

DOI: 10.20189/j.cnki.CN/61-1527/E.202505002

考虑预训练先验的小样本地震相识别模型

刘 学, 柴变芳*, 许 可, 硕良勋

(河北地质大学 信息工程学院, 石家庄 050031)

摘 要: 针对传统地震相识别方法依赖大量高质量标注数据且在小样本场景下识别效果较差的问题, 构建了考虑预训练先验的小样本地震相识别模型 (seismic facies identification model incorporating pretrained few-shot learning, SFI-PFS), 该模型结合 Moco 自监督预训练与原型对齐网络来实现小样本地震相识别。首先, 使用基于 Moco V1 预训练模型的地震编码器, 以地震数据及其 4 种相关地震属性构建的正负样本对作为训练数据, 采用对比自监督训练方法, 使模型具备较强的特征提取能力; 然后, 将预训练的编码器作为原型对齐网络的特征提取器, 构建具有特征提取先验的小样本地震相识别模型; 最后, 在仅有少量标注的地震数据集上微调模型, 实现像素级别的地震相识别。在 F3 地震数据集上的实验结果表明: SFI-PFS 模型在 5-shot 设置下的平均交并比可达 72.4%, 相较于当前主流的地震相识别方法 SFM (Base) 和 Att-DeepLabV3+ 分别提高 8.3% 和 1.7%, 同时在地震相边缘具有更准确的划分结果。

关键词: 地震相识别; 小样本学习; 原型网络; 对比学习

中图分类号: TE19

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2025)05-0014-09



听语音
与作者
聊科研

Few-Shot Seismic Facies Identification Model Incorporating Pretraining Priors

LIU Xue, CHAI Bianfang*, XU Ke, SHUO Liangxun

(School of Information Engineering, Hebei GEO University, Shijiazhuang 050031, China)

ABSTRACT: A seismic facies identification model incorporating pretrained few-shot learning (SFI-PFS) was constructed to address the problems of conventional seismic facies identification methods, which often rely heavily on large-scale labeled data and tend to exhibit reduced performance under few-shot scenarios. The proposed model integrated Momentum Contrast V1 (Moco V1) self-supervised pretraining with a prototype-based network to achieve few-shot SFI. First, the Moco V1 pretrained model was used to train a feature extractor for seismic data. Both positive and negative sample pairs were constructed from seismic data and four distinct gray-level co-occurrence matrix (GLCM) attributes. A contrastive self-supervised method was adopted to enable

收稿日期: 2024-11-15

修回日期: 2025-09-17

录用日期: 2025-09-30

基金项目: 石家庄市驻冀高校基础研究项目 (241790607A)

第一作者: 刘学 (2001—), 女, 硕士研究生, 主要从事机器学习、智能地球物理研究。E-mail: 384896476@qq.com

***通信作者:** 柴变芳 (1979—), 女, 教授, 主要从事机器学习、智能地球物理研究。E-mail: chaibianfang@163.com

引用格式: 刘学, 柴变芳, 许可, 等. 考虑预训练先验的小样本地震相识别模型[J]. 火箭军工程大学学报, 2025, 39 (5): 14-22.

LIU Xue, CHAI Bianfang, XU Ke, et al. Few-shot seismic facies identification model incorporating pretraining priors[J]. Journal of Rocket Force University of Engineering, 2025, 39 (5): 14-22.

the network to acquire discriminative feature extraction capabilities. Subsequently, the pretrained encoder was used as the feature extractor of the prototype network to construct a few-shot SFI model with feature extraction prior. Finally, the prototype-based network was fine-tuned on a small set of labeled seismic data, thereby achieving pixel-level SFI. The experimental evaluations conducted on the F3 seismic dataset show that the SFI-PFS model achieves mean intersection over union (MIoU) scores of 72.4% under 5-shot experimental conditions, outperforming mainstream SFI methods, such as SFM (Base) and Att-DeepLabV3+, with MIoU improvements of 8.3% and 1.7%, respectively. Furthermore, the proposed method achieves higher segmentation accuracy along seismic facies boundaries.

KEYWORDS: seismic facies identification; few-shot learning; prototype network; contrastive learning

地震解释是地震勘探的关键环节, 可依据地震数据推断地下结构并分析油气资源的分布特征。基于深度学习的地震相识别方法^[1-2]根据所使用标注数据的不同, 可分为有监督^[3]、无监督^[4]和半监督^[5]方法。然而, 以上3种方法在地震分析数据有限、标注样本稀缺的情况下均表现不佳。近年来, 相关学者提出面向语义分割任务的小样本学习 (few-shot learning, FSL) 方法, 为解决仅有少量标注样本的地震相识别问题提供了有效途径^[6]。小样本语义分割方法通常采用“预训练-微调”范式, 将预训练模型作为微调模型的特征提取器。在微调阶段, 基于目标提供的少量标注样本, 将其划分为支持集和查询集, 通过预训练编码器在支持集上构建目标模型, 然后以查询集上的模型预测结果来优化目标模型。例如, 许天恩等^[7]利用 Res-UNet 网络模型学习地震数据与地震相之间的非线性关系, 通过扩充样本和迁移策略来解决小样本学习问题。然而, 该方法的迁移策略要求源域和目标域类别保持一致, 但很多目标工区与预训练的源工区之间存在差异。针对标注样本不具有代表性的问题, Luo 等^[8]提出一种基于无监督验证和谱聚类采样的地震地层解释方法, 但该方法假设地层连续, 应用场景十分有限且算法参数多依赖于经验值。Babakhin 等^[9]利用自动生成弱标签的弱监督策略, 解决了仅有少量标注样本的监督学习问题, 但该方法性能受限于弱标签的正确与否。蔡涵鹏等^[10]使用叠前地震纹理特征, 突出微小特殊振幅响应, 同时结合钻井数据先验, 利用少量标注和无标注数据来实现小样本学习, 主要用于地震叠前数据处理。近年来, 伍新明团队^[11-12]提出了一些基于大模型的地震相识别方法, 可用于地质构造、地层层序及地质体解释等任务,

但该类模型对硬件资源要求较高。

与上述方法不同, 基于原型网络的小样本地震相分割 (seismic facies segmentation via prototype learning, SFS-PL) 模型^[13]能够充分利用少量样本数据来学习各类地震相的分类模型, 预训练阶段以无标注地震剖面构建含掩码道训练集, 通过卷积自编码器优化重建损失, 从而完成编码器训练; 微调阶段将预训练编码器接入度量学习原型网络, 利用目标区域少量标注样本优化模型, 最终实现高效地震相分割。SFS-PL 模型网络架构简单、训练高效, 仅通过有限样本便可学习分类模型, 但也存在以下2个问题。一是地震相识别准确率有待提升: 模型仅依赖支持集 (少量标注样本) 学习类原型, 基于最大似然的目标函数使模型对稀少样本极为敏感, 反过来影响模型的表征学习效果, 且未对查询集数据中的类原型进行对齐, 导致类原型未充分覆盖所有标注信息, 存在类原型表征不准确的问题, 最终影响模型预测准确率。二是地震特征提取效果不佳: 以掩码自编码器为预训练模型, 解码阶段通过简单插值逐层重建输入尺度特征图, 但该方法难以重建输入图像, 导致重建损失不足以指导模型学习地震表征。

针对基于原型网络的小样本语义分割模型在地震相识别问题中存在的不足, 本文提出一种考虑预训练先验的小样本地震相识别模型 (seismic facies identification model incorporating pretrained few-shot learning, SFI-PFS)。该模型使用原型对齐网络 (prototype alignment network, PANet) 框架^[14], 并采用 Moco V1 预训练模型来对编码器进行训练, 从而提升地震相识别精度。针对原型网络未能将支持集和查询集类原型进行对齐的问题, 引入原型对齐损失函数来计算待测图像像素

表示与类原型之间的相似度,从而显著提升类原型质量,提高小样本地震相分割精度;针对原始地震数据中存在的噪声会掩盖关键纹理与地质信息的问题,采用灰度共生矩阵作为预训练数据^[15],利用区域统计度量与滑窗计算方法,更精准地刻画地震剖面纹理特征,从而提升对储层相分布、体积及连通性的识别精度;针对原型网络编码器特征提取能力不足的问题,将Moco V1^[16-17]作为预训练编码器,并与地震属性相结合^[18],以多属性作为对比学习的数据增强手段,通过最小化对比损失可构建具备优异特征提取能力的编码器。

1 SFI-PFS 模型构建

考虑预训练的小样本地震相识别模型由2部分组成,分别为基于Moco V1预训练模型的地震编码器模块和小样本地震相识别模块。地震编码器模块采用对比的自监督学习范式进行训练,小样本地震相识别模块使用原型对齐网络进行建模。

1.1 基于Moco预训练模型的地震编码器

地震编码器采用Moco V1预训练模型,其编码器网络框架如图1所示。该模型利用编码器学习输入的样本对并计算其相似度,通过最大化正样本对相似度和最小化负样本对相似度来优化模型。同时,本文基于灰度共生矩阵(gray-level co-occurrence matrix, GLCM)来构建输入样本对。对于每个地震振幅剖面数据,使用连续滑窗计算地震剖面的GLCM属性,并将其转化为纹理特征的二级度量,进而得到最大能量、最小能量、对比度和同质性4个纹理属性剖面作为输入地震剖面的

正样本。然后,分别使用编码器与动量编码器对输入样本对进行编码,再通过多层感知器(multilayer perceptron, MLP)非线性变换得到输入样本对的表示 q 和 k ,并计算对比损失。编码器通过反向传播梯度更新参数,生成动态的地震振幅剖面表示;动量编码器通过动量机制更新,不参与反向传播,以编码器的参数为基础进行缓慢更新。这样的更新方式有助于保持一个稳定的负样本特征库,从而提高模型对比学习中的特征一致性,较大程度保留了地震数据的纹理信息,使模型更容易提取到关键特征。




图1 地震相识别的预训练模型

Fig. 1 Pretrained model for SFI

Moco V1预训练模型的编码器部分使用的是VGG 16网络架构,其框架如图2所示。编码器采用5个阶段卷积操作,Conv1将输入图像尺寸处理为基本残差卷积块输入尺寸,Conv2_x、Conv3_x、Conv4_x、Conv5_x通过基本残差块逐层提取更抽象的特征。编码器将地震振幅剖面 and 属性剖面送入堆叠的卷积块中,经过不同的阶段,产生多个维度特征信息,最后将得到的隐含特征(hidden features)用于模型预测。

Moco V1预训练模型采用对比损失函数In-




图2 Moco V1预训练模型编码器网络框架

Fig. 2 Network architecture of the Moco V1 pretrained model-based encoder

foNCE来计算样本之间的相似性,从而使模型具备对地震相特征学习的能力。此外,InfoNCE还可以缓解地震数据存在背景噪声时带来的识别精度下降问题,通过对比机制区分地震相的有效特征和背景噪声特征,使预训练编码器能够学习到有效的地震相特征。InfoNCE损失函数的表达式为

$$L_q = -\log \frac{\exp(c(q, k_+)/\tau)}{\sum_{i=0}^m \exp(c(q, k_i)/\tau)} \quad (1)$$

式中: q 为当前地震剖面; k_+ 为每次抽取 q 的 4 种 GLCM 属性增强后的正样本嵌入表示; $c(\cdot)$ 为余弦相似度函数; m 为负样本个数; k_i 为当前剖面的第 i 个负样本; τ 为温度参数,通常用来控制任务中样本对之间的相似度分布敏感度。较大的 τ 值更容易将不同的样本视为相似类别,有助于模型更广泛地捕捉数据的一致性特征,较小的 τ 值则会增加相似度计算的敏感度,使模型更注重样本之间的微小差异,有助于模型更精细地区分不同的数据。本文 τ 取 1。

1.2 基于 PANet 的小样本地震相识别模型

1.2.1 SFI-PFS 模型网络架构

小样本地震相识别网络以语义分割网络 PANet 为基础架构,融合度量学习思想构建一致性类原型表示机制,其整体模型结构如图 3 所示。小样本地震相识别模型的训练过程如下。

1) 训练数据划分。采用小样本学习的“支持集-查询集”划分方式将训练数据划分为支持集和查询集。

2) 模型预测。将预训练的 Moco V1 作为编码器主干特征提取模块,分别对支持集与查询集的地震剖面进行编码,输出二者的高层语义表征,为后续原型学习与相似度计算奠定基础。基于支持集高层语义表征,计算各类地震相的嵌入原型,

随后计算查询集每个像素的嵌入表征与各类原型的相似度,并将相似度结果上采样至地震剖面原始尺寸,作为初始地震相预测结果。

3) 基于对齐优化策略的模型优化。首先,依据查询集初始预测结果,计算预测损失;其次,以查询集预测结果作为伪标注信息,构建查询集新原型,并计算支持集表征与新原型的相似度以预测支持集地震相,结合支持集真实标注计算对齐损失;最终通过最小化总损失实现支持集与查询集的特征对齐,并迭代优化模型参数。

本文 SFI-PFS 预训练编码器的部分参数如表 1 所示。

表 1 SFI-PFS 预训练编码器参数

Table 1 Parameters of the SFI-PFS pretrained encoder

模块	卷层数	输入形状	输出形状
Conv1	2	$B, 1, 701, 255$	$B, 64, 350, 127$
Conv2_x	2	$B, 64, 350, 127$	$B, 128, 175, 63$
Conv3_x	3	$B, 128, 175, 63$	$B, 256, 87, 31$
Conv4_x	3	$B, 256, 87, 31$	$B, 512, 43, 15$
Conv5_x	3	$B, 512, 43, 15$	$B, 512, 21, 7$
MLP	3	$B, 512, 21, 7$	$B, 1\,000$

注: ① B 表示每个 batch 的样本个数,由硬件参数和训练数据个数确定; ② 每个样本的输入/输出均为三维张量,三个维度分别为通道数、图高和图宽。

设支持集中的训练样本共有 C 类,每类样本数量为 K ,大小为 701×255 。经编码器提取训练样本的深层表示后,基于学到的深层表示和标注样本可得到类 j 的原型表示,其数学表达式为

$$P_j = \frac{1}{K} \sum_k \frac{\sum_{x,y} F_{j,k}^{x,y} I(M_{j,k}^{x,y} = j)}{\sum_{x,y} I(M_{j,k}^{x,y} = c)} \quad (2)$$




图 3 小样本地震相识别网络架构

Fig. 3 Network architecture of the few-shot SFI

式中: $M_{j,k}$ 为输入的第 j 类中第 k 个地震剖面标注信息; $F_{j,k}$ 为编码器提取到的相应特征图的预测结果; x, y 为地震剖面中每个像素的空间位置索引; $I(\cdot)$ 为一个指示器函数, 函数自变量为真则输出 1, 否则为 0。

在获得所有类别的原型表示和查询集表示后, 根据给定距离函数, 计算查询集表示和原型表示之间的相似度, 此处使用余弦距离。然后应用 softmax 函数计算每个查询集图像样本的每个像素预测为类 j 的概率, 然后根据其预测地震剖面的地震相类别。数学表达式为

$$\hat{Q}_{q,j}^{x,y} = \text{softmax}(-d(F_q^{x,y}, P_j)) \quad (3)$$

式中: F_q 为查询图像上的一个预测对象的特征向量; $d(\cdot)$ 为余弦距离函数; $\hat{Q}_{q,j}^{x,y}$ 为第 q 个查询图像在 (x, y) 位置处属于第 j 类的概率。

1.2.2 SFI-PFS 的优化目标

1) 分割损失

分割结果被上采样到原始大小, 得到查询地震剖面预测结果, 根据标注结果计算分割损失 L_{SEG} 为

$$L_{\text{SEG}} = -\frac{1}{N_{\text{pix}}} \sum_{x,y} \sum_{p_j \in P} I(M_q^{x,y} = j) \log \hat{Q}_{q,j}^{x,y} \quad (4)$$

式中: $M_q^{x,y}$ 为第 q 个查询图像在 (x, y) 位置处的真实类别标注; N_{pix} 为空间位置总数; P 为原型集合。

2) 对齐损失

在获得查询图像的分割预测结果后, 首先对查询特征按照地震相类别进行平均池化, 得到一组类别原型 $\bar{P}$ 。接下来, 将支持集每个像素特征向量 $F_{c,k}$ 与原型 $\bar{P}$ 进行比较, 计算其属于相应查询类别原型的概率 $\hat{S}_{c,k,j}^{x,y}$, 并计算损失 L_{PAR} , 即

$$\hat{S}_{c,k,j}^{x,y} = \text{softmax}(-d(F_{c,k}^{x,y}, \bar{P}_j)) \quad (5)$$

$$L_{\text{PAR}} = -\frac{\sum_{c,k,x,y} \sum_{p_j \in \bar{P}} I(S_{c,k}^{x,y} = j) \log \hat{S}_{c,k,j}^{x,y}}{C \cdot K \cdot N_{\text{pix}}} \quad (6)$$

式中: $S_{c,k}^{x,y}$ 为支持图像真值掩码。

3) 总体损失

$$L = L_{\text{SEG}} + \lambda L_{\text{PAR}} \quad (7)$$

式中: λ 为正则化项, 本文取 $\lambda=1$ 。

2 实验结果与分析

2.1 数据集划分

实验采用荷兰 F3 地震数据集^[19], 该数据集从上到下分为六组岩石地层单元, 分别为基底 (类 1)、斜坡泥岩 A (类 2)、沉积物重力流 (类 3)、

斜坡泥岩 B (类 4)、坡谷 (类 5)、海底峡谷系统 (类 6)。该地质体大小为 $601 \times 901 \times 255$, 主测线 (inline) 从 100 线到 700 线, 联络测线 (xline) 从 300 线到 1 200 线。地震剖面及标注如图 4 所示。




图 4 F3 工区地震剖面 and 标签示例

Fig. 4 Example of seismic section and corresponding labels from the F3 seismic dataset

在模型训练阶段, 将 F3 数据集划分为训练集和测试集。为确保训练数据的多样性和测试数据的覆盖面, 对不同划分方式得到的训练数据集和测试数据集进行实验分析。不同数据集划分方式下 SFI-PFS 模型的预测性能如表 2 所示。本文采用 2 个指标来评估模型的性能, 即像素精度 (pixel accuracy, PA) 与平均交并比 (mean intersection over union, MIoU)。PA 表示正确分类像素占总像素的比例, 侧重全局层面的整体分类正确性; MIoU 通过预测掩码与真实掩码之间的平均重叠率来反映分割精度, 侧重逐类别层面的分割精确性与完整性。计算公式分别为

$$PA = \frac{\sum_{i=0}^C p_{ii}}{\sum_{i=0}^C \sum_{j=0}^C p_{ij}} \quad (8)$$

$$IoU = \frac{|A \cap B|}{|A \cup B|}, \quad MIoU = \frac{1}{C} \sum_{i=1}^C IoU_i \quad (9)$$

式中: p_{ii} 表示将第 i 类分成第 i 类的像素数量; p_{ij} 表示将第 i 类分成第 j 类的像素数量; $|A \cap B|$ 表示预测和真实标签之间重叠的像素数量; $|A \cup B|$ 表示两者的并集像素数量; IoU_i 表示第 i 个类别的 IoU 值。

表 2 不同数据集划分方式下 SFI-PFS 模型的预测性能

Table 2 Performance of the SFI-PFS model under different training and test settings

序号	训练及测试方式	MIoU/%
1	仅使用 inline 测线数据训练和测试	40.2
2	仅使用 xline 测线数据训练和测试	38.7
3	使用双测线数据训练, inline 测线数据测试	68.9
4	使用双测线数据训练, xline 测线数据测试	72.4

如表2所示, 仅使用inline测线数据训练与测试的模型MIoU略高于仅用xline测线数据的结果, 这是因为inline测线的剖面尺寸更大、可用信息较多。当训练集使用双测线数据、测试集分别在inline测线或xline测线划分条件下进行实验, 模型SFI-PFS在xline测线数据集上的测试结果高于inline测线, 原因在于inline测线数据含有更多难分辨的地震相, 模型在训练中接触到的困难样本较多。因此, 本文采用双测线数据上训练模型、双测线上测试模型的方式。

2.2 模型性能对比

为了验证本文所提模型的预测准确性, 在F3数据集上, 将SFI-PFS模型与相关的主流模型SFI-PL、SFM (Base)^[20]、Att-DeepLabV3+^[21]、DSAE^[22]的性能进行对比分析, 结果如表3所示。其中, 黑体表示每列的最大值。SFM (Base) 版本是2025年提出的一种基于预训练基础模型的有监督地震相分析模型, 使用了Transformer编码器提取特征, 通过预训练微调的方式进行地震相识别; Att-DeepLabV3+是基于改进DeepLabV3+网络的半监督地震相识别模型, 使用ResNet 50作为骨干网络, 引入了双注意力机制并将其与ASPP模块串联起来, 从而强化特征图的位置及通道间的像素特征; DSAE使用深度堆栈自编码器对地震数据进行特征提取, 然后根据提取到的特征, 利用无监督聚类算法对地震相进行识别, 无需使用标注数据就能对模型进行训练, 且可以逐层训练, 在堆叠多层后能获得到深层网络, 从而得到更加抽象的特征, 捕捉更多的地震数据语义信息。

表3 SFI-PFS与主流模型的综合性能对比
Table 3 Comparison of SFI-PFS and mainstream models in terms of overall performance

训练方法	训练集 MIoU/%	测试集 MIoU/%	像素准 确率/%
SFM(Base)	80.3	64.1	74.3
SFI-PL(5-shot)	71.5	62.3	69.8
Att-DeepLabV3+	89.5	70.7	82.1
DSAE	46.4	38.3	40.7
SFI-PFS(5-shot)	78.5	72.4	84.6

注: 5-shot表示支持集中每类的标注样本数量。

由表3可以看出, 在F3数据集上, 模型SFI-PFS的MIoU与PA分别为72.4%与84.6%, 较其他几种模型的预测性能有明显提升。其中, SFM

(Base)虽基于较强网络架构, 但仅通过少量标注数据进行微调, 其预测结果反而较差。另外, SFM (Base)与Att-DeepLabV3+的训练集MIoU和测试集MIoU之间的差值分别为16.2%与18.8%, 而SFI-PL与SFI-PFS分别为9.2%与6.1%, 表明SFI-PFS模型相比其他模型不易出现过拟合。这主要得益于原型网络度量学习减少了模型参数, 使模型在较少数据下仍能稳定训练。因此, SFI-PFS模型更符合实际需求, 泛化性更好。为直观比较不同模型的分割性能, 图5展示了剖面实例的预测结果。其中, 不同颜色代表不同的地震相类别。




图5 F3剖面实例上各模型的地震相识别结果对比
Fig. 5 Comparison of SFI results of different models on the F3 seismic section

由剖面实例对比可得, 上述几种模型在圈出部分的地震相识别中均难以达到预期效果, 对于部分地层单元的地震相特征提取困难, 导致识别错误较多, 预测精度低。但相比较来看, SFM模型在黑圈上端部分类别的轮廓识别上均优于其他模型; DSAE方法的错误率过高, 说明无监督模型的识别精度较差; 半监督Att-DeepLabV3+由于使用了无标注和相对较少的标注信息来对模型进行训练, 数据利用更加充分, 但在圈内的边缘分割效果较差且对大面积相连相的分辨上出现明显错误; SFI-PFS模型在圈出区域的类别以及最底层类别的识别精度上均明显优于其他几种模型, 这说明经过自监督预训练的小样本原型学习模型, 更能学习到不同类别之间的区分特征, 能够充分利用无标注信息进行模型训练, 对于类5和类6部分相的识别更加清晰, 从而提高了整体的地震相识别精度。

5种模型对各类地层单元的识别精度对比如表4所示。其中, 粗体为每列中的最优值。从表中可以看出, SFI-PFS模型对整体的地震相识别精度

表 4 不同模型对各类地层单元的识别精度对比

Table 4 MIoU comparisons of various seismic facies categories

训练方法	运行时间/h	各类 MIoU/%						MIoU/%
		第 1 类	第 2 类	第 3 类	第 4 类	第 5 类	第 6 类	
SFM(Base)	1.4	86.0	66.2	74.1	48.1	67.8	42.2	64.1
SFI-PL(5-shot)	0.6	85.8	64.8	75.4	45.7	58.9	28.3	62.3
Att-DeepLabV3+	1.2	87.9	82.3	78.5	59.7	71.4	44.1	70.7
DSAE	0.8	57.8	46.3	66.9	32.1	24.3	16.8	38.3
SFI-PFS(5-shot)	1.1	89.9	71.9	82.9	46.7	72.6	46.4	72.4

相对最高，但对第 2 类和第 4 类的地震相识别效果却不如 Att-DeepLabV3+ 模型。这主要是因为 Deep-LabV3+ 模型架构采用金字塔卷积模块，增强了对地震相边缘的识别，而 SFI-PFS 采用度量学习方法，在类别原型特征的学习上更具有优势，但在细节刻画方面不如 Att-DeepLabV3+ 和 SFM (Base) 等传统监督方法，导致 SFI-PFS 模型对这 2 类地震相的识别精度较低。

2.3 消融实验

为验证预训练模块的有效性，对使用和不使用预训练模块的编码器分别构建 SFI-PFS 模型并对比其预测精度。其中，Pretrain-SFI-PFS 表示使用预训练编码器构建的 SFI-PFS 模型。编码器网络均采用 VGG 16 网络架构，含预训练模块的编码器构建方式如下：1) 以全部地震剖面数据与地震纹理属性剖面为训练数据，通过自监督对比学习方法完成预训练；2) 元训练阶段，按小样本范式随机选取 1 个 (1-shot) 或 5 个 (5-shot) 地震剖面作为支持集，同时随机选取 1 个带标签的地震剖面作为查询集，用于模型训练与参数优化。不含预训练模块的编码器则直接以随机初始化参数进行模型训练，其余实验设置与含预训练模块的实验组保持一致，消融实验结果如表 5 所示。

表 5 F3 数据集上 SFI-PFS 模型的消融实验结果

Table 5 MIoU results of ablation experiments of the SFI-PFS model on the F3 dataset

编码器训练方式	MIoU/%
SFI-PFS-1-shot	46.8
SFI-PFS-5-shot	58.4
Pretrain-SFI-PFS-1-shot	56.7
Pretrain-SFI-PFS-5-shot	72.4

由表 5 中可以看出，相比于未使用预训练模块的 SFI-PFS 模型，Pretrain-SFI-PFS 在 1-shot 和

5-shot 设置下的预测精度分别提高 9.9% 和 14.0%，表明预训练可以给予编码器良好的初始值，从而提高模型的预测精度。另外，本文分别使用 3 种损失函数来对模型进行训练，在 F3 测试集上的预测精度如表 6 所示。

表 6 SFI-PFS 模型使用不同损失函数时的 MIoU 对比

Table 6 MIoU comparison of the SFI-PFS model using different loss functions

实验方法	MIoU/%
分割损失	67.4
对齐损失	54.1
分割损失+对齐损失	72.4

由表 6 可见，使用分割损失+对齐损失函数的模型性能表现最优，较采用单一分割损失函数的模型预测精度提高 5.0%，从而证明了边界特征对齐策略的有效性。同时，使用单一对齐损失函数的模型性能显著下降，表明其作为辅助损失需依赖基础分类损失的监督信号。

2.4 模型收敛性和鲁棒性分析

在 F3 数据集上，对 SFI-PFS、SFM 和 SFI-PL 模型的收敛性进行对比分析，各模型损失值随迭代次数的变化曲线如图 6 所示。从图中可以看到，SFI-PFS 模型在迭代到第 120 次左右时，损失值几乎达到收敛。而 SFI-PL 和 SFM 模型在迭代次数为第 160 次和第 180 次时还存在小幅度震荡，表明 SFI-PFS 模型的收敛速度要比其他 2 个模型更快。SFM 模型在训练开始时，损失值骤降后存在大幅度震荡，而 SFI-PFS 模型损失值的降低速度平缓，每一轮迭代对损失值的影响趋于一致，表明 SFI-PFS 模型表现相对稳定且收敛效果较好。

通过在 F3 工区数据集中添加不同均值和标准差的噪声，分析 SFI-PFS 模型的鲁棒性。由表 7

可知, 随着噪声水平的增加, 模型的 MIoU 呈现下降趋势。当标准差从 0.02 增加至 0.08 时, MIoU 仅从 71.1% 降至 67.9%, 下降幅度为 3.2%, 说明模型在噪声干扰下的性能保持相对稳定, 具有较好的鲁棒性, 可提取各类地震相的主要特征。




图 6 各模型损失值随迭代次数的变化曲线
Fig. 6 Variation curves of loss values of different models with iteration times

表 7 F3 数据集上不同噪声对 SFI-PFS 模型性能影响结果
Table 7 Influences of the SFI-PFS model under different noise conditions on the F3 dataset

序号	噪声参数设置	MIoU/%
1	无噪声	72.4
2	均值为 0.000 941, 标准差为 0.02	71.1
3	均值为 0.000 941, 标准差为 0.04	69.7
4	均值为 0.000 941, 标准差为 0.06	68.6
5	均值为 0.000 941, 标准差为 0.08	67.9

3 结论

为实现对小样本地震相的有效特征提取和准确识别, 本文利用基于 Moco V1 预训练模型的编码器提取地震相特征并学习小样本地震相原型, 利用原型对齐网络构建小样本地震相识别模型, 主要结论如下。

- 1) 利用灰度共生矩阵可增强地震纹理信息, 提升 Moco V1 模型的特征提取能力。
- 2) 利用原型对齐优化策略训练的小样本地震相识别模型, 以查询集预测结果与支持集原型对齐作为训练小样本地震相识别模型的优化目标, 使用查询集分割损失和对齐损失共同指导地震相识别模型的训练。与仅使用查询集上的分割损失训练的模型相比, MIoU 指标提升了 5.0%, 剖面

上的划分结果也更为连续。

3) 与现有无监督地震相识别模型 DSAE 相比, SFI-PFS 的 MIoU 可提升 34.1%; 与现有半监督方法 Att-DeepLabV3+ 相比, 模型的 MIoU 提升了 1.7%; 与现有小样本地震相识别方法 SFI-PL 相比, SFI-PFS 的 MIoU 提升了 10.1%。此外, 在地震剖面实例的细节刻画上, SFI-PFS 相比现有其他几种方法更加准确。

参考文献

[1] 马江涛, 刘洋, 张浩然. 地震相智能识别研究进展[J]. 石油物探, 2022, 61(2): 262-275.
MA J T, LIU Y, ZHANG H R. Research progress on intelligent identification of seismic facies[J]. Geophysical Prospecting for Petroleum, 2022, 61(2): 262-275.

[2] 王浩, 姚俊萍, 李晓军, 等. 带噪声标签细粒度图像分类方法研究综述[J]. 火箭军工程大学学报, 2024, 38(5): 96-108.
WANG H, YAO J P, LI X J, et al. A survey of fine-grained image classification with noisy labels[J]. Journal of Rocket Force University of Engineering, 2024, 38(5): 96-108.

[3] 闫星宇, 顾汉明, 罗红梅, 等. 基于改进深度学习方法的 地震相智能识别[J]. 石油地球物理勘探, 2020, 55(6): 1169-1177.
YAN X Y, GU H M, LUO H M, et al. Intelligent seismic facies classification based on an improved deep learning method[J]. Oil Geophysical Prospecting, 2020, 55(6): 1169-1177.

[4] 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 Q X, LUO Y N, MA X Q, et al. Seismic facies clustering technology based on deep embedding network[J]. Oil Geophysical Prospecting, 2022, 57(2): 261-267.

[5] 顾良勋, 赵云鹤, 柴变芳, 等. 基于半监督对抗网络的地震相识别[J]. 地球物理学进展, 2023, 38(5): 2105-2113.
SHUO L X, ZHAO Y H, CHAI B F, et al. Semi-supervised adversarial network for seismic facies classification[J]. Progress in Geophysics, 2023, 38(5): 2105-2113.

[6] ZHAO J, KONG L L, LYU J C. An overview of deep neural networks for few-shot learning[J]. Big Data Mining and Analytics, 2025, 8(1): 145-188.

- [7] 许天恩, 周怀来, 刘兴业, 等. 基于 Res-UNet 与迁移学习的地震相识别[J]. 地球物理学进展, 2024, 39(1): 319-333.
- XU T E, ZHOU H L, LIU X Y, et al. Seismic facies identification based on Res-UNet and transfer learning[J]. Progress in Geophysics, 2024, 39(1): 319-333.
- [8] LUO J Y, GU X F, LU W K, et al. Seismic stratigraphic interpretation based on unsupervised validation and spectral clustering sampling[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 7674-7683.
- [9] BABAKHIN Y, SANAKOYEU A, KITAMURA H. Semi-supervised segmentation of salt bodies in seismic images using an ensemble of convolutional neural networks[EB/OL]. (2019-08-05) [2024-05-18]. <https://arxiv.org/abs/1904.04445>.
- [10] 蔡涵鹏, 胡浩炀, 吴庆平, 等. 基于叠前地震纹理特征的半监督地震相分析[J]. 石油地球物理勘探, 2020, 55(3): 504-509.
- CAI H P, HU H Y, WU Q P, et al. Semi-supervised seismic facies analysis based on prestack seismic texture[J]. Oil Geophysical Prospecting, 2020, 55(3): 504-509.
- [11] DOU Y M, WU X M, BANGS N L, et al. Geological everything model 3D: a physics-informed promptable foundation model for unified and zero-shot subsurface understanding[EB/OL]. (2025-07-01) [2025-08-29]. <https://arxiv.org/abs/2507.00419>.
- [12] GAO H, WU X M, LIANG L, et al. A foundation model empowered by a multi-modal prompt engine for universal seismic geobody interpretation across surveys[J]. Information Fusion, 2025, 125: 103437.
- [13] ZHAO Y H, CHAI B F, SHUO L X, et al. Few-shot learning for seismic facies segmentation via prototype learning[J]. Geophysics, 2023, 88(3): IM41-IM49.
- [14] WANG K X, LIEW J H, ZOU Y T, et al. PAnet: few-shot image semantic segmentation with prototype alignment[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2019: 9196-9205.
- [15] HE K M, FAN H Q, WU Y X, et al. Momentum contrast for unsupervised visual representation learning[EB/OL]. (2020-03-23) [2024-05-18]. <https://arxiv.org/abs/1911.05722>.
- [16] LIU X, ZHANG F J, HOU Z Y, et al. Self-supervised learning: generative or contrastive[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(1): 857-876.
- [17] CHOPRA S, ALEXEEV V. Applications of texture attribute analysis to 3D seismic data[J]. The Leading Edge, 2006, 25(8): 934-940.
- [18] LI J T, WU X M, YE Y M, et al. Unsupervised contrastive learning for seismic facies characterization[J]. Geophysics, 2023, 88(1): WA81-WA89.
- [19] ALAUDAH Y, MICHAŁOWICZ P, ALFARRAJ M, et al. A machine-learning benchmark for facies classification[J]. Interpretation, 2019, 7(3): SE175-SE187.
- [20] SHENG H L, WU X M, SI X, et al. Seismic foundation model: a next-generation deep learning model in geophysics[J]. Geophysics, 2025, 90(2): IM59-IM79.
- [21] 李晓玲, 柴变芳, 硕良勋, 等. 提升地震相边缘和不规则体识别效果的半监督识别方法[J]. 计算机科学与应用, 2023, 13(9): 1704-1712.
- LI X L, CHAI B F, SHUO L X, et al. Semi-supervised method to improve recognition of seismic facies edges and irregular bodies[J]. Computer Science and Application, 2023, 13(9): 1704-1712.
- [22] 桑凯恒, 张繁昌, 李传辉. 地震倒谱特征参数谱聚类地震相分析方法[J]. 石油地球物理勘探, 2021, 56(1): 38-48.
- SANG K H, ZHANG F C, LI C H. Seismic facies analysis based on cepstrum characteristic parameters and spectral clustering[J]. Oil Geophysical Prospecting, 2021, 56(1): 38-48.

(编辑: 刘建民)