arXiv:2302.10756v1 [cs.CV] 8 Feb 2023

基于物理先验增强深度自编码器的无监督地震采集脚印去除

Feng Qian，*IEEE*会员，Yuehua Yue、Yu He、Hongtao Yu、Yingjie Zhou，*IEEE*会员，Jinliang Tang 和 Guangmin Hu，*IEEE*会员

摘要—**地震采集脚印表现为稳定、微弱且暗淡的结构，并呈现完全的空间相干性，因此在抑制过程中不可避免地会损害有用信号。已有多种脚印去除方法，包括滤波和稀疏表示（SR），据报道，这些方法在克服这一挑战方面取得了良好效果。然而，这些方法（例如 SR）完全依赖于针对有用信号的手工设计图像先验；当给定的地震数据包含复杂地质结构时，这种要求有时并不合理。作为一种替代方案，本文提出了一种脚印去除网络（称为 FR-Net），用于以无监督方式抑制采集到的脚印噪声，且不对有价值的信号作任何假设。FR-Net 的关键在于依据噪声固有的方向性，为脚印采集设计一个单向全变分（UTV）模型。通过利用 UTV 模型对深度卷积自编码器（DCAE）施加强正则化，我们的 FR-Net 将 DCAE 从完全由数据驱动的模型转变为先验增强方法，同时继承了 DCAE 和脚印模型的优势。随后，通过使用反向传播（BP）算法优化 FR-Net，以无监督方式实现脚印噪声与有用信号的完全分离。我们在三个合成数据集和野外数据集上进行了定性和定量评估，结果表明，我们的 FR-Net 优于此前最先进（SOTA）的方法。**

索引词—**地震采集脚印、单向全变分（UTV）、深度卷积自编码器（DCAE）、脚印去除网络（FR-Net）、先验增强。**

I. 引言

ACQUISITION 脚印噪声通常被视为与采集几何而非地质构造相关的异常周期性振幅条带，并且总是出现在横穿三维地震数据的时间切片或层位切片中 [1]。脚印噪声的主要成因多种多样，贯穿数据采集与处理的各个环节，但其中两个关键因素——采集设计以及处理过程中的增强效应——可能发挥了作用 [2]–[4]。脚印噪声的存在会使地震图像变得模糊，并可能在识别和分析真实地下响应，这无疑增加了地震图像解释的不确定性 [5], [6]。因此，脚印去除是地震数据处理过程中极其重要且不可或缺的一步 [7], [8] ，也是本文的重点。

近几十年来，地球物理学界为推动脚印噪声去除方法的发展付出了巨大努力 [1], [9]–[26]。值得注意的是，地震学文献中提出了大量重要方法，大致可分为两类：滤波 [1], [9]–[17] 和稀疏表示（ SR ）方法 [18]–[26]。滤波方法是应用最广泛的技术，可分为两类：波数/频率域滤波和时域滤波。第一类方法最初由 Gulunay 提出 [9], ，将脚印噪声视为空间周期噪声，并尝试在波数域中加以抑制；典型方法包括经典波数滤波 [9], [10], 、自适应波数滤波 [11],、频谱陷波滤波 [12], 、双程频率-波数滤波 [1],以及波数陷波滤波 [13]。第二类方法主要适用于随机噪声抑制，但也可用于脚印去除。典型方法包括基于奇异值分解（SVD）的方法 [14]–[16]和构造导向滤波 [17]。然而，在案例研究中，滤波技术面临一个矛盾：既要显著去除脚印噪声，又要确保真实振幅不受影响。

与波数/频率域方法相比，稀疏表示（SR）被认为能够对干净地震图像和脚印噪声实现更紧凑的表示，从而使二者在稀疏域中更易分离 [18]–[26]。根据所用字典构建的准确程度，SR 方法可分为解析稀疏变换和数据驱动稀疏编码（SC）方法。在解析稀疏变换中，假设噪声抑制是基于给定解析变换基中脚印噪声与干净图像具有不同分布规律这一特点，通过计算二者的稀疏系数来实现的；代表性技术包括小波变换 [7], 、三维复小波变换 [18],、平稳小波变换（SWT） [19], [20], 、基追踪 [21], 以及曲波变换 [22]。具体而言，通过分析系数的能量分布规律，对稀疏系数进行阈值处理或滤波，从而实现脚印噪声与干净地震图像的完全分离。与解析稀疏变换截然不同的是，考虑到

Feng Qian 任职于中国电子科技大学信息与通信工程学院和信息地球科学中心，中国成都，邮编 611731（电子邮箱：fengqian@uestc.edu.cn）。

Yuehua Yue、Yu He 和 Guangmin Hu 均任职于电子科技大学资源与环境学院及信息地球科学中心，中国成都，邮编 611731（电子邮件：3341452205@qq.com；1141448613@qq.com；hgm@uestc.edu.cn）。

Yingjie Zhou 任职于四川大学（SCU）计算机科学学院，中国成都，邮编 610065（电子邮件：yjzhou@scu.edu.cn）。

Jinliang Tang 任职于中国石化地球物理研究院（SGRI）地震成像技术研究所，中国南京 211103（电子邮箱：tangjl.swty@sinopec.com）。

学习字典的原子被发现能够表示干净图像和脚印模式 [23], [24],，基于稀疏编码的去噪方法自然会处理这些学习得到的原子，而忽略稀疏系数的作用。具体而言，稀疏编码方法将脚印噪声抑制视为二值模式分类 [23]–[25] 或对所有学习原子进行滤波的任务 [26] ，从而能够在原子层面分离脚印噪声与干净图像。然而，尽管现有方法在脚印去除方面取得了显著进展，其性能仍依赖于手工设计先验；如果输入地震图像具有超出模型假设范围的意外特性，性能可能会下降。

受深度学习（DL）作为数据处理技术所取得的巨大成功启发，近年来出现了基于深度学习的方法，用于地震图像去噪 [27]–[51]。与传统噪声消除方法相比，基于深度学习的去噪方法始终致力于直观地学习含噪地震图像与相应干净图像之间的潜在映射，而无需任何人工设定的假设 [27]–[38]。在这种情况下，基于深度学习的去噪方法往往专注于随机噪声，并利用各种深度学习模型，旨在最小化训练集上产生的均方误差（MSE）。典型的深度学习网络包括卷积神经网络（CNNs） [27]–[30], 3-D 去噪 CNN（3D-DnCNNs） [31], [32],深度卷积自编码器（DCAEs） [33], [34], 3-D DCAEs [35], [36], 以及张量深度学习（TDL）方法 [37], [38]。其他开放研究领域还包括利用深度学习抑制突发噪声 [39], 耦合噪声 [41]–[44], 涌浪噪声 [45], [46],地滚波噪声 [47]–[49],和沙漠噪声 [50], [51]。然而，目前地球物理学界尚未部署任何深度学习方法来协助抑制采集到的脚印噪声，因为采集脚印噪声及其对应的干净数据是一项并非易事的任务。

为改善这一问题，我们提出了一种脚印去除网络（FR-Net）。该网络由脚印的物理先验及其相关模型直接驱动，因此，与现有的去除方法相比，能够以更完整的无监督方式解耦脚印噪声与反射信号。我们提出的 FR-Net 之所以具有优越性能，可归因于以下特点。1）物理先验增强深度学习：纯深度学习方法无法有效处理脚印噪声；常用的均方误差（MSE）损失针对的是误差传播过程中产生的高斯误差，因此无法去除脚印噪声。基于脚印噪声的物理本质及其建模方式，我们的 FR-Net 将深度学习从完全数据驱动转变为物理先验增强的深度学习，使其兼具深度学习和脚印模型的优势，从而实现出色的性能。2）可解释性：本文致力于构建可解释深度神经网络（xDNN）或可解释机器学习（XML）技术，旨在为 FR-Net 提供更强的描述性方法，并向用户提供额外的先验信息，从而增进对脚印噪声的认识。3）无真实标签：我们的 FR-Net 模型具有一个颇为令人意外的特点：尽管采用了深度学习模型，FR-Net 仍能以无监督方式有效去除脚印噪声，而无需获取脚印噪声及其对应的无噪声结果。

基于上述优势可以明确，FR-Net 是一种很有前景的方法，可用于对含噪三维地震数据进行脚印去除，这也是本文的主要目的。与现有的脚印噪声抑制方法相比，我们的 FR-Net 模型在技术上得以实现，主要归功于三项重大改进，概述如下，作为本文的主要贡献。

1）脚印模 *del*型：T he k键在于hFR-Net is to desi 根据脚印噪声固有的方向性（x 线方向或 y 线方向），设计脚印分离模型（即单向全变分（UTV）模型）。从上述文献综述可以看出，我们的脚印模型与现有的所有去除方法都截然不同。

2)物理先验增强深度学习：受 [33], [34], [39], 启发，我们致力于开发一种深度学习模型，以自动描述受污染地震数据中隐藏的理想图像特征。随后，利用 UTV 模型对深度学习方法施加强正则化，从而构建最终的 FR-Net，实现脚印噪声与反射信号的彻底解耦。据我们所知，本文是首项使用深度学习进行无监督足迹去除的工作。

3) 解决方案：通过推导出的反向传播（BP）算法（该算法基于经典反向传播算法）训练 FR-Net，即可实现脚印噪声与有效信号的完全分离。此外，这一 BP 推导过程或可帮助理解 FR-Net 训练过程中导数计算所体现的物理先验增强特性。不过，在具体实现中，这种新代价函数的导数由 TensorFlow [52]自动计算。

4) 地球物理学界：由于脚印噪声是典型的相干噪声，目前提出的物理先验增强理念对于上述地震数据去噪过程，尤其是相干噪声压制而言，前所未有。它无疑将成为我们未来的研究方向，并极大丰富地震噪声压制理论本身。

在三个公开数据集上获得的大量实验结果表明，与现有最先进（SOTA）方法相比，所提出的 FR-Net 具有更优的性能和有效性。

本文其余部分安排如下：第二节介绍本文通篇使用的 DCAE 和全变差（ TV ）模型的相关背景。第三节讨论问题表述及建模相关问题。第四节完整介绍所提出的方法。第五节给出实验结果和评估，以证明所提出的 FR-Net 的有效性。最后，第六节总结本文工作。

II. 背景

为便于读者理解本研究，本部分简要回顾两个重要主题，为介绍所提出的 FR-Net 提供必要的预备知识。具体而言，有关

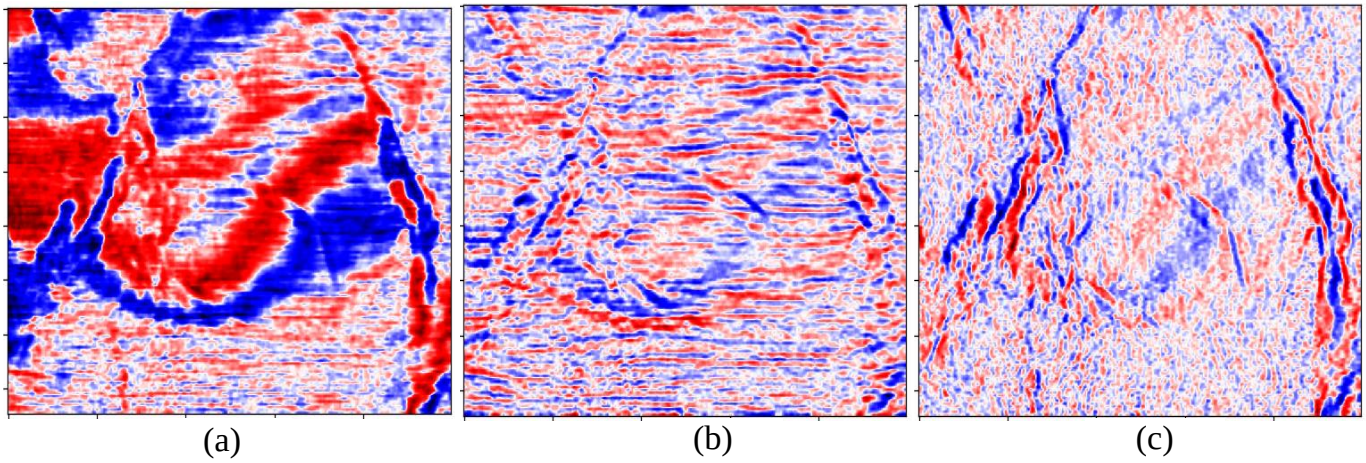

图1。（a）含脚印噪声的地震图像。（b）水平导数。（c）垂直导数。

DCAEs 的基础知识将在第 II-A 节中回顾。随后，第 II-B 节将简要介绍 TV。

A. DCAE

DCAE 是一种端到端模型，由两个组件构成：一个包含多个层的编码器，用于首先将输入地震图像编码为低维潜在特征；以及一个解码器，用于将潜在表示解码回地震图像 [53]。假设输入 $\{\mathbf{X}_n\}_{n=1}^N$已知，则每一层的隐藏表示可通过以下方式获得：

$$\begin{aligned}\mathbf{X}_{n,\ell} &= \mathbf{h}\left(\mathbf{X}_{n,\ell-1}\right) = \sigma\left(\mathbf{W}_{\ell-1}\mathbf{X}_{n,\ell-1} + \mathbf{b}_\ell\right)\\ \mathbf{g}\left(\mathbf{X}_{n,\ell-1}\right) &= \sigma\left(\mathbf{W}_{\ell-1}^\top \mathbf{h}\left(\mathbf{X}_{n,\ell-1}\right) + \mathbf{b}_{\ell-1}\right), \quad \ell \in [K],\end{aligned} \tag{1}$$

其中，$(\cdot)^\top$ 表示给定矩阵的转置，N 表示输入样本对的数量。由于解码器被设计为编码器的逆过程，因此可以将 $\mathbf{X}_{n,\ell-1}$ 输入解码器，并通过最小化后续的重建误差代价，将其输出$\mathbf{X}_{n,\ell}$ 与原始图像进行比较。

$$\mathcal{L}_{\mathrm{MSE}}(\mathbf{Y}_n, \mathbf{X}_{n,\ell-1}; \theta) = \arg\min_\theta \frac{1}{N}\sum_{n=1}^{N}\frac{1}{2}\left\|\mathbf{Y}_n - \mathbf{X}_{n,\ell}\right\|_{\mathrm{F}}^2, \tag{2}$$

其中，$\theta = \{\mathbf{W}_\ell, \mathbf{b}_\ell\}_{\ell=1}^K$ 表示自编码器模型的参数。

B. 全变分

全变分模型最初由Rudin等人提出，旨在解决灰度图像去噪问题，因为它能够保留边缘信息并有效促进分段平滑性。此后，鉴于全变分模型在图像去噪方面表现出色，这种技术的应用日益重要，因此自然适合用于扩展地震图像降噪。

形式上，对于矩阵 $\mathbf{X} \in \mathbb{R}^{n_1\times n_2}$，其导数矩阵$\nabla_x\mathbf{X} \in \mathbb{R}^{(n_1-1)\times n_2}$ 和 $\nabla_y\mathbf{X} \in \mathbb{R}^{n_1\times(n_2-1)}$ 定义为

$$\begin{cases}\nabla_x\mathbf{X}(i,j) = \mathbf{X}(i+1,j) - \mathbf{X}(i,j)\\ \nabla_y\mathbf{X}(i,j) = \mathbf{X}(i,j+1) - \mathbf{X}(i,j),\end{cases} \tag{3}$$

其中，$\mathbf{X}(i,j)$ 表示 $\mathbf{X}$ 的第（i,j）个元素，∇_x 和∇_y 分别表示一阶垂直导数算子和水平导数算子。$\mathbf{X}$ 的全变分写作

$$\|\mathbf{X}\|_{\mathrm{TV}} = \|\nabla_x\mathbf{X}\|_1 + \|\nabla_y\mathbf{X}\|_1. \tag{4}$$

确定图像去噪的全变分范数后，我们可以将其视为先验，并将其纳入最大后验概率（MAP）估计中加以约束，其定义如下：

$$\hat{\mathbf{X}} = \arg\min_{\mathbf{X}\in\mathbb{R}^{m\times n}} \|\mathbf{Y} - \mathbf{X}\|_F^2 + \tau\|\mathbf{X}\|_{\mathrm{TV}}, \tag{5}$$

其中，τ 表示高斯随机噪声的噪声水平。

III. 问题表述与建模

本节提出一种用于脚印去除的物理先验增强深度学习方法。具体而言，我们首先在第 III-A 节陈述并构建脚印去除问题。接着，这种物理先验增强方法的关键是在第 III-B 节建立脚印噪声的 UTV 模型。最后，使用 UTV 模型对深度学习方法进行强正则化，从而得到最终的 FR-Net，以彻底去除脚印噪声。

A. 问题表述

如 [1]，中所述，采集到的脚印噪声是指在三维地震时间切片或层位切片上明显可见的线性空间网格模式。因此，如图 1(a) 所示，含噪数据$\mathbf{Y}$被视为真实图像$\mathbf{X}$、脚印噪声$\mathbf{F}$和随机噪声$\mathbf{N}$的混合物。此外，鉴于采集到的脚印噪声和随机噪声具有加性特征， [26], 由脚印噪声和随机噪声引起的退化过程可表述如下。

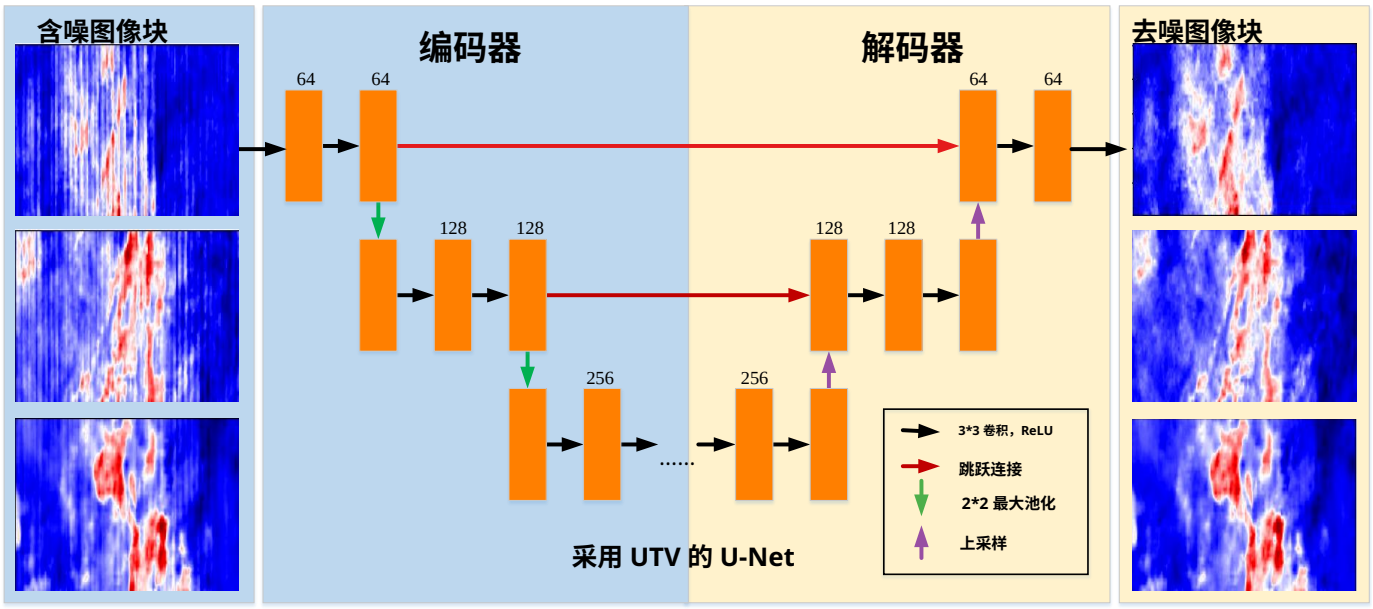

图 2. 我们的 FR-Net 模型概念示意图。

$$\mathbf{Y} = \mathbf{X} + \mathbf{F} + \mathbf{N}. \tag{6}$$

形式上，我们的目标是通过最小化以下方程，从含噪图像$\mathbf{Y}$ 推断潜在的清晰地震图像$\mathbf{X}$ 。

$$\min_{\mathbf{X},\mathbf{F}} \frac{1}{2}\|\mathbf{X} + \mathbf{F} - \mathbf{Y}\|_F^2. \tag{7}$$

从数学角度来看，由于该任务是一个典型的病态逆问题，关键在于设计适当的正则化项，以同时去除脚印噪声$\mathbf{F}$ 和随机噪声$\mathbf{N}$，如下所示：

$$\min_{\mathbf{X},\mathbf{F}} \frac{1}{2}\|\mathbf{X} + \mathbf{F} - \mathbf{Y}\|_F^2 + \tau P(\mathbf{X}) + \lambda P(\mathbf{F}), \tag{8}$$

其中， $P(\mathbf{X})$和 $P(\mathbf{F})$分别表示与清晰地震图像和脚印噪声分量相关的先验， τ 和 λ 均表示正则化参数。迄今为止，最常用的两种技术——显式滤波 [1], [9]–[17] 和SR [18]–[26], ——已被用于脚印噪声抑制。从这些方法可以看出，脚印噪声去除的关键在于为干净图像和脚印噪声建立适当的模型，这将极大地促进两个分量的分离。

B. 脚印噪声建模

脚印去除最重要的一环是对脚印噪声进行建模，现有的主要方法将脚印噪声视为在波数域或时频域中稀疏的空间周期噪声 [9]–[13]。与现有方法类似，我们还充分利用了另一种特性：从时间切片来看，脚印噪声的空间模式是规则的线性条纹或网格模式 [9]–[13]。

利用这一线性特征，鉴于全变分技术具有边缘保持特性或空间局部平滑性，因此自然适用于脚印去除任务 [43]。更重要的是，全变分可以很容易地作为正则项加入深度学习模型的损失函数中 [39], [54]。

然而，如图1(a)所示，可以清楚地看到，脚印噪声具有明显的方向特征。基于此，我们认为经典全变分不适用于脚印去除，因为它不符合脚印噪声的方向特性。作为示例，图1(b)和(c)分别展示了退化地震图像的水平和垂直单向梯度。在图1(b)和(c)中，脚印噪声对穿过脚印噪声的垂直梯度有巨大影响，但对沿脚印噪声方向检测到的梯度完全没有影响。这一事实促使我们限制脚印噪声之间的梯度，同时保留沿脚印噪声方向的梯度。为此，可以采用由Bouali和Ladjal [40]最初提出的UTV模型，该模型利用了脚印噪声的方向特性。UTV模型的形式化表达如下：

$$\mathcal{L}_{\mathrm{UTV}}(\mathbf{X}) = \lambda_1 \left\|\nabla_x \mathbf{X}\right\|_1 + \lambda_2 \left\|\nabla_y (\mathbf{Y} - \mathbf{X})\right\|_1, \tag{9}$$

其中， λ_1 和 λ_2 表示权衡参数。 ∇_x 和 ∇_y分别表示沿x线方向和y线方向的线性一阶差分算子。在此UTV模型中，第一项对沿脚印噪声垂直方向的梯度的 ℓ_1范数进行惩罚，以去除脚印噪声；第二项则对沿脚印噪声方向的梯度之差施加 ℓ_1 范数约束，以揭示或分离潜在的脚印噪声。将公式（9）代入（8），通过最小化包含单向变化的目标函数，可以得到一种稳健的条纹去除方法，如下所示：

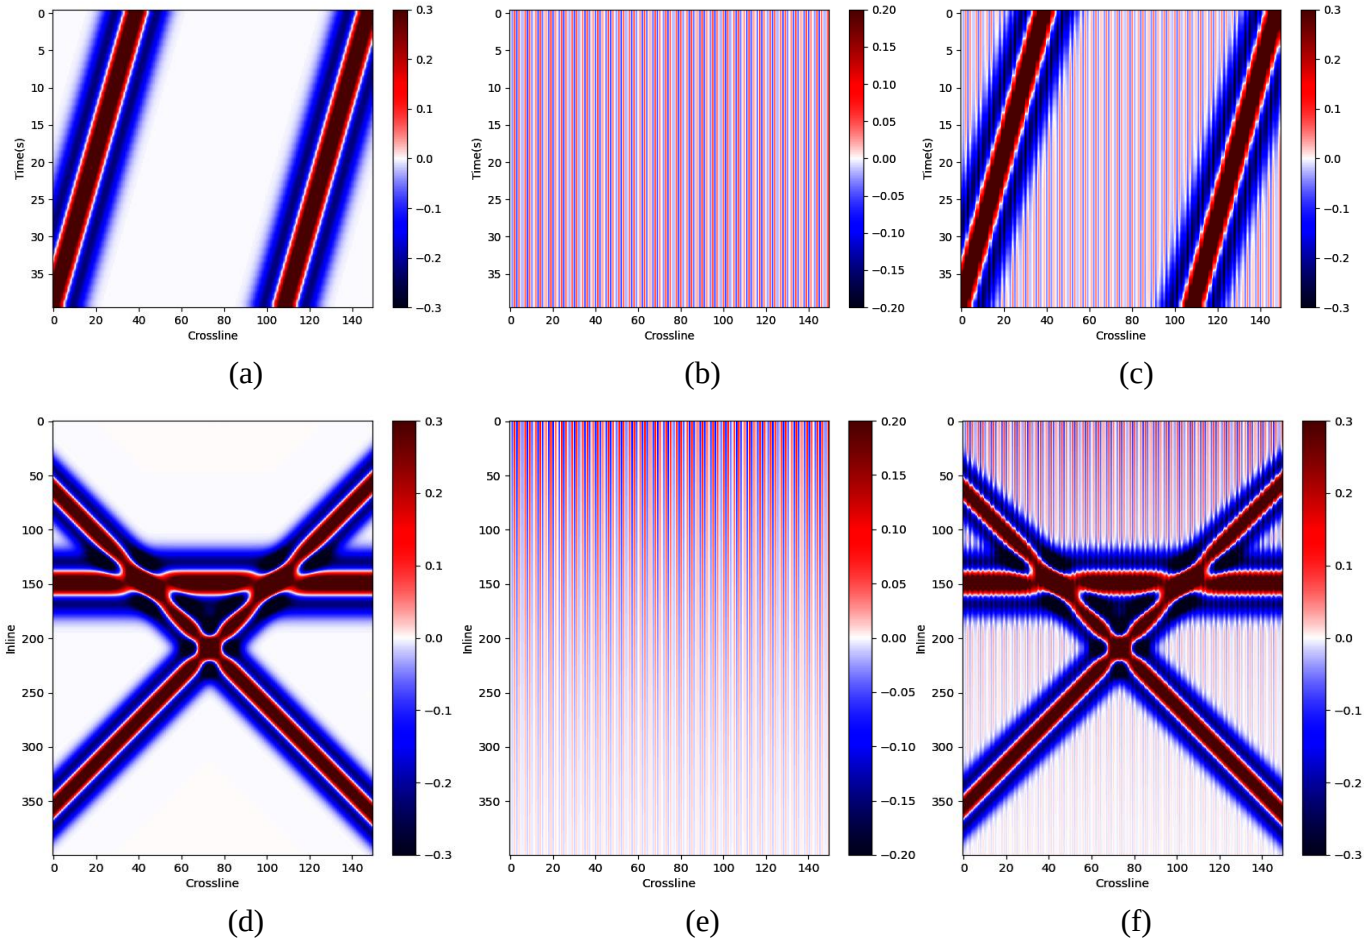

图 3. 合成示例。(a 和 d) 干净的地震图像。(b 和 e) 脚印噪声。(c 和 f) 含噪地震图像。

$$\min_{\mathcal{X}} \frac{1}{2}\|\mathbf{X}-\mathbf{Y}\|_F^2+\tau P(\mathbf{X})+\lambda_1 \|\nabla_x \mathbf{X}\|_1+\lambda_2 \|\nabla_y(\mathbf{Y}-\mathbf{X})\|_1 . \tag{10}$$

为求解关于$\mathbf{X}$的公式（10），有必要构建一个$\mathbf{X}$ 模型，对高度病态的系统方程施加额外约束。

C. 物理先验增强的深度学习建模

根据第 I 节的文献综述可知，目前关于建模 $\mathbf{X}$ 的研究主要依赖手工设计先验。然而，这些先验假设对于$\mathbf{X}$并不总是成立，因此有必要采用深度学习，以数据驱动的方式进行建模。通常，在这种情况下，清晰的 $\widehat{}$地震图像$\mathbf{X}$ 可以建模为非线性自回归:

$$\widehat{\mathbf{X}} = \boldsymbol{h}_\Theta(\mathbf{Y}). \tag{11}$$

通过在 $\mathbf{X}$ 上对深度神经网络进行无监督训练，可以近似得到去噪模型 $\boldsymbol{h}$ （由 Θ 参数化）。利用这一关系，可将公式（2）重写为:

$$\min_{\Theta} \frac{1}{2}\|\boldsymbol{h}_\Theta(\mathbf{Y})-\mathbf{Y}\|^2. \tag{12}$$

随后，将公式（12）代入公式（10），即可得到针对错误脚印去除结果的最终代价函数，同时纳入 $\mathbf{F}$ 的物理模型和$\mathbf{X}$ 的数据驱动模型，如下所示。

$$\begin{aligned}\min_{\Theta} \frac{1}{2}\|\boldsymbol{h}_\Theta(\mathbf{Y})-\mathbf{Y}\|_2^2+\lambda_1\|\nabla_y \boldsymbol{h}_\Theta(\mathbf{Y})\|_1 \\ +\lambda_2\|\nabla_x\left(\boldsymbol{h}_\Theta(\mathbf{Y})-\mathbf{Y}\right)\|_1 .\end{aligned} \tag{13}$$

从公式 (13) 中令人惊讶地发现，为成功推导出一种新的深度学习模型，最优参数从$\mathbf{X}$ 变为 Θ 。另一项挑战是考虑一种专用的深度学习网络结构，该结构应与无监督足迹去除相结合。

IV. 方法

本节分为三个部分。第 IV-A 节介绍所提出的用于脚印去除的 FR-Net 模型。第 IV-B 节给出用于确定新模型参数的相应 BP 算法。第 IV-C 节介绍 FR-Net 的实现细节。

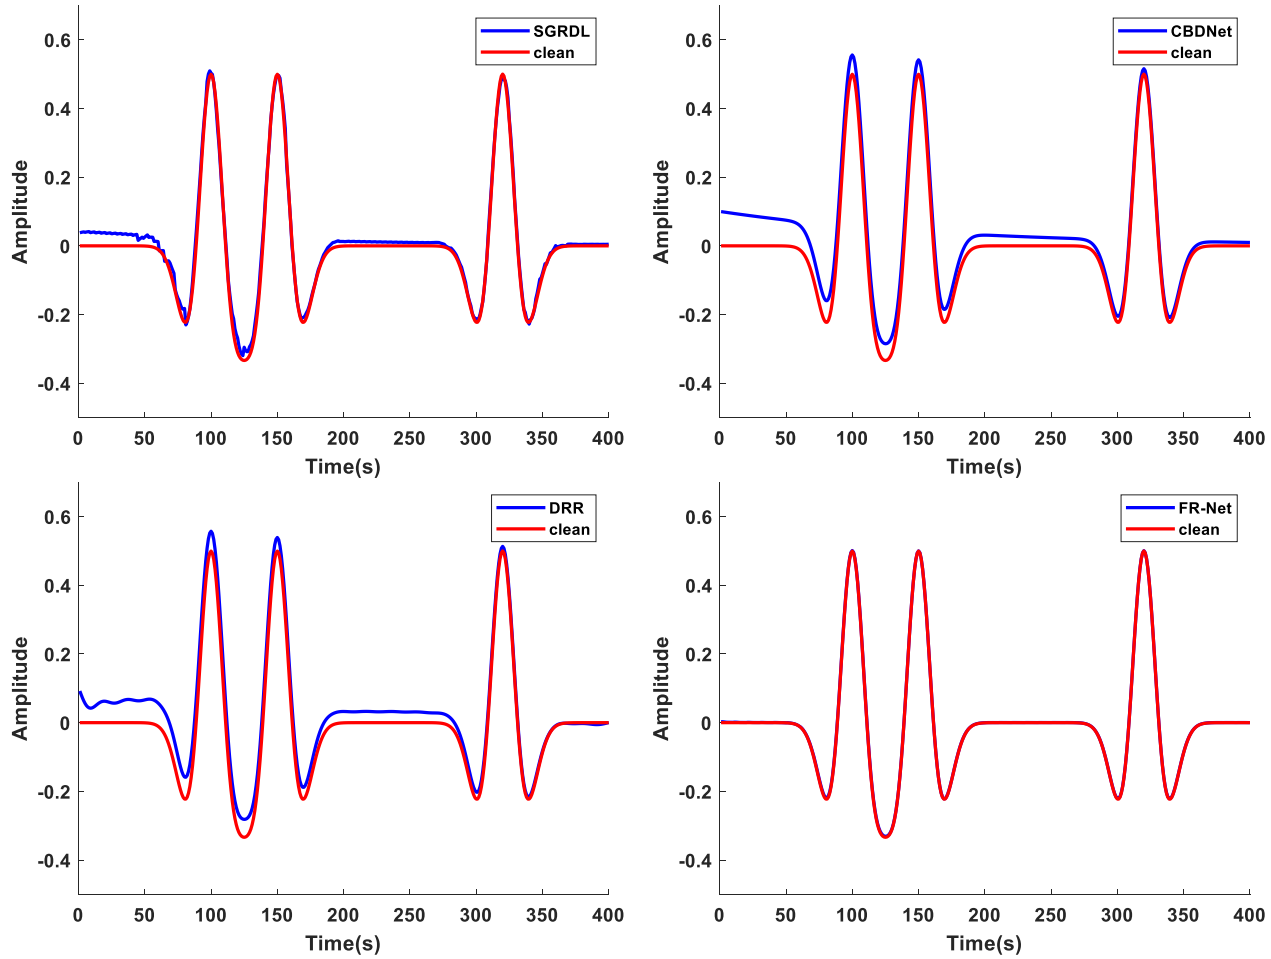

图 4. 单道对比中合成数据集上的结果。

A. 深度卷积自编码器的 *UTV*正则化

正如 [34], [35], 所证明的，DCAE 能够以无监督方式成功去除地震图像中的噪声，其性能优于其他基于模型的学习方法。与我们之前的工作 [37], [39], 一样，可以使用 DCAE 对干净图像$\widehat{}$图像块 $\mathbf{X}$ 进行建模，并训练深度学习网络，以一种便捷的方式从受损地震图像中恢复干净图像。

$$\widehat{\mathbf{X}} = \boldsymbol{h}_\Theta(\mathbf{Y}) = \boldsymbol{D}_\Theta\left(\boldsymbol{E}_\Theta(\mathbf{Y})\right), \tag{14}$$

其中，$\boldsymbol{D}_\Theta(\cdot)$ 表示带有 Θ 的编码器。根据公式 (1)，$\boldsymbol{D}_\Theta(\cdot)$ 的定义如下。

$$\mathbf{X}_{n,\ell} = \boldsymbol{E}_\Theta\left(\mathbf{X}_{n,\ell-1}\right) = \sigma\left(\mathbf{W}_{\ell-1}\mathbf{X}_{n,\ell-1} + \overrightarrow{\mathbf{B}}_\ell\right), \quad \ell \in [K]. \tag{15}$$

相比之下，$\boldsymbol{E}_\Theta(\cdot)$ 表示解码器，它对低分辨率编码进行上采样，并将其映射为原始输入的重建，其定义为

$$\boldsymbol{D}_\Theta\left(\mathbf{X}_{n,\ell-1}\right) = \sigma\left(\mathbf{W}_{\ell-1}^\top \mathbf{h}\left(\mathbf{X}_{n,\ell-1}\right) + \overrightarrow{\mathbf{B}}_{\ell-1}\right), \quad \ell \in [K]. \tag{16}$$

随后，将公式 (14) 代入 (12)，得到

$$\begin{aligned}\mathcal{L} = \min_\Theta \ & \frac{1}{2}\left\|\boldsymbol{D}_\Theta\left(\boldsymbol{E}_\Theta(\mathbf{Y})\right) - \mathcal{Y}\right\|_2^2 + \lambda_1 \left\|\nabla_y \boldsymbol{h}_\Theta(\mathbf{Y})\right\|_1 \\ & + \lambda_2 \left\|\nabla_x\left(\boldsymbol{h}_\Theta(\mathbf{Y}) - \mathbf{Y}\right)\right\|_1 .\end{aligned} \tag{17}$$

脚印去除问题可以用 UTV 正则化自编码器建模，并像任何传统自编码器一样通过 BP算法求解。然而，对于 $\mathcal{L}_{\mathrm{UTV}}$ 正则化问题，与普通的 $\mathcal{L}_{\mathrm{MSE}}$ 相比，采用这种方法求解更为合适，因为二者的代价函数差异很大。因此，有必要推导一种专门的 BP 方法，通过最小化新的代价函数 (17)，求解方程 (17) 中的参数 Θ；详细推导见第四-B 节。

B. FR-Net 的优化

为探究 UTV 正则化在足迹去除中的重要作用，本节将对 FR-Net 的 BP算法进行直接推导。具体而言，梯度下降（GD）作为一种迭代优化方法，通过最小化

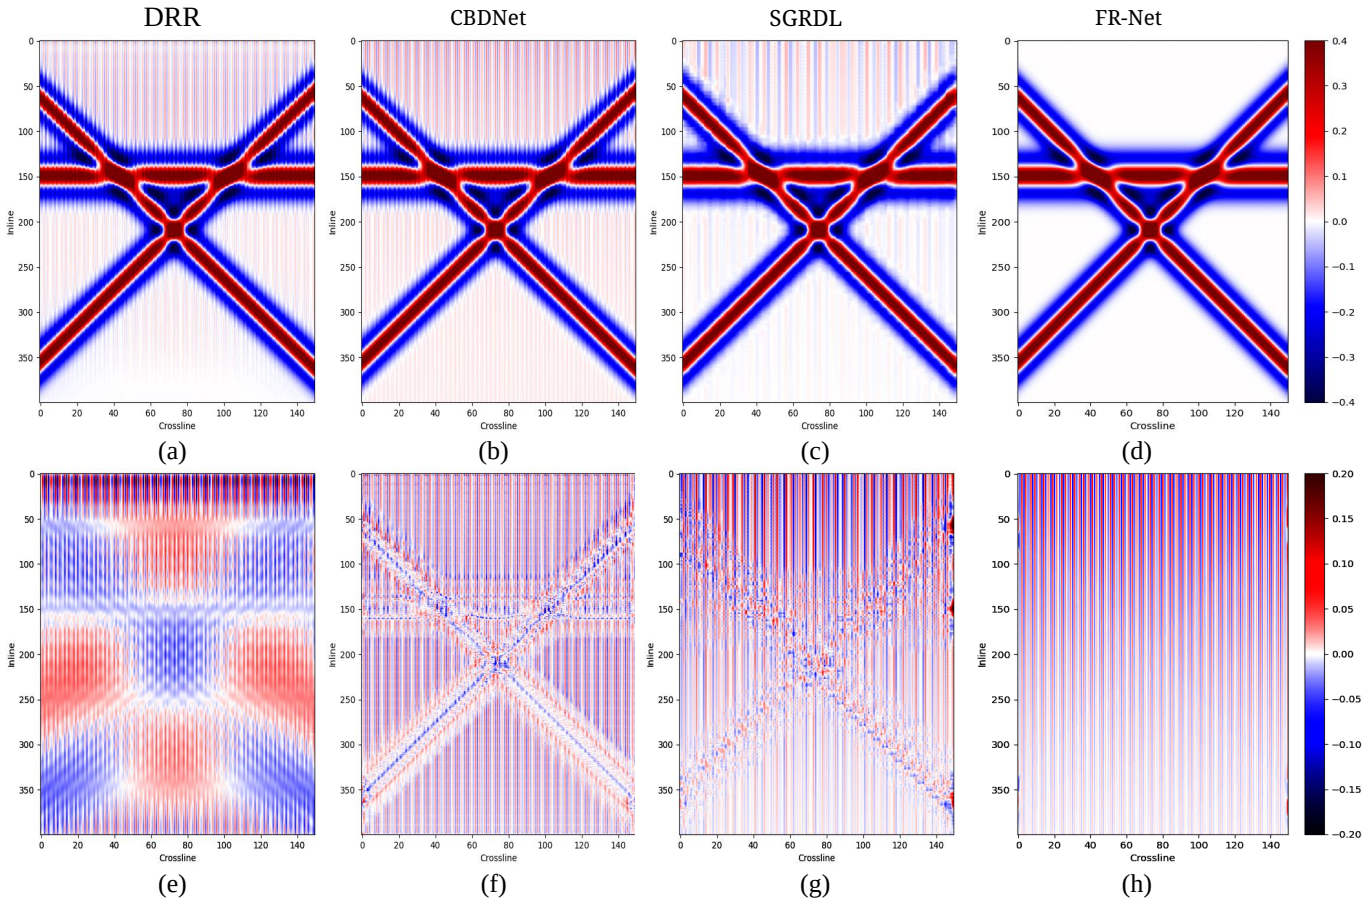

图 5. 合成数据集在 x线剖面对比中的结果。脚印去除结果分别采用 (a) DRR方法、(b) CBDNet方法、(c) SGRDL方法和 (d) 所提出的 FR-Net 方法获得。相应的残差分别采用 (e) DRR方法、(f) CBDNet方法、(g) SGRDL方法和 (h) 所提出的 FR-Net 方法获得。

$\mathcal{L}(\mathbf{Y}_n, \Theta)$（式（17））来逐步调整模型参数$\mathcal{L}$。通过以下推导，可以更清楚地了解 GD 如何更新$\mathbf{W}_{\ell-1}$ 和$\mathbf{B}_\ell$:

$$\mathbf{W}_{\ell-1} \leftarrow \mathbf{W}_{\ell-1} - \alpha \frac{\partial \mathcal{L}(\mathbf{W},\mathbf{B})}{\partial \mathbf{W}_{\ell-1}}, \tag{18}$$

$$\mathbf{B}_{\ell} \leftarrow \mathbf{B}_{\ell} - \alpha \frac{\partial \mathcal{L}(\mathbf{W},\mathbf{B})}{\partial \mathbf{B}_{\ell}}, \tag{19}$$

其中， α 表示学习率，它是一个控制每次迭代步长的超参数。典型的 GD 算法交替更新 $\mathbf{W}_\ell$ 和 $\mathbf{B}_\ell$。具体而言，给定当前对 $\mathbf{B}_\ell$的估计，$\mathbf{W}_\ell$ 可通过计算式 (18) 中的 $\partial\mathcal{L}/\partial\mathbf{W}_{\ell-1}$ 轻松更新，而 $\partial\mathcal{L}/\partial\mathbf{W}_{\ell-1}$则可采用标准的乘法规则进行计算，如下所示。

$$\delta\mathbf{W}_{\ell-1} = \frac{\partial \mathcal{L}}{\partial \mathbf{W}_{\ell-1}} = \frac{\partial \mathcal{L}_{\mathrm{MSE}}}{\partial \widehat{\mathbf{X}}_{n,\ell}} \frac{\partial \widehat{\mathbf{X}}_{n,\ell}}{\partial \mathbf{W}_{\ell-1}} + \frac{\partial \mathcal{L}_{\mathrm{UTV}}}{\partial \widehat{\mathbf{X}}_{n,\ell}} \frac{\partial \widehat{\mathbf{X}}_{n,\ell}}{\partial \mathbf{W}_{\ell-1}}. \tag{20}$$

首先，通过对（2）求导可得 $\partial\mathcal{L}_{\mathrm{Welsch}}/\partial\mathbf{X}_{n,\ell}$ ：

$$\frac{\partial \mathcal{L}_{\mathrm{MSE}}}{\partial \widehat{\mathbf{X}}_{n,\ell}} = \mathbf{Z}. \tag{21}$$

为简化表述，我们引入以下定义：$\mathbf{Z} = \mathbf{Y}_n - \mathbf{X}_{n,\ell}$。接下来，通过对（9）求导可得 $\partial\mathcal{L}_{\mathrm{UTV}}/\partial\mathbf{X}_{n,\ell}$ ：

$$\frac{\partial \mathcal{L}_{\mathrm{UTV}}}{\partial \widehat{\mathbf{X}}_{n,\ell}} = \lambda_1 \operatorname{div}\left(\frac{\nabla_x \widehat{\mathbf{X}}_{n,\ell}}{\|\nabla_x \widehat{\mathbf{X}}_{n,\ell}\|}\right) + \lambda_2 \operatorname{div}\left(\frac{\nabla_y \mathbf{Z}}{\|\nabla_y \mathbf{Z}\|}\right), \tag{22}$$

其中，div(·) 被称为给定矩阵在给定点处的散度。

第二个关键步骤是重点计算$\partial\mathcal{L}/\partial\mathbf{B}_\ell$，其计算方式与 $\delta\mathcal{W}_\ell$ 类似，具体定义如下:

$$\delta\mathbf{B}_\ell = \frac{\partial \mathcal{L}}{\partial \mathbf{B}_\ell} = \frac{\partial \mathcal{L}_{\mathrm{MSE}}}{\partial \widehat{\mathbf{X}}_{n,\ell}} \frac{\partial \widehat{\mathbf{X}}_{n,\ell}}{\partial \mathbf{B}_\ell} + \frac{\partial \mathcal{L}_{\mathrm{UTV}}}{\partial \widehat{\mathbf{X}}_{n,\ell}} \frac{\partial \widehat{\mathbf{X}}_{n,\ell}}{\partial \mathbf{B}_\ell}. \tag{23}$$

现在，我们必须平稳地计算剩余导数 $\partial\mathbf{X}_{n,\ell}/\partial\mathbf{W}_{\ell-1}$ 和 $\partial\mathbf{X}_{n,\ell}/\partial\mathbf{B}_\ell$；具体而言，对式 (1) 关于$\mathbf{W}_{\ell-1}$ 求导，以计算 $\partial\mathbf{X}_{n,\ell}/\partial\mathbf{W}_{\ell-1}$ ，如下所示。

$$\frac{\partial \widehat{\mathbf{X}}_{n,\ell}}{\partial \mathbf{W}_{\ell-1}} = \sigma'\left(\mathbf{W}_{\ell-1}\mathbf{X}_{n,\ell-1} + \mathbf{b}_{\ell-1}\right)\mathbf{X}_{n,\ell-1}, \tag{24}$$

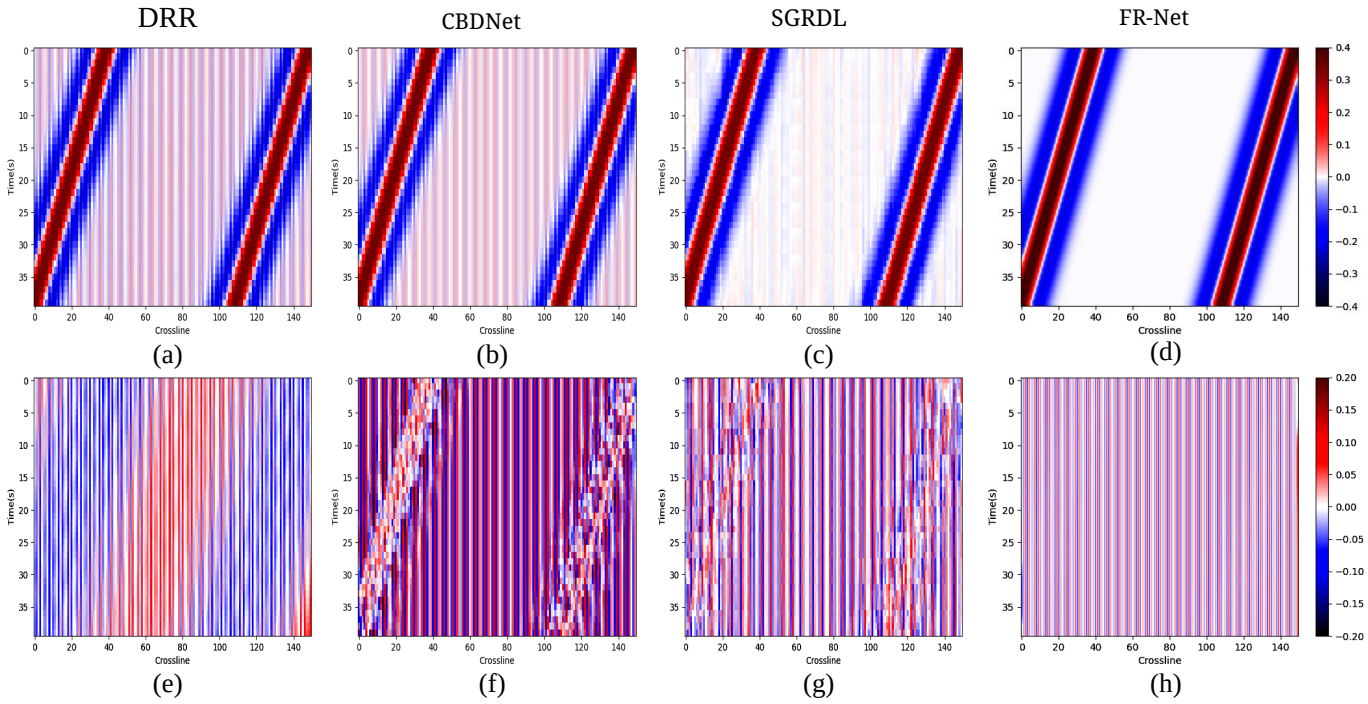

图6. 固定时间切片对比中在合成数据集上获得的结果。脚印去除结果分别采用(a) DRR方法、(b) CBDNet方法、(c) SGRDL方法和(d)所提出的FR-Net方法获得。相应的残差分别采用(e) DRR方法、(f) CBDNet方法、(g) SGRDL方法和(h)所提出的FR-Net方法获得。

其中， σ' 表示激活函数 σ 的导数。接下来，可以对偏置 $\mathbf{B}_\ell$ 求导，并计算 $\partial\mathbf{X}_{n,\ell}/\partial\mathbf{B}_{\ell-1}$ ，如下所示：

$$\frac{\partial\widehat{\mathbf{X}}_{n,\ell}}{\partial\mathbf{B}_{\ell-1}} = \sigma'\left(\mathbf{W}_{\ell-1}\mathbf{X}_{n,\ell-1}+\mathbf{b}_{\ell-1}\right). \tag{25}$$

总之，上述推导有助于理解在 $\partial\mathbf{X}_{n,\ell}/\partial\mathbf{W}_{\ell-1}$ 和 $\partial\mathbf{X}_{n,\ell}/\partial\mathbf{B}_\ell$的交替更新过程中，如何将方程(20)和(23)拆分为新的UTV项和均方误差项，以实现脚印去除。当然，对上述问题进行深入的数学分析超出了本文的讨论范围。此外，值得注意的是， λ_1 和 λ_2 是FR-Net模型最相关的参数，其具体优化方案将在V-D 节中讨论。

C. 实现细节

本节重点介绍并处理与 FR-Net 实现细节相关的两个问题：网络架构和无监督训练样本的构建。具体而言，对于公式（17）中的 $\boldsymbol{h}_\Theta(\cdot)$ 函数，可以采用卷积 U-Net AE 作为 FR-Net，以$\mathbf{Y}_{n,\ell}$为输入来去除脚印噪声。在这种情况下，U-Net 的十九层架构细节如图 2 所示。该架构包含一条收缩路径和一条扩展路径；二者通过对称的跳跃连接、步幅卷积和最大池化相连。具体而言，收缩路径由两个 3×3 卷积组成，后接修正线性单元（ReLU）和一个步幅为 2×2 的最大池化操作，用于 2 进行下采样。扩展路径执行与收缩路径过程相反的操作。

第二个问题涉及为输入的三维地震数据开发一种无监督训练样本生成流程。考虑到脚印噪声会贯穿时间切片，将三维地震数据展平为许多时间切片图像是很自然的做法。然后，我们将每张时间切片图像$\mathbf{Y}$ 裁剪成重叠或不重叠的图像块 $\{\mathbf{Y}_n\}_{n=1}^N$ ，以确保训练样本充足。最后，训练完成的 FR-Net 执行脚印去除后，再通过逆过程重新组织图像，从而得到最终结果。

V. 实验结果

FR-Net 模型构建完成后，我们通过对合成数据和真实场域数据开展一系列对比实验，评估该模型的有效性。首先，实验配置包括所采用的基线方法、数据集、性能指标和参数设置，分别见 V-A 至 V-D 节。所有实验分为两部分：一部分使用 V-E 节中的合成数据，另一部分使用 V-F 节中的真实场域数据。有关实验的讨论见 V-G 节。

A. 基线算法

由于我们提出的 FR-Net 同时包含经典 DCAE 和 UTV 组件，因此我们将所提方法与经典的 TV正则化DCAE模型 [54]进行比较，以验证

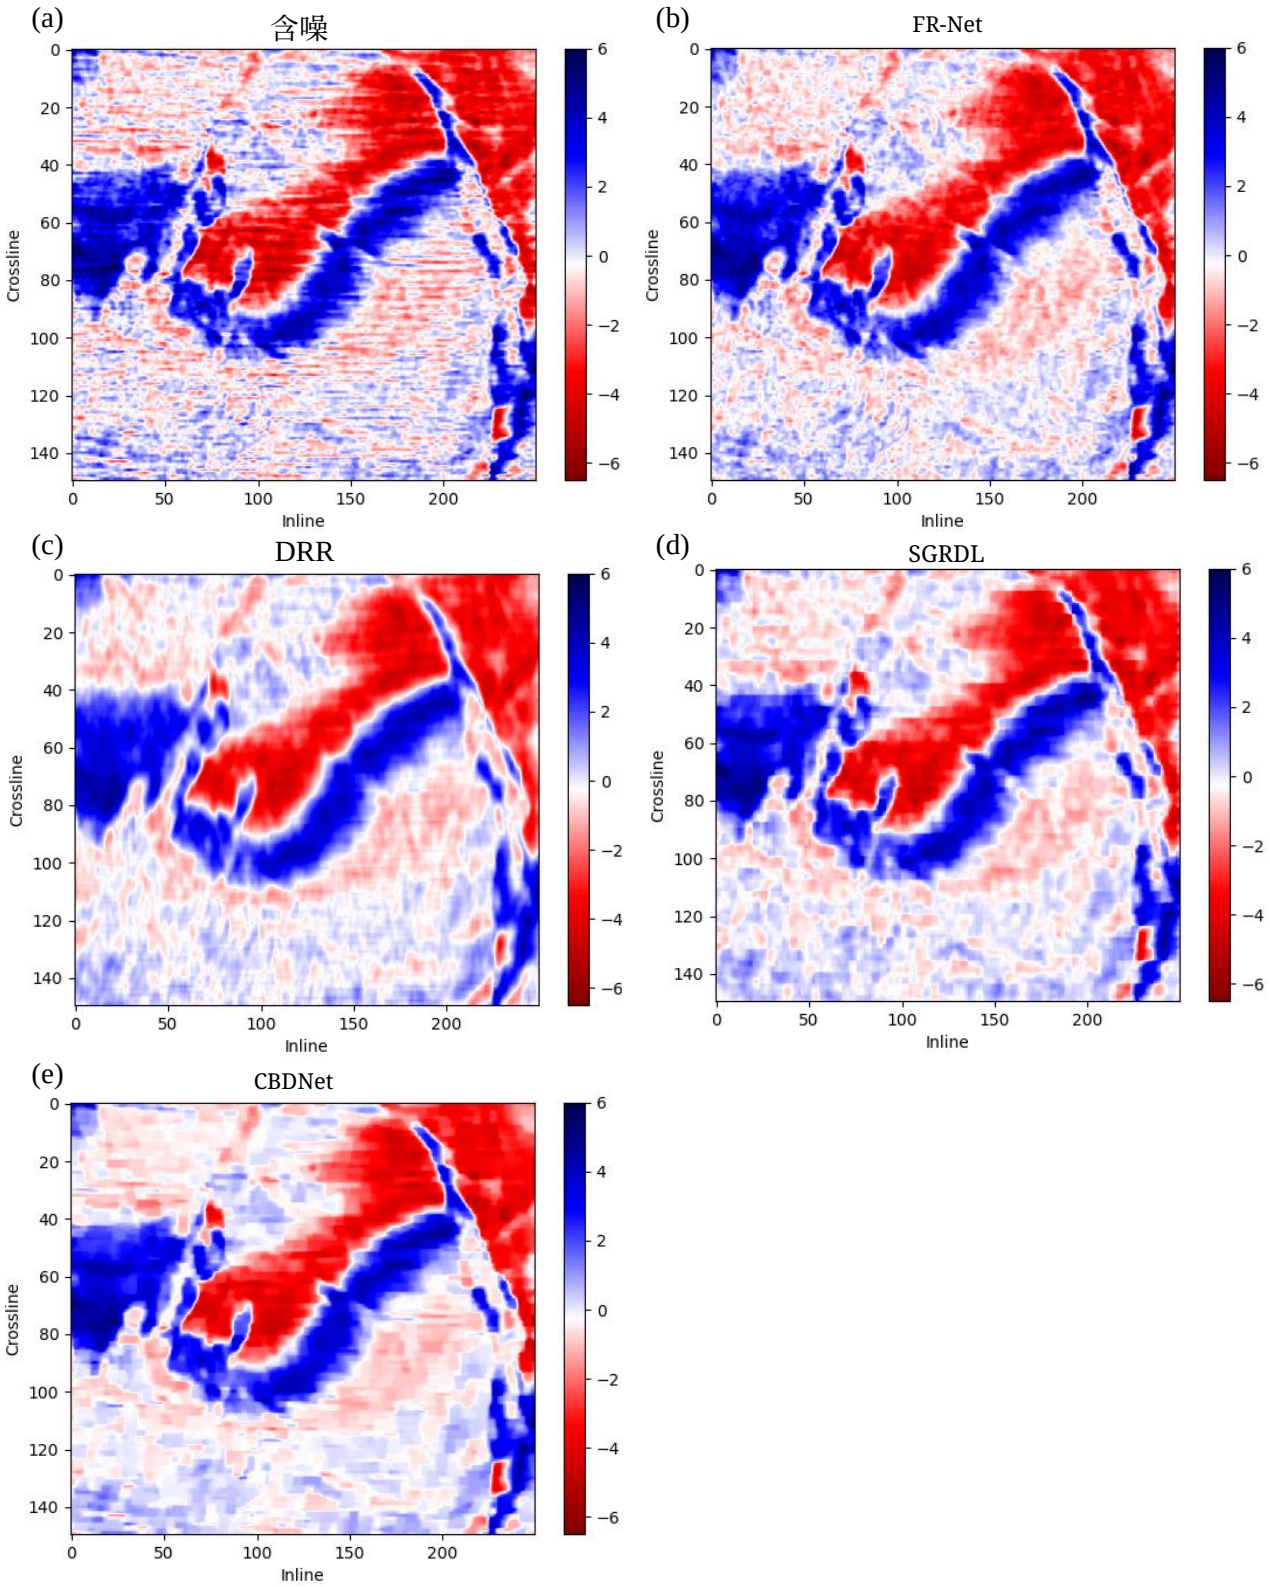

图 7. Penobscot-3D数据集上固定时间切片对比的结果。(a) 恒定时间切片及脚印去除结果分别由以下方法得到：(b) 所提出的 FR-Net、(c) DRR 方法、(d) SGRDL 方法和 (e) CBDNet 方法。

UTV 带来的益处。根据第 I 节中的地震学文献综述，我们还将所提方法与近期的脚印去除模型 [23]和基于奇异值分解的方法进行比较

滤波 [16], , 学习如何有效地从受污染数据中去除噪声，如 [23]所示。这些最先进方法详述如下。

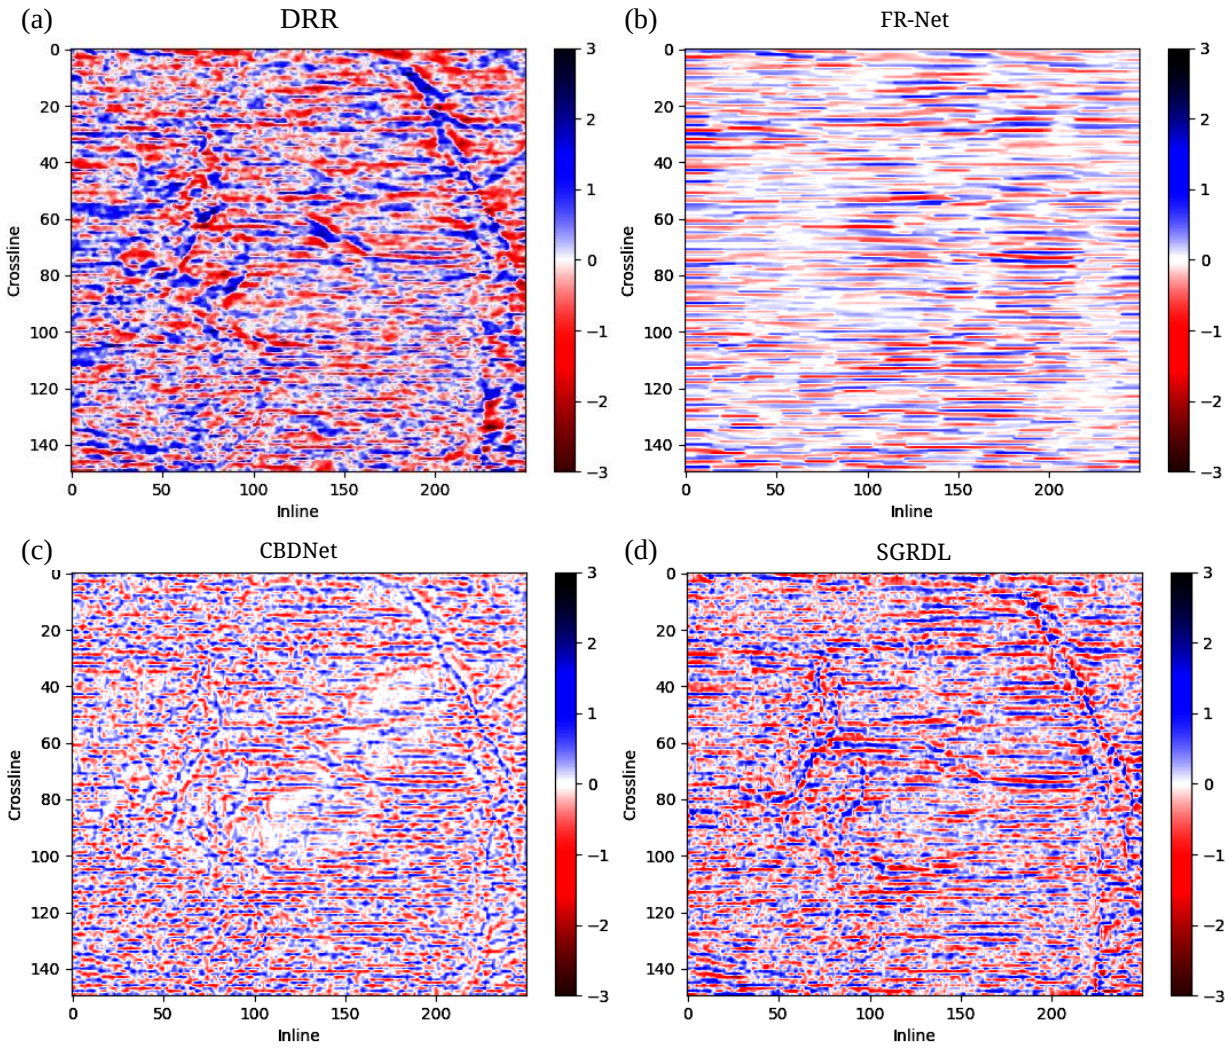

图 8. 在 Penobscot-3D数据集的固定时间切片对比中获得的结果。移除的脚印噪声分别通过以下方法获得：(a) DRR方法、(b) 所提出的 FR-Net 方法、(c) CBDNet方法和 (d) SGRDL方法。

1) 卷积盲去噪网络（*CBDNet*） *[54]*[1]：为公平比较，我们的 FR-Net 和 CBDNet 模型采用相同的网络架构，但使用不同的全变分正则项；也就是说，CBDNet 使用传统全变分，而 FR-Net 使用 UTV。这一比较有助于突出我们的 UTV 惩罚项在脚印去除方面的优势。

2)统计引导的残差字典学习（*SGRDL*） *[23]*[2]：SGRDL构建了一种算法框架，用于学习信号波形的字典原子，并从学习得到的原子中分离出脚印噪声特征。在此例中，SGRDL采用基于统计分析的方法，将字典原子分类为受脚印影响或未受脚印影响。

3) 阻尼秩缩减（*DRR*） *[16]*[2]：通过引入一个阻尼算子，对传统的截断奇异值分解模型进行改进，DRR 倾向于将含噪信号的 Hankel矩阵的向量空间划分为有用信号子空间和噪声子空间。

在实验中，DRR 和 SGRDL 使用 MATLAB 实现，而 CBDNet 和 FR-Net 则在 Google Colab 平台上使用 TensorFlow 实现[3] [4]；请注意，Colab 会在平台上随机为用户分配 GPU。此外，在所有实验中，我们都仔细调整了 DRR 和 SGRDL 的模型参数，使其性能达到与 [16] 和 [23] 中报告的性能相当的水平。

B. 测试数据集

本节旨在通过三组对比展示所提出的 FR-Net 的优越性能，其中一组使用合成场数据，另外两组使用实际场数据。

[1]https://github.com/GuoShi28/CBDNet [2] https://github.com/chenyk1990/reproducible research/tree/master/foot

[3]https://www.tensorflow.org/ [4] https://colab.research.google.com/

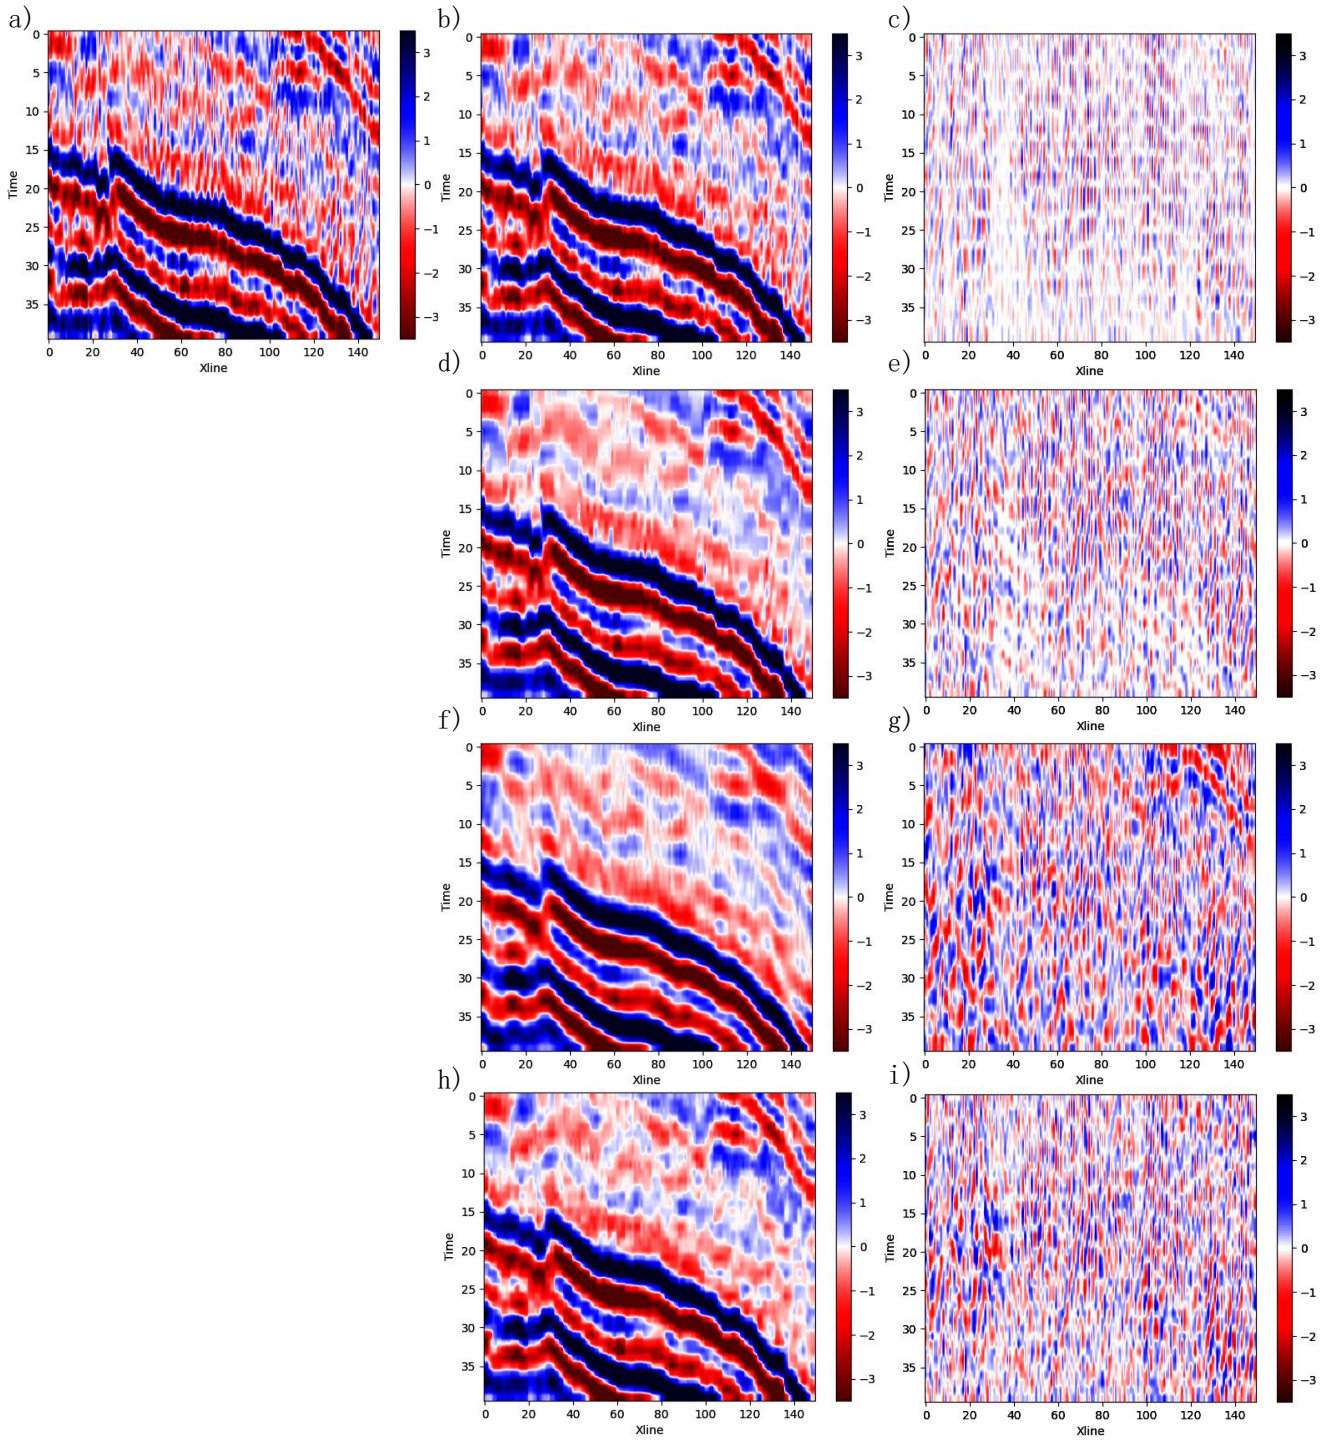

图 9. Penobscot-3D数据集内联剖面对比结果。(a) 原始第 200 个内联剖面。脚印去除结果分别采用 (b) 所提出的 FR-Net、(d) DRR方法、(f) CBDNet方法和 (h) SGRDL方法获得。相应的残差分别采用 (c) 所提出的 FR-Net、(e) DRR方法、(g) CBDNet方法和 (i) SGRDL方法获得。

本文使用的所有数据均可免费公开获取，具体介绍如下。

1) 合成数据[2]：该三维合成数据集由 [23], 使用，仅包含三个线性地震事件，每个事件具有不同的小波。为了生成最终的三维观测数据，特意在清晰数据中加入了严重的脚印噪声。

2) *Penobscot-3D*[5]：Kington 的 Penobscot 子集为研究人员提供了一个可公开获取的数据集，其中的脚印模式在浅层时间切片上清晰可见。每种脚印模式都由一系列长度各异的条带组成，这些条带沿交叉线方向延伸。

[5]https://wiki.seg.org/wiki/Penobscot_3D

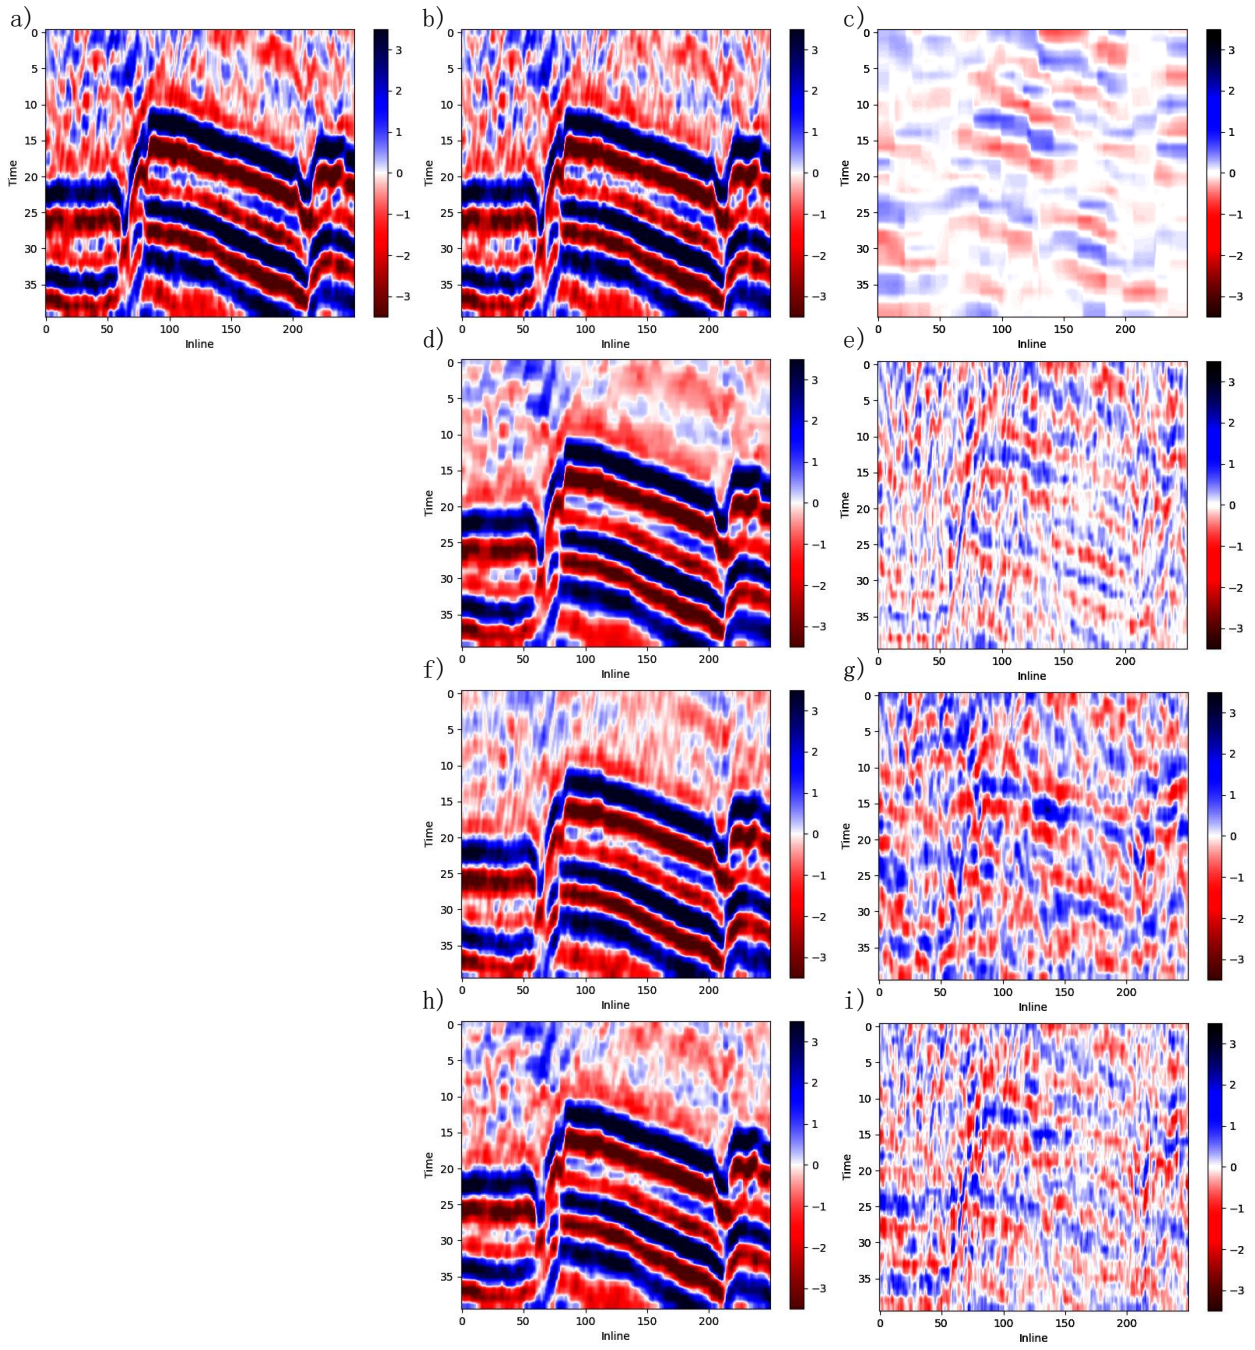

图 10. Penobscot-3D数据集的 x线剖面对比结果。(a) 原始第 40 条 x线剖面。脚印去除结果分别由 (b) 所提出的 FR-Net、(d) DRR方法、(f) CBDNet方法和 (h) SGRDL方法获得。对应的残差分别由 (c) 所提出的 FR-Net、(e) DRR方法、(g) CBDNet方法和 (i) SGRDL方法获得。

3) *Kerry-3D*[6]： Kerry-3D数据集的上部受到由宽度和长度各异的水平条带产生的脚印噪声严重污染；该数据集比 Penobscot 受到的污染更为严重。

这些数据集涵盖了从简单到困难的不同难度，因此足以作为比较脚印去除算法的基准数据集，并全面展示 FR-Net 的特性。

C. 性能指标

在合成数据实验中，真实数据是可用的，因此可以与脚印去除结果进行比较。除了视觉对比之外，使用定量评价指标比较 FR-Net 和最先进方法的去噪性能也十分自然。受 [23], 启发，我们还使用信噪比（SNR）作为定量评价指标。

$$\mathrm{SNR}[\mathrm{dB}] = 10\log_{10}\frac{\|\mathbf{X}\|_2^2}{\|\mathbf{X}-\widehat{\mathbf{X}}\|_2^2}, \tag{26}$$

[6]https://wiki.seg.org/wiki/Kerry-3D

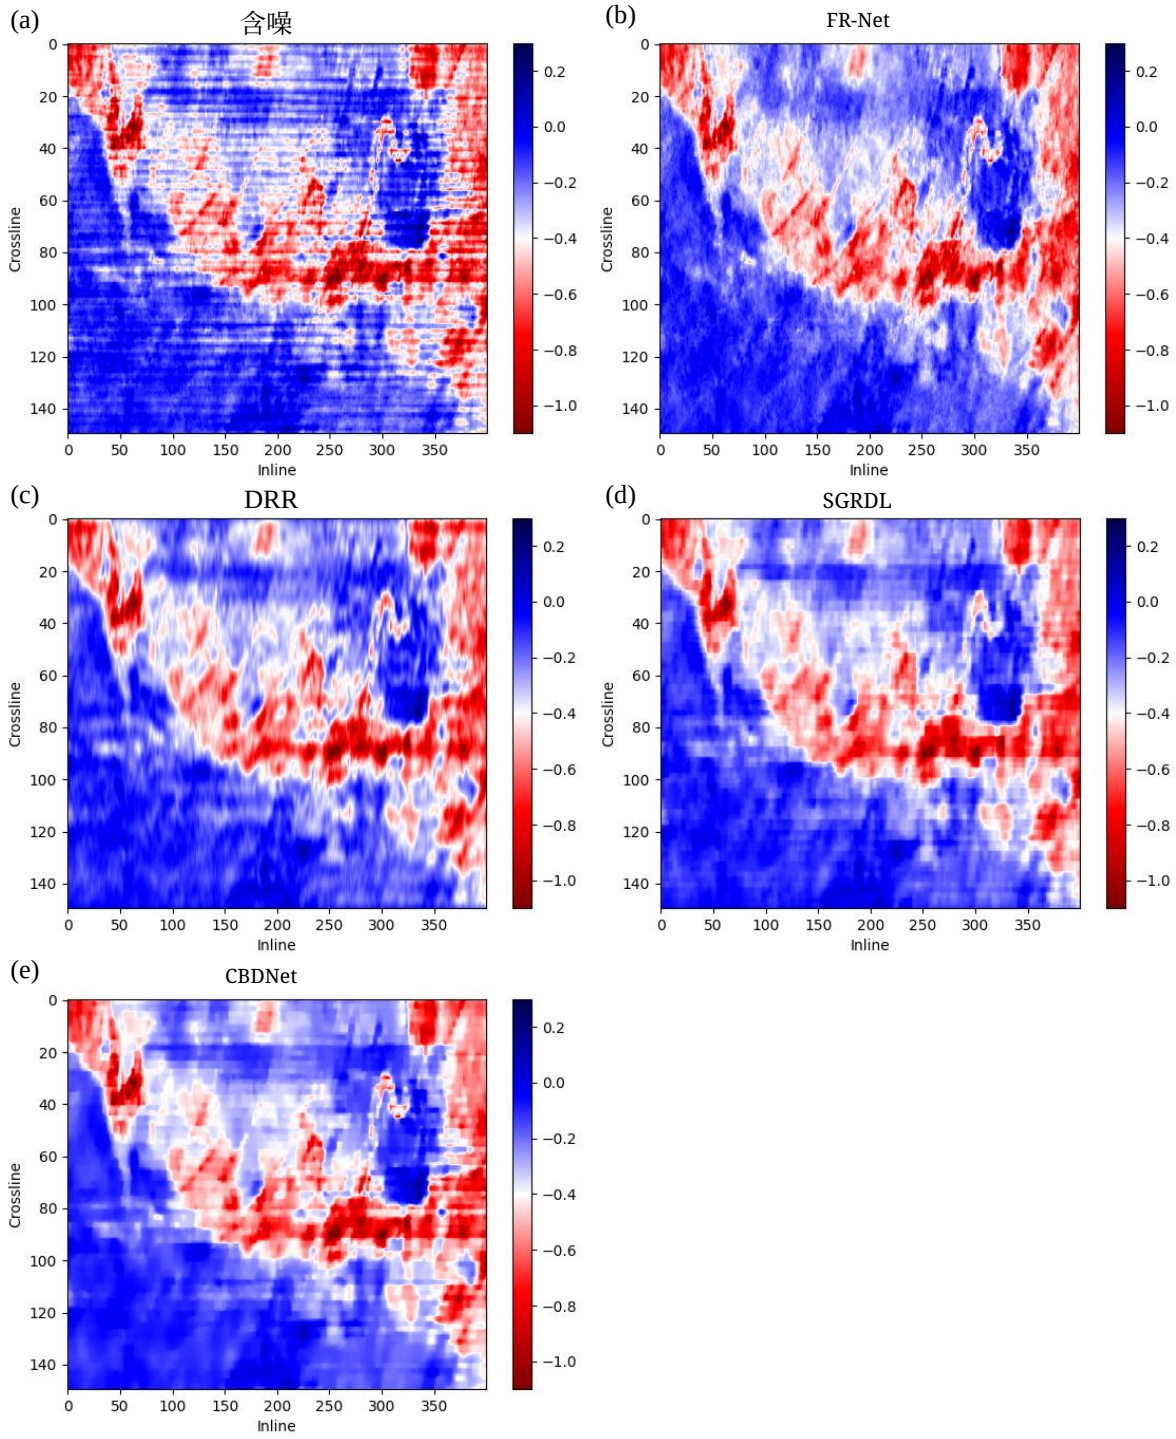

图 11. Kerry-3D数据集上固定时间切片对比的结果。(a) 恒定时间切片及脚印去除结果分别由以下方法获得：(b) 所提出的 FR-Net、(c) DRR方法、(d) SGRDL方法和 (e) CBDNet方法。

其中 $\mathbf{X}$ 和 $\hat{\mathbf{X}}$ 分别表示干净图像和估计图像。

D. 参数设置

在任意选定第 IV-C 节中的 FR-Net 架构后，下一步是预先设置两类参数：代价函数的参数和训练算法参数。FR-Net 的代价函数包含两个必须选定的显式权衡参数： λ_1 和 λ_2。在这里，对于合成数据，我们设定 $\lambda_1 = 6 \times 10^4$ 和 $\lambda_2 = 4 \times 10^5$；对于 Penobscot 数据，我们设定 $\lambda_1 = 4.5 \times 10^4$ 和 $\lambda = 3 \times 10^5$；对于 Kerry- 3D 数据，我们设定 $\lambda_1 = 5 \times 10^4$ 和 $\lambda_2 = 3 \times 10^5$。确定代价函数的参数后，

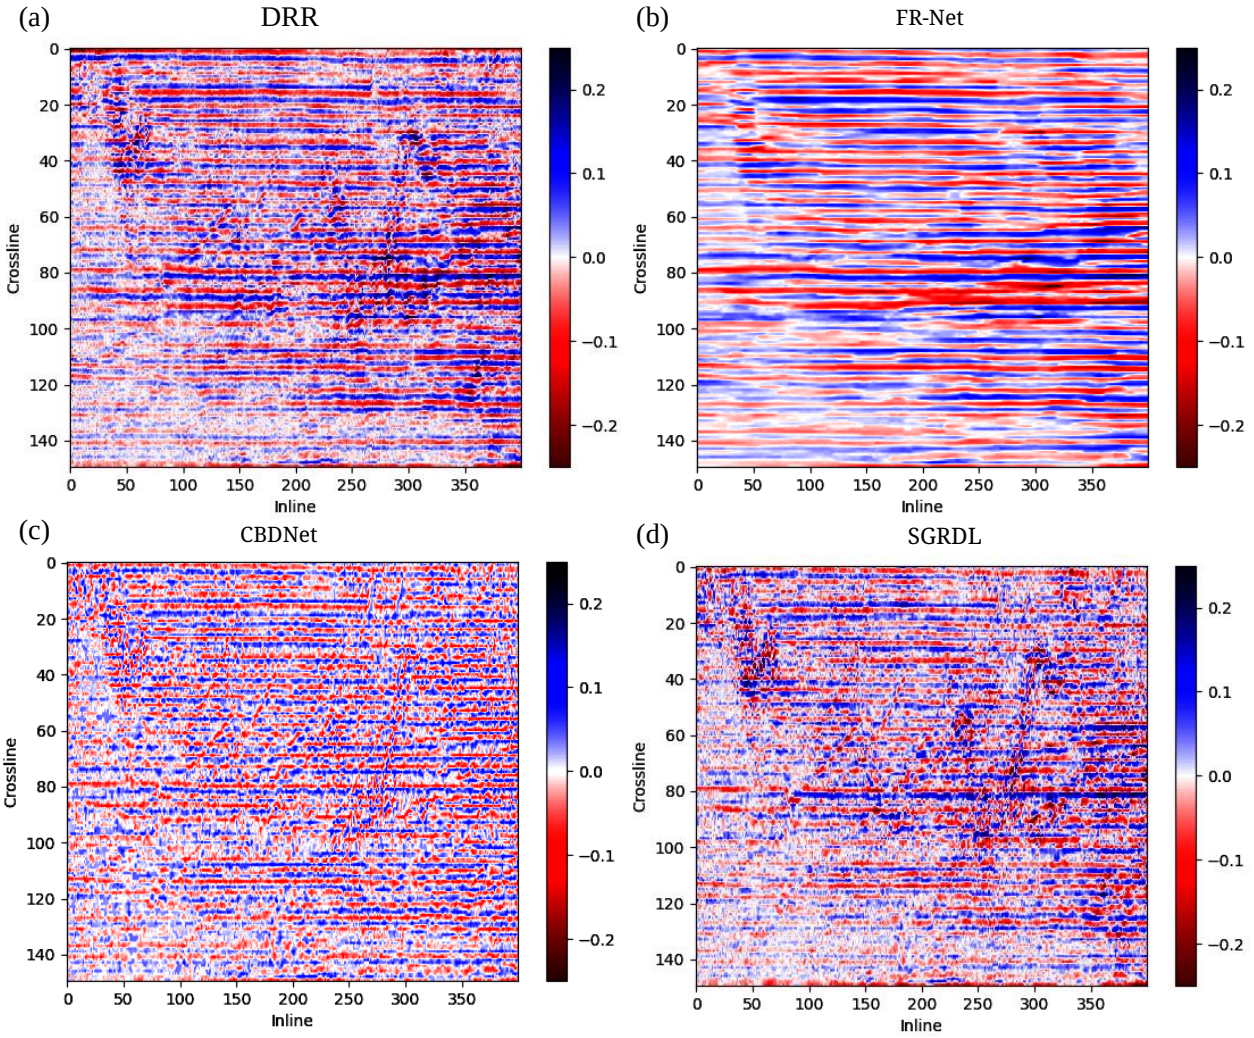

图 12. (a) 输入的 3D Kerry-3D 数据集上的固定时间切片对比结果。去除的脚印噪声分别使用 (a) DRR方法、(b) 所提出的 FR-Net 方法，(c) CBD 数据集上的固定时间切片对比结果。去除的脚印噪声分别使用 (a) DRR方法、(Net 方法，以及 (d) SGRDL 方法。

通过超参数优化（即使用 Adam 优化器）来选择最佳训练算法参数，例如批量大小和学习率。具体而言，合成数据和 Kerry-3D 数据的最终学习率设为 1.0×10^{-5}，Penobscot 数据的最终学习率设为 1.0×10^{-4}，所有数据集的批量大小均设为 5。

E. 合成数据实验

为验证 FR-Net 模型，我们在一个由 [23] 中的开源代码生成的三维合成数据集上对其进行测试，并人为添加了随道内方向衰减的垂直脚印噪声，如图 3 所示。值得注意的是，在脚印去除过程中，FR-Net 完全不会接触干净的地震图像，因为它和之前一样，仅用于计算 SNR 值。实际上，在预处理阶段，我们必须将含噪地震图像拆分为 50×50 个图像块，然后将所有图像块输入 FR-Net。

图 5 和图 6 展示了针对合成数据集进行的两组定切片对比，呈现了获得的恢复效果和残差。从图 5 以及图6还证实，FR-Net几乎不会留下条带残差，而最先进方法无法彻底消除所有脚印噪声。此外，如图4所示，通过单道对比可以更直观地证明最先进方法和FR-Net方法的脚印噪声残差。值得注意的是，图4中的FR-Net结果近乎完美，能够将有用信号与受脚印噪声污染的地震数据完全分离；这是因为所有模拟脚印噪声都力求严格满足UTV方向性假设。除了视觉对比之外，我们还通过定量信噪比对比来表征残余脚印噪声水平，如表I所示。从表I可以看出，与DRR、CBDNet和SGRDL技术分别达到的10.29、20.69和20.10 dB相比，我们的FR-Net模型产生的残余脚印噪声最少（36.00 dB）。显而易见，所提出的方法能够在不损失任何信息的情况下，将有效反射信号从含噪地震图像中无缝分离出来。

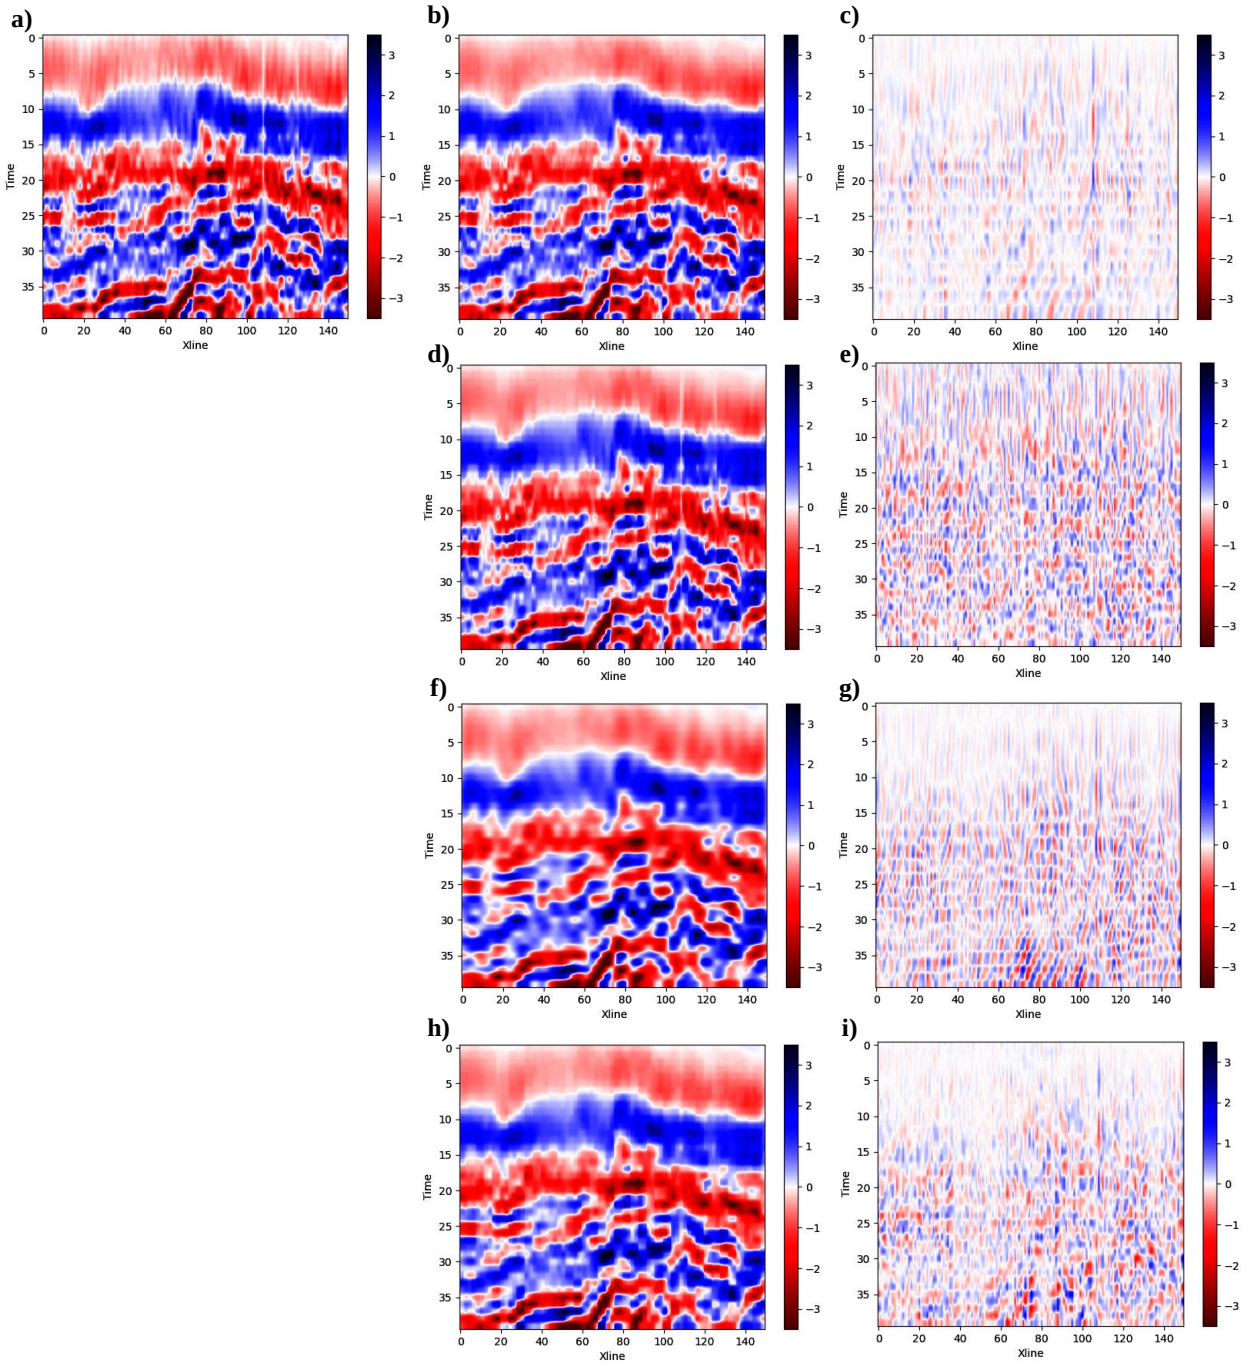

图13. Kerry-3D数据集内联剖面对比实验的结果。(a) 原始第163道内剖面。脚印去除结果分别采用 (b) 所提出的 FR-Net、(d) DRR方法、(f) CBDNet方法和 (h) SGRDL方法获得。相应的残差分别采用 (c) 所提出的 FR-Net、(e) DRR方法、(g) CBDNet方法和 (i) SGRDL方法获得。

F. 实地数据实验

为验证所提出方法在实际应用中的优越性和有效性，我们将FR-Net应用于两个不同的真实场域数据集：Penobscot-3D和Kerry-3D。如第V-B节所述，这些真实场域数据涵盖了广泛的脚印噪声水平，有助于确定所提出的FR-Net对不同噪声强度的适应能力。因此，根据所选的脚印噪声水平，目前整个真实场域数据测试由以下部分组成：以下两个子实验。

在第一个示例中，我们展示了 FR-Net 在 Penobscot-3D 数据集上的有效性和准确性。Kerry-3D 数据集存在严重的采集脚印，这可能给 Penobscot 数据带来重大的工程挑战，如图 7(a) 所示。具体而言，图 7(b)-(e) 和图 8(a)-(d) 展示了采用所提出的 FR-Net 方法和最先进方法所实现的噪声消除结果及相应的脚印去除效果。从图 7 和图 8 可以清楚地看出，FR-Net 能够有效地

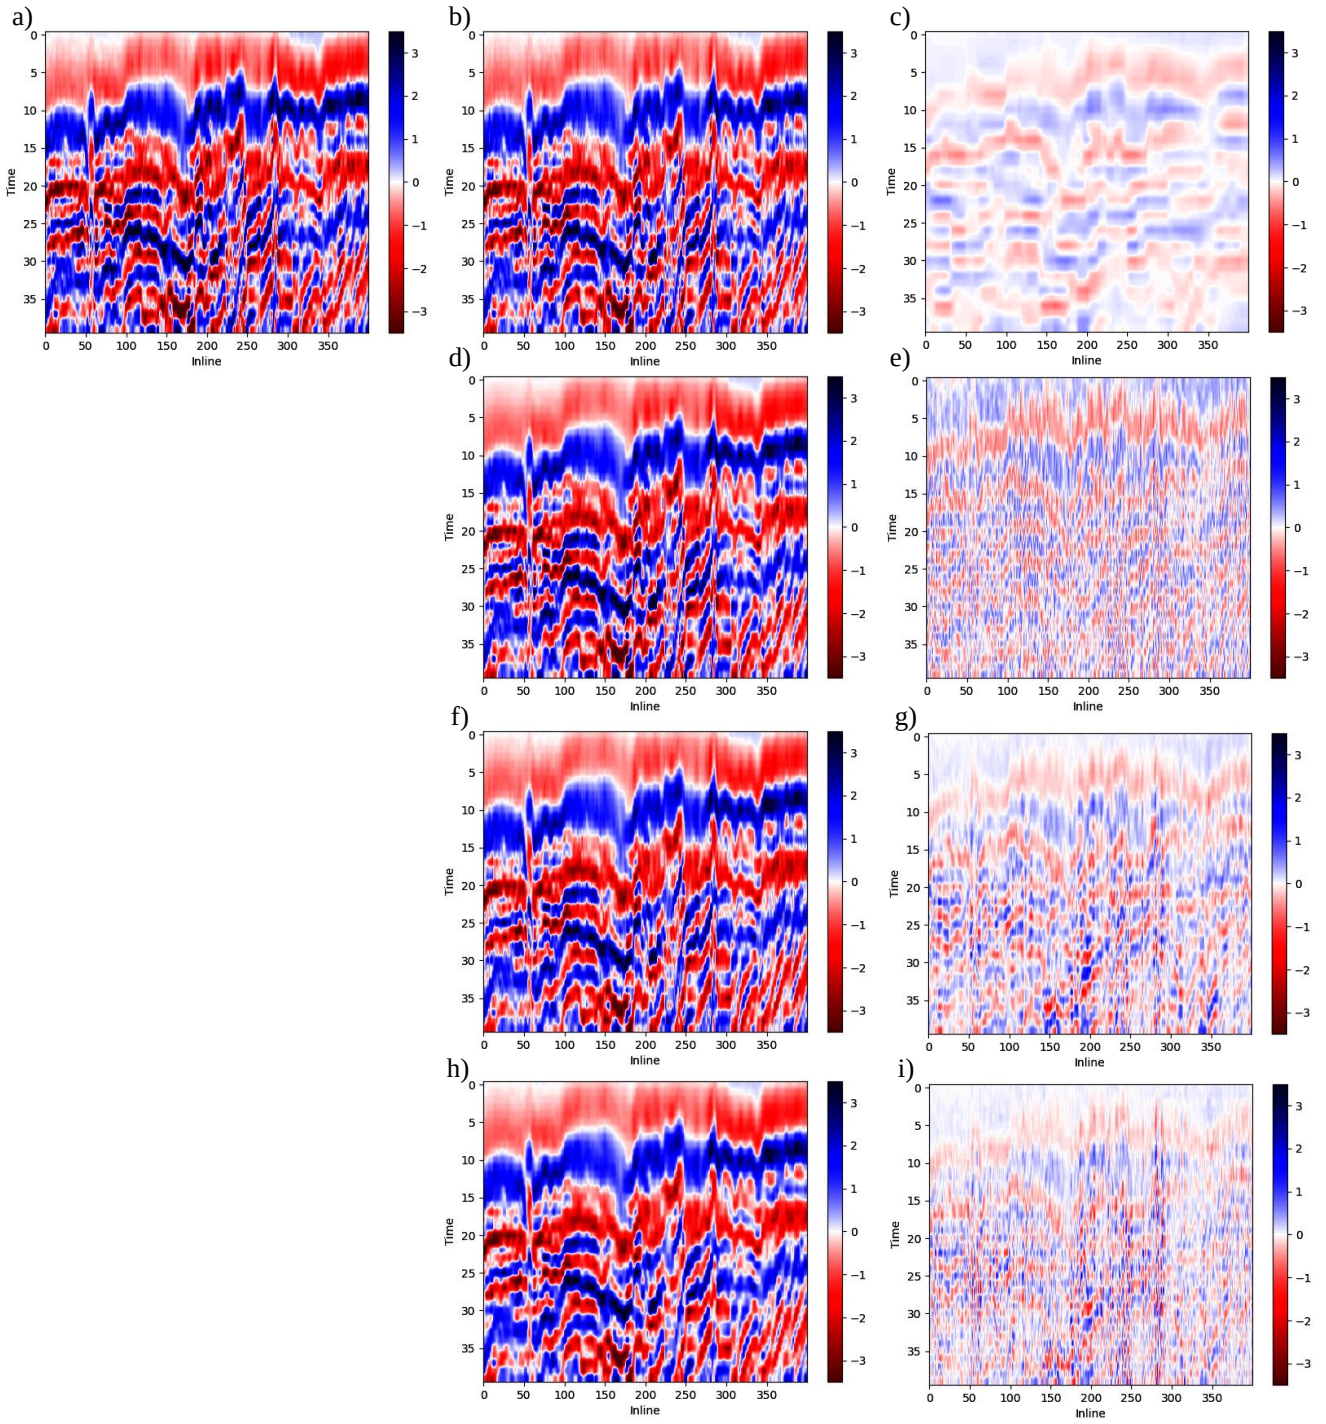

图14. Kerry-3D数据集x线剖面对比结果。(a) 原始第70道x线剖面。采用以下方法获得脚印噪声去除结果：(b) 所提出的FR-Net、(d) DRR方法、(f) CBDNet方法和(h) SGRDL方法。采用以下方法获得对应的残差：(c) 所提出的FR-Net、(e) DRR方法、(g) CBDNet方法和(i) SGRDL方法。

去除脚印噪声，同时不会降低地震图像分辨率；而最先进算法往往会导致图像边缘过度平滑，或在生成的图像中留下残余足迹。为进一步比较脚印去除效果，我们选取图 7(a) 中的两条线进行剖面检查，如图 9 和图 10 所示。毫无疑问，图 9 和图 10 中的所有结果均重现了初步发现，因此证实了 FR-Net 方法取得了显著的在未发生信号泄漏的情况下衰减脚印噪声，并有效保留边缘。

在第二个示例中，我们使用带有严重脚印噪声的 Kerry-3-D 实测数据，进一步测试所提出的 FR-Net。与前面一样，首先在时间切片上比较这四种方法是很自然的，如图11和图12所示。在视觉质量方面，除了去除

表I DRR、CBDNet、SGRDL 和所提出的 FR-Net 方法在合成数据集上的脚印去除结果定量比较

方法	合成数据集
DRR	10.29 分贝
CBDNet	20.69 dB
SGRDL	20.10 dB
提出的 FR-Net	**36.00** 分贝

脚印噪声外，所提出的 FR-Net 生成的结果与原始地震图像最为接近，因此优于其他最先进方法。同样，图13和图14展示了从图11(a)中选取的两条测线，以进一步考察各对比方法的脚印噪声去除效果。从图13和图14可以看出，FR-Net 在条带残差中删除的有意义信号更少，而最先进方法总是会对有用信号造成过多损害。因此，我们可以得出结论：对于脚印噪声严重的 Kerry-3-D 数据，所提出的 FR-Net 方法能够显著提升最先进方法的脚印去除效果。

G. 讨论

如 [23], [24], [26],所假设的那样，有用信号、脚印噪声和随机噪声是叠加的。在这种情况下，我们训练 FR-Net，将有用信号与脚印噪声分离，并将它们集中到相应的独立分量中。从图 5、6、7 和 11 可以清楚地看出，脚印噪声被非常干净地去除了，但有用信号中不可避免地仍残留大量随机噪声，这是 FR-Net 的主要缺点。其根本原因在于，纯 U-Net 无法通过无监督学习有效消除随机噪声 [54]。值得注意的是，针对经典的噪声抑制任务，已有多种方法被提出以弥补这一不足，例如结构导向滤波 [17]。

就计算复杂度而言，我们的 FR-Net 与标准 U-Net 几乎相同，因为我们只在其代价函数中添加了一个常规的 UTV 项，并未改变网络架构，也没有产生任何推理开销。与典型的深度学习网络一样，U-Net 和 FR-Net 也都因训练过程具有递归特性而面临较高的计算复杂度，这也是任何深度学习模型普遍存在的问题。

与标准 U-Net 一样，FR-Net 也对参数较为敏感，需要通过大量实验才能获得最优参数。除了标准 U-Net 使用的训练率和批量大小等网络参数外，还必须调整方程（13）中的权衡参数 λ_1 和 λ_2，因为它们会显著影响脚印去除的效果。具体而言，我们必须将权衡参数 λ_1 和 λ_2 设置为适当值，既不能过低，也不能过高。如果 λ_1 和 λ_2 过大，FR-Net 将去除过多的脚印噪声，并使底层信号发生失真。如果权衡参数λ_1 和 λ_2 过小，FR-Net 的效率将会降低。

VI. 结论

本文提出了一种物理先验增强脚印噪声去除网络，即 FR-Net，用于以无监督方式抑制采集到的脚印噪声。具体而言，为了捕获脚印噪声内在的方向性特征，我们设计了 UTV模型，该模型与当前所有去除方法都有显著区别。随后，利用 UTV模型对深度学习方法施加强正则化，得到最终的 FR-Net，从而将深度学习从完全数据驱动的方法转变为物理先验增强技术。通过以无监督方式联合优化 FR-Net 模型，BP 算法实现了脚印噪声与有效信号的完全分离。在合成数据集和真实场域数据集上获得的实验结果表明，与最先进方法相比，我们的方法在信噪比评价和视觉质量方面取得了显著提升。

未来的研究将继续把所提出的物理先验增强深度学习框架扩展至其他类型的噪声衰减，例如涌浪噪声、地滚波噪声和沙漠噪声。我们还将探索 UTV 与其他模型的结合，例如低秩近似（LRA）、稀疏表示（SR）和字典学习。在这种情况下，我们不仅借助 UTV 成功分离了脚印噪声，还获得了一些意想不到的特性，例如能够弥补 FR-Net 的缺陷，抑制其无法消除的随机噪声。

致谢

作者谨向副编辑和两位匿名审稿人致谢，他们提出的建设性意见极大地改进并澄清了本文。

参考文献

[1] S. Chopra 和 G. Larsen，“采集脚印噪声的检测与去除”，*CSEG Recorder*，第 25 卷，第 8 期，第 16–20 页，2000 年 10 月。[2] S. Hill、M. Shultz 和 J. Brewer，“采集脚印噪声与叠加次数图”，*The Leading Edge*，第 18 卷，第 6 期，第 686–695 页，1999 年 6 月。[3]J. E. Savage 和 J. C. Mathewson，“根据现有二维数据预测三维地震脚印”，*The LeadingEdge*，第 20 卷，第 5 期，第 464–473 页，2001 年 5 月。[4]J. Li、J. Gao、J. Mei 和 X. Chen，“海上地震拖缆采集的脚印模拟与分析”，载于第 *78* 届 *SEG* 年会国际会议技术计划扩展摘要，2008 年 12 月，第 120–124 页。[5] K. J. Marfurt、R. M. Scheet、J. A. Sharp 和 M. G. Harper，“用于地震层序属性制图的采集脚印噪声抑制”，《地球物理学》，第 63 卷，第 3 期，第 1024–1035 页，1998 年 2 月。[6] J. K. Cooper，“地震采集脚印：建模与抑制”，硕士论文，研究生院，2010年。[7]A. Alali、G. Machado 和 K. J. Marfurt，“利用二维连续小波变换辅助属性驱动的脚印噪声抑制”，*Interpretation*，第 6 卷，第 2 期，第 T457–T470 页，2018年5月。

[8] S. K. Sahai 和 K. A. Soofi，“利用简单二维滤波器降低地震数据中的脚印噪声”，*Geohorizons*，第 7 卷，第 14–17 页，2006 年 7 月。[9] N. Gulunay、F. Martin 和 R. Martinez，“三维数据采集伪影去除——空时频域中的点编辑”，载于第 *56* 届欧洲地球科学家与工程师协会（*EAEG*）会议论文集，1994 年 6 月，第 cp-47-00184 页。[10]R. Soubaras，“非正交三维几何中的采集脚印噪声衰减”，载于第 *72* 届 *SEG* 年会国际会议技术计划扩展摘要，2002 年 1 月，第 2142–2145 页。[11] S. Falconer 和 K. J. Marfurt，“属性驱动的脚印噪声抑制”，载于第 *78* 届 *SEG* 年会国际会议技术计划扩展摘要，2008 年 12 月，第 2667–2671 页。[12] N. G¨ul¨unay，“采集几何脚印去除”，载于第 *69* 届 *SEG* 年会国际会议技术计划扩展摘要，1999 年 1 月，第 637–640 页。[13] J. M. Drummond、A. J. Budd 和 J. W. Ryan，“适应含噪三维数据——衰减采集脚印噪声”，载于第 *70* 届 *SEG* 年会国际会议技术计划扩展摘要，2000 年 1 月，第 9–12 页。[14] M. S. Al-Bannagi、K. Fang、P. G. Kelamis 和 G. S. Douglass，“利用截断奇异值分解技术抑制采集脚印噪声：沙特阿拉伯案例研究”，*TheLeadingEdge*，第 24 卷，第 8 期，第 832–834 页，2005 年 1 月。[15] M. Al-Bannagi、K. Fang、P. Kelamis 和 G. Douglass，“利用截断奇异值分解技术抑制采集脚印噪声”，载于第 *74* 届 *SEG* 年会国际会议技术计划扩展摘要，2004 年 12 月，第 1957–1960 页。[16] Y. Chen、D. Zhang、Z. Jin、X. Chen、S. Zu、W. Huang 和 S. Gan，“基于阻尼秩约简方法的五维地震数据同时去噪与重建”，*Geophysical J. Int.*，第 206 卷，第 3 期，第 1695–1717 页，2016 年 9 月。[17] G. C. Fehmers 和 C. F. H¨ocker，“利用构造导向滤波快速进行构造解释”，*Geophysics*，第 68 卷，第 4 期，第 1286–1293 页，2003 年 7 月。[18] Z. Yu、R. Abma、J. Etgen 和 C. Sullivan，“ 利用小波去噪衰减噪声和同时源干扰 ”，《地球物理学》，第 82 卷，第 3 期，第 V179–V190 页，2017 年 5 月。[19]X. Chen、W. Yang、Z. He 和 W. Zhong，“基于三维平稳小波变换的自适应采集脚印压制：中国案例研究”，*J. Appl.Geophys.*，第 77 卷，第 1–6 页，2012 年 2 月。[20] M. Cvetkovic、S. Falconer、K. J. Marfurt 和 S. Ch´avez- P´erez，“基于二维平稳小波变换的采集脚印噪声抑制”，载于第 *77* 届 *SEG* 年会国际会议技术计划扩展摘要，2007 年 9 月，第 2590–2594 页。[21] R. Zhang，“利用基追踪去噪抑制脚印噪声”，载于第 *79* 届 *SEG* 年会国际会议技术计划扩展摘要，2009 年 10 月，第 3361–3366 页。[22] A. G´orszczyk、M. Malinowski 和 G. Bellefleur，“利用二维曲波变换增强硬岩环境中采集的三维叠后地震数据”，*GeophysicalProspecting*，第 63 卷，第 4 期，第 903–918 页，2015 年 3 月。[23] W. Chen、O. M. Saad、H. Wang 和 Y. Chen，“统计学——

用于脚印噪声去除的引导式残差字典学习，” *IEEE* 地球科学与遥感汇刊, 第60卷，第1–11页，2022年，文章编号4502011。[24] D. Liu、L. Gao、X. Wang和W. Chen，“一种采用原子分裂的地震脚印压制字典学习方法，”《地球物理学》, 第 86 卷，第 6 期，第 V509–V523 页，2021年11月。[25]L. Gao、W. Xiaokai、W. Chen和W. Chao，“一种基于局部形态分量分析的采集脚印压制方法，”载于第*86*届*SEG*年度国际会议技术计划扩展摘要集，2016年9月，第4710-4714页。[26] J. L. G´omez和D. R. Velis，“利用残差字典学习去除地震数据中的脚印噪声，”《地球物理学》, 第85卷，第4期，第V355–V365页，2020年7月。[27] S. Yu、J. Ma和W. Wang，“用于去噪的深度学习——用于去噪的深度学习，”《地球物理学》, 第84卷，第6期，第V333–V350页，2019年11月。[28] E. Wang和J. Nealon，“将机器学习应用于三维地震图像去噪与增强，” *Interpretation*, 第7卷，第3期，第SE131–SE139页，2019年8月。[29] W. Li、H. Liu和J. Wang，“一种基于快速灵活卷积神经网络的去噪深度学习方法，” *IEEE* 地球科学与遥感汇刊, 第60卷，第1–13页，2022年，文章编号5902813。[30] L. Yang、W. Chen、H. Wang和Y. Chen，“通过改进的残差卷积神经网络进行深度学习地震随机噪声衰减，”*IEEE* 地球科学与遥感汇刊, 第 59 卷，第 9 期，第 7968–7981 页，2021 年 9 月。[31]D. Liu、W. Wang、W. Chen、X. Wang、Y. Zhou和Z. Shi，“地震数据中的随机噪声抑制：深度学习能做什么？”载于第*88*届*SEG*年度国际会议技术计划扩展摘要集，2018年8月，第2016–2020页。[32]D. Liu、W. Wang、X. Wang、C. Wang、J. Pei和W. Chen，“基于三维卷积神经网络的叠后地震数据去噪，” *IEEE* 地球科学与遥感汇刊, 第58卷，第3期，第1598–1629页，2020年3月。[33]M. Zhang、Y. Liu和Y. Chen，“基于深度卷积神经网络的无监督地震随机噪声衰减，” *IEEE Access*, 第7卷，第179810–179 822页，2019年12月。[34] O. M. Saad和Y. Chen，“用于地震随机噪声衰减的深度去噪自编码器，”《地球物理学》, 第 85 卷，第 4 期，第 V367–V376 页，2020年7月。[35] L. Yang、S. Wang、X. Chen、O. M. Saad、W. Chen、Y. A. S. I. Obou´e和Y. Chen，“使用深度跳跃自编码器进行无监督三维随机噪声衰减，” *IEEE* 地球科学与遥感汇刊, 第60卷，第1–16页，2022年，文章编号5905416。[36]O. M. Saad和Y. Chen，“一种完全无监督且高度泛化的随机噪声抑制深度学习方法，” *GeophysicalProspecting*, 第69卷，第4期，第709–726页，2021年4月。[37] F. Qian、Z. Liu、Y. Wang、Y. Zhou和G. Hu，“时频域中利用深度张量卷积神经网络进行无真实标签的三维地震随机噪声衰减，” *IEEE* 地球科学与遥感汇刊, 第60卷，第

第1-17页，2022年，文章编号5911317。[38] F. Qian、Z. Liu、Y. Wang、S. Liao、S. Pan和G. Hu，“Dtae：用于三维地震数据插值的深度张量自编码器，”*IEEE* 地球科学与遥感汇刊, 第60卷，第1-19页，2022年，文章编号5904219。[39] F. Qian、W. Guo、Z. Liu、H. Yu、G. Zhang和G. Hu，“利用鲁棒深度卷积自编码器进行无监督随机地震噪声衰减，”*IEEE* 地球科学与遥感汇刊, 第60卷，第1-16页，2022年，文章编号5913016。[40] M. Bouali和S. Ladjal，“利用单向变分模型实现MODIS数据的最优去条带，”*IEEE* 地球科学与遥感汇刊, 第49卷，第8期，第2924–2935页，2011年6月。[41] Y. Zhao、Y. Li和N. Wu，“基于卷积神经网络的分布式声学传感垂直地震剖面数据去噪器，”*IEEE* 地球科学与遥感汇刊, 第60卷，第1-11页，2022年，文章编号5900511。[42] Q. Feng和Y. Li，“基于奇异谱分析的深度学习去噪网络：采用多通道SVDDCNN进行地震数据去噪，”*IEEE* 地球科学与遥感汇刊,，第60卷，第1–11页，2022年，文章编号5902911。[43] L. I. Rudin、S. Osher和E. Fatemi，“基于非线性全变分的噪声去除算法，”《物理学*D*：非线性现象》, 第60卷，第1-4期，第259–268页，1992年11月。[44] Y. Zhao、Y. Li和N. Wu，“基于卷积神经网络的分布式声学传感地震数据耦合噪声抑制，”*IEEE Geosci. RemoteSens. Lett.*, 第19卷，第1-5页，2022年，文章编号8025605。[45] X. Zhao、P. Lu、Y. Zhang、J. Chen和X. Li，“涌浪噪声衰减：一种深度学习方法，”*The LeadingEdge*, 第38卷，第12期，第934–942页，2019年12月。[46]B. Farmani和M. W. Pedersen，“卷积神经网络在涌浪噪声衰减分类中的应用，”载于第*90*届*SEG*年度国际会议技术计划扩展摘要集，2020年9月，第2868–2872页。[47] H. Li、W. Yang和X. Yong，“地滚波噪声衰减的深度学习，”载于第*88*届*SEG*年度国际会议技术计划扩展摘要集，2018年8月，第1981–1985页。[48] N. Pham和W. Li，“用于地滚波衰减的物理约束深度学习，”《地球物理学》, 第87卷，第1期，第V15–V27页，2022年1月。[49] Y. Yuan、X. Si和Y. Zheng，“利用生成对抗网络进行地滚波衰减——利用GAN进行地滚波衰减，”《地球物理学》, 第85卷，第4期，第WA255–WA267页，2020年7月。[50]H. Ma、H. Yao、Y. Li和H. Wang，“用于沙漠地震噪声抑制的深度残差编码器–解码器网络，”*IEEE Geosci. RemoteSens. Lett.*, 第17卷，第3期，第529–533页，2020年3月。[51] Y. Zhao、Y. Li、X. Dong和B. Yang，“基于改进DnCNN的沙漠地震数据低频噪声抑制方法，”*IEEE Geosci. Remote Sens.Lett.*, 第16卷，第5期，第811–815页，2019年5月。[52]M. Abadi、P. Barham、J. Chen、Z. Chen、A. Davis，J. Dean、M. Devin、S. Ghemawat、G. Irving、M. Isard等，《TensorFlow：一个大规模机器学习系统》，载于第 *12* 届 *USENIX* 操作系统设计与实现研讨会（*OSDI*）论文集，2016 年 11 月，第 265–283 页。[53] G. E. Hinton 和 R. Zemel，《自编码器、最小描述长度与亥姆霍兹自由能》，载于神经信息处理系统进展会议（*NeurIPS*）论文集，1993 年 12 月，第 6 卷，第 3–10 页。[54] S. Guo、Z. Yan、K. Zhang、W. Zuo 和 L. Zhang，《迈向真实照片的卷积盲去噪》，载于*IEEE/CVF* 计算机视觉与模式识别会议（*CVPR*）论文集，2019 年 6 月，第 1712–1722 页。[55] Y. Chen、W. Huang、D. Zhang 和 W. Chen，《用于改进秩约简三维地震数据去噪与重建的开源 MATLAB 代码包》，计算机与地球科学，第 95 卷，第 59–66 页，2016 年 10 月。