对实际地震数据进行由构造导向的平滑处理，这种平滑操作可以有效地保留地震图像中的主要结构特征，同时去除其中的随机噪声

成分，从而得到一个去噪的地震数据版本（图 3.6 b）。




图 3.7 合成地震数据分别加入随机高斯噪声 (a) 和实际地震数据的背景噪声 (b)

在平滑处理之后，我们通过将原始地震数据与其平滑后的版本做减法操作，提取出了实际地震图像中的背景噪声（图 3.6 c）。接下来，我们将提取出来的背景噪声应用到合成地震数据中。为了实现这一目标，我们首先设定了一个随机的信噪比（SNR），以保证添加到无噪声合成数据中的噪声既真实又不会过分干扰数据的基本特征。通过上面的方法，我们能生成既包含真实背景噪声又保持特定信噪比的最终合成地震数据集。

图 3.7 显示了带有随机噪声和真实噪声的合成地震图像，通过对比可以看出，加入从真实地震数据中提取的背景噪声的优势在于，我们可以创建出更加真实、更接近实际地震数据的训练数据集。

为了评估我们新工作流程模拟出的合成训练数据集的有效性，我们采用了一种对比实验的方法。我们使用新旧两种工作流程生成的数据集分别训练了两个模型，并将这两个模型应用于同一批实际地震数据中，模型的预测结果展示在图 3.8 中。

在图 3.8a 和 b 所展示的实际地震图像中，我们可以清楚地看到一系列具有如黄色箭头所示的明显断面波特征的断层。图 3.8 e 和 f 展示的预测结果，是使用改进后的合成地震数据集训练的模型预测得到的，其对这些具有断面波的断层模式进行了准确的检测。相比之下，如图 3.8c 和 d 所示的结果，是使用原始工作流程得到的合成地震数据集训练的模型在实际地震数据上的检测结果，可以明显看出，这些具有断面反射波特征的断层没有被有效地识别出来，同时检测结果中还伴随有大量的噪点。

通过这一比较，显而易见，采用新数据集训练出的模型在性能上有了显著的提升，特别是在处理包含具有断面反射波特征的地震数据时，展现出更好的泛化能力。




图 3.8 新、旧数据集在有断面波特征地震数据下的断层检测对比

注：与大多数以明显的反射轴不连续性为特征的断层不同，如 (a) 和 (b) 中黄色箭头所示的一些断层在断面上表现出明显的反射波特征。由 Wu et al. (2019a) 训练的 CNN 模型对于具有反射波特征的断层的检测效果不佳，如 (c) 和 (d) 所示。如 (e) 和 (f) 所示，通过使用具有此断层特征的新训练数据集重新训练的 CNN 模型，断层检测显著改善。

3.2.3 数据采样率

在实际的地震资料采集过程中，由于采集仪器的差异和对精度的不同要求，所得到的实际地震数据的采样率呈现多样性。这种采样率的差异对地震图像中的地质构造，包括断层的尺度和角度等关键特征，具有显著影响。而卷积神经网络在训练结束后，模型的、网络感受野的范围是固定的，模型在训练和预测推理的过程中都是在这一固定视野下进行断层特征提取和识别。但断层的特征会随着采样率的改变而发生变化，这就要求我们的网络能够准确识别和理解在不同采样率下的断层形态，从而更好地泛化于采样率多变的实际地震数据之上。

基于上述的思路，我们认为模型需要通过在不同采样率下的地震数据上进




图 3.9 人类视觉系统感受野示意图

行训练，以此学会断层构造在不同采样率下的不同特征。这样，即使在采样率多样化的实际应用场景中，我们的模型也能够准确地进行断层特征提取和识别，提高地震断层检测的准确度和泛化性。接下来，我们会论证训练数据采样率的增广对模型效果的影响以及从感受野的角度来解读其背后的原理。

1. CNN 的感受野

和深度学习中的很多来自于神经科学的术语类似，感受野（Receptive Field, RF）这一概念最早也是出自于人类视觉系统对人感官空间的定义。生物神经元的感受野指的是：在感受空间内收到刺激时，神经元产生反应的部分。如下图 3.9 所示，图中的网格是人眼可以看到的整个区域，也被称为视野。在人类的视觉系统中，由上百万个神经元组成，而单个神经元能感受到的信息占整个视野的区域大小就被称为感受野。

同样的，在深度学习领域中的感受野被类似地定义为：CNN 某一层特征图的像素点对应于原始输入图像局部的区域大小。特征图每个像素的感受野越大，也就代表着其具有更大的提取信息的视野范围，包含了更全局、更高级的语义信息。

如上图 3.10 所示的是一个两层卷积操作网络模型的感受野计算的示意图：输入层的尺寸为 5×5 ，使用卷积核大小为 3×3 （ $stride=1$ ， $padding='SAME'$ ）后，从示意图中我们可以看出其感受野的大小为 5×5 。具体的，CNN 的感受野的计算可以总结为下面的计算公式：这是单独成行的公式：

$$RF_i = (RF_{i+1} - 1) \times stride_i + K_{size_i} \quad (3.5)$$

其中， RF_i 表示 i 层的感受野大小， i 表示第 i 个特征层， $stride$ 表示卷积的步长， K_{size} 表示当前层的卷积核大小。

通过上面的公式计算得到的网络感受野往往比较大，但实际上，并非感受野




图 3.10 深度神经网络感受野计算示意图

中所有的像素对于输出的特征图都有着相同权重的贡献。Luo et al. (2016) 的研究证明，感受野存在一个有效区域，被称为有效感受野 (Effective Receptive Field)，它服从一个高斯分布，从中心到四周衰减，且不同的激活函数对于 CNN 的有效感受野的影响是不同的。同时，通过使用池化操作和膨胀卷积能有效的增加模型的有效感受野，如下图所示：




图 3.11 不同模型下的有效感受野

2. 合成数据的采样率增广

CNN 的感受野，决定了模型提取和学习输入数据特征的视野大小，这对于断层检测任务也同样重要。具体来说，在断层的检测任务中，CNN 的最终输出是输入地震数据中每个像素相对应的一个断层概率图。

为了更直观的展示 U-Net 模型的感受野，如图 3.12 所示，我们绘制了 U-Net 的感受野，用彩色的色标进行展示，并将其与地震数据图像进行叠加显示。

如上图所示，我们可以很明显地看到，U-Net 的感受野范围其实是有限的，无法涵盖地震图像中一些大尺度的断层。但是，在理想情况下，我们希望我们的模型可以有一个更大的有效感受野，在一个大的视野下接受来自地震数据更为

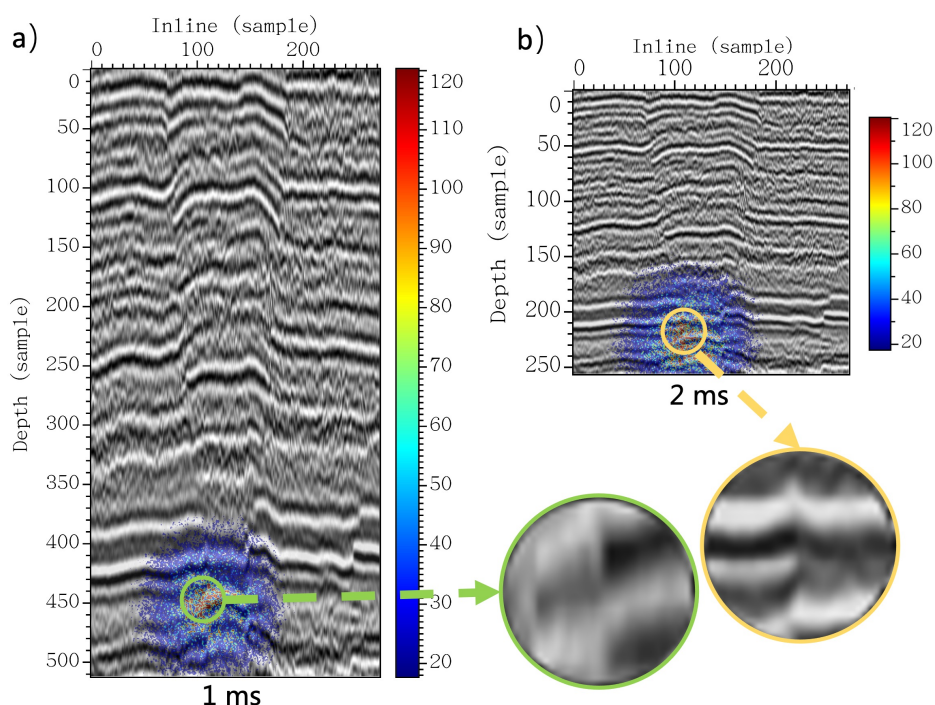


图 3.12 U-Net 感受野和地震数据叠加展示图

注：二维地震图像及其对应的 U-Net 模型有效感受野（叠加显示在地震图像上），采样间隔分别为 1 毫秒（a）和 2 毫秒（b）。

全局的信息，这样才能保证模型输出更为稳定且连续的预测结果。

由于 CNN 模型有效感受野主要与模型的结构有关，在模型训练后是固定的，这也意味着，在训练过程中，模型只能从固定的视野中学习和提取来自于地震数据图像中的断层特征。而在固定视野下，随着地震数据采样率的改变，断层特征会发生很明显的变化。

为了更加直观的说明上述的问题，如图 3.12 中所示，我们从一个实际地震数据中选择了二维切片，通过下采样，我们分别获得了该区域在 1ms 和 2ms 垂直采样间隔下的地震图像。

很明显，在这两幅图像中，即使是同一个地震数据，仅仅改变了其垂向的采样率，同一个断层的形态和尺度发生了巨大的变化，断层在地震图像中的倾角也发生了变化。在图 3.12 中，我们在两个实际地震图像相对应的同一个区域绘制了 U-Net 的有效感受野，图中的小圆圈代表我们所选择的模型有效感受野中的一个区域，大圆圈则显示了小圆圈区域内地震图像特征的放大视图。

2ms 采样间隔的地震图像仍然保留了清晰的断层特征，而 1ms 采样间隔的地震图像中的断层特征变得模糊且与 2ms 采样下的特征不同。所以，即使对于相同的地震数据，仅仅改变采样率也会导致断层的形态和尺度发生显著变化，从而影响断层在图像中的表示方式。

对于通过固定采样率的数据集训练的模型来说，识别和学习不同采样率下




图 3.13 数据集采样率增广示意图

的断层特征是困难的，进一步证实了固定感受野在处理多尺度地质结构时的局限性。为了提高通过合成数据集训练的模型的泛化能力，我们丰富了数据集的采样率，使其能使模型更好地适应实际地震数据。

需要注意的是，地震数据的频率与采样率密切相关，这两个因素共同影响地震中明显的断层几何形状。在生成合成训练数据集的阶段，我们已经随机设置了 Ricker 小波的各种峰值频率。所以这里，我们只考虑在训练过程中使用不同采样间隔来进行训练数据集的增强。

基于上面的思路，我们沿着垂向方向，将我们的合成数据集的维度从 $128 \times 128 \times 128$ 上采样到 $256 \times 128 \times 128$ ，如上图 3.13 所示。然后，我们将原始的合成数据与上采样后的数据混合，构成我们的新的具有混合的采样间隔的训练数据集。我们将在下一节中进行实验，以验证通过多尺度数据训练的断层检测模型的效果。

3.3 网络模型超参数对模型效果的影响

除了训练数据集之外，网络超参数也是一个重要因素，它显著地影响网络性能。为了深入研究超参数如何影响断层分割的效果，并明确网络架构设计的基本准则，本章讨论了下面三个关键的神经网络超参数：损失函数、网络层数和通道数。

在实验的网络模型选择方面，我们选择了 Wu et al. (2019a) 在 2019 年提出的 FaultSeg3D 中使用的简化版 U-Net 架构作为基准模型。这样做是因为该网络模型被广泛地用于地震断层检测，通过对这一经典模型的探究，能获得更为普适性的结论经验。

3.3.1 损失函数对模型效果的影响

损失函数是网络训练的基石，因为整个网络的训练流程都是由损失函数控制并推进的。特别是在断层分割任务中，由于断层标签中的断层样本与非断层样本之间存在着高度的不平衡分布，这种不均衡可能会误导网络选择全部预测非断层样本，以此来最小化通常用于二元分割任务的一些损失函数。

因此，为了提高我们的断层分割任务的准确性，选择一个合适的损失函数显得尤为关键。针对这一问题，我们挑选了三种能够有效处理数据不平衡的损失函数：平衡交叉熵（Balanced Cross Entropy, BCE）损失、均方误差（Mean Squared Error, MSE）损失以及平衡 CE-Dice 损失。

下面，我们设计了一系列对比实验，以探究在不同损失函数作用下网络性能的差异。

1. 平衡交叉熵损失（BCE）

平衡交叉熵损失（BCE）损失函数是一种基于二分类交叉熵（Binary Cross Entropy）改进的损失函数，用于解决数据类别不平衡问题，尤其是在二分类任务中 (Xie et al., 2015)。在很多实际应用中，例如医疗图像分析、文本分类和物体检测等领域，数据往往存在较大的类别不平衡性，即某一类的样本数量远多于另一类。这种不平衡性会导致模型倾向于预测数量较多的类别，从而忽略掉数量较少但同样重要的类别。

Balanced Cross-Entropy Loss 通过调整损失函数中每个类别的权重来解决这个问题，提高模型对少数类别的识别能力，其基本公式可以表示为：

$$\mathcal{L}_{\text{Balanced-CE}} = -\beta \sum_{i=0}^{i=N} y_i \log(p_i) - (1 - \beta) \sum_{i=0}^{i=N} (1 - y_i) \log(1 - p_i), \quad (3.6)$$

其中， N 是样本总数， y_i 是样本 i 的真实标签， p_i 是模型预测样本 i 为正类的概率， β 是平衡因子，用于调整正负样本的权重。通常情况下， β 被设置为类别数量的倒数或其他根据实际情况调整的值，以减少类别不平衡对模型的影响。

BCE 损失函数具有下面的优点：（1）提高模型对少数类的识别能力：通过为少数类分配更高的权重，平衡交叉熵损失能够有效提升模型对少数类样本的识别准确性。（2）灵活性高：平衡因子 β 可以根据具体的应用场景和数据分布进行调整，增加了模型训练的灵活性。

同时，平衡交叉熵损失也存在着一些不足和缺点：（1）参数调整复杂：平衡因子 β 的设定对模型性能有较大影响，但并没有通用的设置方法，需要根据具体问题通过实验来调整，增加了模型调优的难度。（2）可能导致过拟合：在数据样本极端不平衡的情况下，对少数类的过度关注可能会导致模型在训练集上过

拟合，降低模型的泛化能力。

2. 均方误差损失 (MSE)

均方误差 (MSE) 损失是机器学习和深度学习中最常用的损失函数之一，特别是在回归问题中。它衡量的是预测值与实际值之间差异的平方的平均值，因此，它能够量化预测误差的大小。

MSE 损失的原理基于最小化预测值和实际值之间的差异。通过对这些差异的平方求平均，可以得到一个非负值，其中较小的值表示较低的误差，即预测结果与实际结果更加接近。MSE 损失函数，通过惩罚较大的误差（由于平方操作）促进了模型预测结果朝着更高准确性的方向更新。

MSE 损失的公式表示为：

$$\mathbb{L}_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.7)$$

其中， n 是样本数量， y_i 是第 i 个样本的实际值，而 \hat{y}_i 是第 i 个样本的预测值。

一般的，MSE 损失主要应用于回归问题，如预测房价、股票价格等。它也可以在优化算法中作为损失函数来最小化误差，进而调整模型参数。MSE 损失具有以下优点（1）易于理解和实现。（2）平方误差可以放大预测结果中较大的误差，因此 MSE 对离群值非常敏感，有助于模型识别并纠正较大的预测误差。但是，其也存在着以下的缺点：（1）对离群值过于敏感，可能导致模型训练不稳定。（2）在不平衡的数据集中，MSE 可能导致模型偏向于多数类，从而忽略了少数类的预测。

虽然 MSE 损失并不被常用于分类问题，但是基于 Kato et al. (2021) 的研究，通过为少数类别的样本分配更高的权重，鼓励模型去更为关注此类样本的预测误差，来提高模型对于小数类样本的预测准确率和敏感度。具体地，在 Kato et al. (2021) 的研究中，他们考虑到如果将标签的值解释为该标签的向量长度，那么对于向量长度较大的标签，模型预测该数值将会更为困难。

基于上述思路，研究中引入了一个参数 α 。通过给少数类样本的标签乘以较大的 α 值，可以有效增加样本量较少的类别的向量长度，从而使这些不平衡样本之间拉开更大的差异，使模型以便更多地关注少数类样本。针对我们的断层检测任务，我们将超参数 α 设定为 2，以期通过这种方法缓解数据不平衡对模型性能的影响。

3. 平衡交叉熵-Dice 损失

平衡交叉熵-Dice 损失，是我们基于 Dice 损失函数，将其与平衡交叉熵联合起来的一个复合函数。主要考虑了 Dice Loss 是一种常用于医学图像分割和处理高度不平衡数据集的损失函数 (Milletari et al., 2016)，这与我们断层检测的任务

十分相似 (Gao et al., 2021, 2022)。它源自 Dice 系数，这是衡量两个样本相似度的统计工具，特别适用于二值数据，通过最大化预测结果与真实结果之间的重叠率，它自然而然地弱化了数量较多的负样本对损失函数的影响，从而使模型更加关注于少数类的正确预测。在医学图像分割中，Dice Loss 被用来优化模型以增加其预测分割与实际分割之间的相似度。

Dice Loss 的原理基于 Dice 系数，后者定义为两倍重叠区域与各自区域之和的比例。这意味着，如果预测结果与真实结果完全重叠，Dice 系数为 1，表示完美的相似度。相反，如果没有重叠，Dice 系数为 0，表示完全不相似。

Dice Loss 的计算公式可以表示为：

$$\mathbb{L}_{Dice} = 1 - \frac{2 \times |Y \cap \hat{Y}|}{|Y| + |\hat{Y}|} \quad (3.8)$$

其中， Y 表示真实标签， \hat{Y} 表示预测标签。符号 $|\cdot|$ 表示集合中元素的数量，即标签为正的像素点数。这个公式通过最大化预测与真实标签之间的重叠来鼓励模型学习。Dice Loss 主要应用于医学图像分割，如肿瘤、器官等的精确识别。其次，它也被广泛应用于处理类别不平衡的数据集，因为它通过关注预测和真实结果之间的重叠部分，自然地减轻了类别不平衡的问题。

Dice Loss 具有下列的优点：(1) 针对不平衡样本的有效性：在处理不平衡数据集时，尤其是正样本远少于负样本的情况下，Dice Loss 能有效提升模型性能。(2) 直接关注预测和真实标签的相似度：这对于图像分割任务尤其重要，因为分割的准确度直接关系到模型的最终性能。

其也存在下列缺点：(1) 对小对象敏感性较低：由于 Dice Loss 是基于全局相似度的，它可能不会很好地捕捉到小区域的细节。(2) 训练初期不稳定：特别是当预测和真实标签之间的重叠很小时，Dice Loss 可能导致梯度的不稳定。

为了解决 Dice 损失训练时不稳定的问题，我们将平衡交叉熵损失与 Dice 损失按照一定的权重组合起来，如下面的公式所示：

$$\mathbb{L}_{BalancedCE-Dice} = \gamma * \mathbb{L}_{Dice} + (1 - \gamma) \mathbb{L}_{Balanced-CE}, \quad (3.9)$$

其中，参数 γ 决定了两个损失函数占总函数的权重，经过我们的测试，我们将 γ 的值设置为 0.95。

4. 对比实验

为了寻找最适合于断层检测任务的损失函数，本研究设计了一个对比实验，利用在先前研究中提及的三种不同损失函数对 Wu et al. (2019a) 工作中的简化 U-Net 模型进行了训练。具体而言，在模型训练中，我们使用了 320 组地震数据及其相对应的断层标签作为训练数据集，同时，将另外的 80 组数据作为验证集，以确保训练过程的有效性和模型评估的准确性。

在 U-Net 网络架构设计方面，网络的起始层第一个下采样模块的通道数被设定为 32，并规定在网络中每经过一个下采样模块，通道数便翻倍增加。这种设计旨在逐步提取更深层次的特征，从而增强模型的学习能力和泛化能力。所有三种不同损失函数下的模型均进行了 100 个训练周期的训练，并且它们都达到了收敛状态。

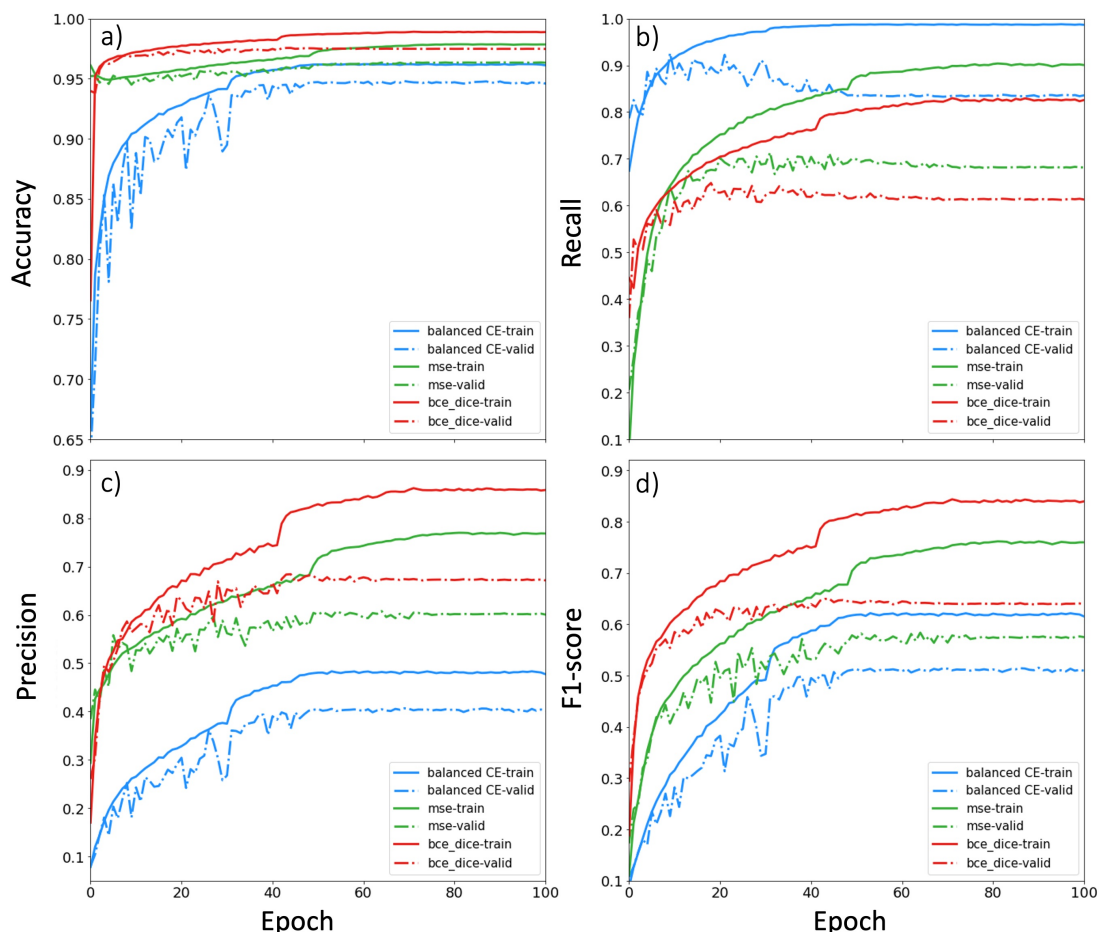


图 3.14 不同损失函数下的模型训练曲线

为了全面比较和评估这三个模型的性能，我们不仅绘制了它们的训练过程曲线，包括准确率、召回率、精确率和 F1 分数，还计算了模型在实际地震数据验证集上的倒角距离指标。这些指标和曲线为我们提供了一个全面的性能评估框架，使我们能够从多个维度对比模型的优劣。

表 3.1 不同损失函数下的模型预测结果评估

Metrics	Loss functions		
	Balanced Cross Entropy	MSE	Balanced CE-Dice loss
P2L CD	1.6947	1.1564	0.9863
L2P CD	0.4323	0.6928	0.7053
BCD	2.1271	1.8492	1.6916

综合对比图 3.14 所示的所有评估曲线和表 3.1 中的性能指标后，我们得出了

下面的结论：采用平衡 CE-Dice 损失函数的模型在本研究的断层检测任务中表现最为出色。上述的实验结论不仅为断层检测领域提供了一个有效的损失函数选择，也进一步证实了平衡 CE-Dice 损失函数在样本分布不均衡任务中的有效性。

3.3.2 网络特征数对模型效果的影响

除了损失函数，模型卷积过程中的通道数也会影响模型性能。为了深入研究卷积神经网络中的特征数量对模型性能的影响，我们针对 U-Net 模型的首个卷积块，选择了三种不同的特征数量设定：16、32、以及 64 个特征，旨在探索这一参数变化如何影响模型的学习效果和性能表现。基于这一设定，我们分别构建并训练了三个 U-Net 模型，以进行断层检测任务的学习，仅在网络的特征数量上有所区别。

我们记录了如图 3.15a 至 e 展现的三个模型训练过程的训练曲线，直观反映了训练进度和模型效果的差异。同时，为了更精确地评估模型在实际应用场景中的表现，我们基于人工标注的地震数据验证集计算了如表 3.2 中展示的三个模型收敛后的倒角距离指标结果，该指标能够有效反映断层检测的准确性。

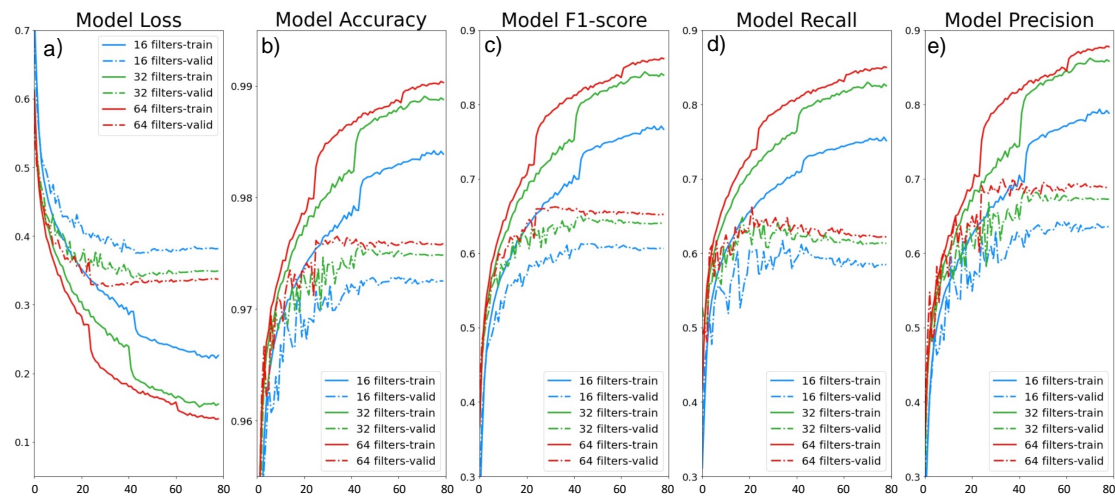


图 3.15 不同通道数下的模型训练曲线

从实验结果中观察到，随着卷积层通道数量的增加，模型在断层检测任务上的性能有所提升。具体而言，当特征数量从 16 增加至 32 时，模型在所有评估指标上均显示出显著的改进。然而，当特征数量继续增加至 64 时，尽管仍能观察到性能的进一步优化，但这种提升的幅度相对有限。值得注意的是，拥有 64 个特征通道的模型虽然在评价指标得分上表现更佳，但同时其训练曲线也展现出了更加明显的过拟合现象，这可以通过训练与验证曲线之间更大的差距看出。此外，与拥有更少特征数量的模型相比，64 特征通道的模型在训练过程中需要更多的计算资源和时间。

基于上述分析，我们建议在 U-Net 模型的第一个卷积块中设置 32 个特征滤波器。这一选择不仅考虑到了模型性能的优化，也兼顾了计算资源的高效利用，实现了在保证高效率的同时，达到了较高的模型性能。

表 3.2 不同通道数下的模型预测结果评估

Metrics	Number of Filters		
	16	32	64
P2L CD	1.09518	1.03802	1.07200
L2P CD	1.43134	1.14980	0.96116
BCD	2.52653	2.18782	2.03316

3.3.3 网络层数对模型效果的影响

在本节中，我们开展了一系列实验，旨在深入探讨网络层数对其性能的具体影响。为此，我们基于简化版的 U-Net 模型设计了实验，其中模型的层数分别被设定为 7 层和 9 层。在实验设置中，为了保证其他的超参数一致，在模型的第一个下采样模块中，通道数的数量被初始化为 32。我们通过分析 3.16 a 至 e 中展示的训练曲线，以及表 3.4 中记录的 Chamfer 距离评估结果，对比了不同网络深度下的性能差异。

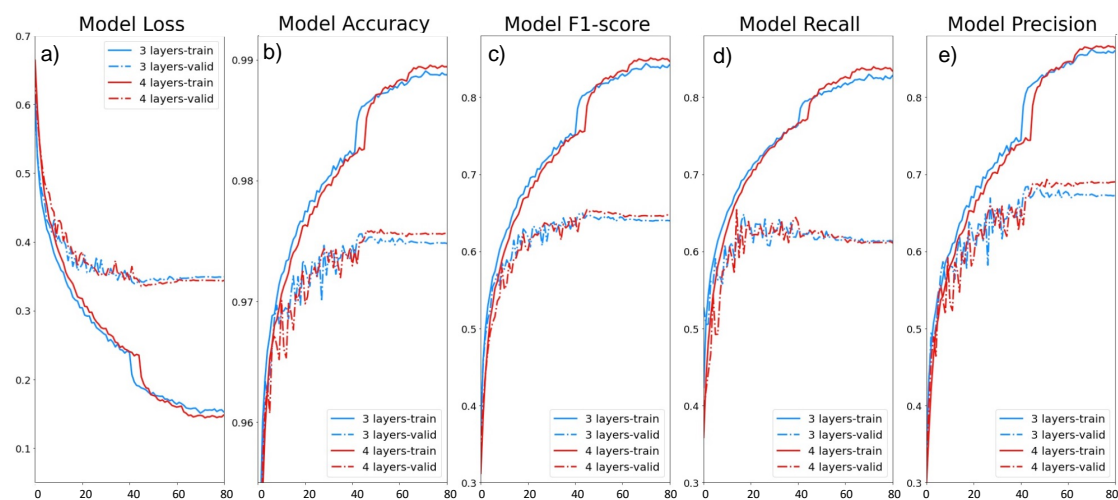


图 3.16 不同网络层数下的模型训练曲线

表 3.3 不同网络层数下的模型预测结果评估

Metrics	Number of Layers	
	7	9
P2L CD	0.9863	0.6675
L2P CD	0.7053	0.7807
BCD	1.6916	1.4481

实验结果明显显示，较深的网络架构在提取断层特征这一关键任务上展现出了显著的优势。这一发现表明，随着网络深度的增加，模型的表达能力得到了显著提升，从而能够更准确地捕捉到输入数据中的复杂特征。因此，我们得出结

论，网络的深度对于改善模型性能具有一定的作用，在 U-Net 模型下，更深的网络模型的断层检测效果更好。

3.4 FaultSeg3D Plus 模型介绍

基于上述实验，我们对影响模型效果的因素进行了探讨和深入分析，也对模型的参数设置、数据集的合成有了更深刻的理解和认识，为我们进一步优化基于深度学习的断层检测工作流程，设计更高效，性能更优越的网络，提供了可借鉴的基础。基于我们的实验结论，我们提出了如下改进的网络设计（FaultSeg3D Plus）和多尺度的训练流程。

3.4.1 网络结构和超参数

在优化后的工作流程中，我们进行了几项关键的调整，网络模型的参数图如下图所示：

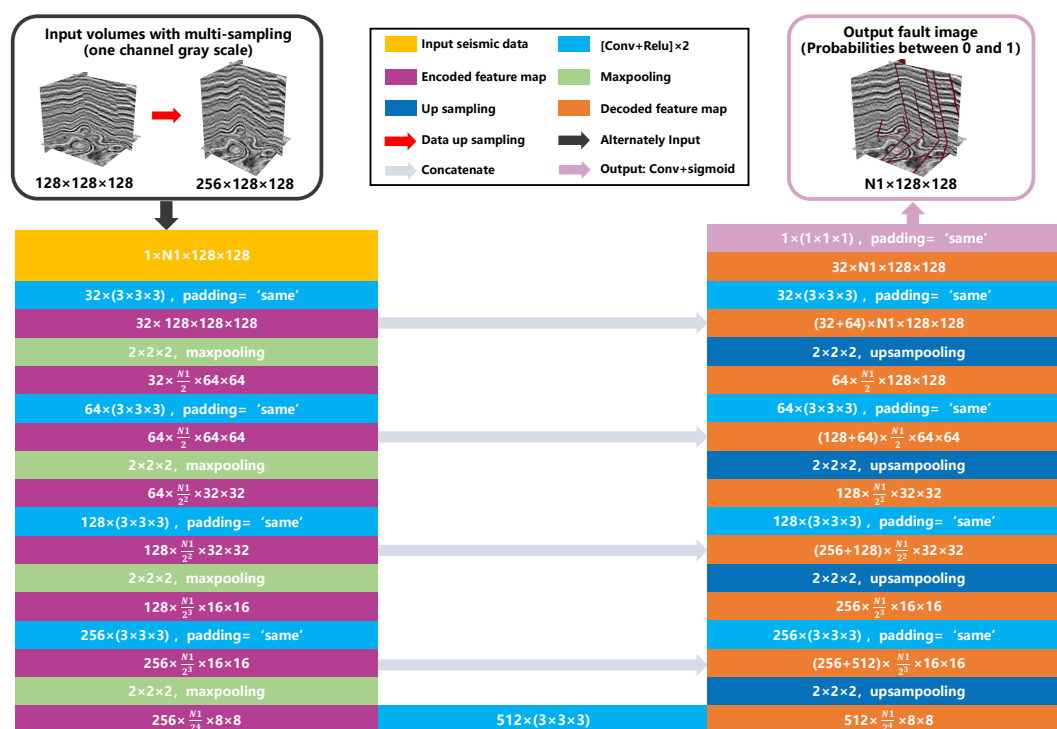


图 3.17 FaultSeg3D Plus 模型结构示意图

首先，对于网络的通道数，我们将第一个卷积块的滤波器数量设置为 32；其次，我们决定将卷积层的总数增加到 18（即 9×2 ）；最后，我们采用了平衡的 CE-Dice 损失函数来训练模型，以期在保持模型训练效率的同时，进一步提升模型的泛化能力和性能。

3.4.2 多尺度数据训练

此外，我们也认识到，除了合理的超参数设置和精心设计的网络架构之外，训练数据的质量和多样性也是决定模型性能上限的关键因素。良好的训练数据集不仅应包含丰富多样的特征，而且应能覆盖尽可能广泛的实际数据采样率特征，以确保模型具备较强的泛化能力。

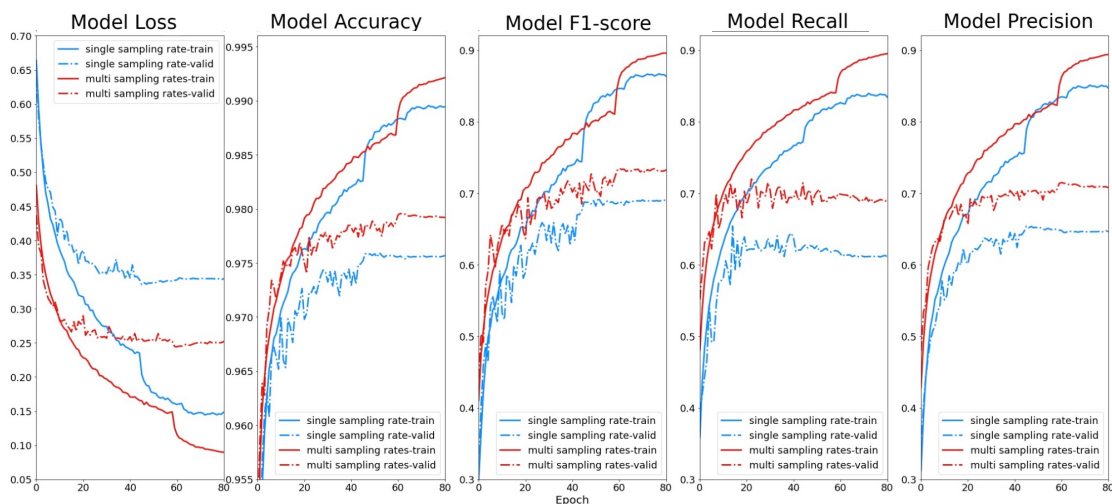


图 3.18 不同训练数据下的模型训练曲线

表 3.4 不同训练数据采样率下的模型预测结果评估

Metrics	Number of sampling rates	
	1	2
P2L CD	0.66747	0.40017
L2P CD	0.78066	0.60612
BCD	1.44812	1.00629

在之前的研究工作中，模型是基于单一采样率的合成地震数据进行训练的，这在一定程度上限制了模型处理不同采样率地震数据的能力。针对这一问题，我们采取了一种创新的方法：通过混合原始数据集和上采样后的训练数据集，生成了一个包含多个采样率的新数据集。这一策略不仅扩展了数据集的纵向采样率，也为模型训练提供了更为丰富和多元的数据基础。

为了证明这一策略的有效性，下面我们将展示如何利用这个包含多采样率断层特征的新数据集来训练我们提出的改进版 CNN 模型，并将其性能与旧模型进行对比分析。我们分别使用单一采样率和多采样率数据集来训练这两种模型，并通过由混合数据集构成的验证集来公平地评估和比较两种模型下的性能，特别是在泛化到不同采样率数据方面的能力。通过如下图 3.19 所示的多尺度数据训练流程，使 U-Net 模型可以识别不同采样率下的断层特征，并提升模型对各种实际地震数据的泛化能力。

通过分析如图 3.18 所示的网络训练曲线和表 3.4 所示的倒角距离的评估结果，我们发现，与仅使用单一采样率数据集训练的模型相比，使用多尺度训练策

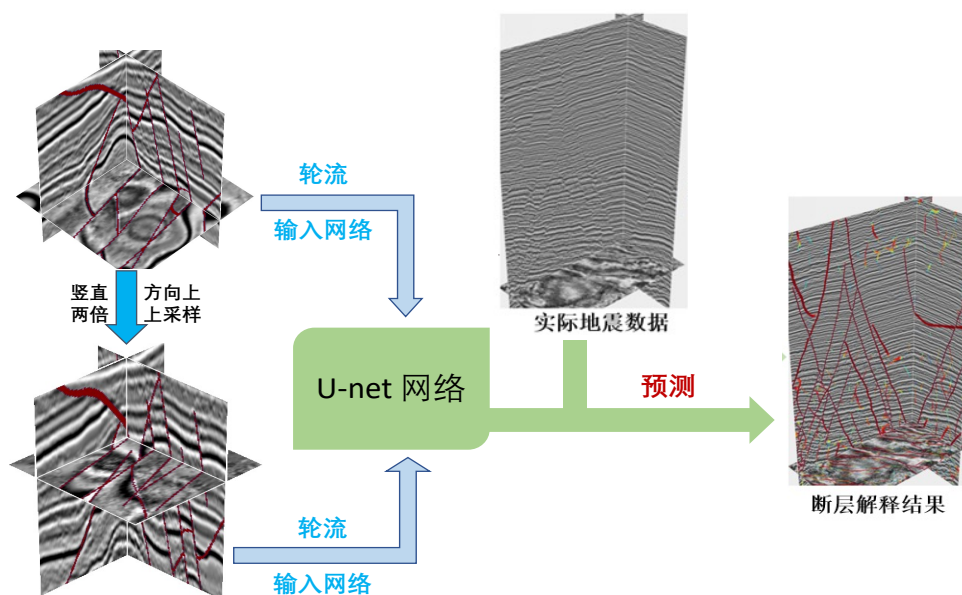


图 3.19 多尺度训练示意图

略的模型在泛化到不同采样率的地震数据时表现出更强的能力，并在断层预测方面取得了更优的性能。

为了进一步展示模型在实际工区中的泛化能力，我们将上面训练的两个模型分别应用于如下图所示的实际地震数据中。我们观察到如图 3.20，多尺度训练的模型能够产生更连续、尤其是在大尺度断层预测方面更为精确的结果，这一发现充分证明了我们改进的训练策略的有效性。

3.5 模型推理阶段的多尺度融合增强

在上一节，关于数据集的采样率构成的对比实验中（3.20），我们可以发现其实卷积神经网络的预测缺乏稳健性，未能保持对输入数据的尺度变换的不变性，也就造成了模型使用单一采样率训练后，无法在其他尺度下的断层上较好的泛化。本节，我们将从 CNN 的不变性和等变性这两个特性入手，分析目前 CNN 断层检测模型预测结果不稳定的原因，并给出相应的解决方案。

3.5.1 卷积神经网络的等变性和不变性

当 CNN 首次设计时，人们相信由于其具有局部连接、共享权重和池化操作的特性，使其能具有等变性（equivariance）和不变性（invariance），进而对于输入图像的位置和形态的变化具有一定程度的鲁棒性。

1. 等变性

等变性指的是，我们对输入到网络中的数据进行一系列例如：平移、旋转、尺寸放缩等操作时，模型特征的输出也会产生对应的一系列操作，如下图 3.21 所




图 3.20 数据集采样率增广示意图

注：图 3.20 (a) 展示的是单一采样率数据集训练的模型的断层检测结果，图 3.20 (b) 展示的是多尺度训练模型的断层检测结果。

示。这一特性主要体现在语义分割或识别一类问题，它能保证无论我们的目标发生上述变换后，也能获得一致的模型预测和响应。




图 3.21 CNN 等变性示意图

等变性的性质可以用下面的公式表示：

$$\text{transform}[F(x)] = F[\text{transform}(x)] \quad (3.10)$$

其中 x 表示输入的数据， $F(x)$ 表示 CNN 网络运算， $\text{transform}(x)$ 代表变换操作。

2. 不变性

不变性指的是，网络对于输入数据的变化仍然可以输出相同的结果，如下图 3.22 所示。这一点，则体现在分类和识别类的任务，具有不变性的网络，即使输入数据发生了形态上的变化，仍然可以得到正确的对应分类。




图 3.22 CNN 不变性示意图

不变性的性质可以用下面的公式表示：

$$F(x) = F[\text{transform}(x)] \quad (3.11)$$

其中 x 表示输入的数据， $F(x)$ 表示 CNN 网络运算， $\text{transform}(x)$ 代表变换操作。

3. CNN 等变性和不变性的缺失

事实上，根据一些研究 (Azulay et al., 2018; Zhang, 2019)，CNN 并不具有这种变换不变性，因为 CNN 中的下采样操作（如最大池化和步进卷积）忽略了采样定理。在他们的研究中，输入图像中的大量信息和细节特征在 CNN 的下采样操作后消失，且难以通过重采样恢复，这导致在输入图像发生小的变换时模型的预测结果发生剧烈的不稳定情况。

其实，上述问题也存在于断层检测任务中。为了说明这一点，我们对一个实际地震数据进行了缩放和旋转的操作，如图 3.23 显示了它们对应的预测。

图 3.23a 显示了从原始地震体的三维断层预测结果中提取的二维切片。图 3.23b 显示了同一个二维切片，但是进行旋转后的三维地震数据的断层预测结果中提取出来的（在预测前，地震体围绕垂直轴旋转了 270 度）。图 3.23c 显示了同一个二维切片，但是从缩放操作后的三维地震数据的断层预测中提取出来的（在预测前，地震体被下采样两次）。

通过比较未进行变换的原始地震数据和变换后的地震数据的预测结果，我们发现这些预测并不遵循 CNN 的变换不变性，三个结果是不一致，且效果存在明显优劣的。通过放缩变换的断层预测结果比原始输入的预测要好，这也同样证明了，训练过的 CNN 断层检测模型，未能保持对输入数据在尺度和旋转变换操




图 3.23 CNN 实际数据在常规预测、多尺度预测、多角度预测下的结果对比

注：通过上述测试，训练好的 CNN 模型缺乏变换不变性。同一个 CNN 模型在相同的地震图像的不同变换操作中得到了不同的断层检测结果：(a) 常规输入，(b) 旋转操作，和 (c) 缩放操作。

作上的不变性。

从上面的实验，我们发现由于 CNN 缺乏不变性和等变性，使得模型对于输入数据的一些微小变化过于敏感，使得预测结果出现缺失和错误的情况。目前，也有很多研究致力于通过各种手段来增强和克服 CNN 缺乏不变性和等变性的问题，例如通过数据增强来增加模型的鲁棒性、改进 CNN 的网络结构，引入新的卷积方式或是模型架构或是引入注意力机制。

3.5.2 多尺度和多角度预测流程

为了解决上面所提到的 CNN 对输入数据所缺乏的等变性和不变性，我们提出下面的解决思路：基于预测阶段的数据增广的思想，我们可以通过对待预测的数据进行例如旋转、重采样等不同形式的数据增广，然后让训练好的模型在不同的数据增广的形态下进行地震断层的检测。接着，使用数据融合和增强的策略进一步合并多个模型推理的结果。上面的流程，其实也正如我们人类进行地震体解释时的过程，解释人员不能仅仅依靠一个切面就得出解释的结论，而需要综合多方面的信息，最后给出更为准确的解释结果。除了 CNN 中的变换不变性缺失外，实际地震数据在断层方向、构造模式和采样间隔方面也存在变化，网络对于某种程度上获得稳定的断层预测不够稳健。

基于上面的思路，我们提出了一种测试阶段数据增强策略（Test-Time Augmentation, TTA）作为模型预测阶段的后处理流程。具体地，TTA 通过对输入地震数据进行多个方向的下采样以及旋转操作，进而使模型在多个尺度和旋转后的角度的地震数据上进行断层的预测，并进一步对多个尺度和角度下的预测结果进行融合和增强，以达到提高卷积神经网络模型的泛化能力。为了方便，在我们的论文中，我们将多尺度预测流程称之为 Multi-Scale ATT (MS-ATT)，多方向

预测流程称之为 Multi-Orientation ATT (MO-ATT)。

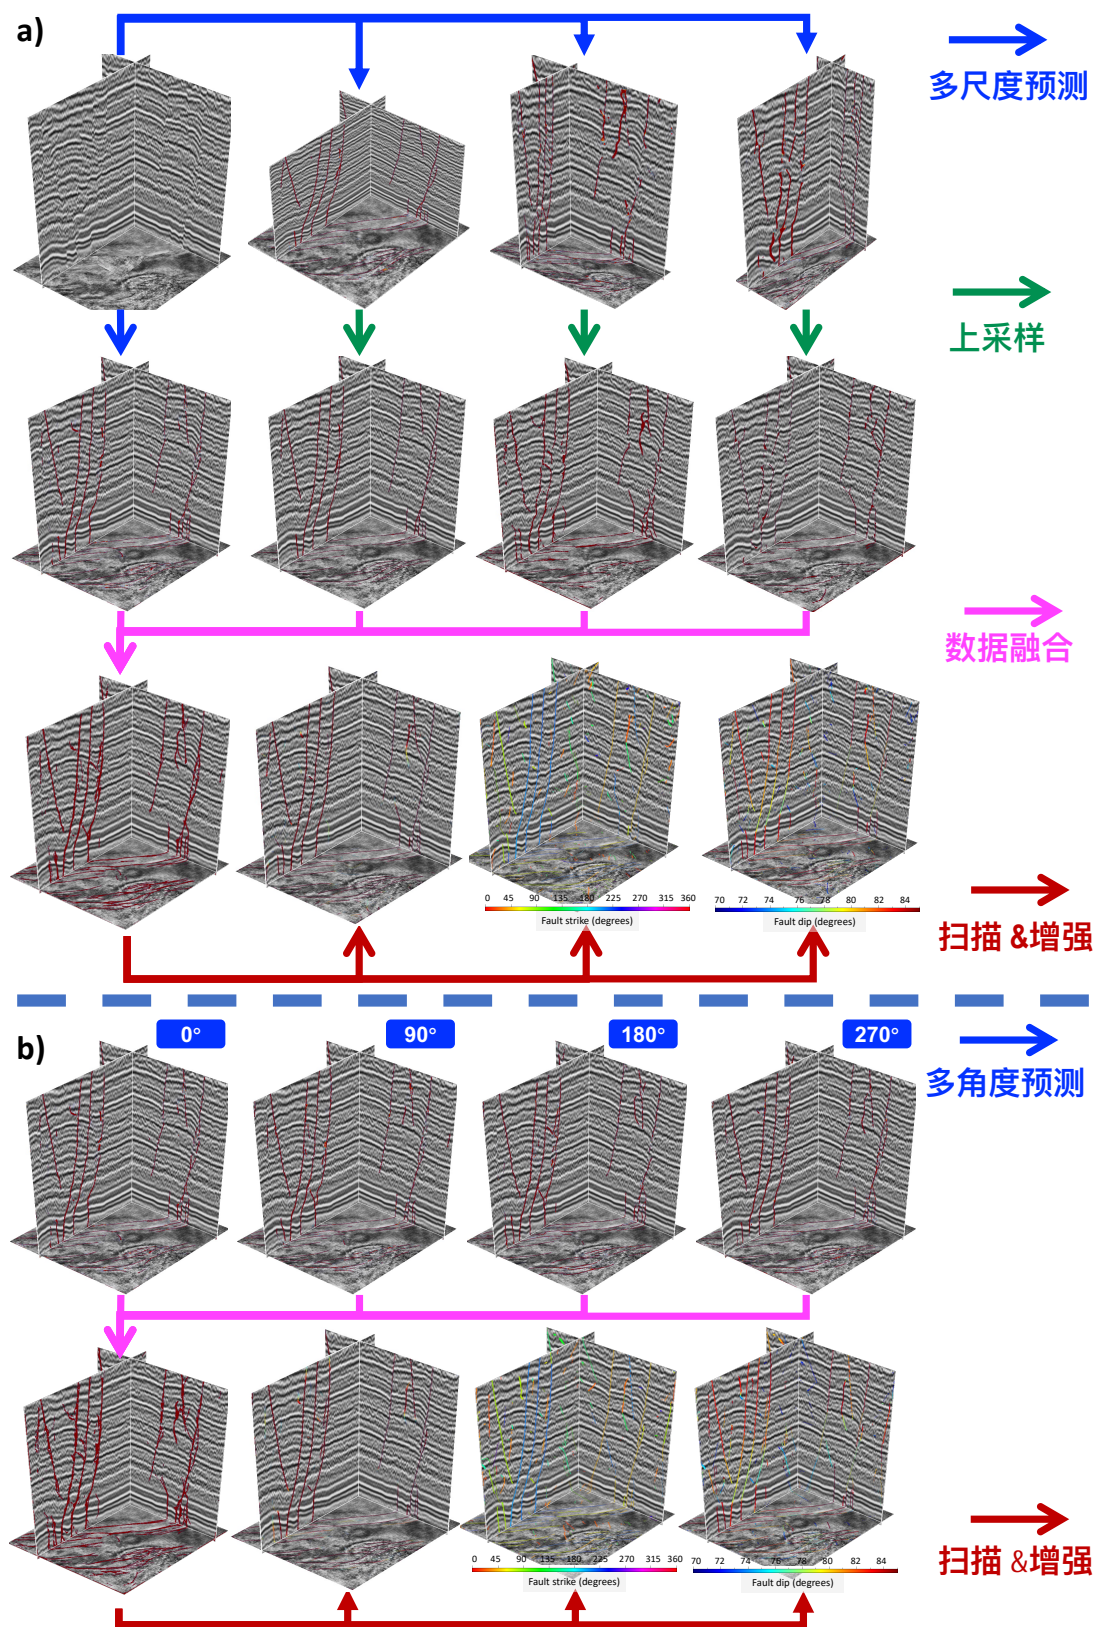


图 3.24 多尺度和多角度预测流程图

注：不同尺度 (a) 和方向 (b) 下的断层预测的工作流程，对多个角度和尺度下的预测结果进一步融合和增强，以获得具有更完整、更连续的断层检测结果。

图 3.24a 展示了多尺度预测工作流程。首先，我们分别沿着主测线 (Inline)、联络测线 (Xline) 和时间或深度方向对实际地震数据进行下采样。然后，我们对原始地震数据和三个重采样数据使用训练好的断层检测模型进行预测推理，以获得它们对应的断层检测概率体。在不同的尺度下，模型能够提供更加全局和详细的断层检测结果。接着，我们将三个下采样的断层预测体重新采样回原始大小，并将它们与原始尺度下的断层预测结果进行融合。融合操作是通过取四个断层检测体每个对应数据点的最大值来进行的。

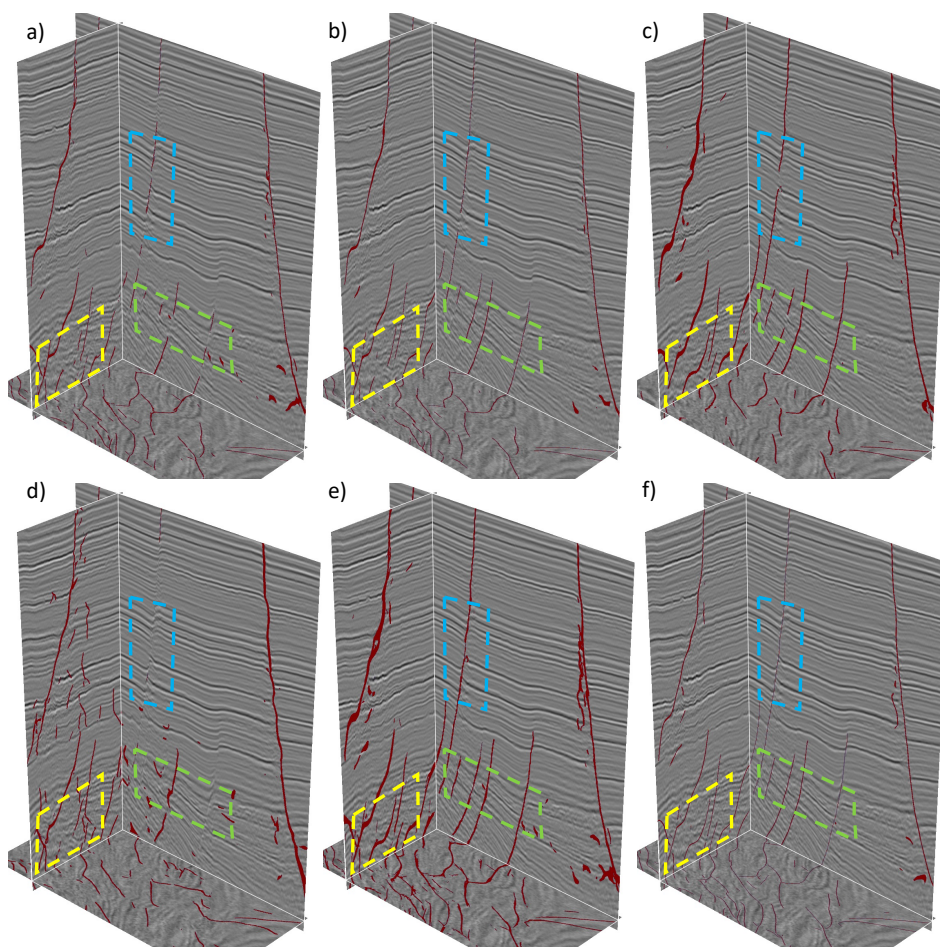


图 3.25 多尺度预测分步处理图

注：在原始地震数据 (a) 以及相应的在垂直方向 (b)、Inline 方向 (c) 和 Crossline 方向 (d) 的下采样数据的断层检测结果。这四个检测结果进一步被融合 (e) 并增强 (f) 以获得最终断层结果。

为了获得更连续和准确的结果，我们对融合结果执行一个断层扫描和增强的操作 (Wu et al., 2017)。该算法通过一个基于匹配滤波的扫描方法，能在获得断层走向，倾角信息的同时，沿着断层的方向对断层的预测结果进行滤波，以起到抑制噪声，增强检测结果连贯性的效果。在融合和增强之后，便能得到一个优化后的断层检测结果，这些断层检测结果具有更连续且低噪声的优点，同时我们还能获得关于断层体对应的走向的估计 (三个最终输出体中的第二个) 和倾角 (三

个最终输出体中的第三个)。

图 3.24b 展示了多角度预测的工作流程。我们简单地对输入地震数据，分别沿着垂直方向的轴线来旋转地震数据，分别得到旋转 90° 、 180° 、 270° 后的数据体，并将上面四个不同方向下的地震数据输入到训练好的断层检测模型中。接着，和多尺度预测工作流程类似，我们对上面四个方向下的断层检测结果进行融合和增强，最终得到优化后的多角度断层检测结果。

为了证实工作流的有效性，我们在一个实际地震数据上分别应用多尺度和多角度的预测流程，并在图 3.25 和 3.26 中逐步展示该流程下每一步结果。

在图 3.25 中，当模型仅应用于原始数据时，图 3.25a 中彩色框内标注出了许多不连续的断层检测结果。在融合了沿着三个方向重采样后的预测结果之后，断层检测结果的连续性得到了提升，但此时的结果存在很多噪声且断层比较粗，横向分辨率不高。最后，图 3.25f 中的展示的是经过扫描增强后的结果，原来断层检测结果中的不连续预测得到了优化，溶蚀压制了检测结果中的噪声，断层结果得到了优化和增强。

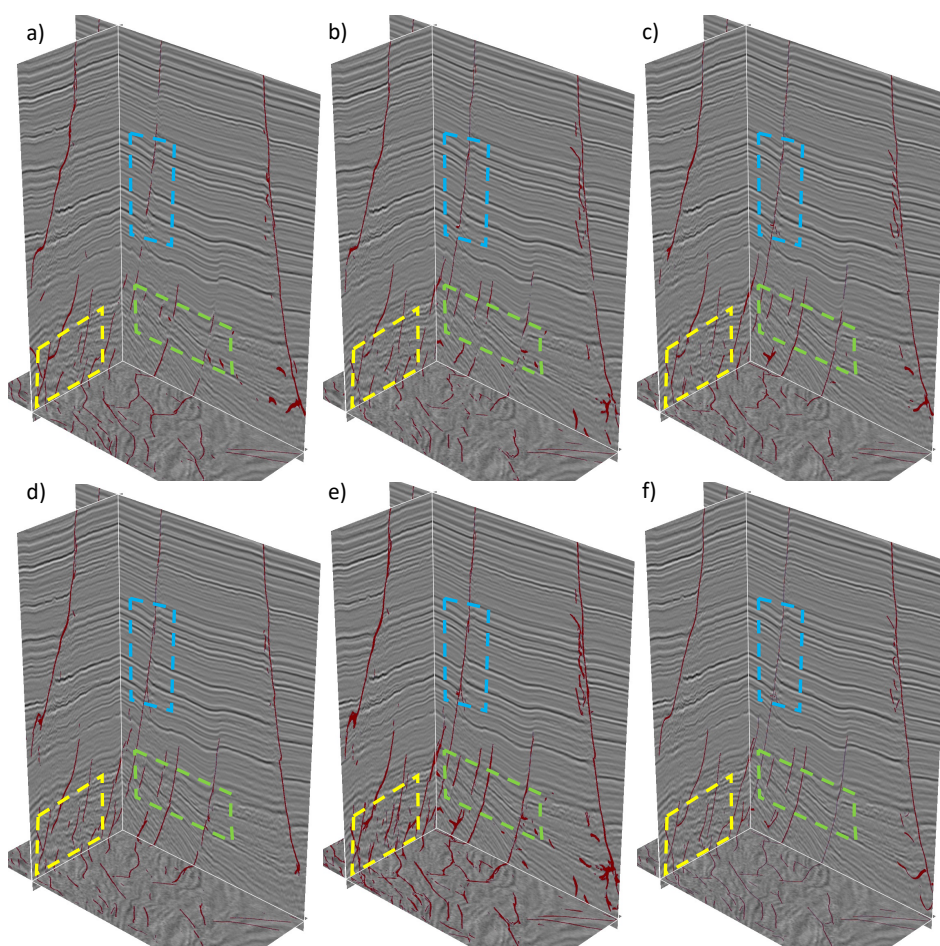


图 3.26 多角度预测分步处理图

注：原始地震数据 (a) 及其绕垂直轴旋转 90° (b)、 180° (c) 和 270° (d) 的地震数据的断层预测结果。这四个预测结果进一步经过融合 (e) 并增强 (f) 以获得最终结果。

在图 3.26 中, 当我们对输入数据旋转时, 图 3.26a 中彩色框标记的不连续的断层预测结果在图 3.26b~ 3.26d 中变得更连续。此外, 通过合并来自不同输入角度的断层检测结果, 融合后的断层体显示出更好的连续性和更高的准确性。同样地, 通过扫描和增强后, 最终输出了一个更加连续和准确的断层检测结果。

为了定量评估 TTA 策略在断层检测中的效果, 并与未使用 TTA 得到的结果进行比较, 我们在我们标注的真实地震数据验证集上分别进行了 MS-TTA 和 MO-TTA 的后断层检测, 并使用定量的指标来评估几种方法下的断层预测结果, 如表 3.5 所示。

表 3.5 不同预测流程下的断层检测结果定量评估

Metrics	without TTA	MS-TTA	MO-TTA
Accuracy	0.9834	0.9886	0.9863
Precision	0.9401	0.9578	0.9518
Recall	0.7485	0.7673	0.7580
F1-Score	0.8239	0.8520	0.8438
P2L CD	0.1406	0.1123	0.1261
L2P CD	0.2787	0.2015	0.2447
BCD	0.4194	0.3138	0.3708

从表 3.5 的定量评估和图 3.25 与 3.26 中的断层预测可以看出, 这两种工作流程使 CNN 模型能够从多个视角预测三维地震体中的断层特征, 并且通过融合多个形态下的预测结果有助于最后输出更细致、连续的断层检测结果。我们推荐将着两种工作流程作为断层预测流程的后处理操作, 并且 MS-TTA 和 MO-TTA 这两种预测流程也可以尝试将他们两种工作流程结合在一起进行, 以处理一些复杂的实际地震工区的断层检测。

3.6 实际工区地震数据验证

为了更好的验证和评估我们提出的 FaultSeg3D Plus 的效果, 我们选择了四个来自于不同工区的实际地震数据, 并将我们优化后的工作流程和 Wu et al. (2019a) 开源的 FaultSeg3D 模型分别对这四个数据进行断层检测。从下面的展示的检测结果的对比可以看出, 我们所提出的对原模型的改进方案是有效的, 通过对整个断层检测从数据准备和生成、模型设计、网络训练以及预测阶段的改进和优化, FaultSeg3D Plus 的断层检测结果的准确性、连续性都得到了明显的提升, 也证明了我们模型在实际数据工区的泛化性和稳定性。

3.6.1 工区一概况和检测结果

第一个三维数据工区是采集于荷兰的北海的 F3 工区, 是油气勘探领域的一个重要研究区, 数据被开源于 SEG Wiki。该地区的地质结构复杂且富含碳氢化

合物类资源,是地质学家和地球物理学家的研究热点地区,为地下结构和断层发育历程提供了丰富的高质量资料。

F3 地区的地壳断裂发育十分明显且显著且复杂,工区内包含多个断裂面并相互交织。同时,该工区发育的断层类型也十分丰富且广泛,包括正断层、逆断层以及走滑断层等。这些不同类型的断层发育也反映了不同的地壳应力状态和演化历史。这些断层的存在,对于油气的运移以及贮藏都起到了重要作用,目前基于可获取的高分辨率三维地震数据进行断层的解释,能为油气的勘探提供更为准确的断层位置与活动性以及油气富集的位置信息。

如下图 3.27 所示的分别是选取的 F3 工区的一块三维地震工区的地震图像(图 3.27a),以及分别由 FaultSeg3D(图 3.27b)和 FaultSeg3D Plus(图 3.27c)预测的断层检测结果。经过比较,可以明显看出,我们通过改进训练流程并进行多尺度预测的断层检测结果效果更好。尤其是对于 F3 工区大量平行且复杂的断层检测方面表现出了优异的性能。与改进前的 FaultSeg3D 的结果相比,我们的方法在检测到的断层在视觉上更为锐利,示出了更高的连续性和较少的噪点,整体图像更加清晰。上面的结果表明,我们优化后的模型能够更精确地区分地质结构中的微小变化,这对于断层的识别至关重要;其次,通过多尺度的预测以及融合增强的流程,使得模型的断层检测结果能够减少背景噪声,使得断层线条在地震剖面图中更加突出;最后,多尺度数据的训练以及优化的网络模型训练参数,使得模型在处理地震数据的复杂性和多样性方面表现得更加稳定,从而能够更连续、更准确地追踪断层方向,形成更好的断层检测结果。

3.6.2 工区二概况和检测结果

第二个三维数据工区(图 3.28a),我们选择了一个纵向采样率较高的实际地震数据,其深度方向、crossline 方向以及 inline 方向的维度分别是:2501,481,281。由于数据的纵向采样间隔为 1ms,使得工区内断层在纵向上的尺度很大,只有模型具有更为全局的特征感受能力,才能输出准确且连续性强的断层检测结果。我们选择了该工区的一个区块进行了模型效果的验证,图 3.28a 和 b 分别展示了由 FaultSeg3D 和 FaultSeg3D Plus 预测的断层检测结果。

为了更好地展示该工区的断层发育构造,在图 3.28a 中,我们使用红色的虚线对工区内的几个断层构造进行了注明。可以看出本工区的断层结构由于受到数据噪声的影响,断层特征比较模糊,尤其是在蓝色虚线标注的两个地层之间,岩石的横向变化导致了反射的不连续性和模糊。在这种复杂的地质背景下,要求断层检测算法不仅能够对噪声表现出高度的鲁棒性,还需能够从宏观的角度深入分析地震结构特征。

从图 3.28b 的检测结果中我们可以看出,通过我们基于多尺度分辨率以及包

含真实数据噪声的训练数据集训练的模型，能够显著的提高断层检测的准确性，和图 3.28a 的基线模型相比，能生成更为清晰、无噪声、连续可追踪的断层检测结果。此外，在两个地层的交界处，即使在断层特征相对来说不是很明显的区域，我们的工作流程也能精确的对断层构造进行识别和刻画。

3.6.3 工区三概况和检测结果

在工区三，我们选择了一个地质结构异常复杂的三维地震工区，其特征为断层密集并频繁发生交错。从图 3.29a 所示的地震数据图像，我们观察到该区域内断层主要为平行分布，展现了一个高度密集的断层网络。这些断层在尺度上表现出显著的多样性，包括横跨整个地震数据集的大型断层和较为局部的小型断层。此外，这些断层之间存在交叉现象，进一步增加了地质结构的复杂度。这种复杂的断层发育模式要求模型必须具备捕捉全局与局部地质构造细节的高敏感性。

对比基线模型和我们优化后的模型在图 3.29a 和图 3.28c 中的检测结果，显而易见的差异体现了我们模型的优越性。基线模型在描述大尺度断层及其交叉关系方面表现得并不理想，细节刻画不够准确，且在分辨率上略显不足。相反，我们经过优化的模型不仅展示了更为清晰的断层线索，而且在高分辨率下对断层的交叉关系进行了准确无误的识别。上面的结果对比表明，通过对模型进行细致的调整和优化，我们能够大幅提高地震断层检测的精确度，尤其是在处理复杂地质结构时的性能表现。

3.6.4 工区四概况和检测结果

第四个实际三维地震工区，我们选择了一个具有较为复杂的断层构造特征的工区。从图 3.30a 中可以看出，本工区的断层的纵向尺度较大，这些断层不仅相互交错，形成了复杂的断层网络，而且各断层的走向呈现多样性，体现了地质构造的复杂性和多变性。此外，随着数据深度的增加，受到噪声干扰和清晰度降低的影响，使得深部断层特征的辨识度大幅下降，从而增加了模型对于这些复杂断层结构检测的难度。

在采用基线模型进行断层检测时，结果中出现了大量的噪点。图 3.30b 展示的检测结果显示，断层之间的交互关系和断层连续性存在不足，尤其是在一些断层较为密集的区域，检测结果显得杂乱无章，难以清晰识别和区分不同的断层构造。相比之下，图 3.30c 展示了我们通过改进检测工作流程后获得的结果，显著优于基线模型的表现。改进后的模型不仅提高了断层检测的连续性和分辨率，还对断层之间的复杂交互关系进行了更为精准的描述和刻画。

3.6.5 检测结果对比与分析

从上述这四个数据的预测结果中，我们可以发现，我们改进后的工作流程，能很大程度的改善模型对断层构造识别的准确度和连续性。

数据一是一个经典的三维地震工区，断层发育丰富且构造复杂，我们的模型表现出稳定和准确的预测结果。数据二的数据纵向采样率比较大，也使得断层的纵向尺度较长，但我们的模型仍然能以一个较大的感受范围，或得连续，干净的检测结果。数据三是一个断层结构复杂且响应较弱的实际地震数据，我们模型的预测结果相较于基线模型展现出更高的抗造性和连续性。数据四的断层贯穿浅、中、深的地层，断层的尺度较大，断层的地震响应也随着深度在变化，但我们的模型仍然可以获得一个完整且连续的预测。

上述检测结果充分证明了 **FaultSeg3D Plus** 模型在面对多样化的挑战时，如不同的数据采集工区、采集方法、采样率以及断层构造的多变性特征下，都能展现出其稳定而精准的断层识别能力。通过对断层检测全流程的优化和改进，**FaultSeg3D Plus** 能更好地对复杂多变的实际地震工区数据进行高效的断层检测，展现了其强大的鲁棒性和泛化能力。通过对基于深度学习的断层检测流程的深入分析和优化，研究人员可以更准确地识别和分析地震数据中的断层结构，进而为地质结构的研究和资源的探测提供有力支持。

3.7 本章小结

在本章中，我们全面探讨了基于卷积神经网络（CNN）的断层检测工作流程的优化策略。通过深入分析和系统性的对比研究，我们不仅验证了 CNN 在断层检测任务中的有效性，而且还对模型结构、训练数据、损失函数等关键因素对网络效果的影响进行了细致探讨。此外，通过对 CNN 的等变性和不变性的探究，我们设计了多尺度和多角度的预测阶段的后处理流程，进一步提高了断层检测模型的鲁棒性和连续性。

1. U-Net 模型设计与优化：我们选取了广泛应用于图像分割任务的 U-Net 模型作为基础，通过对比实验，探索了损失函数、网络层数及特征数等超参数对模型性能的具体影响，对模型进行了改进和优化，以适应地震断层检测的特点和需求，增强了模型的特征提取能力和泛化性能。

2. 合成数据集的真实度：我们探究了训练数据集的合成算法对模型性能的影响。通过引入例如：断层断面波特征、实际数据的背景噪声以及数据纵向采样率的增广，显著提高了合成训练数据的真实性和多样性，从而优化了模型在实际地震数据中的应用效果。

3. **FaultSeg3D Plus** 模型：基于上述研究成果，我们提出了 **FaultSeg3D Plus**

模型。该模型采用了改进的网络结构和多尺度数据训练策略，能够更准确地识别和预测地震数据中的断层信息。实验结果证明，**FaultSeg3D Plus** 在断层检测任务中相比于原始基线模型，展现出了显著的性能提升。

4. 多尺度和多角度的断层检测流程：通过对 CNN 的等变性和不变性分析，我们基于预测阶段的数据增广的思路，设计了一个多尺度和多角度的断层检测后处理流程，通过对多个形态下的检测结果的融合，以及扫描增强，获得更具有连续性和准确度的检测结果。

综上所述，本章通过对基于 CNN 的断层检测的工作流程在多个方面进行了优化和深入研究，不仅提高了断层检测的准确率和效率，而且为深度学习在地震数据断层检测的后续研究提供了可借鉴的基础。




图 3.27 工区一地震图像和断层检测结果对比

注：图 3.27 (a) 和 (b) 分别由Wu et al. (2019a) 开源的 FaultSeg3D 模型和我们优化后的 FaultSeg3D Plus 预测的断层结果。




图 3.28 工区二地震图像和断层检测结果对比

注：图 3.28 (a) 和 (b) 分别由Wu et al. (2019a) 开源的 FaultSeg3D 模型和我们优化后的 FaultSeg3D Plus 预测的断层结果。




图 3.29 工区三地震图像和断层检测结果对比

注：图 3.29 (a) 和 (b) 分别由 Wu et al. (2019a) 开源的 FaultSeg3D 模型和我们优化后的 FaultSeg3D Plus 预测的断层结果。




图 3.30 工区四地震图像和断层检测结果对比

注：图 3.30 (a) 和 (b) 分别由Wu et al. (2019a) 开源的 FaultSeg3D 模型和我们优化后的 FaultSeg3D Plus 预测的断层结果。

第 4 章 基于可提示引擎的交互式深部断层检测

随着大模型和通用人工智能的发展，目前各类常见的机器学习任务开始趋向于使用一个使用庞大数据集训练的通用基座模型作为基础，再基于小领域的具体数据和任务，对基础模型进行微调或自适应训练，以适应各种各样的下游任务。得益于庞大数量数据集的前期预训练，基础模型的特征提取能力得到了巨大的提升，也使得后续模型在下游任务的微调中更加稳定且强大。

在语义分割领域，也出现了很多效果显著的分割大模型，例如 Segment Anything Model (SAM) (Kirillov et al., 2023)，这些研究都推动了计算机数据以及图像分割领域的进一步发展，并取得了远超传统深度学习方法的效果。

在本章，我们将具有可提示引擎的 SAM 模型，通过在我们手动标注的深部断层的小批量数据集上进行微调，探究了基础分割大模型在断层检测领域应用的可能性，也为大尺度、断层特征不明显的深部断层的检测，提供了一种新的解决思路。

4.1 基于 CNN 的深部断层检测现状

目前基于 CNN 的断层检测算法被广泛地应用于实际地震工区的断层检测中，成为了目前深度学习方法下断层检测的主流。但受限于 CNN 模型的感受野和特征提取能力、合成训练数据集的断层构造类别的不完备以及地震数据采集和成像的质量的问题，目前的方法仍然很难泛化于所有情况下的地震工区，尤其在一些深部大尺度的断层检测中，容易出现断层检测结果不连续甚至无断层响应的情况。

4.1.1 深部断层的特点

地球地壳较深区域的大尺度断层是地下的重要结构之一，它通常发育在深达数十公里。深部断层的解释是油气勘探的重点问题，同时也对地球动力学以及地球内部演化起到了重要意义。

地球深部发育的断层通常表现出尺度大的特点，断层的长度和宽度均可达到极大的尺度，远超于浅部发育的断层。深部断层的类型通常为走滑断层、倾滑断层或逆冲断层，这也与浅部常发育的正断层构造大不相同，断层断面的性质和结构，也常常会随着其深度的增加而改变，我们将深部断层的深度定义在 5~10 千米左右的深度范围。

从地震图像上看（图 4.1），由于深部断层位于地表的深部，使得地震波能量

到达深部时，能量由于发生几何扩散作用，使得深部断层的响应较弱，同时也使得地震图像在该区域的信噪比变低，影响了断层构造的成像。此外，由于深部大尺度断层两侧的岩石的物理性质的差异较大，也使得部分断层在断面上的响应强烈，在图像上形成一个明显的反射特征。




图 4.1 深部大尺度断层地震图像

4.1.2 深部断层检测的现存问题

首先，深部大尺度断层的这些特点与在浅层和中层发育的断层差距较大，而目前主流的深度学习方法的训练数据集，大多模拟的是浅、中层的断层构造，并且，数据的尺寸也远远小于深部断层的尺度，而使用更大尺寸的训练数据集，又对计算设备的内存和性能要求很高。所以，由于训练数据和深部断层的差距较大，使得训练好的模型无法更好的泛化于深部断层的地震数据。




图 4.2 CNN 模型下的深部大尺度断层检测结果

其次,目前大部分的断层检测模型是基于卷积神经网络架构的。卷积神经网络通过卷积的操作来进行输入数据的特征提取,而 CNN 的感受野很大程度上受到卷积核大小的控制,这种特征提取的方式,使得 CNN 只能对输入数据的局部特征进行提取,无法很好地处理更大范围、更大尺度的数据。而 CNN 这一特性,使得深部断层的检测更为困难。

如图 4.2所示的是基于 CNN 网络的断层检测模型在具有深部大尺度特征的地震图像上的检测结果,我们可以看到,模型对于图中位于深部发育的断层特征失去了响应,只检测出了一些浅部,特征比较明显的断层构造。显然,上述的断层检测结果,无法满足目前的精度需求。

4.2 基于可提示引擎的分割网络

为了解决深部大尺度断层的检测问题,我们提出了一个基于 SAM 大模型微调的方案。首先, SAM 模型是一个以 Transformer 架构为主的网络模型,而 Transformer 具有更好的全局的注意力机制,对于深部断层的大尺度能很好的适应。但是, Transformer 模型 (Vaswani et al., 2023) 的训练要求大量数据,训练的成本和时间较高。

目前,深部大尺度断层缺乏可用的断层标签,同时大量的人工标注也需要巨大的人工成本,我们很难获得大量的可供模型学习、收敛的训练数据集。幸运的是, SAM 模型的预训练是基于 1000 万张图片进行的,其具有较强的通用性和泛化性。这样,基于我们手工少量的深部断层标注,通过合理的微调手段,我们选择对 SAM 的预训练模型进行微调,使其能适应深部断层检测的任务。

4.2.1 Transformer 模型原理

Transformer 模型(图 4.3)被设计的初衷是用于自然语言处理领域,来解决序列到序列的任务,主要由编码器(Encoder)和解码器(Decoder)组成。在编码器部分,模型会学习输入序列的表示,进行特征的提取。在解码器部分,会输出最终的目标序列。Transformer 的创新在于它的自注意机制(Self-Attention),该机制通过对输入数据的计算,能得到各个元素之间的关系,进而得到彼此的注意力权重,获得更为全局、长距离的全局信息。

Transformer 的编码器,是由 N 个结构一致的模块构成,每个模块又由多头自注意力层(Multi-Head Self-Attention)和前馈网络构成(Position-wise Feed-Forward Networks)。多头自注意力层通过三个不同的权值矩阵来得到输入数据对应的查询(Query)、键(Key)、值(Value)三个量,然后使用下面的公式计算注意力

得分：

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4.1)$$

其中， Q 表示查询矩阵， K 表示键矩阵， V 表示值矩阵， d_k 表示键向量的维度， QK^T 表示查询矩阵和键矩阵的转置的点积，分母中的 $\sqrt{d_k}$ 是一个缩放因子，用于控制点积的大小，防止在进行 softmax 操作时进入梯度较小的区域，Softmax 函数被应用于每一行，将注意力权重归一化使得每一行的和为 1。

这个得分是决定了每个输出对应的权重。接着，通过 Softmax 函数的计算，得到每个元素最后的归一化后的注意力得分，最后得到每个元素的输出。

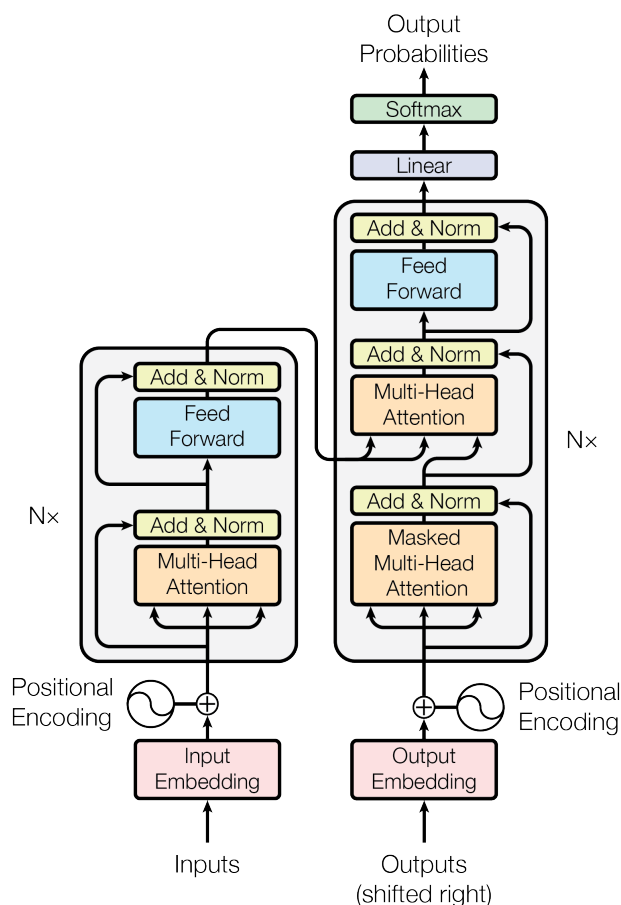


图 4.3 Transformer 模型架构图 (Vaswani et al., 2023)

位置前馈网络的作用是对每个位置使用一个相同的全连接网络，其通过两个线性变换层和一个 ReLU 几乎函数构成。编码器的每一个模块的输出结果使用了残差操作，然后进行层归一化（Layer Normalization）以克服梯度消失或梯度爆炸的问题。

和编码器的结构类似，解码器也是由 N 个相同的模块构成，但是存在着一些不同。首先，解码器的多头自注意力层会进行掩码的操作，以克服靠后的信息发生泄漏，保证每次用于预测的信息来自于已知元素。其次，解码器中还有一个编码器-解码器注意力层（Encoder-Decoder Attention），用于综合考虑来自于编码

和解码的内容。最后通过前馈神经网络和层归一化，最后输出目标的向量表示。

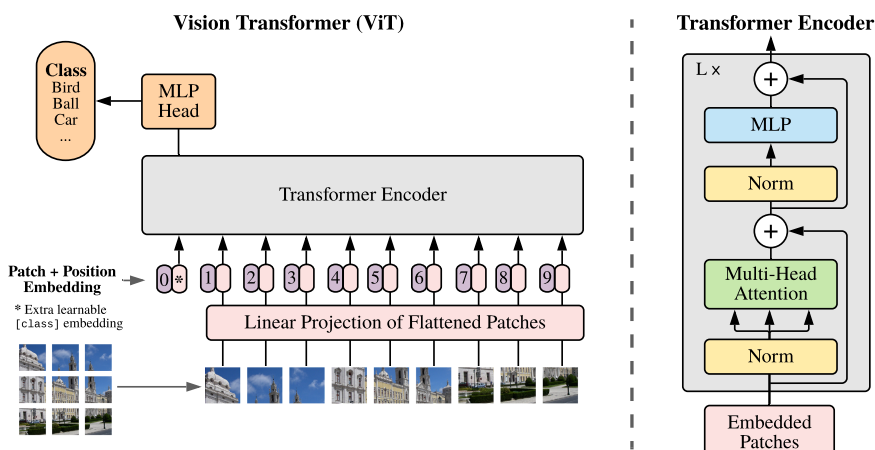


图 4.4 Vision Transformer 模型架构图 (Dosovitskiy et al., 2021)

Dosovitskiy et al. (2021) 将常用于自然语言处理领域的 Transformer 引用在了计算机视觉领域，提出了一个里程碑式的 Vision Transformer (ViT)。其基本结构都沿用了 Transformer 的基本架构，不同之处是 ViT 在输入图片是，需要将图片处理成类似于一个个文字的小块，每个小块被称为 patch，然后将每个小块转换为一个个序列化后的嵌入向量，后续的编码和解码操作和 Transformer 基本一致。

4.2.2 SAM 网络结构

SAM 是一个通用的图像分割任务的基础大模型，它在分割任务中表现出色，即使在一些不常见、不清晰的分割对象上也表现出很好的泛化能力。




图 4.5 SAM 模型架构图 (Kirillov et al., 2023)

如上图 4.5所示的是，SAM 的模型架构图，它主要由图像编码器 (Image Encoder)、提示解码器 (Prompt Encoder) 和掩码解码器 (Mask Decoder) 这三个模块构成。

首先是图像编码器，在网络架构的选择上，SAM 选择了使用经过了预训练的 ViT 的模型结构，通过将输入图像分割为 16×16 的小块，然后将图像映射成 768 维的向量，并加上描述每个块位置的位置编码，接着通过 16 个 transformer block 和两层卷积操作，得到维度为 256 的图像嵌入 (Image Embedding)。

对于 SAM 的提示解码器，它也是模型的一大创新。通过提示解码器，模型可以将我们人工标注的一些可提示的信息，例如：点、框线或是粗略标注的掩码

投射到和图像编码器相同输出维度的空间上。

最后，掩码解码器是整个模型最为复杂的一个结构，其结构图如下图所示：

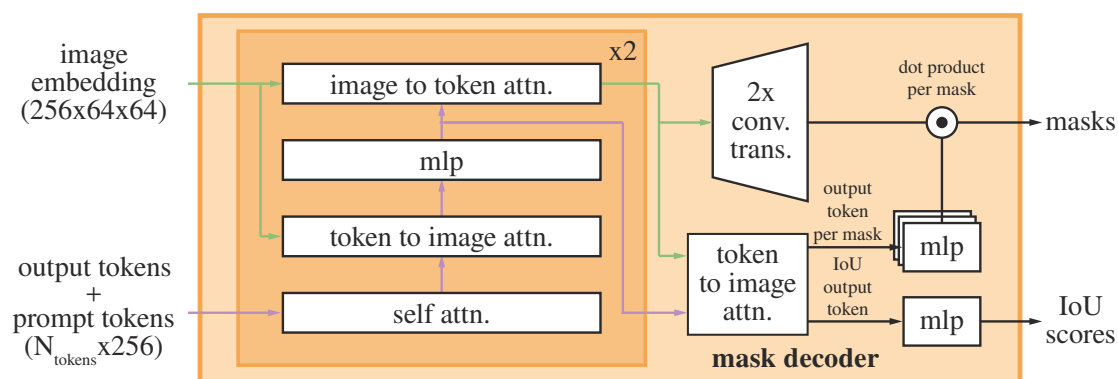


图 4.6 SAM 的 mask decoder 结构图 (Kirillov et al., 2023)

来自于图像编码器和提示解码器的输出被输入到掩码解码器，在 Mask Decoder 中提示 token 与 output token 互相进行自注意力计算，同时图像嵌入又与提示嵌入进行双向的注意力计算，在两个方向上输出每个分割的得分以及用于分割的新表示，最后，将上面的表示和通过上采样后的图像嵌入进行点乘，最后得到预测的分割的结果。

4.2.3 提示信息的常见形式

SAM 模型为模型的训练和微调提供了多种可用的提示信息的形式，主要分为稀疏和密集的两类大的类别：

1. 稀疏型提示

稀疏提示指的是，通过一些离散型的介入，对所需要分割的目标进行的描述方式，主要有以下几类：

(1) 点：用户可以给出图像中的一个或多个点，输入到提示解码器的形式为：点具体位置的嵌入以及关于前景或背景的特征嵌入。

(2) 框：一个或多个指定的框，输入到提示解码器的形式为：左上角和右下角位置的位置嵌入以及分别表征“左上角”和“右上角”概念的嵌入。

(3) 文本：一段描述所需要分割的物体的文字，输入到提示解码器的形式为：将文字输入到 Clip 模型 (Radford et al., 2021) 后输出的嵌入。

2. 密集型提示

对于密集的掩码提示，主要是以粗略的掩码标注为主，输入的掩码尺寸是原始图像 4 倍下采样后的大小，再通过两次步长为 2 的卷积操作，获得最后 16 倍下采样的结果，最后与图嵌入相加，输入到提示解码器。

4.3 训练数据集的标注和提示信息生成

由于 SAM 模型的训练和微调，需要训练数据对应的标签以及合适的提示信息，而目前实际地震数据的深部断层缺少对应的标签，下面的一节，我们主要介绍了深部断层标签和提示信息的准备流程。

4.3.1 深部断层的人工标注

为了获得足够，且优质的深部断层检测的标签，我们首先经过了大规模的实际地震数据的筛选，选择了四个比较有代表性的三维地震数据（图 4.7），每个数据都具有比较明显且丰富的深部断层的特征。

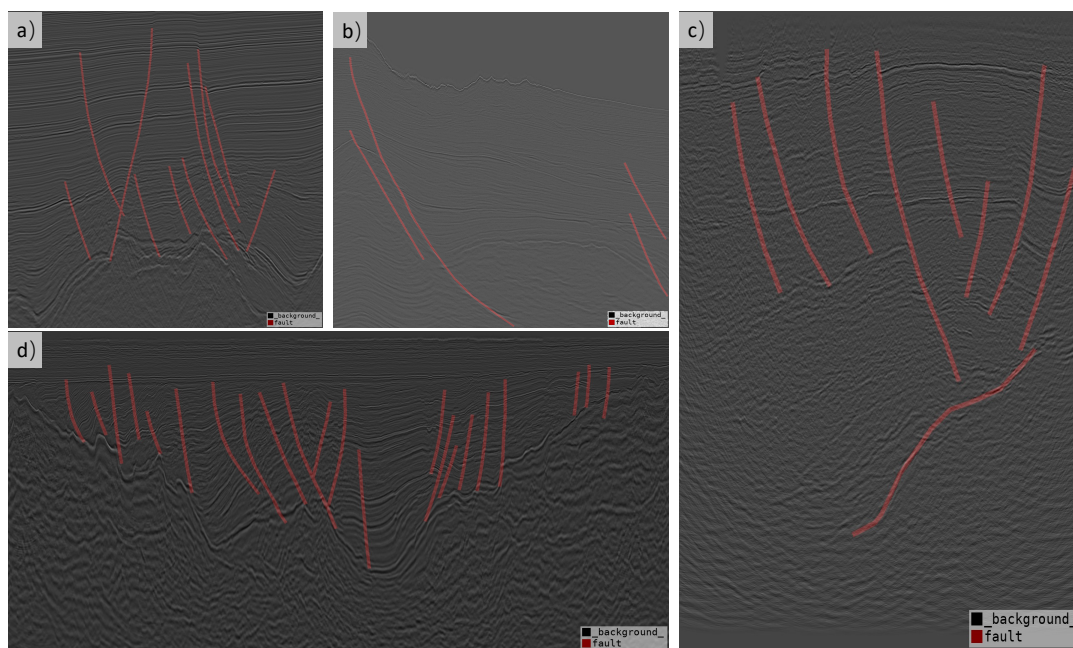


图 4.7 深部断层地震图像与标注

注：图 4.7a~d 展示了分别来自四个具有深部大尺度断层工区的二维地震数据图像和对应的断层标注（红色）

由于目前的模型对于浅部正断层的识别已经表现的很好了，我们对上面的四个地震数据的标注主要针对于深部的断层。同时，我们在后续模型的微调和训练中，每次只随机地选择每个地震数据所标注的断层中的一条断层作为提示信息所对应的断层，所以在标注的过程中，由于人工标注的主观性，一些断层构造的漏标和少标，并不会影响整个模型的微调。对于每张二维地震图像，我们的标注任务量也并不大，每张图大致标注 5-20 个独立的断层就能达到我们的需求。

同时，由于 SAM 模型极强的泛化能力，针对于一个三维地震数据，需要标注的二维切片数量的要求也可以被大幅的降低，下表是我们统计的上面四个实际地震数据的尺寸大小以及响应的二维切片的标注率。

表 4.1 深部断层标注统计

数据名	数据维度 (n1,n2,n3)	标注切片数量	标注率
数据一	(1276, 945, 1449)	100	4.12%
数据二	(1000, 2000, 2001)	75	1.84%
数据三	(2501, 1501, 1001)	111	2.77%
数据四	(1501, 1601, 400)	40	1.99%

4.3.2 断层检测提示信息的生成

SAM 模型的训练不仅需要地震图像的断层标签，同时也需要相对应的提示信息。针对于断层结构的特点，并考虑到后续进行模型推理过程中用户对提示信息输入和交互上的方便性，我们选择以点的形式作为模型微调的提示信息。同时，点的提示信息也可以很方便地从我们的断层标签中获取，我们只需要对已经标注好的断层标签进行随机采样，每个采样点就可以作为我们模型微调输入的提示信息，这样也能减少对于提示信息标注的人工成本。

在标注时，我们为断层标签的宽度设置的是 2 个像素的宽度，考虑到用户在进行交互式操作时，对点形提示信息的选择和输入可能存在一定的误差。为了缓解此类误差带来的影响，我们在生成提示信息之前，首先对断层标签进行了膨胀操作，将断层的宽度增加至 5 个像素。通过这种方式，在一个更宽的范围内进行提示信息的采样，从而提高了模型对于用户选择点提示信息时的容错能力。

以下图 4.8 为一个示例，展示了一组地震图像及其对应的断层标签和生成的提示信息。图中，黄色线条表示人工标注的断层标签，而红色点标记则代表了从断层标签中采样得到的点形提示信息。

4.4 基于 Adapter 的 SAM 模型微调

4.4.1 大模型微调的研究现状

SAM 模型用于模型预训练的训练数据类型和数量众多，模型的主要目的也是为了实现一种自然图像的通用分割工具。然而，当直接将此模型应用于一些特定的细分领域，如断层检测或医学图像分割等场景时，会遇到一定的局限性。这主要是因为 SAM 模型在设计时，并没有特别针对这些领域的深入需求和特定的领域知识进行优化。因此，尽管 SAM 模型在图像分割的一般任务上表现出色，但在这些特定应用场景下，其效果可能无法达到最佳状态。

针对上述问题，对基础大模型进行微调已经成了目前大模型应用于下游任务的主流选择。目前主流的大模型的微调方案主要可以分为以下五大类：(1) Fine-tune: 模型全部参数的更新微调，计算成本较高 (Howard et al., 2018)。(2) Prompt-tune: 比较著名的有 P-tuning(Gu et al., 2023)、LoRA(Hu et al., 2021)、Prompt-tuningcitep(Lester et al., 2021)、AdaLoRA(Zhang et al., 2023) 等方法，这种微调方法

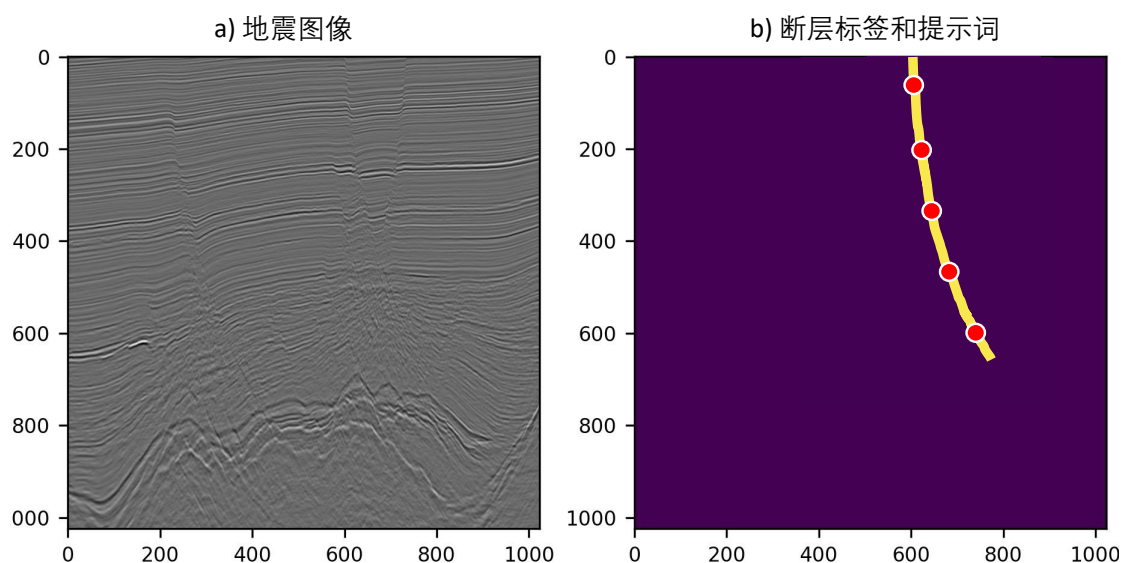


图 4.8 深部断层标签和提示信息示意图

注：图 4.8 (a) 展示了一个具有深部断层构造的地震图像。图 4.8 (b) 展示了 (a) 图中地震图像对应的断层标签，其中的红色点表示了我们从断层标签中采样得到的点提示信息。

只进行部分参数的微调，减少了显存和训练时间。(3) **Adapter Tuning**: 在模型的结构中嵌入一个额外的 **Adapter** 结构，在微调时，只更新 **Adapter** 的权重 (Houlsby et al., 2019)。(4) **BitFit**: 只进行偏差项和任务头的训练和权重更新 (Zaken et al., 2022)。

4.4.2 深部断层微调工作流程

为了使 **SAM** 模型能更好地完成深部断层的分割任务，我们借用了医学图像分割领域的 **Medical SAM Adapter (MSA)** (Wu et al., 2023) 的工作流程来实现。由于 **SAM** 的参数量巨大，如果直接进行全参数下的微调，需要很昂贵的算力和时间成本。**MSA** 模型选择了 **Adapter Tuning** 的方式进行模型的微调，通过在 **SAM** 模型中插入 **Adapter** 模块，使其能在模型微调的过程中学到目标领域的特征表示，同时不需要进行整个模型参数的更新，其优势在于，基础模型的预训练参数是保持不变的，只需要更新很小量的 **Adapter** 模块中的参数，就可以使模型更好的适应新的任务，同时避免模型灾难性遗忘的问题。

下面我们介绍一下 **MSA** 的主要结构：

1. **图像编码器 (Image Encoder)**: 图像编码器是基于一个标准的 **Vision Transformer (ViT)** 来设计的。在预训练阶段，使用 **Masked Autoencoder (MAE)** 的方式进行模型的训练，通过这一方式，增强了模型对于图像的特征提取能力。

2. **提示编码器 (Prompt Encoder)**: 和 **SAM** 的提示编码器结构一致，主要用于各类提示信息的特征提取。对于 **MSA** 和我们的断层检测任务，模型主要处理

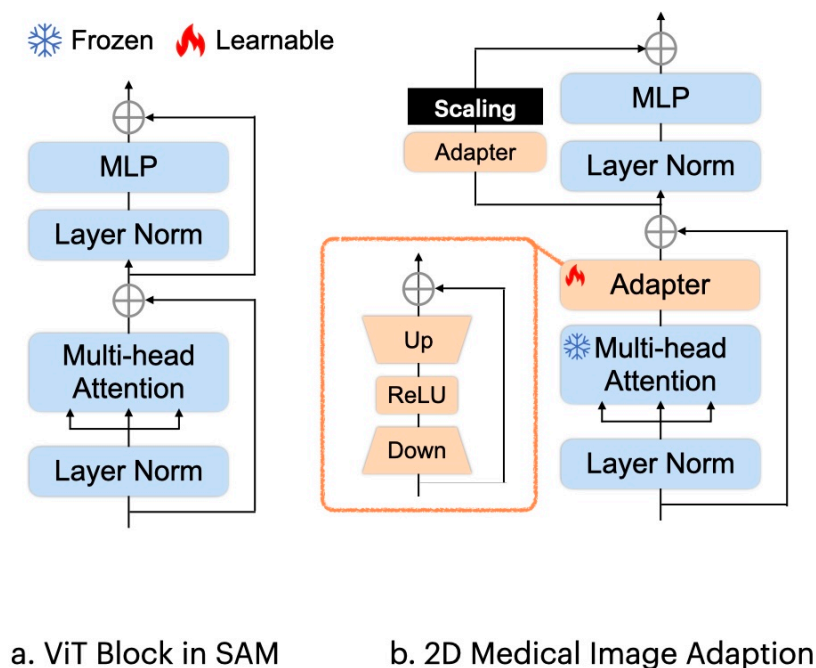


图 4.9 MSA 模型示意图 (Wu et al., 2023)

的是稀疏的点类型的提示信息，并将这些提示信息转为位置编码，再学习对应的嵌入。

3. 掩码解码器 (Mask Decoder): 一个基于 Transformer 的解码器，和 SAM 结构一致，包括一个双向的注意力计算，使模型获得提示信息和图像嵌入的双向信息。

4. Adapter 模块: 这是 MSA 的创新和核心结构 (图 4.9)，它是一个瓶颈型模型，包括向下投影模块、ReLU 激活层和向上投影模块。其中向下投影模块通过 MLP 层，将嵌入压缩为较低的维度，然后向上投影又通过 MLP 层将嵌入恢复到原来的维度。这样的 Adapter 模块被嵌入到 ViT 的两个部分，一个在 ViT 多头注意力层之后，另一个在被放在 MLP 层的残差路径之中。

基于上面的流程，MSA 通过在 SAM 架构中引入 Adapter 模块，实现了模型在细分领域的微调，这种方法不仅能快速地完成模型的新领域学习，同时极大减少了微调的算力的要求，也避免了模型出现灾难性遗忘的问题。

接下来，我们使用在上一节处理和生成的断层标签和对应的提示信息，基于 MAS 模型进行深部断层检测的微调，我们使用了下列的参数进行模型的训练：输入图像尺寸为 1024×1024 ，批大小设置为 2，初始学习率为 $1e-6$ ，损失函数选择了 DiceCELoss，使用 Adam 优化器进行优化，使用一张 NVIDIA Tesla V100-40g 进行训练，训练轮次为 600 个 epoch。

4.5 实际数据预测

为了验证我们对 SAM 模型经过微调后在深部断层识别上的效果，我们将模型应用于几个实际地震数据切片。具体而言，我们的测试数据有两个来源。首先，一部分测试数据来源于验证集，这些数据完全未曾在模型训练过程中出现，以此确保测试能在一定程度上反映模型对未知数据的处理能力。其次，为了进一步检验模型的泛化能力，我们选择了一个完全陌生的地震数据进行模型测试。这批数据与训练数据在地质特征及来源上均有显著差异，且不属于同一地震数据工区。通过这样的双重测试设计，我们旨在全面评估经过微调的 SAM 模型在实际应用中识别深部断层的能力，证明模型在多样数据上的泛化性。

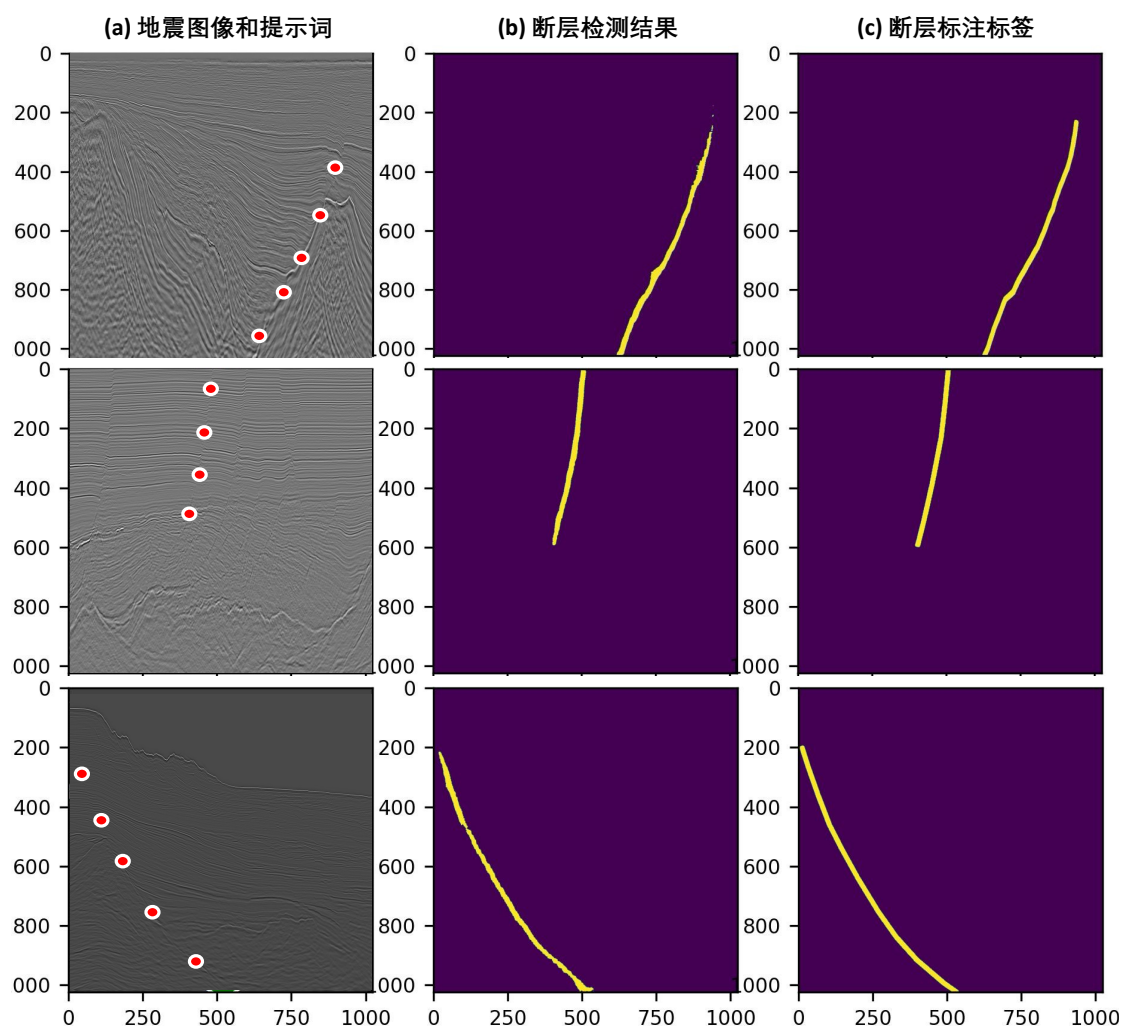


图 4.10 SAM 微调模型在验证集上的检测结果

注：图 4.10 (a) 展示了我们选取的验证集的地震图像和给出的点提示信息（用红色点表示）。图 4.10 (b) 展示了基于提示信息网络预测的断层结果。图 4.10 (c) 展示了验证集对应的专家标注的断层标签。

我们通过给定目标断层对应的点类型的提示信息，让模型在上述的几个数据上进行大尺度的深部断层检测，图 4.10 是模型在验证集上的检测结果。可以看

出，我们的模型通过少量训练集样本的微调，微调后的 SAM 模型，对于同工区的未参与训练的大尺度断层，展现出同样准确的断层检测效果。基于提示信息的先验信息，我们的模型的断层预测结果和标签基本一致，对于大尺度断层的刻画也很连续和准确。

为了更进一步测试模型断层检测的稳定性和泛化能力，如 4.11 所示，我们选择了一个对微调模型完全陌生的一个三维地震数据，箭头所指示的是该工区发育的一个很大规模的大尺度断层。




图 4.11 新工区三维地震图像

注：本图展示了一个模型完全未见过的实际地震数据的三维图像，黄色箭头所指的是该工区的深部大尺度断层。

下图 4.12 展示的是，我们微调后的 SAM 模型在该数据的一个二维切片上的断层检测结果以及和我们专家标注的断层标签的对比结果。

我们可以看出，通过很少量的数据的微调，我们的模型已经能很好地实现深部断层的检测，模型的检测结果和标签基本一致，这也证明了模型的整个微调过程，不存在过拟合于训练数据的情况。尤其，对于模型完全未见过的地震数据（图 4.11），我们的模型也展现了十分准确且鲁棒的结果。

4.6 本章小结

本章深入探讨了基于可提示引擎的 SAM 模型在深部断层检测领域的应用，着重分析了目前深部大尺度断层检测特有的挑战，并提出了一种创新的解决方




图 4.12 新工区的断层检测结果

注：图 4.12 (a) 展示了我们选取的实际数据的二维地震图像和给出的点提示信息（用红色点表示）。图 4.12 (b) 展示了基于提示信息网络预测的断层结果。图 4.12 (c) 展示了实际数据地震数据对应的专家标注的断层标签。

案：通过极少量的实际断层人工标注的训练数据集和以及从标签中生成的提示信息，并结合针对性的模型微调策略，获得一个能识别深部断层小领域特征的 SAM 模型。具体而言，本章内容围绕以下几个关键点进行详细阐述：

1. 深部断层检测的现状与挑战：首先，本章对当前深部大尺度断层检测技术的研究现状进行了分析和总结，指出基于传统卷积神经网络（CNN）的方法虽在浅中部的断层检测领域取得了一定的进展和效果，但仍面临着因深部断层的大尺度和低响应特征以及 CNN 有限的感受野而导致的检测连续性差和泛化能力弱等问题。

2. SAM 模型的理论基础及其在断层检测中的应用：本章详细介绍了 SAM 模型的结构与原理，并讨论了其在深部断层检测中的应用前景。特别强调了 Transformer 架构在处理大尺度、低响应特征方面的优势，如全局注意力机制的引入，有助于模型捕捉更加复杂和细微的地质特征。此外，还探讨了如何通过提示信息增强模型对特定断层特征的识别能力，从而进一步提高检测效率和准确率。

3. 训练数据集的标注与提示信息生成：本研究的一个关键环节是如何准备和标注训练数据集，以及如何生成有效的提示信息以指导模型学习。本章通过少量的、精细化地标注深部断层数据，并创新性地采用点形式的提示信息，有效地降低了人工标注成本，同时增强了模型对复杂断层结构的识别能力。

4. 基于 Adapter 的 SAM 模型微调策略：为了进一步适应深部大尺度断层检测的特定需求，本章提出了一种基于 Adapter 模块的 SAM 模型微调方法。通过在预训练的 SAM 模型中嵌入可学习的 Adapter 模块，对少量参数进行调整，使得模型能够适应特定的深部断层检测任务，从而避免了在大规模参数更新过程中可能出现的过拟合和学习效率低下的问题。本研究实现了模型参数的局部更新，既保留了模型的泛化能力，又显著提高了其在特定任务上的性能。

5. 实际数据预测与效果评估：在模型训练和微调的基础上，本章还展示了模型在实际地震数据上的预测效果，通过与传统方法的对比，验证了基于可提示引擎的 SAM 模型在深部断层检测任务上的优越性。

综上所述，本章不仅展示了基于可提示引擎的 SAM 模型在深部断层检测上的应用潜力，而且通过实验验证了其在提高检测精度和效率方面的显著优势。这些成果为深部地质结构的自动识别与分析提供了新的解决方案和思路。

第 5 章 总结与展望

5.1 本文内容总结

在地球科学领域，地震断层检测一直是一个重要领域和关键技术。通过对地震断层的解释，我们可以对于地下地壳运动、地质演化以及地震活动有更深入的了解。同时，断层的检测对于资源的勘探也十分重要，油气等资源多发育于断层附近，精确的断层检测能为油气的定位和开发提供重要支持。

基于卷积神经网络的断层检测得到了广泛的研究和发展，但目前的研究仍然面临着不足和挑战，本文详细的对断层检测从评价指标、影响 CNN 断层检测的多个因素、预测阶段的数据增广以及深部断层的可交互式检测这些方面进行了探究，以展示 CNN 的特性和训练经验，并提升断层检测结果的准确性和模型的泛化性。

下面对本文的研究进行总结：

(1) 断层检测评价指标对比研究：我们对语义分割领域的评价指标进行了调研和对比，通过模拟实际情况下可能的预测结果，对基于像素的和基于距离的评价指标进行了测试和对比。最终，我们定量地证明了双向倒角距离对断层检测任务具有更好的适用性。

(2) 基于 CNN 断层检测影响因素的探究：我们基于被广泛使用的 U-Net 模型作为基线模型，从以下因素进行了探究并得出以下结论：首先对于合成训练数据集，通过改进合成地震数据正演的流程，我们模拟了更为真实的断面反射波特征，并从实际地震数据中提取背景噪声作为合成地震数据的噪声。此外，我们还发现，由于模型感受野有限且固定，通过对数据的纵向采样率进行增广，可以增强模型对复杂实际地震数据的泛化能力。我们还对损失函数的进行了讨论并提出了 BC-Dice loss 来更好的完成模型训练。最后我们对 U-Net 的模型架构进行了探究，发现更深，通道数更多的模型能获得更佳的断层分割表现。

(3) 多尺度和多角度预测流程：由于 CNN 缺少等变性和不变性，我们提出了一套预测阶段的数据增广的工作流程，通过多尺度和多角度地进行多个增广后数据的断层预测，再进行多个结果的融合于增强，最终输出更稳定、连续和准确的断层检测结果。

(4) 可交互式深部断层检测：为了解决目前 CNN 方法对深部大尺度断层泛化性不佳的问题，我们基于大数据预训练下的 SAM 模型，使用 Adapter 的方式进行了该模型在深部大尺度断层任务上的微调。实验证明，仅通过很少量的手动标注和自动化生成的提示词，就可以实现 SAM 模型的小领域迁移，达到可交互式的深部断层检测。

5.2 未来展望

随着深度学习的不断革新和发展，地震断层的智能检测技术也需要不断地更新。尽管本研究对现有的模型进行了深入的探究和改进，但面对复杂且不确定强的实际地震数据，目前的研究仍然存在着可以进一步优化的空间：

(1) 目前的合成地震数据的算法还可以进一步的优化改进，以模拟出更为真实且丰富的断层构造模式，如：走滑断层、多边形断层、铲状断层等。上述断层也是目前研究的热点和痛点问题，通过合理的正演手段来获取更高质量的地震数据集，能很大程度提升模型的效果和泛化能力。

(2) 目前对于断层检测的评价标准，评估的验证集还不够完善。在断层检测的领域，缺少有影响力的规则的制定者与高质量的可用于对比的基线模型和评估规范。由于标注的时间成本巨大，本工作只提供了一个二维数据的验证集。构建一个高质量的结果验证体系对于本领域的后续研究对比，都有着很重要的意义。

(3) 可提示引擎在其他地球物理的分割或分类问题上的应用。本研究所提出的可提示引擎的工作流程，也为地球物理的其他分割或分类问题，例如岩丘、溶洞等构造，提供了可借鉴的经验。通过这样的流程，我们能更好的发挥大模型的特征提取能力来解决地球物理领域的问题。

参 考 文 献

- AN Y, GUO J, YE Q, et al. 2021. Deep convolutional neural network for automatic fault recognition from 3d seismic datasets[J]. *Computers & Geosciences*, 153: 104776.
- AN Y, DU H, MA S, et al. 2023. Current state and future directions for deep learning based automatic seismic fault interpretation: a systematic review[J]. *Earth-Science Reviews*: 104509.
- AQRAWI A A, BOE T H. 2011. Improved fault segmentation using a dip guided and modified 3d sobel filter[M]//SEG Technical Program Expanded Abstracts 2011. Society of Exploration Geophysicists: 999-1003.
- AZULAY A, WEISS Y. 2018. Why do deep convolutional networks generalize so poorly to small image transformations?[A].
- BOND C E, GIBBS A D, SHIPTON Z K, et al. 2007. What do you think this is? ‘conceptual uncertainty’ in geoscience interpretation[J]. *GSA today*, 17(11): 4.
- BRIDLE J S. 1990. Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition[M]//*Neurocomputing: Algorithms, architectures and applications*. Springer: 227-236.
- CANNY J. 1986. A computational approach to edge detection[J]. *IEEE Transactions on pattern analysis and machine intelligence*(6): 679-698.
- DI H, SHAFIQ M A, ALREGIB G. 2017. Seismic-fault detection based on multiattribute support vector machine analysis[C]//2017 SEG International Exposition and Annual Meeting. OnePetro.
- DI H, WANG Z, ALREGIB G. 2018. Why using cnn for seismic interpretation? an investigation [C]//2018 SEG International Exposition and Annual Meeting. OnePetro.
- DI H, GAO D, ALREGIB G. 2019. Developing a seismic texture analysis neural network for machine-aided seismic pattern recognition and classification[J]. *Geophysical Journal International*, 218(2): 1262-1275.
- DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. 2021. An image is worth 16x16 words: Transformers for image recognition at scale[A]. arXiv: 2010.11929.
- DOU Y, LI K, ZHU J, et al. 2021a. Efficient training of 3d seismic image fault segmentation network under sparse labels by weakening anomaly annotation[A].
- DOU Y, LI K, ZHU J, et al. 2021b. Attention-based 3-d seismic fault segmentation training by a few 2-d slice labels[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-15.
- FAN H, SU H, GUIBAS L J. 2017. A point set generation network for 3d object reconstruction from a single image[C]//*Proceedings of the IEEE conference on computer vision and pattern*

- recognition. 605-613.
- FAWCETT T. 2006. An introduction to roc analysis[J]. *Pattern recognition letters*, 27(8): 861-874.
- FOSSSEN H. 2016. *Structural geology*[M]. Cambridge university press.
- GAO K, HUANG L, ZHENG Y. 2021. Fault detection on seismic structural images using a nested residual u-net[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-15.
- GAO K, HUANG L, ZHENG Y, et al. 2022. Automatic fault detection on seismic images using a multiscale attention convolutional neural network multiscale attention fault detection[J]. *Geophysics*, 87(1): N13-N29.
- GDALYAHU Y, WEINSHALL D, WERMAN M. 2001. Self-organization in vision: stochastic clustering for image segmentation, perceptual grouping, and image database organization[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10): 1053-1074.
- GIBA M, WALSH J, NICOL A. 2012. Segmentation and growth of an obliquely reactivated normal fault[J]. *Journal of Structural Geology*, 39: 253-267.
- GU J, HAN Z, CHEN S, et al. 2023. A systematic survey of prompt engineering on vision-language foundation models[A].
- HALE D, EMANUEL J. 2003. Seismic interpretation using global image segmentation[M]//SEG Technical Program Expanded Abstracts 2003. Society of Exploration Geophysicists: 2410-2413.
- Hale, D. 2013. Methods to compute fault images, extract fault surfaces, and estimate fault throws from 3d seismic images[J]. *Geophysics*, 78(2): O33-O43.
- HAMZEH A. 2021. Machine learning methods in fault detection[Z].
- HAN J, MORAGA C. 1995. The influence of the sigmoid function parameters on the speed of backpropagation learning[C]//International workshop on artificial neural networks. Springer: 195-201.
- HINTON G E, SALAKHUTDINOV R R. 2006. Reducing the dimensionality of data with neural networks[J]. *science*, 313(5786): 504-507.
- HOULSBY N, GIURGIU A, JASTRZEBSKI S, et al. 2019. Parameter-efficient transfer learning for nlp[A]. arXiv: 1902.00751.
- HOWARD J, RUDER S. 2018. Universal language model fine-tuning for text classification[A]. arXiv: 1801.06146.
- HU E J, SHEN Y, WALLIS P, et al. 2021. Lora: Low-rank adaptation of large language models[A].
- HUANG L, DONG X, CLEE T E. 2017. A scalable deep learning platform for identifying geologic features from seismic attributes[J/OL]. *The Leading Edge*, 36(3): 249-256. <https://doi.org/10.1190/tle36030249.1>.
- JACQUEMIN P, MALLET J L. 2005. Automatic faults extraction using double hough transform

- [C]//2005 SEG Annual Meeting. OnePetro.
- KATO S, HOTTA K. 2021. Mse loss with outlying label for imbalanced classification[A].
- KIRILLOV A, MINTUN E, RAVI N, et al. 2023. Segment anything[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 4015-4026.
- LECUN Y, BOTTOU L, BENGIO Y, et al. 1998. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 86(11): 2278-2324.
- LECUN Y, BENGIO Y, HINTON G. 2015. Deep learning[J]. nature, 521(7553): 436-444.
- LESTER B, AL-RFOU R, CONSTANT N. 2021. The power of scale for parameter-efficient prompt tuning[A].
- LI F, LU W. 2014. Coherence attribute at different spectral scales[J]. Interpretation, 2(1): SA99-SA106.
- LIS, YANG C, SUN H, et al. 2019. Seismic fault detection using an encoder–decoder convolutional neural network with a small training set[J]. Journal of Geophysics and Engineering, 16(1): 175-189.
- LIU N, HE T, TIAN Y, et al. 2020. Common-azimuth seismic data fault analysis using residual unet [J]. Interpretation, 8(3): SM25-SM37.
- LUO W, LI Y, URTASUN R, et al. 2016. Understanding the effective receptive field in deep convolutional neural networks[J]. Advances in neural information processing systems, 29.
- MARFURT K J, KIRLIN R L, FARMER S L, et al. 1998. 3-d seismic attributes using a semblance-based coherency algorithm[J]. Geophysics, 63(4): 1150-1165.
- MARFURT K J, SUDHAKER V, GERSZTENKORN A, et al. 1999. Coherency calculations in the presence of structural dip[J]. Geophysics, 64(1): 104-111.
- MILLETARI F, NAVAB N, AHMADI S A. 2016. V-net: Fully convolutional neural networks for volumetric medical image segmentation[C]//2016 fourth international conference on 3D vision (3DV). IEEE: 565-571.
- MOHAMMADPOOR M, TORABI F. 2020. Big data analytics in oil and gas industry: An emerging trend[J]. Petroleum, 6(4): 321-328.
- NAIR V, HINTON G E. 2010. Rectified linear units improve restricted boltzmann machines[C]// Proceedings of the 27th international conference on machine learning (ICML-10). 807-814.
- PEDERSEN S I, SKOV T, HETLELID A, et al. 2003. New paradigm of fault interpretation[C]// 2003 SEG Annual Meeting. OnePetro.
- PEDERSEN S I, SKOV T, RANDEN T, et al. 2005. Automatic fault extraction using artificial ants[M]//Mathematical methods and modelling in hydrocarbon exploration and production. Springer: 107-116.
- POWERS D M. 2020. Evaluation: from precision, recall and f-measure to roc, informedness,

- markedness and correlation[A].
- RADFORD A, KIM J W, HALLACY C, et al. 2021. Learning transferable visual models from natural language supervision[A]. arXiv: 2103.00020.
- RANDEN T, PEDERSEN S I, SØNNELAND L. 2001. Automatic extraction of fault surfaces from three-dimensional seismic data[M]//SEG Technical Program Expanded Abstracts 2001. Society of Exploration Geophysicists: 551-554.
- ROBERTS A. 2001. Curvature attributes and their application to 3 d interpreted horizons[J]. First break, 19(2): 85-100.
- RONNEBERGER O, FISCHER P, BROX T. 2015. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical image computing and computer-assisted intervention. Springer: 234-241.
- SHI J, MALIK J. 2000. Normalized cuts and image segmentation[J]. IEEE Transactions on pattern analysis and machine intelligence, 22(8): 888-905.
- SOKOLOVA M, LAPALME G. 2009. A systematic analysis of performance measures for classification tasks[J]. Information processing & management, 45(4): 427-437.
- VAN BEMMEL P P, PEPPER R E. 2000. Seismic signal processing method and apparatus for generating a cube of variance values[M]. Google Patents.
- VASWANI A, SHAZEER N, PARMAR N, et al. 2023. Attention is all you need[A]. arXiv: 1706.03762.
- WEI X L, ZHANG C X, KIM S W, et al. 2022. Seismic fault detection using convolutional neural networks with focal loss[J]. Computers & Geosciences, 158: 104968.
- WU J, JI W, LIU Y, et al. 2023. Medical sam adapter: Adapting segment anything model for medical image segmentation[A]. arXiv: 2304.12620.
- WU X. 2017. Directional structure-tensor-based coherence to detect seismic faults and channels[J]. Geophysics, 82(2): A-13.
- WU X, FOMEL S. 2018a. Automatic fault interpretation with optimal surface voting[J]. Geophysics, 83(5): O67-O82.
- WU X, HALE D. 2016. 3d seismic image processing for faults[J]. Geophysics, 81(2): IM1-IM11.
- WU X, ZHU Z. 2017. Methods to enhance seismic faults and construct fault surfaces[J/OL]. Computers & Geosciences, 107(Supplement C): 37 - 48. <http://www.sciencedirect.com/science/article/pii/S0098300417301346>. DOI: <https://doi.org/10.1016/j.cageo.2017.06.015>.
- WU X, SHI Y, FOMEL S, et al. 2018b. Convolutional neural networks for fault interpretation in seismic images[C]//2018 SEG International Exposition and Annual Meeting. OnePetro.
- WU X, LIANG L, SHI Y, et al. 2019a. Faultseg3d: Using synthetic data sets to train an end-to-end convolutional neural network for 3d seismic fault segmentation[J]. Geophysics, 84(3):

- IM35-IM45.
- WU X, LIANG L, SHI Y, et al. 2019b. Multitask learning for local seismic image processing: fault detection, structure-oriented smoothing with edge-preserving, and seismic normal estimation by using a single convolutional neural network[J]. *Geophysical Journal International*, 219(3): 2097-2109.
- XIE S, TU Z. 2015. Holistically-nested edge detection[C]//Proceedings of the IEEE international conference on computer vision. 1395-1403.
- XIONG W, JI X, MA Y, et al. 2018. Seismic fault detection with convolutional neural network[J]. *Geophysics*, 83(5): O97-O103.
- YAN Z, LIU S, GU H. 2019. Fault image enhancement using a forward and backward diffusion method[J]. *Computers & Geosciences*, 131: 1-14.
- YILMAZ Ö. 2001. Seismic data analysis: Processing, inversion, and interpretation of seismic data [M]. Society of exploration geophysicists.
- YU T, WANG X, CHEN T J, et al. 2022. Fault recognition method based on attention mechanism and the 3d-unet[J]. *Computational Intelligence and Neuroscience*, 2022.
- ZAKEN E B, RAVFOGEL S, GOLDBERG Y. 2022. Bitfit: Simple parameter-efficient fine-tuning for transformer-based masked language-models[A]. arXiv: 2106.10199.
- ZHANG B, LIU Y, PELISSIER M, et al. 2014. Semiautomated fault interpretation based on seismic attributes[J]. *Interpretation*, 2(1): SA11-SA19.
- ZHANG Q, CHEN M, BUKHARIN A, et al. 2023. Adalora: Adaptive budget allocation for parameter-efficient fine-tuning[A]. arXiv: 2303.10512.
- ZHANG R. 2019. Making convolutional networks shift-invariant again[C]//International conference on machine learning. PMLR: 7324-7334.
- ZHENG Z, ZHE Y, HANMING G. 2020. Automatic fault recognition with residual network and transfer learning[J]. *Oil Geophysical Prospecting*, 55(5): 950-956.

致 谢

在中国科学技术大学这个科研和学习的圣地，我有幸度过了三年的研究生生涯，现在我站在毕业的门槛上，回望过去，心中充满了无尽的感激和不舍。此刻，我想要通过这篇致谢，向所有支持我、关心我的人表达我的谢意。

首先，我必须深深地感谢我的导师伍新明教授。在我的学术旅程中，伍老师不仅是我的指路人，更是我的精神榜样。在科大的这三年，伍老师的高超学术能力和对专业知识的深刻理解，深深的让我折服。在科研中，和老师的交流讨论也让我收获颇丰，无论是在地球物理的知识和 AI 的算法，还是良好的科研、汇报的习惯和建议，都让我逐渐从一个学生走向真正有科研素养的研究生。在科研学习之余，伍老师还很关心大家的心理状态和未来规划，总能在我迷茫时给予我灵感，引领我走过难关。在求职期间，伍老师更是给予了我莫大的帮助，无论是在精神鼓励还是实际行动上，都让我深感温暖。老师的严谨治学、勤勉工作的态度，将会是我终生的学习榜样。

此外，我也要感谢身边我的父母，您们总是我最坚实的依靠。在我追求学术梦想的道路上，是您们的理解和鼓励，给予了我无限的力量和勇气。您们的辛勤付出和无私奉献，是我无法用任何语言完全表达的感激。今天，当我站在人生的这个重要节点上回望，每一步都凝聚着您们的汗水和泪水，你们的爱和付出是我最为宝贵的财富。

同时我也要感谢我的同门以及所有给予我支持和帮助的朋友们。感谢毕钲发师兄，在我刚入学科大时热心地带我熟悉环境，喝 1958 咖啡，组织给我过生日，让我刚入组就深深地感受到 CIG 的温暖。感谢高航师兄，和师兄相处的三年，深深感受到了师兄对学术的严谨和对身边人满满的善意和真诚。尤其感谢在我压力巨大的求职季时，高航师兄对我的开导和鼓励，以及各种出谋划策，分享经验，给了我莫大的支持和感动。感谢子健师兄，从我实习到最后成功签约，师兄一直不遗余力地为我答疑解惑，关注我的进展，给了我巨大的支持和帮助。感谢恩华师兄，很幸运有恩华这样的好朋友，我们一起自驾，一起爬黄山，一起实习。这些日子，是恩华师兄的开导和鼓励，让我对未知的求职更加有信心。感谢晓明哥，永远都是有求必应，有问必答，永远都是 CIG 沉稳、热心和积极向上的老大哥。感谢金涛师兄，师兄是我心目中的技术大佬和开源大神。金涛师兄写的技术博客早已成了每个新生入学必读，师兄开发的 `cigSegy` 和 `cigVis` 也是更佳卓越的工作，也方便了大家的科研。感谢瀚林师兄，全能型的瀚林师兄永远都积极地为组内的大家奉献，研一一年的专业课，师兄也给了我巨大的支持和帮助。感谢王雨婷师妹，作为我在 CIG 最好的朋友，我们一起旅行，一起吃美食，一

起健身运动，无话不说。很高兴且荣幸，研究生的三年能有你这样好的朋友。感谢薛智文师兄，在我迷茫无措的时候，给我很多帮助和支持。感谢魏志祥师弟，师弟不仅自己学习能力和代码能力超强，还很愿意和我们探讨或解决大家的科研问题。感谢杨佳润师兄，一开始 1108 办公室只有我和佳润师兄，师兄一直都很乐意解答我科研和生活上的问题，还带着大家运动，吃好吃的，是我们办公室暖心的老大哥。感谢张文师姐，为课题组的聚餐、组会等各项活动付出很多，保障了整个组日常的顺利运转。感谢绍琦师弟，热心地在寒假帮我照顾我的鱼。还要感谢方惠京、司旭、李亚星、张青山、谢东子、刘子琛、田晨琪、韩龙、陈诺、杨志国、张青、高晖等 CIG 其他所有的小伙伴们，感谢你们的陪伴和支持，让我感受到这个大家庭的温暖。感谢我在科大的好朋友，章涛、郑群、刘璞，希望我们的友情万古长青。

还要感谢我办公桌上，日夜陪伴我的小鱼们，你们给我的科研生活注入了更多的生气。还想感谢科大后街卖热干面的襄阳大叔，这是我在全合肥吃到的最正宗的热干面，让我这个在异乡求学的孩子能吃到来自家乡的味道。

最后，我想要表达对中国科学技术大学的深深感激。这里不仅有激发人心的学术氛围，还有浓厚的人文关怀。校园里的每一棵樱花树，都见证了我的成长与变化，春天的樱花如梦如幻，犹如学校对我们每一个学生的期许——在知识的海洋中绽放最美丽的自己。这样的环境，让我在追求学术的同时，也不断地丰富和提升自己的人文素养。

再次感谢所有的老师、同学和朋友，是你们让我的研究生生涯如此丰富多彩。虽然即将离开，但我相信，无论未来走向何方，中国科学技术大学的精神和这份深厚的感情将永远伴随着我，激励我向着更高的目标努力。再见了，亲爱的母校，感谢你在这最美的年华里给予我的一切。

在读期间发表的学术论文与取得的研究成果

已发表论文

1. Li, Y., X. Wu*, Z. Zhu, J. Ding, and Q. Wang, 2024, FaultSeg3D plus: a comprehensive study on evaluating and improving CNN-based seismic fault segmentation, *Geophysics*. (Accepted)