3DInvNet：一种基于深度学习的三维探地雷达数据反演方法

戴琪琪、李宜辉（IEEE 高级会员）、孙海涵、欧金妮薇、Mohamed Lokman Mohd Yusof 和 Abdulkadir C. Yucel（IEEE 高级会员）

摘要—从探地雷达（GPR）数据重建三维介电常数图，对于绘制地下环境图和检查地下结构完整性具有重要意义。传统的迭代三维重建算法存在强非线性、病态性和计算成本高等问题。为解决这些问题，本文提出一种名为3DInvNet的三维深度学习方案，用于从探地雷达 C扫描重建三维介电常数图。该方案采用具有特征注意力机制的先验三维卷积神经网络，以抑制由地下非均质土壤环境引起的C扫描噪声。随后，设计了一种包含多尺度特征聚合模块的三维U形编码器-解码器网络，以建立从去噪后的C扫描到三维介电常数图的最优逆映射。此外，采用三步分离学习策略对网络进行预训练和微调。该方案应用于数值模拟和实测数据。定量和定性结果表明，**该网络具备**对探地雷达 C扫描进行去噪以及重建地下目标三维介电常数图的能力，并具有良好的泛化能力和鲁棒性。

索引词— 深度学习、去噪、探地雷达 (GPR)、介电常数图、三维重建

I. 引言

G探地雷达（GPR）凭借成本低、无损检测的特点，已广泛应用于地球物理勘探和土木工程领域。根据探地雷达获取的数据重建的三维介电常数图，对于了解地下目标的信息十分有用，例如其形状、尺寸、位置、方向和介电常数。这些信息对于地下目标识别、地球物理缺陷检测，以及以下对象的健康监测都大有裨益：

本研究得到新加坡国家发展部研究基金和新加坡国家公园局的支持（通讯作者：李宜辉；Abdulkadir C. Yucel）。Q. Dai、Y. H. Lee 和 A. C. Yucel 隶属于新加坡南洋理工大学电气与电子工程学院，邮编 639798（电子邮箱：daiq0004@e.ntu.edu.sg，{eyhlee, acyucel}@ntu.edu.sg）。H. -H. Sun 隶属于新加坡南洋理工大学机械与航空航天工程学院，以及澳大利亚塔斯马尼亚大学工程学院（电子邮箱：haihan.sun199403@gmail.com）。G. Ow 和 M. L. M. Yusof 隶属于新加坡国家公园局，邮编 259569（电子邮箱：{genevieve_ow, mohamed_lokman_mohd_yusof }@nparks.gov.sg）。

地下管线设施和生物体（例如树根）[1]。

有几种传统算法可用于根据探地雷达 C扫描重建三维地下图像，例如反投影算法（BPA）[2], 基尔霍夫偏移 [3], 和逆时偏移（RTM）[4]。然而，这些偏移算法只能近似确定目标的位置和形状，却无法重建其介电常数图，而介电常数信息对于目标识别和健康检测至关重要。为了重建地下介电常数图， [1]，[5]，[6]提出了一种全波形反演（FWI）算法。该算法通过非线性最小二乘优化过程，从探地雷达数据中重建地下结构的介电常数图。然而，由于处理三维探地雷达数据的计算成本较高，目前大多数全波形反演研究仅关注二维情况。迄今为止，仅有两项研究将三维全波形反演应用于根据探地雷达数据重建地下介电常数或电导率分布。在[7], 中，采用了一种结合全变分（TV）正则化和海森矩阵近似的全波形反演算法。生成一个小型三维区域的三维介电常数图大约需要一周时间。为了提高三维全波形反演的效率，[8]提出了一种改进全变分（MTV）正则化方案。然而，反演过程仍需约16小时才能生成一幅三维介电常数图。此外，在应用全波形反演算法时，仅考虑了几何形状简单且规则的地下目标。全波形反演算法较高的计算复杂度和有限的泛化能力极大地限制了其在复杂三维地下场景重建中的应用。

近年来，深度学习技术已被用于解决逆散射和电磁（EM）成像问题 [9]-[11]。这些研究采用了全数据驱动和物理辅助学习等方法，证明了深度学习在电磁成像领域的有效性。例如，在 [12], 中，为了根据散射场重建相对介电常数分布，研究人员采用了 U-Net 架构[13] ，并引入了三种不同的方案，包括直接反演、反向传播和主导电流方案。在 [14], 中，研究人员建立了深度神经网络（DNN）架构与非线性电磁逆散射迭代方法之间的联系，随后使用三个级联卷积神经网络（CNN）处理输入的复值图像，以确定研究区域的介电常数图。在 [15], 中，一种复值深度

采用卷积编码器-解码器网络从接收到的散射场数据中提取特征片段，并反演散射体的介电常数对比度。结合畸变 Born 方案对非均匀背景中的未知物体进行粗略成像，在 [16] 中精心设计了生成对抗网络（GAN），以输出精细的介电常数图。这些研究证明，深度学习技术在求解一般电磁逆问题方面具有很高的效率和准确性。

人们进一步研究了基于深度学习的方法在探地雷达中的应用 [17]-[18], ，尤其是用于探地雷达逆问题，例如探地雷达图像分类、特征识别、地下目标检测以及目标属性恢复 [19]-[23]。这些技术已展现出学习输入探地雷达数据与所需输出之间非线性映射的能力。研究人员已探索使用深度神经网络从探地雷达 B 扫描重建二维地下介电常数分布图 [24]-[27]。在 [24], 中，介绍了三种深度神经网络，包括编码器-解码器 [28], 、U-Net [13], 和条件生成对抗网络 [29], , 用于从 B 扫描重建二维地下介电常数分布图。在 [25], 中，采用带有实例归一化的 U-Net 架构，从探地雷达数据生成二维介电常数分布。为解决从 B 扫描重建隧道衬砌复杂介电常数图所面临的挑战，[26] 提出了一种名为 GPRInvNet 的逐道编码器-解码器网络。在此基础上，[27] 提出了改进的介电常数反演网络 PINet，以解决衰减引起的问题。然而，上述所有研究都只关注二维域介电常数图的恢复，因此只能提供地下场景的剖面信息。尤其当地下目标较为复杂时，无法获取目标的方向和形状等信息，且仅凭一个横截面不足以生成目标的完整轮廓。此外，用于二维反演的全波仿真无法捕捉三维现实世界中的实际电磁现象。在二维建模中，虽然假设散射沿一个坐标方向保持不变，但作为激励使用的线源被假设为无限长，且极化只能是线性极化。然而，在实际的三维建模中并非如此，二维建模所得结果可能与三维建模的实际响应截然不同 [7]。通过三维全波仿真重建三维介电常数图，可以克服二维重建的局限性。但这无法通过上述研究直接实现。因此，亟需研究用于重建三维地下介电常数分布图的深度学习方法。

地下介电常数图重建的一项主要挑战，是探地雷达数据中的直接耦合、地面反射和环境噪声等噪声模式与目标反射相互干扰。近年来，人们提出了许多用于探地雷达数据去噪的传统方法，包括均值减法 [30]-[32], 奇异值分解（SVD）[33]-[34], 主成分分析（PCA）[35]-[36], 以及非负矩阵分解（NMF）[37]-[38]。然而，这些信号的去噪性能当场强或噪声模式的形状与目标反射特征相似时，处理算法在复杂的非均质环境中的性能会显著下降。为提高探地雷达数据去噪的准确性和效率，已有研究提出了基于深度学习的方案 [23], [39]-[43]。在 [23], [39], 和 [40],中，深度神经网络用于识别包含双曲线的感兴趣区域（RoIs），或生成双曲线二值掩膜以突出目标反射区域。在 [41]-[43], 2中，采用了编码器-解码器网络和 U-Net 来预测仅包含目标反射的无杂波 B扫描图像。实验结果表明，深度学习技术在消除环境噪声并保留目标反射方面效果显著。[42]-[43] 中的对比研究证明，在探地雷达数据去噪方面，基于深度学习的方法优于传统算法。

在这项工作中，我们提出了一种名为 3DInvNet 的深度学习方案，该方案在进行先验去噪后，根据探地雷达 C扫描重建地下三维介电常数图。据我们所知，这是首项通过深度学习方案基于探地雷达数据进行三维地下场景重建的工作。与现有的基于深度学习的探地雷达检测/二维重建方案相比，我们的方案的主要贡献总结如下。

1) 先前提出了一种三维去噪网络，称为去噪器，旨在抑制非均质土壤环境导致的探地雷达 C扫描中的噪声。与 [41]-[43], 中复杂的网络不同，去噪器采用一个小型三维卷积神经网络，并结合残差学习和特征注意力机制，有效提取含噪C扫描中地下目标的反射特征。 2) 去噪后，设计了一种三维U形编码器-解码器网络，称为反演器，用于将去噪器预测的去噪后的C扫描映射为地下三维介电常数图。不同于在 [44], 中使用单尺度传统卷积的方法，本文提出多尺度特征聚合模块，以提取具有不同属性的多个目标的特征。 3) 采用三步分离学习策略进行预-

训练并微调去噪器和反演器。

测试结果清楚地表明，所提出的方案能够对C扫描进行去噪，并以极高的精度和效率重建三维介电常数图。对比结果表明，相较于使用含噪C扫描，使用去噪后的C扫描重建三维介电常数图的精度有所提升。在新场景下的测试结果表明，所提出的方案具有良好的泛化能力和鲁棒性。

本文其余部分安排如下：第二节介绍所提出的网络结构和学习策略。第三节通过仿真数据测试验证所提方法的有效性。第四节展示在新场景下的泛化能力和鲁棒性测试。第五节介绍实测数据测试。第六节给出讨论与结论。需要指出的是，为了区分标量、向量和矩阵，本文其余部分采用粗体小写字母表示一维数组（向量）（例如 **a**），粗体

大写字母表示二维数组（矩阵）（例如 $\mathbf{A}$），粗体欧几里得花体字母表示多维数组（张量）（例如 $\boldsymbol{\mathcal{A}}$），斜体小写字母表示标量（例如a），斜体大写字母表示张量的维度（例如 A），粗斜体大写字母表示算子（例如 $\boldsymbol{A}(\cdot)$）。

II. 方法

在探地雷达环境中，探地雷达系统将电磁波发射到地面中。地面，并接收地下目标反射的信号。如图1所示，探地雷达系统沿xy 平面上的平行测线移动后，即可获得三维C扫描。如果$\tilde{\boldsymbol{\mathcal{X}}}$ 是地下场景的三维介电常数图， $\boldsymbol{H}(\cdot)$表示对地下场景中的散射机制进行正向建模，而$\boldsymbol{\mathcal{Y}}$ 是得到的C-

扫描后，正问题可表示为 $\boldsymbol{\mathcal{Y}} = \boldsymbol{H}(\tilde{\boldsymbol{\mathcal{X}}})$。逆问题旨在根据 C扫描重建地下场景，其表示为

$$\tilde{\boldsymbol{\mathcal{X}}} = \boldsymbol{H}^{-1}(\boldsymbol{\mathcal{Y}}). \tag{1}$$

它将C扫描中的电磁信息转换为地下目标的介电常数图。3D该图是$\tilde{\boldsymbol{\mathcal{X}}}$ 的子集，在本文中表示为$\boldsymbol{\mathcal{X}}$。基于深度学习求解逆问题的目标是找到$\boldsymbol{\mathcal{Y}}$ 与$\boldsymbol{\mathcal{X}}$之间的最优逆映射关系$\boldsymbol{H}^{-1}(\cdot)$，该关系可由三维深度神经网络模型描述，随后将$\boldsymbol{\mathcal{Y}}$ 转换为

$\boldsymbol{\mathcal{X}}$，通过$\boldsymbol{H}^{-1}(\cdot)$实现。为克服环境噪声的干扰，我们提出了一种用于三维探地雷达数据反演的两阶段方案，称为3DInvNet。该方案包括一个三维去噪网络（去噪器），用于从输入的含噪C扫描 $\boldsymbol{\mathcal{Y}}$ 中获得去噪后的C扫描$\boldsymbol{\mathcal{Y}}_{\boldsymbol{D}}$；以及一个三维反演网络（反演器），用于根据$\boldsymbol{\mathcal{Y}}_{\boldsymbol{D}}$重建$\boldsymbol{\mathcal{X}}$。

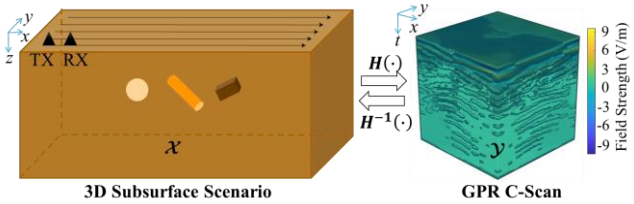


图1. 三维探地雷达数据反演的任务定义。

A. 去噪器

将[41]-[43] 中的二维深度神经网络应用于探地雷达B扫描去噪时，其在三维场景中的一个局限是三维C扫描图像处理的计算负担较重。为缓解这一问题，采用一种带有特征注意力机制[45], 的小型三维卷积神经网络，称为去噪器，以对非均质土壤条件下的C扫描进行去噪。如图2(a)所示，去噪器由三个阶段组成：i）初始特征提取，ii）特征学习，以及iii）重建。首先，初始特征提取模块包含一个 3×3×3 卷积层，其通道数为 C_1，步幅为1×1×1，通过$\boldsymbol{\mathcal{Y}} \in \mathrm{R}^{D\times H\times W}$ 从输入的含噪C扫描中提取初始特征$\boldsymbol{\mathcal{F}}_0 \in \mathrm{R}^{C_1\times D\times H\times W}$，方式为

$$\boldsymbol{\mathcal{F}}_0 = \boldsymbol{\delta}\big(\boldsymbol{K}(\boldsymbol{\mathcal{Y}})\big), \tag{2}$$

其中 D、 H 和 W 沿主轴方向，即 depth, height, and width 的 spatial dimensions。$\boldsymbol{K}(\cdot)$表示三维卷积层。$\boldsymbol{\delta}(\cdot)$ 表示修正线性单元（ReLU）激活函数，以确保网络具有较强的非线性。

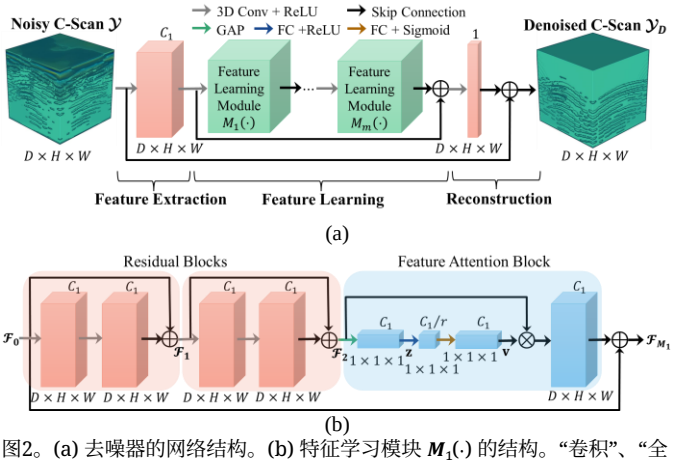


图2。(a) 去噪器的网络结构。(b) 特征学习模块 $\boldsymbol{M}_1(\cdot)$ 的结构。“卷积”、“全局平均池化”和“全连接层”分别表示卷积层、全局平均池化和全连接层。

接下来，使用m 特征学习模块 $\boldsymbol{M}(\cdot)$ 来挖掘提取出的初始特征 $\boldsymbol{\mathcal{F}}_0$中的关键信息。如图2(b)所示，每个特征学习模块由两个残差块和一个特征注意力块组成。每个残差块包含两个带有恒等映射的3×3×3 卷积层，以避免梯度爆炸[46]。残差块的运算表示为

$$\boldsymbol{\mathcal{F}}_1 = \boldsymbol{\delta}\left(\boldsymbol{K}\left(\boldsymbol{\delta}\big(\boldsymbol{K}(\boldsymbol{\mathcal{F}}_0)\big)\right) + \boldsymbol{\mathcal{F}}_0\right) \tag{3}$$

$$\boldsymbol{\mathcal{F}}_2 = \boldsymbol{\delta}\left(\boldsymbol{K}\left(\boldsymbol{\delta}\big(\boldsymbol{K}(\boldsymbol{\mathcal{F}}_1)\big)\right) + \boldsymbol{\mathcal{F}}_1\right). \tag{4}$$

残差 k 旨在增强 $\boldsymbol{\mathcal{F}}_2 \in \mathrm{R}^{C_1\times D\times H\times W}$ 中重要特征的权重。具体而言，首先应用全局平均池化，以通过以下方式生成通道统计量 $\mathbf{z} \in \mathrm{R}^{C_1\times 1\times 1\times 1}$ 。

$$\mathbf{z}(c) = \frac{1}{D\times H\times W}\sum_{d=1}^{D}\sum_{h=1}^{H}\sum_{w=1}^{W}\boldsymbol{\mathcal{F}}_{2\,c,d,h,w}, \tag{5}$$

其中，c 是沿主轴的 index, and l, 索引和 为捕获通道间依赖关系，采用一种简单的门控机制 [47]，该机制由两个全连接层 $\boldsymbol{F}_{\mathbf{W}}(\cdot)$ 和 Sigmoid函数 $\boldsymbol{\sigma}(\cdot)$ 组成。注意力向量 $\mathbf{v} \in \mathrm{R}^{C_1\times 1\times 1\times 1}$ 的计算方式为

$$\mathbf{v} = \boldsymbol{\sigma}\left(\boldsymbol{F}_{\mathbf{W}_1}\left(\boldsymbol{\delta}\left(\boldsymbol{F}_{\mathbf{W}_2}(\mathbf{z})\right)\right)\right), \tag{6}$$

其中，$\mathbf{W}_1 \in \mathrm{R}^{C_1\times C_1/r}$ 和 $\mathbf{W}_2 \in \mathrm{R}^{C_1/r\times C_1}$ 是权重矩阵，r 是用于限制模型复杂度的缩减比率。随后，通过逐通道乘法使用 $\mathbf{v} \in \mathrm{R}^{C_1\times 1\times 1\times 1}$ 对 $\boldsymbol{\mathcal{F}}_2 \in \mathrm{R}^{C_1\times D\times H\times W}$ 进行重缩放，得到经注意力加权的特征图，其维度与 $\boldsymbol{\mathcal{F}}_2$ 相同。通过残差连接，第一个特征学习模块 $\boldsymbol{M}_1(\cdot)$ 的输出特征图 $\boldsymbol{\mathcal{F}}_{\boldsymbol{M}_1} \in \mathrm{R}^{C_1\times D\times H\times W}$ 计算如下

$$\boldsymbol{\mathcal{F}}_{\boldsymbol{M}_1} = \mathbf{v}\times\boldsymbol{\mathcal{F}}_2 + \boldsymbol{\mathcal{F}}_0. \tag{7}$$

如图所示，特征 $\boldsymbol{\mathcal{F}}_{\boldsymbol{M}_m}(a) \in \mathrm{R}^{C_1\times D\times H\times W}$ 表示为 the final feature

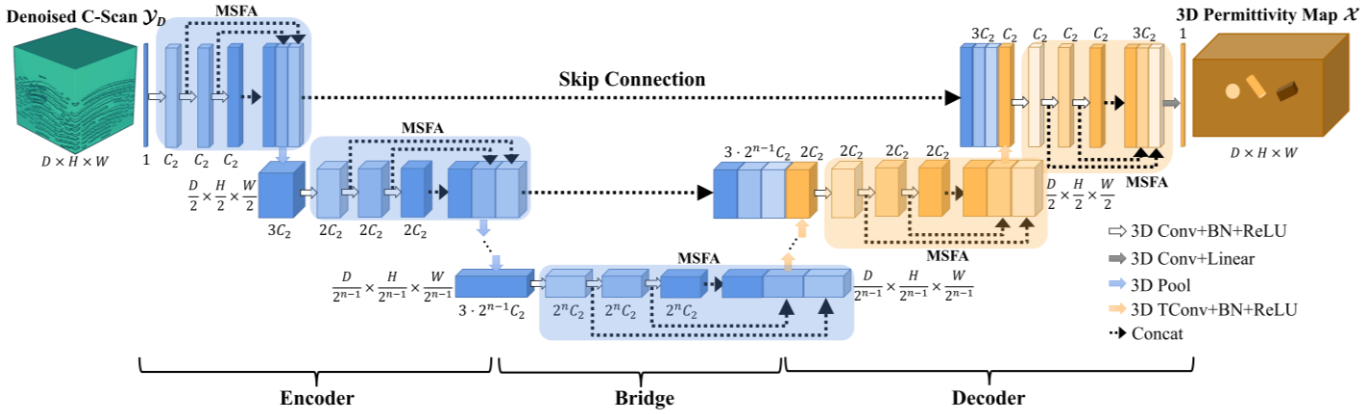


图 3. 反演器的网络结构。“Conv”、“BN”、“ReLU”、“Linear”、“Pool”、“TConv”、“Concat”和“MSFA”分别表示卷积层、批归一化、修正线性单元激活、线性激活、最大池化层、转置卷积层、拼接操作和多尺度特征聚合模块。

$$\mathcal{F}_{M_m} = \boldsymbol{M}_m\left(\boldsymbol{M}_{m-1}\left(\cdots\left(\boldsymbol{M}_1(\mathcal{F}_0)\right)\right)\right). \tag{8}$$

最后，as shown in Fig. 2(a), a reconstruction module，通过以下方式根据学习到的特征表示重建去噪后的C扫描 $\mathcal{Y}_D \in \mathrm{R}^{D\times H\times W}$

$$\mathcal{Y}_D = \boldsymbol{\delta}\left(\mathcal{Y} + \boldsymbol{K}\left(\mathcal{F}_0 + \mathcal{F}_{M_m}\right)\right). \tag{9}$$

B. 反演器

完成前述去噪后，设计了一种名为 Inverter 的三维反演网络，用于根据去噪后的 C 扫描重建三维地下介电常数图。如图 3 所示，Inverter 基于 3D U-Net [44], 构建，其结构由带有跳跃连接的编码器和解码器组成。在传统结构中，[44], 每个编码块或解码块都包含两个连续的单尺度卷积层。为了提取不同尺度的地下目标特征，在每个编码块和解码块中提出了一种多尺度特征聚合（MSFA）机制。每个 MSFA 模块包含三个3×3×3 步幅为1×1×1的卷积层。增加卷积层数量旨在：1）加深网络，以增强其将 C 扫描映射为三维介电常数图的非线性映射表征能力；2）提取目标反射的更大尺度特征。MSFA 模块中第f个卷积层的输出特征图$\mathcal{F}_{r_f}$ 的感受野（RF）大小由[48]计算得出

$$r_f = r_{f-1} + \left(k_f - 1\right) \times \prod_{i=1}^{f-1} s_i. \tag{10}$$

k 和 s 分别为固定值 1 和 1。随后，不同的感受野大小会产生多个尺度 [48]。如图 3 所示，当通道数为 C_2时，我们在每个编码块和解码块中沿通道维度拼接

$r_1 \times r_1$ $\mathcal{F}_{r_2} \in$ $\mathcal{F}_{r_1} \in$ $C_2\times D\times H\times W$ $r_1 \times \mathrm{R}$ $r_2 \times r_2 \times r_2$

$C_2\times D\times H\times W$ （感受野大小为 ）、R（感受野大小为 ）以及 $\mathcal{F}_{r_3} \in$ $\mathrm{R}^{C_2\times D\times H\times W}$ （感受野大小为 $r_3 \times r_3 \times r_3$ ）。融合后的多尺度特征图 $\mathcal{F}_{r_{1\sim3}} \in \mathrm{R}^{3C_2\times D\times H\times W}$ 表示为

$$\mathcal{F}_{r_{1\sim3}} = Concat\left(\mathcal{F}_{r_1}, \mathcal{F}_{r_2}, \mathcal{F}_{r_3}\right). \tag{11}$$

不同于通过并行引入大量额外卷积层（这会大幅增加 [41], 中的计算成本），所提出的 MSFA 模块直接结合来自具有不同感受野的连续卷积层的特征图，从而能够高效地捕获探地雷达 C扫描中由地下目标各种属性所产生的多尺度反射模式特征。

如图 3 所示，编码器由 n 个编码块组成。每个编码块由一个 MSFA 模块和一个步幅为 2×2×2 的 2×2×2 最大池化层组成。MSFA 模块从输入的 C扫描中提取物体特征，并在经过池化层下采样后获得这些特征的压缩表示。n个编码块的通道数设置为 $[C_2, 2C_2, \cdots, 2^{n-1}C_2]$。在编码器之后，使用一个具有 2^nC_2 个通道的 MSFA 模块连接编码器和解码器。对称的解码器包括 n 个解码块。每个解码块包括一个步幅为 2×2×2 的2×2×2 转置卷积层，用于上采样，以及一个 MSFA 模块，用于根据物体特征的压缩表示重建介电常数图。所有转置卷积层以及 MSFA 模块中的卷积层后面都接有批归一化（BN）和 ReLU 激活。通道数对称地设置为 $[2^{n-1}C_2, 2^{n-2}C_2$ 、 …、 $C_2]$。通过拼接编码器中分辨率相同的所有卷积层来实现跳跃连接，这可以提供高分辨率特征，并补偿编码器下采样过程中造成的信息损失。在最后阶段，一个步幅为 1×1×1 的3×3×3 单通道卷积层后接线性激活，输出所需的三维介电常数图。

C. 学习策略

步骤 1：预训练去噪器。使用大量多样化的含噪和无噪声C扫描对去噪器进行预训练。将预测的去噪后的C扫描 $\mathcal{Y}_D$ 与真实值 $\widehat{\mathcal{Y}}_D$ 之间的均方误差（ MSE ）用作损失函数：

$$\boldsymbol{L}_1(\boldsymbol{\mathcal{Y}_D}, \widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}) = \frac{1}{D \cdot H \cdot W} \sum_{d=1}^{D} \sum_{h=1}^{H} \sum_{w=1}^{W} \left(\boldsymbol{\mathcal{Y}}_{\boldsymbol{D}_{d,h,w}} - \widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}_{d,h,w}} \right)^2. \quad (12)$$

采用 Adam优化器 [49] 更新网络参数，以最小化去噪损失。work

步骤2：预训练反演器。在预训练阶段，将无噪声C扫描的真实值 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$ 用作反演器的输入数据。在无噪声C扫描的指导下，反演器能够准确捕捉目标的反射特征，同时克服非均质土壤反射所造成的噪声模式干扰。预测的介电常数图 $\boldsymbol{\mathcal{X}}$ 与真实值 $\widehat{\boldsymbol{\mathcal{X}}}$ 之间的平均绝对误差（MAE）用作损失函数：

$$\boldsymbol{L}_2(\boldsymbol{\mathcal{X}}, \widehat{\boldsymbol{\mathcal{X}}}) = \frac{1}{D \cdot H \cdot W} \sum_{d=1}^{D} \sum_{h=1}^{H} \sum_{w=1}^{W} \left| \boldsymbol{\mathcal{X}}_{d,h,w} - \widehat{\boldsymbol{\mathcal{X}}}_{d,h,w} \right|, \quad (13)$$

。反演器的训练通过Adam优化器最小化反演损失。随后在测试阶段，将从去噪器获得的去噪后的C扫描 $\boldsymbol{\mathcal{Y}}_{\boldsymbol{D}}$输入反演器，并重建相应的三维介电常数图 $\boldsymbol{\mathcal{X}}$。

步骤 3：微调预训练网络。为增强网络在与预训练数据集差异很大的新场景中的泛化能力，通过微调步骤 1–2 中获得的预训练网络，进一步采用迁移学习 [50] 。首先，生成一小批包含新场景的额外数据。其次，将预训练网络设为初始状态，并使用新的训练数据集，根据损失函数 (12) 和 (13) 进一步更新网络参数，直至收敛。最后，经过微调且迁移了数据域的网络能够预测去噪后的 C扫描，并为新场景重建三维介电常数图。

III. 数值实验

A. 数据集生成

数据集 I。为了训练和测试所提出的网络，我们生成了一个涵盖多种地下场景的数据集。每个数据集都包含一个含噪C扫描 $\boldsymbol{\mathcal{Y}}$、一个无噪声C扫描 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{d}}$，以及相应的三维介电常数图 $\widehat{\boldsymbol{\mathcal{X}}}$。数值数据由开源三维有限差分时域模拟器 gprMax [51]-[52] 生成。如图 1 所示，考虑一个 1×1×0.26 m^3 的土壤环境。分辨率为 2.5×2.5×2.5 mm^3。土壤的相对介电常数和电导率分别设为 4 和 0。赫兹偶极子发射中心频率为 1 GHz 的 Ricker信号。时间窗设为 15 ns。使用一个距离偶极子 10 cm 的探头采集反射信号。偶极子和探头均位于地面上方 2 cm 处。扫描轨迹如图1中的黑线所示。共有 12 条扫描线，每条线上有 10 个等间距扫描点。地下目标的形状随机选为圆柱体、球体或箱体。每个目标的介电常数从 [8, 27]范围内随机选取。对于圆柱体，其半径和长度分别从区间 [0.02, 0.05]m ([0.29, 0.73] 波长)和 [0.01, 0.33] m ([0.15, 4.84] 中随机选取波长)中随机选取。对于球体，其半径从 [0.02, 0.05] m ([0.29, 0.73]波长)中随机选取。对于箱体，所有边长均从 [0.04, 0.1] m ([0.59, 1.47] 波长)中随机选取。需要注意的是，波长根据 2.2 GHz 的最高有效频率计算。地下目标可放置在土壤中央、范围为 0.4×0.4×0.26 m^3的区域内，以确保形成完整的双曲线图样。对模拟得到的C扫描进行零时刻校正和均值减法 [32] ，以去除直接耦合信号和地面反射，然后将其用作无噪声C扫描的真值 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$。

为模拟异质土壤反射造成的环境噪声，采用三维 Peplinski 混合模型 [53]-[54] 构建不含任何物体的土壤环境。土壤属性设为：砂分数 0.6、黏土分数 0.4、体积密度 2 g/cm^3, ，砂粒密度为 2.66 g/cm^3。将 50 种不同材料（由 50 个 Debye 函数描述，含水体积分数范围为 0.1% 至 10%）随机分布在土壤中，得到相对介电常数范围 [3.63, 7.42] 以及电导率范围[0.01, 0.05] S/m。为增加噪声模式的多样性，生成十种随机非均质分布，模拟得到的 C扫描仅包含环境噪声。经零时刻校正和均值减法 [32], 后，将仅含噪声的 C扫描添加到无噪声C扫描 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$ 中，形成合成的含噪C扫描 $\boldsymbol{\mathcal{Y}}$。最后，生成 5850 组 [$\boldsymbol{\mathcal{Y}}$, $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$, $\widehat{\boldsymbol{\mathcal{X}}}$] （1950 个单目标场景和 3900 个双目标场景）用于预训练，并生成 150 组（50 个单目标场景和 100 个双目标场景）用于测试。

数据集 II。为了将所提出的方法进一步应用于非均质场景，与数据集 I 中直接相加的方式不同，目标被埋入非均质土壤中，并在 xy 平面上进行探地雷达扫描，以获取含噪 C扫描 $\boldsymbol{\mathcal{Y}}$。需要注意的是，非均质土壤的随机分布也是全新的。通过从含噪 C扫描中减去仅含噪声的 C扫描，得到真实的无噪声 C扫描 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$ 。真实介电常数图中的背景介电常数设为 5.72，即非均质土壤模型中 50 种材料的平均相对介电常数。通过随机选择地下目标的属性，生成 285 组 [$\boldsymbol{\mathcal{Y}}$, $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$, $\widehat{\boldsymbol{\mathcal{X}}}$] （95 个单目标场景和 190 个双目标场景），用于微调预训练的去噪器和反演器；另生成 15 组（5 个单目标场景和 10 个双目标场景）用于测试。

B. 实现细节

所提出的方案基于 PyTorch [55] 实现，并在 NVIDIA GeForce RTX 3090 图形处理器上运行。每个 C扫描都被归一化到 [0, 1]范围。所有 C扫描和介电常数图都调整为 128×128×128大小。数据集 I 中含噪C扫描 $\boldsymbol{\mathcal{Y}}$ 和无噪声C扫描 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$ 用于根据 (12) 预训练去噪器。数据集 I 中的无噪声C扫描 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$ 和三维介电常数图 $\widehat{\boldsymbol{\mathcal{X}}}$ 用于根据 (13) 预

训练反演器。去噪器中的 m 和 C_1 分别设为 2 和 8。反演器中的 n 和 C_2 分别设为 4 和 8。学习率初始设为 0.001，若训练损失在上一训练轮次没有下降，则将其降低至当前值的 98%。去噪器和反演器分别预训练 100 个训练轮次。使用验证损失最低的模型测试性能。在测试阶段，将含噪C扫描 $\boldsymbol{\mathcal{Y}}$ 输入预训练的去噪器，再将去噪后的C扫描 $\boldsymbol{\mathcal{Y}_D}$ 输入预训练的反演器，最终输出三维介电常数图 $\boldsymbol{\mathcal{X}}$。以预训练的去噪器和反演器作为初始状态，使用数据集 II 进一步微调网络。为避免过拟合，学习率设为较小的 0.0006，若训练损失在上一训练轮次没有下降，则将其降低至当前值的 99%。

结构相似性（SSIM）、峰值信噪比（PSNR）、平均绝对误差（MAE）和平均相对误差（MRE）用于分析去噪器的去噪性能。SSIM、均方误差（MSE）、MAE 和平均绝对百分比误差（MAPE）用于评估反演器的反演性能。这些指标表示为：

$$SSIM(\mathcal{T},\mathcal{P}) = \frac{(2\mu_{\mathcal{P}}\mu_{\mathcal{T}} + c_1)(2\sigma_{\mathcal{PT}} + c_2)}{(\mu_{\mathcal{P}}^2 + \mu_{\mathcal{T}}^2 + c_1)(\sigma_{\mathcal{P}}^2 + \sigma_{\mathcal{T}}^2 + c_2)}, \quad (14)$$

$$MSE(\mathcal{T},\mathcal{P}) = \frac{1}{D\cdot H\cdot W}\sum_{d=1}^{D}\sum_{h=1}^{H}\sum_{w=1}^{W}\left(\mathcal{P}_{d,h,w} - \mathcal{T}_{d,h,w}\right)^2, \quad (15)$$

$$PSNR = 10\log_{10}\frac{1}{MSE(\mathcal{T},\mathcal{P})}, \quad (16)$$

$$MAE(\mathcal{T},\mathcal{P}) = \frac{1}{D\cdot H\cdot W}\sum_{d=1}^{D}\sum_{h=1}^{H}\sum_{w=1}^{W}\left|\mathcal{P}_{d,h,w} - \mathcal{T}_{d,h,w}\right|, \quad (17)$$

$$MRE(\mathcal{T},\mathcal{P}) = \frac{\sqrt{\sum_{d=1}^{D}\sum_{h=1}^{H}\sum_{w=1}^{W}\left(\mathcal{P}_{d,h,w} - \mathcal{T}_{d,h,w}\right)^2}}{\sqrt{\sum_{d=1}^{D}\sum_{h=1}^{H}\sum_{w=1}^{W}\mathcal{T}_{d,h,w}^2}}\cdot 100\%, \quad (18)$$

$$MAPE(\mathcal{T},\mathcal{P}) = \frac{1}{D\cdot H\cdot W}\sum_{d=1}^{D}\sum_{h=1}^{H}\sum_{w=1}^{W}\frac{|\mathcal{P}_{d,h,w} - \mathcal{T}_{d,h,w}|}{|\mathcal{T}_{d,h,w}|}\cdot 100\%. \quad (19)$$

在这些公式中，$\mathcal{P}$ 表示预测结果，即 h can 可以是去噪后的C扫描 $\boldsymbol{\mathcal{Y}_D}$，也可以是重建的三维介电常数图 $\boldsymbol{\mathcal{X}}$。$\mathcal{T}$ 表示真实值 $\widehat{\boldsymbol{\mathcal{Y}}}_{\boldsymbol{D}}$ 或 $\widehat{\boldsymbol{\mathcal{X}}}$。$\mu_{\mathcal{P}}$ 和 $\mu_{\mathcal{T}}$ 分别是 $\mathcal{P}$ 和 $\mathcal{T}$ 的均值。$\sigma_{\mathcal{P}}$ 和 $\sigma_{\mathcal{T}}$ 分别是 $\mathcal{P}$和 $\mathcal{T}$的方差。$\sigma_{\mathcal{PT}}$ 是 $\mathcal{P}$ 和 $\mathcal{T}$ 的协方差。$c_1 = (0.01i)^2$ 和 $c_2 = (0.03i)^2$ 是两个变量，其中 i 是图像像素的动态范围。计算所有测试样本各项指标的平均值，以评估性能。

C. 结果分析

1) 定量结果：3D 去噪性能的评估指标列于表 I 中。对于数据集 I 中含有额外噪声的测试数据，经过充分训练的去噪器能够获得较高的结构相似性指数（SSIM）和峰值信噪比（PSNR），以及较低的平均绝对误差（MAE）和平均相对误差（MRE）。对于数据集 II 中模拟的含噪数据，使用微调后的网络，仍然能够实现较高的去噪精度。尽管数据集 II 的 C扫描中的反射模式与数据集 I 中的不同，但迁移学习能够使经过数据集 I 预训练的网络适应新的数据集 II，从而有效提高网络的泛化能力。

表 I 数据集 I 和 II 上的去噪评估指标

数据集	# of 测试样本	结构相似性指数 ($\times10^{-2}$) (↑)	峰值信噪比（分贝）(↑)	平均绝对误差 ($\times10^{-4}$) (↓)	平均相对误差 (%) (↓)
I	150	99.96	62.99	3.78	0.14
II	15	99.98	66.95	2.08	0.09

数据集 I 和 II 上的反演评估指标（表 II）

组别	数量 I	数量 II	结构相似性指数 ($\times10^{-2}$) (↑) I	结构相似性指数 ($\times10^{-2}$) (↑) II	均方误差 ($\times10^{-2}$) (↓) I	均方误差 ($\times10^{-2}$) (↓) II	平均绝对误差 ($\times10^{-2}$) (↓) I	平均绝对误差 ($\times10^{-2}$) (↓) II	平均绝对百分比误差 (%) (↓) I	平均绝对百分比误差 (%) (↓) II
i	50	5	99.91	99.65	3.04	1.81	0.49	0.76	0.07	0.11
ii	67	6	99.73	99.26	8.90	8.06	1.10	1.64	0.15	0.20
iii	33	4	99.63	99.10	15.12	19.30	1.74	2.89	0.21	0.31
i、ii 和 iii	150	15	99.77	99.34	8.31	8.98		1.04	1.68	0.14	0.20

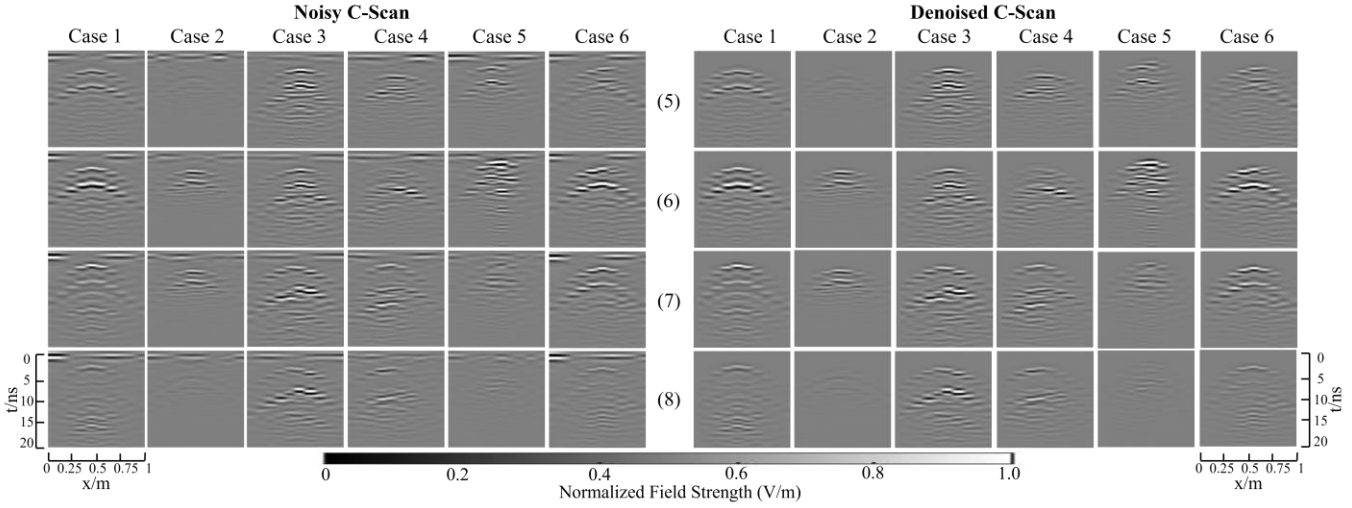


图 4. 去噪器使用数据集 I 预测的去噪后的C扫描成像结果。需要注意的是，每个C扫描都包含12个B扫描，并展示了具有主要反射特征的选定B扫描（6）—（8）。

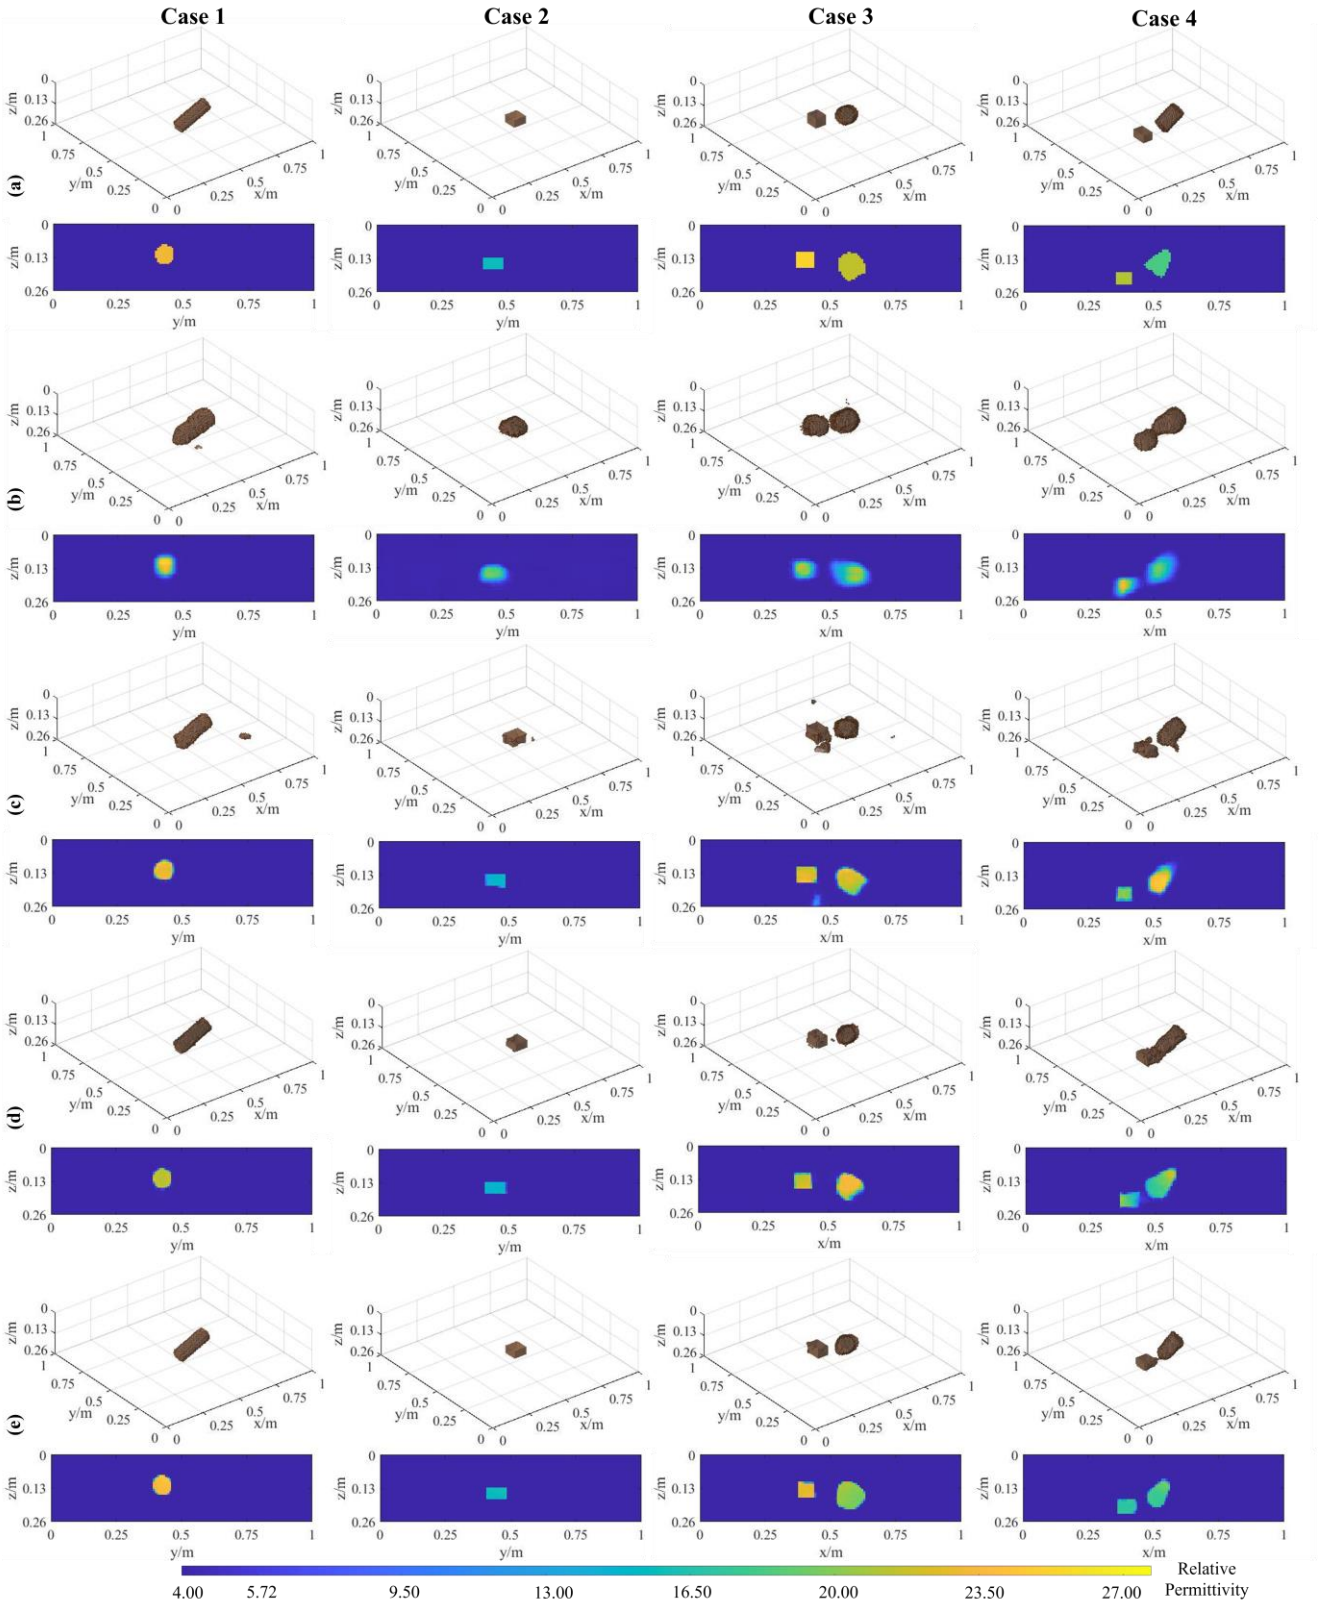


图 5. 所提出的 3DInvNet 对三维介电常数分布图的预测成像结果：数据集 I 中的单目标场景（案例 1-2）和双分离目标场景（案例 3-4）。其中，(a) 显示真实值，(b)-(e) 分别显示使用模型 (1)-(4) 得到的预测结果。

为了定量分析使用反演器进行三维介电常数图重建的准确性，我们将测试数据分为三组：i）单目标情况，ii）两个分离目标情况，以及 iii）双重叠目标情况。这些指标数据集 I 和 II 中三种类型数据的结果如表 II 所示。显然，对于数据集 I 和 II，单目标情况（组 i）的结构相似性指数、均方误差、平均绝对误差和平均绝对百分比误差均为最佳。对于双分离目标情况（组 ii），结构相似性指数较低，且

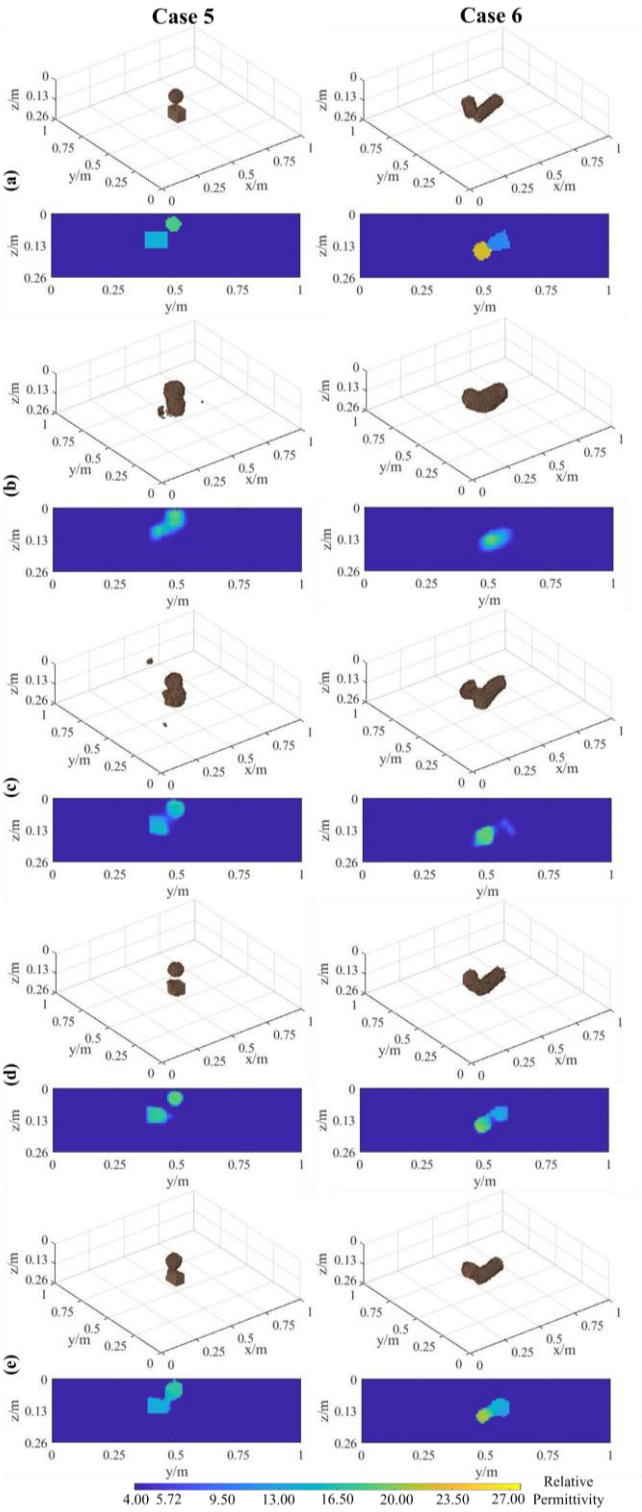


图 6. 数据集 I 中两个重叠目标场景（案例 5-6）的三维介电常数图成像结果。（a）显示真实值，（b）-（e）分别显示使用模型 (1)-(4) 得到的预测结果。

均方误差、平均绝对误差和平均绝对百分比误差均高于单目标情况。这种性能下降是因为包含两个目标的地下场景更加复杂，使得重建双目标介电常数图比单目标情况更具挑战性。在双重叠目标情况（组 iii）的 C扫描中，双曲线特征甚至这使问题更加复杂，增加了探地雷达数据反演的难度。这一点可由结构相似性指数降低，以及均方误差、平均绝对误差和平均绝对百分比误差升高体现。总体而言，数据集 I 中涵盖这三种情况的 150 个测试样本具有较高的结构相似性指数和较低的均方误差、平均绝对误差及平均绝对百分比误差，证明了反演器能够准确重建介电常数图。与数据集 I 的结果相比，数据集 II 中 15 个测试样本的平均结构相似性指数略低，平均均方误差、平均绝对误差和平均绝对百分比误差则较高，但仍令人满意。

在反演效率方面，所提出的方案优于经典迭代算法。例如，在最保守的情形下，全波形反演的一次迭代需要针对给定的介电常数图计算一次 C扫描；在我们的实验中，使用 GPU 平台上的模拟器 gprMax 完成这一计算需要 40 多分钟。此外，全波形反演通常需要多次迭代 [7]-[8], , 这显然非常耗时。然而，如表 III 所示，使用所提出的 3DInvNet（包括去噪器和反演器）生成一幅介电常数图，测试总耗时仅为 0.59 s，比全波形反演一次迭代所需时间至少少 4000 倍。尽管预训练和微调的计算开销较大，但只需进行一次。利用训练充分的网络，可以根据 C扫描近乎实时地预测三维介电常数图。

表 III 所提出的 3DInvNet 的计算时间

网络	参数数量 ($\times 2^{20}$)	预训练 时间（小时）	微调 时间（小时）	测试 时间（秒）
去噪器	0.01	27.50	2.05	0.20
反演器	3.06	58.33	3.70	0.39

2) 成像结果：对于数据集 I，去噪器得到的去噪后的 C扫描的成像结果如图 4 所示。案例 1-2、案例 3-4 和案例 5-6 分别展示了单目标场景（组 i）、两个分离目标场景（组 ii）和两个重叠目标场景（组 iii）。为清晰地显示去噪后的C扫描，绘制了选定的 B扫描[(5)-(8)]，这些B扫描包含每个 C扫描中的主要反射特征。与含噪C扫描相比，去噪后的C扫描中由非均质土壤环境反射引起的噪声得到了显著抑制。地下目标的反射模式被提取出来，并作为反演器的输入，以重建三维介电常数图。

如图 5–6 所示，将反演器 [图 5(e) 和图 6(e)] 预测的三维介电常数图与真实三维介电常数图 [图 5(a) 和图 6(a)]进行了比较。图中展示了三维几何结构和介电常数图的一个切片。在三维几何结构中，土壤环境设为透明色，目标以棕色显示。案例 1-2 展示了单目标场景的结果。预测的几何结构与真实值中的实际几何结构相符。为进一步评估介电常数图估计的准确性，我们比较了横截面上的介电常数图真实值与预测结果。可以看出，预测的介电常数图在数值和位置上都

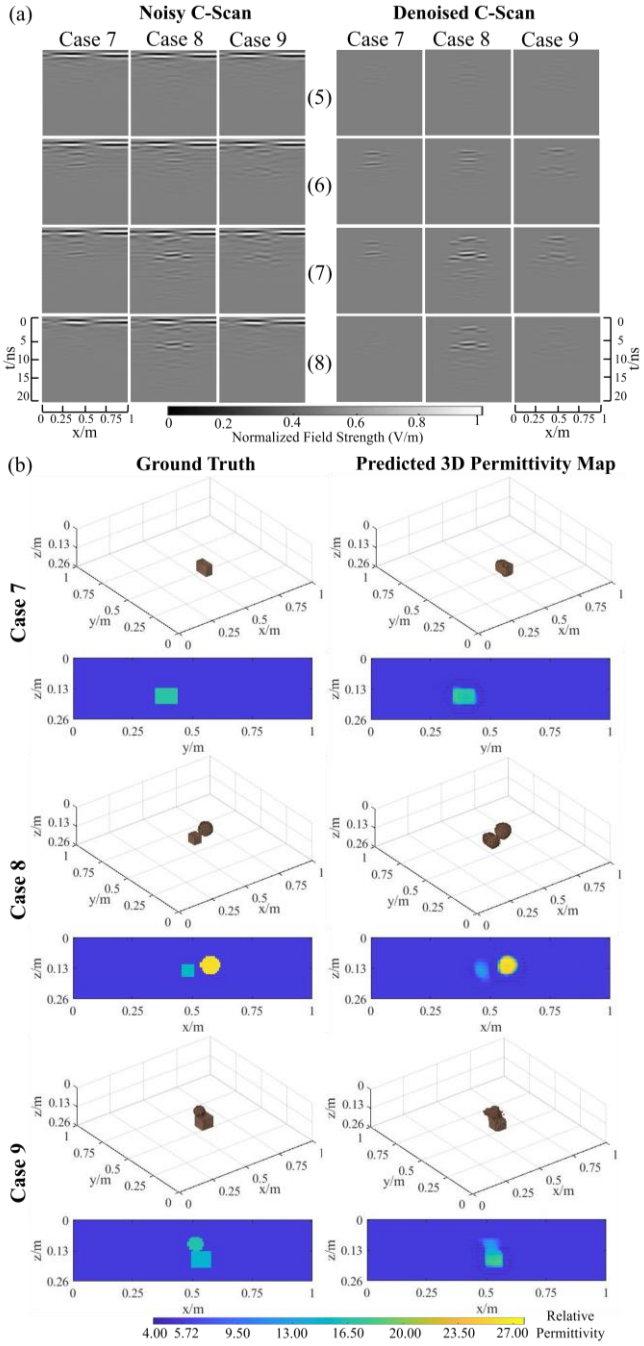


图 7. (a) 去噪器对数据集 II 进行处理后得到的去噪后的C扫描。(b) 反演器对数据集 II 进行处理后重建的三维介电常数图。

与真实值非常接近。案例 3-4 展示了两个分离目标案例的成像结果。与单目标场景相比，两个目标会在 C扫描中产生更复杂的特征，例如交错的双曲线和易造成误导的多次反射噪声。如图所示，所提出的方法仍然具有较高的准确性。尽管这些埋于土壤中的目标形状、位置、尺寸和介电常数值各不相同，但预测的三维几何结构和介电常数图的一个切片均与真实值相符。

为验证所提方案具有较高的分辨率性能，图6中的案例5–6展示了针对重叠及非均匀目标的反演结果。由于地下分布更加复杂，从C扫描重建三维介电常数图也更具挑战性。成像结果表明，图6(e)所示的预测介电常数图与图6(a)所示的真实值接近。尽管目标边缘存在一些偏差，仍然能够清晰识别地下目标。

为进一步展示真实模拟噪声数据上的成像性能，图 7 给出了数据集 II 的去噪和反演结果。图 7(a)-(b)分别展示了去噪后的C扫描和重建的三维介电常数图。案例 7-9 分别给出了组 i-iii 中的三个示例。如图所示，将去噪器得到的几乎没有杂波的去噪后C扫描作为反演器的输入，预测得到的三维介电常数图与真实值相符。尽管对于双目标案例而言，其结果不如使用大量数据训练的网络在数据集 I 上取得的结果精确，但仍能很好地识别地下目标。

D. 对比研究

为证明所提出的去噪器和反演器中 MSFA 模块的有效性，本文比较了数据集 I 上四种消融模型的反演指标，如表 IV 所示。四种模型包括：(1) 基线 3D U-Net，每个编码或解码块中包含三个连续卷积层；(2) 仅使用反演器；(3) 去噪器和基线 3D U-Net；(4) 所提出的模型。如表 I V 所示，模型 (1) 的表现最差，这是因为环境噪声干扰了介电常数重建过程，且网络的感受野有限。模型 (2) 通过 MSFA 模块增强了多尺度感知能力，性能有所提升，但仍受 C扫描中环境噪声的干扰。与模型 (1) 相比，模型 (3) 借助去噪器中的噪声抑制过程，重建精度显著提高。我们提出的模型（模型 (4)）表明，先用去噪器对 C扫描进行去噪，再用反演器重建介电常数图，能够获得最高精度。

表 IV 数据集 I 对比研究的反演指标比较

模型	去噪器	MSFA 模块	SSIM ($\times10^{-2}$) (↑)	MSE ($\times10^{-2}$) (↓)	MAE ($\times10^{-2}$) (↓)	MAPE (%) (↓)
(1)	×	×	99.06	14.12	2.72	0.46
(2)	×	✓	99.19	9.01	2.75	0.56
(3)	✓	×	99.55	9.32	1.92	0.36
(4)	✓	✓	**99.77**	**8.31**	**1.04**	**0.14**

数据集 I 中使用四种模型对单目标场景和双分离目标场景的成像结果分别如图 5(b)-(e) 所示，双重重叠目标场景的成像结果分别如图 6(b)-(e) 所示。可以观察到，如图 5(b) 和图 6(b) 所示，模型 (1) 的表现最差。重建目标的形状和介电常数值与其真实值相差甚远。如图 5(c) 和图 6(c) 所示，在不使用去噪器的情况下，模型 (2)

错误地将噪声模式识别为目标的反射，并在预测的三维介电常数图中重建出一些杂波。如图 5(d) 和图 6(d) 所示，由于引入了去噪器，使用模型 (3) 预测的介电常数图中的杂波有所减少，但地下目标的介电常数值和尺寸仍不准确，尤其是在图示案例 3–6 的双目标场景中。这是由于反演网络的多尺度特征提取能力有限。如图 5(e) 和图 6(e) 所示，使用模型 (4) 重建的三维介电常数图与真实值最为接近；该模型在反演器中结合了去噪器和 MSFA 模块，在目标的尺寸、位置、形状、方向和介电常数值方面都最为准确。

E. 超参数选择

为分析所提方案的超参数选择，表 V 对比了去噪器和反演器在不同参数下的评估指标。如表所示，对于去噪器，增加特征学习模块的数量 m并提高通道数 C_1 ，可以获得更准确的去噪结果。对于反演器，随着编码/解码模块的数量 n 和通道数 C_2 增加，重建精度也随之提高。这些改进得益于加深和加宽的网络能够更准确地描述输入图像与输出图像之间的映射关系。然而，增加这些超参数也会提高网络训练和测试的计算成本，尤其是在三维情况下。根据图 4-7 所示的成像结果，当去噪器的 m 和 C_1 分别达到 2 和 8 时，去噪后的C扫描能够清晰显示地下目标的反射特征；当反演器的 n和 C_2 分别达到 4 和 8 时，重建图能够达到较高的精度。因此，在本研究中选择这些超参数值，以平衡成像性能和计算负担。

表 V 使用不同超参数时数据集 I 上的评估指标

去噪器		结构相似性指数（×10⁻²）	峰值信噪比（分贝）	平均绝对误差（×10⁻⁴）	平均相对误差（%）
m	C_1	(↑)	(↑)	(↓)	(↓)
0	8	99.63	53.04	9.43	0.45
1	8	99.88	57.86	6.02	0.26
2	**8**	**99.96**	**62.99**	**3.78**	**0.14**
2	4	99.81	55.67	7.88	0.34
2	2	98.75	46.57	13.86	0.95
反演器		结构相似性指数 (×10⁻²)	均方误差 (×10⁻²)	平均绝对误差 (×10⁻²)	平均绝对百分比误差 (%)
n	C_2	(↑)	(↓)	(↓)	(↓)
2	8	98.23	10.67	3.67	0.75
3	8	98.93	7.77	2.96	0.61
4	**8**	**99.77**	**8.31**	**1.04**	**0.14**
4	4	99.63	8.50	1.54	0.24
4	2	99.65	9.77	1.65	0.26

表 VI 泛化和鲁棒性测试的评估指标

去噪器	结构相似性指数 (×10⁻²)	峰值信噪比（分贝）	平均绝对误差 (×10⁻⁴)	平均相对误差 (%)
	(↑)	(↑)	(↓)	(↓)
III	99.71	68.52	3.73	0.29
IV	99.99	69.97	1.41	0.07
V	99.97	60.26	5.15	0.20
反演器	结构相似性指数（×10⁻²）	均方误差（×10⁻²）	平均绝对误差（×10⁻²）	平均绝对百分比误差 (%)
	(↑)	(↓)	(↓)	(↓)
III	99.78	13.13	1.35	0.16
IV	98.97	13.10	2.82	0.35
V	98.68	9.33	3.31	0.66

IV. 泛化能力与鲁棒性测试

A. 零目标/三目标场景

数据集 III。为评估所提方案的泛化能力，采用预训练的去噪器和反演器对C扫描进行去噪，并恢复非均质土壤中埋有三个目标或未埋有任何目标的15种场景。需要指出的是，预训练数据集（数据集 I）仅包含单目标和双目标场景，因此，三目标和无目标场景对于去噪网络和反演网络而言都是全新的场景。土壤和目标的其他属性以及数据集生成流程均与数据集 I 相同。

测试结果。如表 VI（数据集III）所示，无需进行任何额外的重新训练或微调，去噪器和反演器在该测试数据集上的评估指标仍然令人满意。将去噪器输出的去噪后的C扫描作为反演器的输入，重建的三维介电常数图的成像结果如图8(a)所示。案例10展示了土壤中没有埋藏物体时的成像结果。重建的几何结构和单切片介电常数图均仅包含土壤环境。案例11和12分别对应存在三个具有不同随机属性的埋藏物体的情形。从三维几何结构和单切片介电常数图可以看出，预测结果与真实值吻合良好。尽管训练数据集未涵盖无物体和三个物体的情形，所提出的方法仍能以较高精度重建这些情形下的三维介电常数图。

B. 新的非均质土壤条件

数据集 IV。为评估所提方法从具有新噪声模式的 C扫描中重建地下场景的鲁棒性，构建了采用新非均质土壤条件的三维 Peplinski 混合模型。与数据集 II 中的土壤属性不同，砂分数、黏土分数、含水量范围、相对介电常数范围和电导率范围分别设置为 0.5、0.5, [0.1%、15%], [3.62、8.59],and [0.01 和 0.06] S/m。真实介电常数图中的背景介电常数设置为 6.34，即新土壤模型中 50 种材料的平均相对介电常数。使用新土壤模型生成了另外 285 个训练数据集，用于微调预训练网络，并生成了 15 组数据用于测试。实现细节与数据集 II 的相同。

测试结果。如表 VI（数据集 IV）所示，去噪器在高结构相似性指数和峰值信噪比、低平均绝对误差和平均相对误差方面的表现，表明其对新型非均质土壤环境下获取的 C扫描具有较高的去噪精度。随后

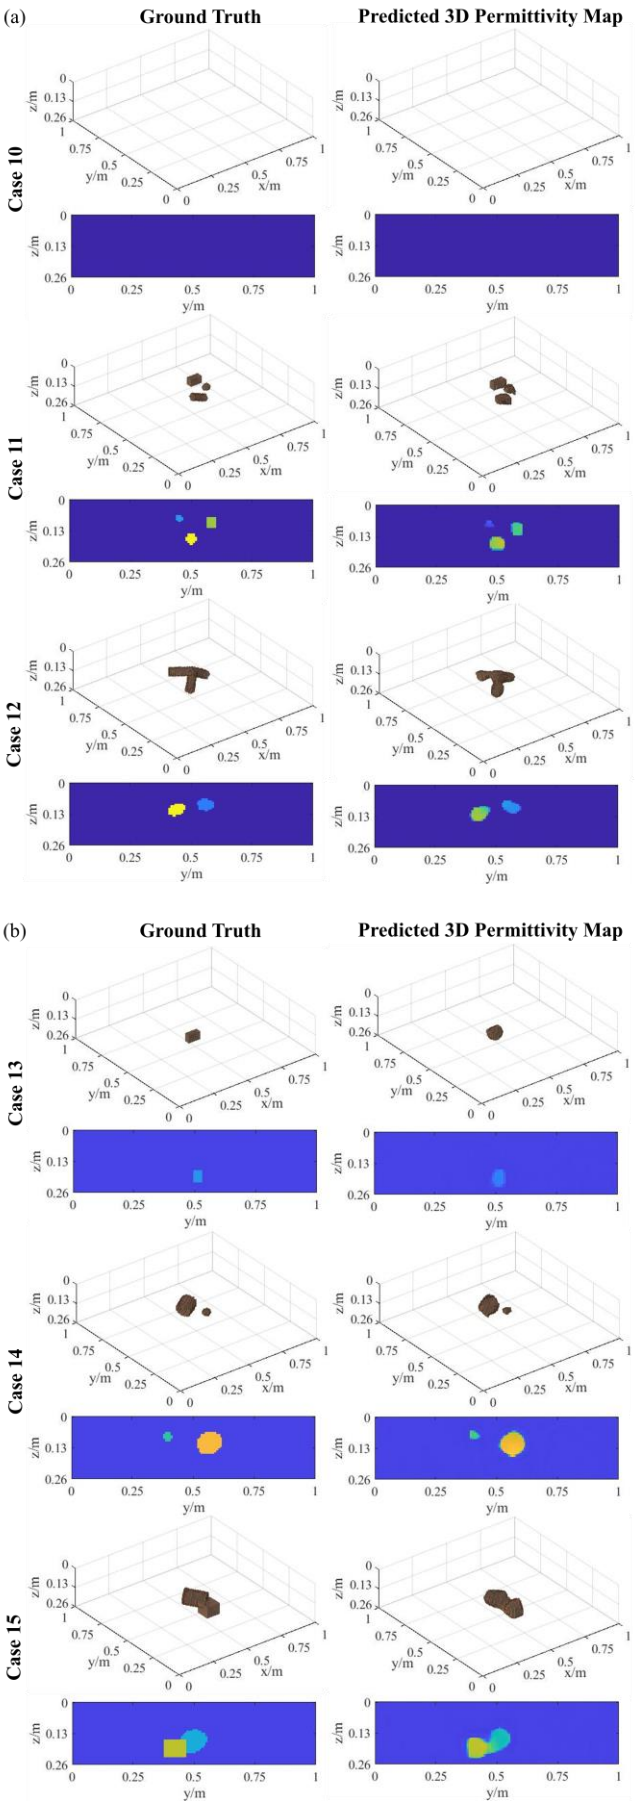


图8. 在（a）数据集III、（b）数据集 IV 和（c）数据集V 上进行泛化能力和鲁棒性测试的成像结果。

反演器能够从去噪后的 C扫描中重建三维介电常数图，且具有较高的结构相似性指数以及较低的均方误差、平均绝对误差和平均绝对百分比误差。图8(b)中的案例 13–15 展示了三种反演结果的成像示例，分别对应单目标、两个分离目标和两个重叠目标的情形。从这些可视化结果可以清楚看出，预测的三维介电常数图与真实值接近，土壤介电常数及地下目标的属性均得到了准确恢复。

C. 商用探地雷达天线模型

数据集V。为进一步测试所提方案在实际商用天线上的泛化能力，本文在gprMax中使用GSSI 400 MHz探地雷达天线模型 [56] 来发射和接收信号。与通过1 GHz下的偶极子/探针配置获得的数据集I–IV相比，工作频率和发射/接收配置均发生了变化，并将天线模型与地面之间的高度设为零，从而导致C扫描中的反射模式存在显著差异。地下场景的其他属性与数据集 I中的保持一致。利用GSSI 400 MHz探地雷达天线模型生成了285个数据集，用于微调预训练网络。微调后的网络用于对15个含噪C扫描进行去噪，并预测三维介电常数图。

测试结果。如表 VI（数据集V）所示，商用 GSSI 400 MHz天线型号表现出较高的结构相似性指数，证明其具有令人满意的去噪性能，并且

去噪器具有较高的峰值信噪比以及较低的平均绝对误差和平均相对误差。就反演性能而言，反演器较高的结构相似性指数以及较低的均方误差、平均绝对误差和平均绝对百分比误差表明，三维介电常数图重建具有良好的准确性。为了直观地分析反演结果，对单目标、两个分离目标和两个重叠目标场景下预测的三维介电常数图与真实值进行了比较，如图8(c)中的案例16–18所示。从成像结果可以清楚地看出，预测的介电常数图与相应的真实值高度吻合。地下目标的特征得到了高精度还原。这些结果验证了，通过使用少量额外数据集对预训练网络进行微调，所提出的3DInvNet在具有新工作频率和配置的商用天线系统上表现出卓越的泛化能力。

V. 实测数据测试

A. 数据集收集与实验设置

在沙质试验场中开展探地雷达实验，以验证所提方案的适用性和有效性。如图9(a)所示，使用配备400 MHz天线的商用GSSI Utility Scan Pro探地雷达系统获取B扫描，并将其堆叠成C扫描。扫描区域为1×1 m^2。每个C扫描包含21个B扫描，相邻两条道之间的距离为5 cm。每个B扫描由88个A扫描组成，每个A扫描的采样点数为512。时间窗设置为20 ns。如图9(b)所示，旋转扫描区域以模拟目标的各种水平取向，并沿 x 和 y 轴移动，以实现从不同位置对目标进行扫描。通过埋设目标来改变深度、垂直取向等其他属性。从五个形状、尺寸和介电常数值各异的木制目标中选取埋藏物体。如图10(a)所示，使用Keysight N1501A介电探头测量目标和沙子的相对介电常数（ε_r）。五份沙样的相对介电常数平均值为3.65，并将其设为训练所提网络时真实值中的背景相对介电常数。实验中埋藏物体的属性如图10(b)所示。目标的x坐标、 y 坐标、 z 坐标（深度）、水平角和垂直角的范围为[35, 65] cm，[35, 65] 厘米，[9, 25] 厘米，[0, 60] 度和[0, 60] 度，分别。

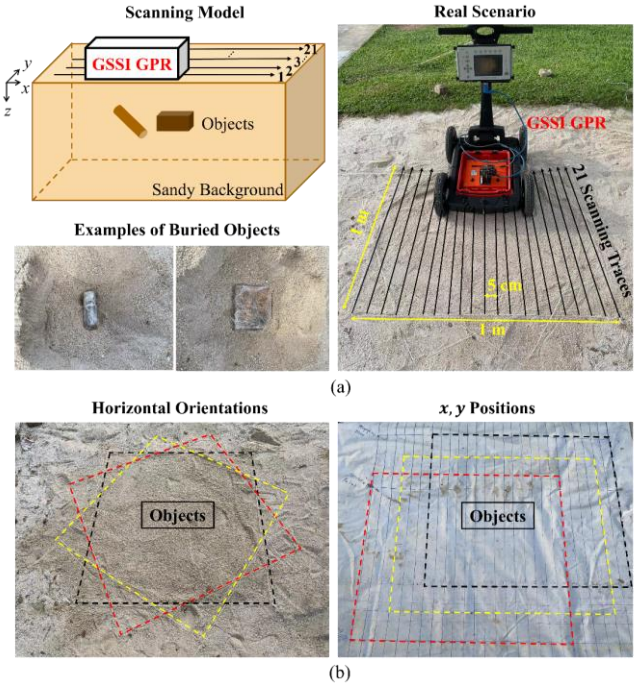


图1。真实实验场景。(a) 使用商用探地雷达系统进行扫描的模型。(b) 用于模拟不同水平取向（左侧）和x、 y 位置（右侧）的扫描区域。

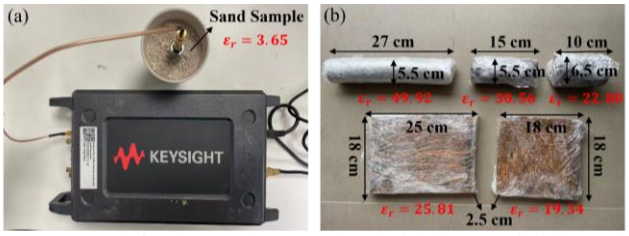


图10。(a) 相对介电常数测量装置。(b) 实际实验中使用的埋藏物体的属性。

每个测得的C扫描都归一化到[0, 1],的范围，调整大小至128×128×128，并经过零时刻校正和均值减法预处理[32]，以形成输入的含噪C扫描。为获得真实去噪C扫描，在远离物体区域的空旷区域测量一个C扫描，并将其从含噪C扫描中减去。共获取了220组实测含噪C扫描、去噪后的C扫描以及地下

表 V 实测测试数据的评估指标

组		i						ii				iii			i、ii 和 iii
	测试数据编号	(1)	(2)	(3)	(4)	(5)	Ave.	(6)	(7)	(8)	Ave.	(9)	(10)	Ave.	Ave.
reconed	结构相似性指数 (×10⁻²) (↑)	99.95	99.96	99.96	99.96	99.95	**99.96**	99.94	99.94	99.94	**99.94**	99.96	99.95	**99.96**	**99.95**
	峰值信噪比 (分贝) (↑)	58.72	59.96	59.31	59.27	59.12	**59.28**	57.15	57.15	57.71	**57.34**	59.43	59.29	**59.36**	**58.75**
	平均绝对误差 (×10⁻⁴) (↓)	7.78	6.94	7.05	7.51	6.87	**7.23**	9.66	9.17	8.58	**9.14**	7.16	7.27	**7.22**	**7.80**
	平均相对误差 (%) (↓)	0.23	0.20	0.22	0.22	0.22	**0.22**	0.28	0.27	0.27	**0.27**	0.21	0.22	**0.22**	**0.23**
reinvni	结构相似性指数 (×10⁻²) (↑)	99.64	99.60	99.76	99.70	99.61	**99.66**	99.57	99.57	99.48	**99.54**	99.44	99.37	**99.41**	**99.57**
	均方误差 (×10⁻¹) (↓)	4.89	8.52	1.73	2.50	1.25	**3.78**	6.58	3.54	8.57	**6.23**	8.81	11.37	**10.09**	**5.78**
	平均绝对误差 (×10⁻²) (↓)	3.38	4.31	2.26	2.73	2.69	**3.08**	4.15	3.85	5.14	**4.38**	5.59	5.79	**5.69**	**3.99**
	平均绝对百分比误差 (%) (↓)	0.61	0.58	0.43	0.37	0.49	**0.49**	0.48	0.66	0.82	**0.65**	0.80	0.89	**0.85**	**0.61**

获得三维介电常数图后，对预训练的去噪器和反演器进行微调，共训练100轮。

B. 反演结果分析

1) 定量结果：使用微调后的网络，采用10个实测测试数据集来评估所提出方案的性能。去噪器和反演器的定量结果如表 VII所示。组 i、ii 和 iii 分别包括5个单目标情况、3个双分离目标情况和2个双目标接触案例。对于去噪器，与之前的数值数据集相比，平均结构相似性指数、峰值信噪比、平均绝对误差和平均相对误差均出现了可接受的下降。由于如图11(a)所示，实际测量的 C-扫描具有随机分布的噪声，因此这种精度下降是合理的

干扰物体反射特征的图样。根据去噪后的C扫描，表 VII 评估了反演器在各种地下场景中的重建精度。可以观察到，组 i 的均方误差、平均绝对误差和平均绝对百分比误差最低，结构相似性指数最高；而组 ii 和组 iii 的四项指标略逊于组 i，这是因为所得 C 扫描中两个物体的特征更为复杂。当组 iii 中的两个物体相互接触时，其双曲线图样高度交错，导致重建精度进一步下降。

2）成像结果：去噪后的C扫描和重建的三维介电常数图的成像结果如图 11 所示。案例19-20为单目标场景，案例 21为双分离目标场景，案例 22为双接触目标

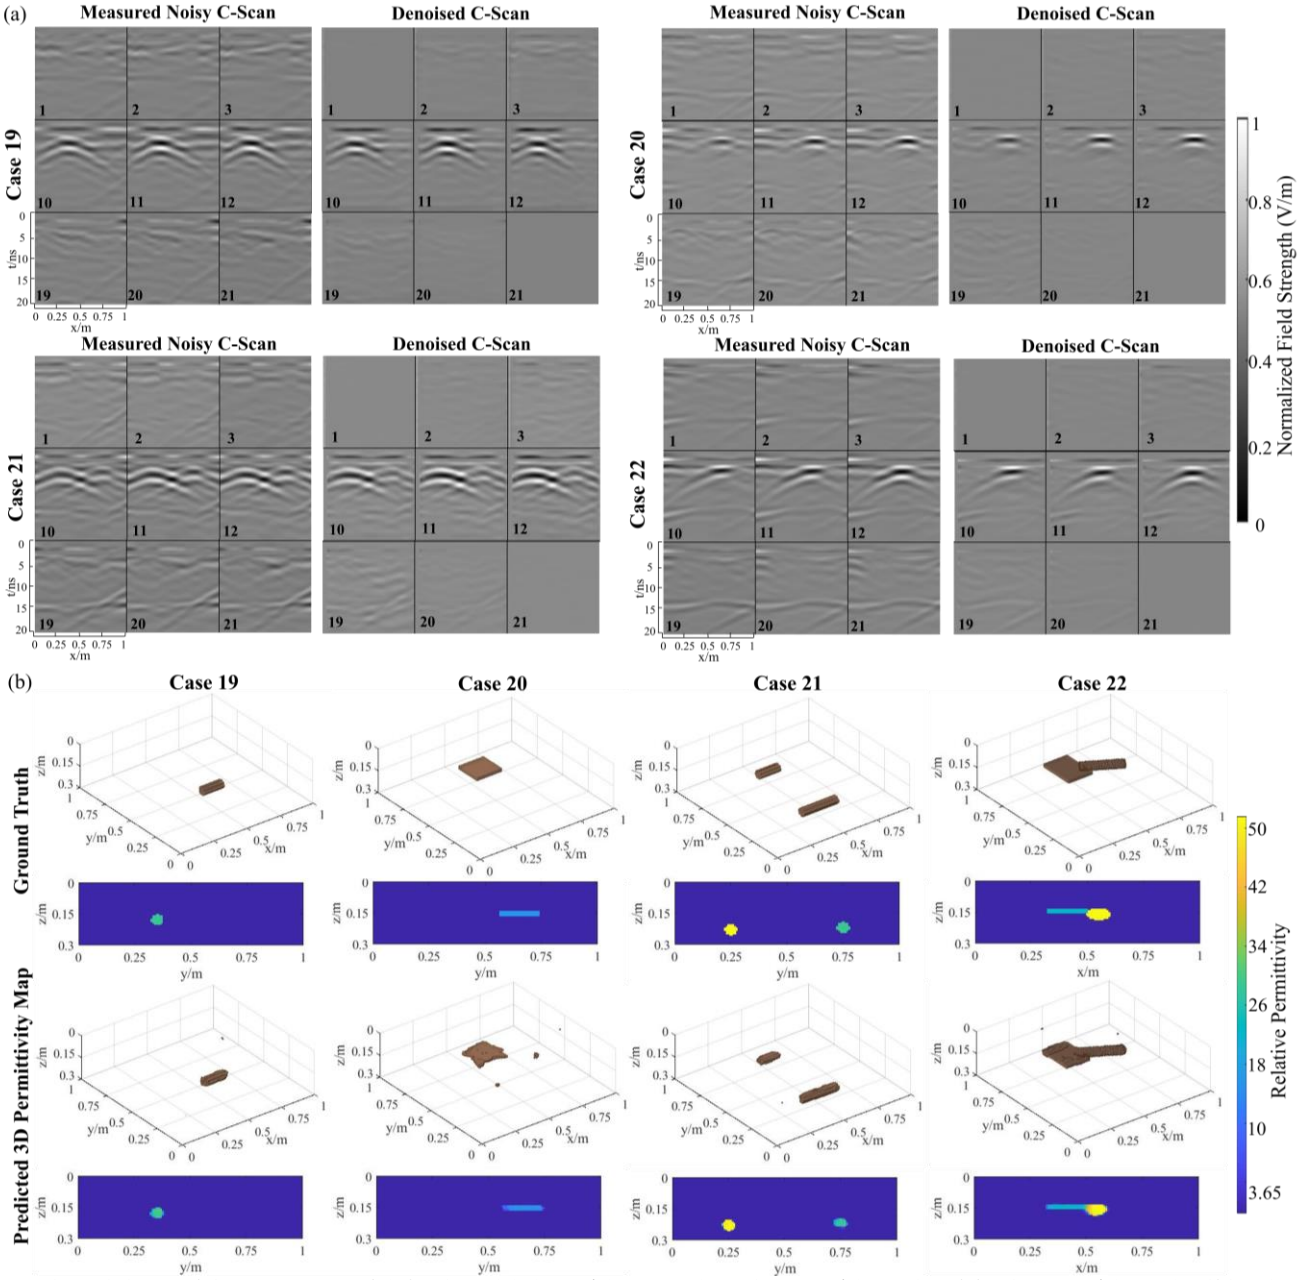


图 11. (a) 实测 C扫描的三维去噪结果。(b) 三维介电常数图重建结果。案例 19–20 为单目标场景，案例 21 为双分离目标场景，案例 22 为双接触目标场景。

场景。图11(a)展示了输入的含噪C扫描以及去噪器得到的去噪后C扫描。图中直观展示了每个C扫描中包含主要反射特征或明显噪声模式的选定B扫描。与含噪C扫描相比，去噪后的C扫描噪声和由地下环境反射造成的杂波更少，目标的反射模式也更加清晰。图11(b)展示了反演器根据去噪后的C扫描预测得到的三维重建结果。对比了预测的三维介电常数图及其真实值，包括三维几何结构和介电常数图的一个切片。案例19和20分别展示了圆柱体和箱体的重建结果。反演器预测的结果与真实值吻合良好。对于案例21和22所示的双分离目标场景和双接触目标场景，重建的三维介电常数图在地下目标的形状、尺寸、方向、位置和介电常数值方面均接近真实值。尽管目标周围出现了一些杂波，且两个接触目标之间的边缘略显模糊，但仍可清楚观察到地下目标的特性。这些定量和定性结果表明，所提出的3DInvNet能够有效地根据实测数据重建地下三维介电常数图。

VI. 结论

本文提出了一种称为 3DInvNet 的两阶段方案，用于快速对探地雷达 C扫描进行去噪，并重建三维地下介电常数分布图。第一阶段称为去噪器，能够有效提取地下目标的信息特征，并抑制探地雷达 C扫描中的环境噪声。第二阶段称为反演器，用于建立去噪后的C扫描的判别特征与相应地下场景之间的关系。数值数据和实测数据上的测试结果表明，所提出的方法能够准确且高效地重建三维介电常数图。此外，通过将所提出的网络应用于各种地下场景，验证了其泛化能力和鲁棒性。本文首次实现了用于三维地下结构重建的三维深度学习技术，为解决探地雷达三维反演问题并减轻三维重建的计算负担提供了一种新颖且高效的方法。

需要指出的是，所提出的方案存在一定的局限性。1）基于监督式深度学习的技术需要大量数据集来预训练网络。使用下采样数据集训练的网络所描述的映射关系会不准确。当测试数据与预训练集略有不同时，可使用迁移学习，利用一小批额外数据微调预训练网络。然而，当测试案例与预训练集中的情形完全不同时，则需要使用大量新数据重新训练网络。2）由于现有超参数自动调优技术尚不成熟，目前的深度学习算法需要通过试验来设置超参数。我们的开源框架发布于 https://github.com/Qiqi- Dai/3DInvNet。研究人员可以下载并使用我们的框架，并在未来通过实现此类自动调优算法对其进行改进。3）微调反演网络需要预先估计土壤介质的平均介电常数。构建涵盖不同背景环境的多样化数据集有助于解决这一问题，我们将在未来的工作中对此进行研究。此外，开发用于探地雷达检测与成像的物理信息深度学习框架，将是我们未来研究的重点。

参考文献

[1] D. Feng、X. Wang 和 B. Zhang，“通过多尺度反演和双参数全波形反演改进探地雷达剖面中的隧道衬砌缺陷重建”，Adv. Eng. Inform.，第41卷，2019年8月，文章编号100931。[2] M. Pereira、D. Burns、D. Orfeo、Y. Zhang、L. Jiao、D. Huston 和 T. Xia，“用于增强现实可视化的三维多基地探地雷达成像”，IEEE Trans. Geosci. Remote Sens.，第58卷，第8期，第5666–5675页，2020年8月。[3] L. Zou、Y. Wang、I. Giannakis、F. Tosti、A. M. Alani 和 M. Sato，“利用探地雷达和低成本GPS绘制树根分布图并进行评估”，Remote Sens.，第12卷，第8期，2020年4月，文章编号1300。[4] M. Wang、H. Wang 和 H. Liu，“用于地下成像的探地雷达三维叠前逆时偏移”，载于《第17届国际探地雷达会议（GPR）论文集》，瑞士拉珀斯维尔，2018年6月，第1–4页。[5] F. Lavoué、R. Brossier、L. Métivier、S. Garambois 和 J. Virieux，“多偏移距探地雷达数据全波形反演实现的二维介电常数与电导率成像：一种频域拟牛顿方法”，Geophys. J. Int.，第197卷，第1期，第248–268页，2014年4月。 [6] H. Qin、X. Xie、J. A. Vrugt、K. Zeng 和 G. Hong，“利用跨孔探地雷达和贝叶斯波形反演进行地下结构缺陷检测与重建”，Autom. Constr.，第68卷，第156–169页，2016年8月。[7] F. Watson，“迈向探地雷达三维全波反演”，载于《IEEE RadarConf论文集》，美国宾夕法尼亚州费城，2016年5月，第1–6页。[8] X. Wang 和 D. Feng，“ 采用改进全变分正则化方案的三维地表探地雷达多参数全波形反演”，IEEE Geosci. Remote. Sens. Lett.，第18卷，第3期，第466–470页，2021年3月。[9] M. Salucci、M. Arrebola、T. Shan 和 M. Li，“人工智能：实时逆散射与电磁成像的新前沿”，IEEE Trans. Antennas Propag.，第70卷，第8期，第6349–6364页，2022年8月。[10] X. Chen、Z. Wei、M. Li 和 P. Rocca，“逆散射问题深度学习方法综述（特邀综述）”，Prog. In Electromagn. Res.，第167卷，第67–81页，2020年6月。[11] A. Massa、D. Marcantonio、X. Chen、M. Li 和 M. Salucci，“深度神经网络在电磁学、天线与传播中的应用——综述”，IEEE Antennas Wirel. Propag. Lett.，第18卷，第11期，第2225–2229页，2019年11月。[12] Z. Wei 和 X. Chen，“用于全波非线性逆散射问题的深度学习方案”，IEEE Trans. Geosci. Remote Sens.，第57卷，第4期，第1849–1860页，2019年4月。[13] O. Ronneberger、P. Fischer 和 T. Brox，“U-Net：用于生物医学图像分割的卷积网络”，载于《国际医学图像计算与计算机辅助干预会议论文集》，德国慕尼黑，2015年10月，第234–241页。[14] L. Li、L. G. Wang、F. L. Teixeira、C. Liu、A. Nehorai 和 T. J. Cui，“DeepNIS：用于非线性电磁逆散射的深度神经网络”，IEEE Trans. Antennas Propag.，第67卷，第3期，第1819–1825页，2019年3月。[15] H. M. Yao、L. Jiang 和 E. I. Wei，“基于深度卷积编码器—解码器架构的增强型深度学习方法，用于电磁逆散射问题”，IEEE Antennas Wirel. Propag. Lett.，第19卷，第7期，第1211–1215页，2020年7月。[16] X. Ye、Y. Bai、R. Song、K. Xu 和 J. An，“一种基于生成对抗网络的非均匀背景成像方法”，IEEE Trans. Microw. Theory Tech.，第68卷，第11期，第4684–4693页，2020年11月。

[17] Z. Tong、J. Gao 和 D. Yuan，“深度学习在探地雷达中的应用进展：综述”，Constr. Build Mater.，第258卷，第120371页，2020年10月。[18] X. L. Travassos、S. L. Avila 和 N. Ida，“人工神经网络与机器学习技术在探地雷达中的应用：综述”，Appl. Comput. Inform.，第17卷，第2期，第296–308页，2021年4月。 [19] L. E. Besaw 和 P. J. Stimac，“用于探地雷达B扫描分类的深度卷积神经网络”，载于《SPIE论文集》，第9454卷，2015年5月，文章编号945413。[20] W. Lei、J. Zhang、X. Yang、W. Li、S. Zhang 和 Y. Jia，“探地雷达B扫描图像中的双曲线自动检测与拟合”，Automat. Constr.，第106卷，2019年10月，文章编号102839。[21] P. Bestagini、F. Lombardi、M. Lualdi、F. Picetti 和 S. Tubaro，“利用自编码器从多极化探地雷达体数据中探测地雷”，IEEE Trans. Geosci. Remote Sens.，第59卷，第1期，第182–195页，2021年1月。[22] H. -H. Sun、Y. H. Lee、C. Li、G. Ow、M. L. M. Yusof 和 A. C. Yucel，“通过多极化聚合与选择神经网络估计细长地下物体的方向”，IEEE Geosci. Remote. Sens. Lett.，第19卷，第1–5页，2022年。[23] H. H. Sun、Y. H. Lee、Q. Dai、C. Li、G. Ow、M. L. M. Yusof 和 A. C. Yucel，“通过掩膜引导多极化集成神经网络估计非均质土壤环境中的树根参数”，IEEE Trans. Geosci. Remote Sens.，第60卷，第1–16页，2022年。 [24] J. K. Alvarez 和 S. Kodagoda，“将深度学习图像到图像转换网络应用于探地雷达雷达图，以实现基础设施监测中的地下成像”，载于《ICIEA论文集》，中国武汉，2018年5月，第611–616页。[25] L. Xie、Q. Zhao、C. Ma、B. Liao 和 J. Huo，“Ü-Net：用于探地雷达数据反演的深度学习方案”，J. Environ. Eng. Geophys.，第25卷，第2期，第287–292页，2021年6月。[26] B. Liu、Y. Ren、H. Liu、H. Xu、Z. Wang、A. G. Cohn 和 P. Jiang，“GPRInvNet：基于深度学习的探地雷达数据反演，用于隧道衬砌”，IEEE Trans. Geosci. Remote Sens.，第59卷，第10期，第8305–8325页，2021年10月。[27] Y. Ji、F. Zhang、J. Wang、Z. Wang、P. Jiang、H. Liu 和 Q. Sui，“基于深度神经网络的探地雷达数据介电常数反演”，IEEE Sensors J.，第21卷，第6期，第8172–8183页，2021年3月。[28] V. Badrinarayanan、A. Kendall 和 R. Cipolla，“Segnet：用于图像分割的深度卷积编码器-解码器架构。” IEEE Trans. Pattern Anal. Mach. Intell.，第39卷，第12期，第2481–2495页，2016年10月。[29] P. Isola、J. Y. Zhu、T. Zhou 和 A. A. Efros，“利用条件对抗网络实现图像到图像的转换”，载于《IEEE计算机视觉与模式识别会议（CVPR）论文集》，美国夏威夷州檀香山，2017年7月，第5967–5976页。[30] H. Brunzell，“利用脉冲雷达探测浅埋物体”，IEEE Trans. Geosci. Remote Sens.，第37卷，第2期，第875–886页，1999年3月。[31] A. M. Zoubir、I. J. Chant、C. L. Brown、B. Barkat 和 C. Abeynayake，“利用脉冲探地雷达探测地雷的信号处理技术”，IEEE Sens. J.，第2卷，第1期，第41–51页，2002年2月。[32] A. Benedetto、F. Tosti、L. B. Ciampoli 和 F. D’Amico，“道路检测中探地雷达信号处理技术概述”，Signal Process.，第132卷，第201–209页，2016年3月。 [33] F. Abujarad、G. Nadim 和 A. Omar，“利用奇异值分解（SVD）抑制探地雷达数据中的杂波并检测地雷”，载于《第3届先进探地雷达国际研讨会（IWAGPR）论文集》，荷兰代尔夫特，2005年5月，第37–42页。[34] W. Xue、Y. Luo、Y. Yang 和 Y. Huang，“基于窗长优化汉克尔矩阵奇异值分解的探地雷达数据噪声抑制”，Sensors，第19卷，第17期，2019年，文章编号3807。[35] B. Karlsen、J. Larsen、H. B. D. Sorensen 和 K. B. Jakobsen，“比较用于反人员地雷探测的探地雷达系统中基于主成分分析和独立成分分析的杂波抑制方法”，载于《第11届IEEE统计信号处理研讨会论文集》，新加坡，2001年8月，第146–149页。[36] G. Chen、L. Fu、K. Chen、C. D. Boateng 和 S. Ge，“基于主成分分析的探地雷达数据自适应地杂波抑制”，IEEE Trans. Geosci. Remote Sens.，第57卷，第6期，第3271–3282页，2019年6月。[37] D. Kumlu 和 I. Erer，“利用非负矩阵分解去除探地雷达图像中的杂波”，J. Electromagn. Waves Appl.，第32卷，第16期，第2055–2066页，2018年6月。[38] D. Kumlu 和 I. Erer，“通过鲁棒非负矩阵分解改进探地雷达中的杂波去除”，IEEE Geosci. Remote Sens. Lett.，第 17 卷，第 6 期，第 958–962 页，2020 年 6 月。[39] W. Lei 、 F. Hou 、 J. Xi 、 Q. Tan 、 M. Xu 、 X. Jiang 、 G. Liu 和 Q. Gu，“ 探地雷达 B 扫描图像中的自动双曲线检测与拟合 ”，Autom. Construct.，第 106 卷，2019 年 10 月，文章编号 102839。[40] H. Liu、C. Lin、J. Cui、L. Fan、X. Xie 和 B. F. Spencer，“利用探地雷达和深度学习检测并定位混凝土中的钢筋”，Autom. Construct.，第 118 卷，2020 年 10 月，文章编号 103279。[41] Q. Dai、Y. H. Lee、H. H. Sun、G. Ow、M. L. M. Yusof 和 A. C. Yucel，“DMRF-UNet：一种用于非均质土壤条件下探地雷达数据反演的两阶段深度学习方案”，IEEE Trans. Antennas Propag.，第 70 卷，第 8 期，第 6313–6328 页，2022 年 8 月。[42] E. Temlioglu 和 I. Erer，“一种基于卷积自编码器的创新方法，用于探地雷达中的埋藏威胁检测杂波去除”，IEEE Trans. Geosci. Remote Sens.，第 60 卷，第 1–13 页，2022 年。[43] H. H. Sun、W. Cheng 和 Z. Fan，“利用混合数据学习去除真实世界探地雷达图像中的杂波”，IEEE Trans. Geosci. Remote Sens.，第 60 卷，第 1–14 页，2022 年。[44] Ö. Çiçek、A. Abdulkadir、S. S. Lienkamp、T. Brox 和 O. Ronneberger，“3D U-Net：通过稀疏标注学习密集体积图像分割”，载于《国际医学图像计算与计算机辅助干预会议论文集》，希腊雅典，2016 年 10 月，第 424–432 页。[45] S. Anwar 和 N. Barnes，“利用特征注意力进行真实图像去噪”，载于《IEEE国际计算机视觉会议论文集》，韩国首尔，2019 年 10 月，第 3155–3164 页。[46] K. He、X. Zhang、S. Ren 和 J. Sun，“用于图像识别的深度残差学习”，载于《IEEE计算机视觉与模式识别会议（CVPR）论文集》，美国内华达州拉斯维加斯，2016 年 6 月，第 770–778 页。[47] J. Hu、L. Shen 和 G. Sun，“挤压与激励网络”，载于《IEEE计算机视觉与模式识别会议（CVPR）论文集》，犹他州盐湖城，2018 年 6 月，第 7132–7141 页。[48] A. Araujo、W. Norris 和 J. Sim，“计算卷积神经网络的感受野”，Distill，第 4 卷，第 11 期，第 151 页，2019 年 11 月。[49] D. P. Kingma 和 J. Ba，“Adam：一种随机优化方法”，2014 年，arXiv:1412.6980。[50] C. Tan、F. Sun、T. Kong、W. Zhang、C. Yang 和 C. Liu，“深度迁移学习综述”，载于《国际人工神经网络会议论文集》，希腊罗得岛，2018 年 10 月，第 270–279 页。[51] C. Warren、A. Giannopoulos 和 I. Giannakis，“gprMax：用于模拟探地雷达电磁波传播的开源软件”，Comput. Phys. Commun.，第 209 卷，第 163–170 页，2016 年 12 月。[52] C. Warren、C. Warren、A. Giannopoulos、A. Gray、I. Giannakis、A. Patterson、L. Wetter 和 A. Hamrah，“基于 CUDA 的 gprMax GPU引擎：开源有限差分时域法电磁仿真软件”，Comput. Phys. Commun.，第 237 卷，第 208–218 页，2019 年 4 月。[53] N. R. Peplinski、F. T. Ulaby 和 M. C. Dobson，“0.3–1.3 GHz 范围内土壤的介电特性”，IEEE Trans. Geosci. Remote Sens.，第 33 卷，第 3 期，第 803–807 页，1995 年 5 月。[54] I. Giannakis、A. Giannopoulos 和 C. Warren，“用于地雷探测的探地雷达真实有限差分时域法数值建模框架”，IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.，第 9 卷，第 1 期，第 37–51 页，2016 年 1 月。[55] A. Paszke、S. Gross、F. Massa、A. Lerer、J. Bradbury、G. Chanan、T. Killeen、Z. Lin、N. Gimelshein、N. Gimelshein、A. Desmaison、A. Köpf、E. Yang、Z. DeVito、M. Raison、A. Tejani、S. Chilamkurthy、B. Steiner、L. Fang、J. Bai、S. Chintala，“PyTorch：一种命令式风格的高性能深度学习库”，载于《神经信息处理系统进展会议论文集》，加拿大温哥华，第 32 卷，2019 年 12 月，第 8026–8037 页。[56] I. Giannakis、A. Giannopoulos 和 C. Warren，“采用新型线性/非线性全波形反演优化的真实有限差分时域法探地雷达天线模型”，IEEE Trans. Geosci. Remote Sens.，第 57 卷，第 3 期，第 1768–1778 页，2019 年 3 月。