仿真到真实的 SAR 图像复原：用于联合去斑和旁瓣抑制的元数据驱动模型

Antoine De Paepe *、Pascal Nguyen †、Michael Mabelle †、C´
édric Saleun *、Antoine Jouad´é *、Jean-Christophe Louvigne *
*法国军备总局信息控制部，布吕兹，法国
†国防人工智能部，布吕兹，法国

arXiv:2601.01541v1 [eess.IV] 4 Jan 2026

摘要—合成孔径雷达（SAR）能够在各种天气和光照条件下提供有关地表的重要信息。然而，斑点噪声这一固有现象以及明亮目标周围的旁瓣，给 SAR 图像的准确解译带来了挑战。现有的大多数 SAR 图像复原方法将去斑和旁瓣抑制作为彼此独立的任务处理。本文提出一种统一框架，利用基于 MOCEM 生成的逼真 SAR 模拟数据集训练的神经网络（NNs），联合完成这两项任务。随后可在真实 SAR 图像上进行推理，展现出有效的仿真到真实（Sim2Real）迁移能力。此外，我们将采集元数据作为神经网络的辅助输入，从而提升了复原性能。

索引词—合成孔径雷达、图像复原、去斑、旁瓣抑制、元数据注入、仿真到真实

符号与术语

本文中，合成孔径雷达图像一词广义上指合成孔径雷达数据，包括单视复数（SLC）图像及其幅度表示。为明确起见，我们会在必要时明确区分二者。在第二节中，所有向量均表示为列向量。符号“$\top$”表示矩阵转置运算。对于给定的列向量 $\boldsymbol{s} = [s_1, s_2, \cdots, s_n]^\top \in \mathcal{S}^n$，其中 $\mathcal{S}$ 可以是 $\mathbb{R}$ 或 $\mathbb{C}$，s_k 表示 $\boldsymbol{s}$ 的第 k 个元素。对于 $\mathcal{S} \triangleq \mathbb{C}$ 的特定情形，我们记为 $\boldsymbol{s} = \boldsymbol{s}^{\text{re}} + i\boldsymbol{s}^{\text{im}}$，其中 $\boldsymbol{s}^{\text{re}} \in \mathbb{R}^n$ 表示实部，$\boldsymbol{s}^{\text{im}} \in \mathbb{R}^n$ 表示虚部。我们将 $\boldsymbol{D_s} \triangleq \text{diag}(\boldsymbol{s}) \in \mathcal{S}^{n\times n}$ 定义为对角矩阵，其对角元素由向量 $\boldsymbol{s}$ 的各分量给出。

I. 引言

合成孔径雷达成像已成为一项至关重要的遥感技术，广泛应用于环境监测、灾害管理和军事监视等多个领域。SAR 能够在各种条件下获取高分辨率图像，因此成为观测和分析地表的宝贵工具。

尽管具有诸多优势，SAR 图像仍常受固有噪声（尤其是斑点噪声）以及明亮目标周围旁瓣的影响，这些问题可能会掩盖关键细节。为提升合成孔径雷达图像的解译质量，必须解决斑点噪声和旁瓣带来的挑战。

人们已开发出多种旁瓣抑制技术，分别针对 SAR 信号处理的不同方面。最广泛使用的方法是窗函数 [1], ，例如汉明窗、汉宁窗和凯泽窗。这些窗函数通过在处理过程中平滑雷达信号来降低旁瓣振幅，但代价是损失部分分辨率。更复杂的方法旨在降低旁瓣电平，同时避免显著损害分辨率或信号强度，例如空间变加权（SVA）[2]。然而，SVA 也存在一些缺点：它会扭曲斑点主导区域的统计特性，使点状目标扩散到多个像素，并引入负偏差，导致均匀区域看起来反射率较低 [3]。近年来，深度学习的发展催生了基于卷积神经网络（CNN） [4]和双向循环神经网络（RNN） [5] 的模型，以缓解这些问题。

与旁瓣抑制技术类似，合成孔径雷达图像去斑点噪声已得到广泛研究，目前通常采用两大类方法处理：变分方法和基于学习的技术。

变分方法通常将问题表述为代价函数的最小化，该代价函数由数据保真项和正则化项构成：前者根据 Goodman斑点模型 [6] 描述斑点噪声的统计特性，后者则融入关于底层图像的先验知识 [7, 8]。

基于深度学习的方法通常使用加入合成斑点噪声的自然图像对进行训练，以有效学习去斑任务。受 DnCNN架构[11]的启发，SAR-CNN [9] 和 ID-CNN[10]专门针对斑点噪声的乘性特性而设计。此外，最初为医学图像分割开发的 UNet架构 [12], 已证明在自然图像复原任务中效果显著 [13, 14, 15], ，其适应性也已在 SAR去斑应用中得到验证 [16, 17]。这些网络擅长捕捉多尺度特征，这对于复原含噪合成孔径雷达图像中的精细细节至关重要。生成对抗网络（GAN）已

也成为合成孔径雷达图像复原的强大工具[18, 19]。合成孔径雷达图像复原领域的一项较新进展，是应用条件扩散过程 [20, 21]对合成孔径雷达图像进行去斑。最后，无需依赖真实值（GT）数据的自监督学习方法 [22, 23],正逐渐成为合成孔径雷达图像复原的有效方案。

尽管深度学习方法前景广阔，但由于训练策略的影响，大多数方法主要用于抑制空间非相关斑点噪声。然而，在真实 SAR 图像中，斑点噪声通常会受到 SAR传递函数的影响而呈现空间相关性。这种域差距可能导致实际应用中的复原效果不理想。针对这一挑战，目前开发的方法寥寥无几，例如 MuLoG-DRUNet [24],这一即插即用（PnP）方法，它是首个能够有效抑制空间相关斑点噪声的稳健技术。

本文提出一种基于深度学习方法的新颖方案，用于 SAR 图像复原中的联合去斑和旁瓣抑制。我们使用 MOCEM[25] 创建了一个带有真实值的 SAR 图像数据集，专门用于复现真实场景中观察到的斑点噪声特性及 SAR传递函数的影响。该数据集用于监督学习任务，且其与真实合成孔径雷达采集的一致性使仿真到真实的 SAR 图像复原得以有效实现。此外，我们提出将 SAR采集元数据纳入复原过程。通过将元数据集成到深度学习框架中，我们提供了上下文信息，使神经网络能够根据特定采集条件调整其复原策略。

II. 方法

A. 问题表述

SAR采集过程涉及一种通常安装在飞机或卫星上的传感器，该传感器作为主动系统，向地表发射电磁波，并将反射信号捕获为一组复值测量。这些测量经过相干组合，以合成一个较长的虚拟孔径，从而形成场景反射率 $\boldsymbol{x} \in \mathcal{X} \triangleq \mathbb{R}_{+}^{n}$的 SLC 图像 $\boldsymbol{y} \in \mathcal{Y} \triangleq \mathbb{C}^{n}$。为便于解释和实际处理，SAR 图像也可用 SLC 的振幅表示，定义为 $\tilde{\boldsymbol{y}} \triangleq |\boldsymbol{y}|$，其中 $\tilde{\boldsymbol{y}} \in \tilde{\mathcal{Y}} \triangleq \mathbb{R}_{+}^{n}$。由于 SAR 系统的脉冲响应以及雷达信号的相干特性，SAR 图像通常会受到旁瓣和空间相关斑点噪声的共同影响。我们将与 SAR传递函数相关的线性空间域算子记为 $\boldsymbol{H} \in \mathbb{R}^{n \times n}$。根据 Goodman模型，通常假设对于恢复任务，在不存在电子噪声的情况下，测量值 $\boldsymbol{y}$服从圆对称高斯分布 [22]，其独立元素为

$$(\boldsymbol{y}|\boldsymbol{H}, \boldsymbol{x}) \sim \mathcal{CN}(\mathbf{0}_{\mathcal{X}}, \boldsymbol{H}\boldsymbol{D}_{\boldsymbol{x}}\boldsymbol{H}^{\top}), \tag{1}$$

其中，$\mathcal{CN}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ 表示均值为 $\boldsymbol{\mu} \in \mathbb{R}^{n}$、协方差矩阵为 $\boldsymbol{\Sigma} \in \mathbb{R}^{n \times n}$的复圆对称高斯分布。该模型可以重新参数化，以体现斑点噪声的乘性特征：

$$\boldsymbol{y} = \boldsymbol{H}(\mathcal{C}(\boldsymbol{x}^{\frac{1}{2}}) \odot \boldsymbol{n}), \quad \boldsymbol{n} \sim \mathcal{CN}(\mathbf{0}_{\mathcal{X}}, \boldsymbol{I}_{\mathcal{X}}), \tag{2}$$

其中，$\mathcal{C}: \mathbb{R}^{n} \to \mathbb{C}^{n}$ 是复化算子，使得$\mathcal{C}(\boldsymbol{x}) = \boldsymbol{x} + i\boldsymbol{x}$，而 $\boldsymbol{n}$ 表示复数形式的乘性斑点噪声。

当传递函数 $\boldsymbol{H}$ 已知时，可通过求取 $\boldsymbol{x}$的最大后验（MAP）估计来实现图像复原，即：

$$\max_{\boldsymbol{x} \in \mathcal{X}} p(\tilde{\boldsymbol{y}}|\boldsymbol{H}, \boldsymbol{x}) \cdot p(\boldsymbol{x}), \tag{3}$$

其中，条件概率密度函数（PDF）$p(\tilde{\boldsymbol{y}}|\boldsymbol{H}, \boldsymbol{x})$由式（1）给出，$p(\boldsymbol{x})$是关于$\boldsymbol{x}$的先验概率密度函数，通常未知，并以促进分段光滑性的正则化项（其后验对数形式）替代。然而，求解式（3）中的逆问题依赖于对 $\boldsymbol{H}$的了解，而在许多实际应用中，这些信息可能无法获取，尤其是在处理流程或采集几何属于专有信息或未公开时。在这种情况下，由于缺少准确的系统模型，传统的基于模型的复原方法将无法应用或不可靠，尤其是在联合去斑和旁瓣抑制任务中。

为了解决这一局限，我们考虑采用另一种策略，利用大量已知的SAR传递˜函数来训练神经网络 $f_{\boldsymbol{\theta}}: \mathcal{Y} \to \mathcal{X}$，其参数由 $\boldsymbol{\theta} \in \boldsymbol{\Theta}$ 表示，并且能够泛化到未见过或未明确表征的系统。训练过程可表述为以下最小化问题

$$\min_{\boldsymbol{\theta} \in \boldsymbol{\Theta}} \mathbb{E}_{(\boldsymbol{x}, \tilde{\boldsymbol{y}}) \sim p(\boldsymbol{x}, \tilde{\boldsymbol{y}})}[\ell(f_{\boldsymbol{\theta}}(\tilde{\boldsymbol{y}}), \boldsymbol{x})], \tag{4}$$

其中，$p(\boldsymbol{x}, \tilde{\boldsymbol{y}}) = \int p(\tilde{\boldsymbol{y}}|\boldsymbol{H}, \boldsymbol{x})p(\boldsymbol{H})p(\boldsymbol{x})d\boldsymbol{H}$ 是 $\boldsymbol{x}$ 和 $\tilde{\boldsymbol{y}}$ 的联合概率密度函数，并对 $p(\boldsymbol{H})$（可能的SAR传递函数的概率密度函数）进行边缘化；$\ell: \mathcal{X} \times \mathcal{X} \to \mathbb{R}$ 是一个损失函数。通过这种方式，模型能够隐式学习反转传递函数 $\boldsymbol{H}$ 和斑点噪声的复合效应。这种方法实现了无模型SAR图像复原，尤其适用于实际运行场景。

B. 仿真到真实：利用仿真学习真实世界图像复原

在现实场景中，获取大量成对样本（$\boldsymbol{x}$、$\tilde{\boldsymbol{y}}$）$\sim p$（$\boldsymbol{x}$、$\tilde{\boldsymbol{y}}$）用于监督学习几乎是不可能的。因此，有必要通过生成合成训练数据集进行仿真，以克服这一限制。我们提出使用通过 MOCEM [25] 软件获取的模拟SAR图像。该用于建模 SAR采集的仿真工具能够完整复现 SAR成像链，从计算机辅助设计（CAD）模型生成高保真的合成孔径雷达图像，同时纳入基本的电磁材料属性。具体而言，

它可以访问观测到的 SLC 图像 $\boldsymbol{y} \in \mathcal{Y}$、在应用系统传递函数 $\boldsymbol{H}$ 之前获得的中间 SLC 图像 $\boldsymbol{z} \in \mathcal{Z}$（对应于式（2）中的 $\mathcal{C}(\boldsymbol{x}^{\frac{1}{2}}) \odot \boldsymbol{n}$），以及场景反射率 $\boldsymbol{x} \in \mathcal{X}$。尽管 $\boldsymbol{x}$ 并不代表物理上可测量的量，但由于人工操作员很容易对其进行解释，因此它是一个有效的真实值候选。不同图像如图 1 所示。



(a) 场景反射率 $\boldsymbol{x}$。　(b) 单视复数的振幅 单视复数 $\boldsymbol{z}$。　(c) 单视复数的振幅 单视复数 $\boldsymbol{y}$。

图 1：使用 MOCEM 生成的图像。

MOCEM 软件还会为每个场景提供详细的元数据 $\boldsymbol{m} = [m_1, \cdots, m_d]^\top \in \mathcal{M} \triangleq \mathbb{R}^d$，其中 d 是每个场景的元数据参数数量，包括雷达几何参数、斜视角、采集分辨率、噪声水平以及其他特定于采集的参数。这些补充信息可用于进一步提升模型性能。

我们的方法是仅使用 MOCEM 生成的模拟合成孔径雷达图像来训练图像恢复神经网络，同时利用已知的真实值反射率场景及其相关元数据。训练完成后，这些模型将直接应用于真实的合成孔径雷达采集数据进行推理，即使缺少配对的真实数据，也能实现图像恢复。这种仿真到真实策略利用仿真的物理保真度，有效泛化至真实世界的合成孔径雷达成像场景，从而弥合合成数据训练与实际部署之间的差距。

C. 用于提升性能的输入变体和自定义损失函数

对于监督学习任务，用于训练神经网络 $f_{\boldsymbol{\theta}}$ 的最小化问题（4）可推广为

$$\min_{\boldsymbol{\theta}} \mathbb{E}_{(\boldsymbol{v},\boldsymbol{w})\sim p(\boldsymbol{v},\boldsymbol{w})}[\ell(f_{\boldsymbol{\theta}}(\boldsymbol{v}), \boldsymbol{w})] \tag{5}$$

其中，$\boldsymbol{v} \in \mathcal{V}$ 是神经网络的输入，$\boldsymbol{w} \in \mathcal{W}$ 是目标，$p(\boldsymbol{v}, \boldsymbol{w})$ 是联合分布。定义可能的输入、目标、损失函数和模型架构集合，会对复原性能产生重大影响。在模型选择方面，考虑到 DRUNet 架构 [26], 最初是为即插即用 ADMM 框架中的高斯去噪而设计，且效果出色，我们选择保留该架构并对其进行调整，以用于 SAR 图像复原。我们还实现了一个加入挤压-激励（SE）模块的 DRUNet——这些模块通过全局池化执行挤压操作，再由多层感知机（MLP）生成通道级激励权重，以重新校准特征图 [27]——我们将其称为 SEDRUNet。我们保留 $\boldsymbol{v} = (\tilde{\boldsymbol{y}}, \boldsymbol{y}^{\text{re}}, \boldsymbol{y}^{\text{im}})$，将振幅 $\tilde{\boldsymbol{y}}$ 与实部和虚部一同叠加，$\boldsymbol{y}^{\text{re}}$ 并作为神经网络的输入。尽管 $\boldsymbol{y}$的实部和虚部已包含振幅信息，我们进行了实验（结果未在论文中展示），发现利用这三个通道的信息能够提升性能。目标设为 $\boldsymbol{w} = \boldsymbol{x}$。我们提出使用不同的损失函数 ℓ来训练 DRUNet 架构：图像复原任务中常用的平均绝对误差（MAE）；感知损失（PL） [28],, 通过比较从预训练网络中提取的高层特征表示来保持感知质量；以及边缘保持损失（EPL） [29], , 通过惩罚图像梯度差异，强调保留清晰边缘和精细结构。下文中，我们将使用相应损失函数训练的模型分别记为 DRUNetEPL 和 DRUNet PL。

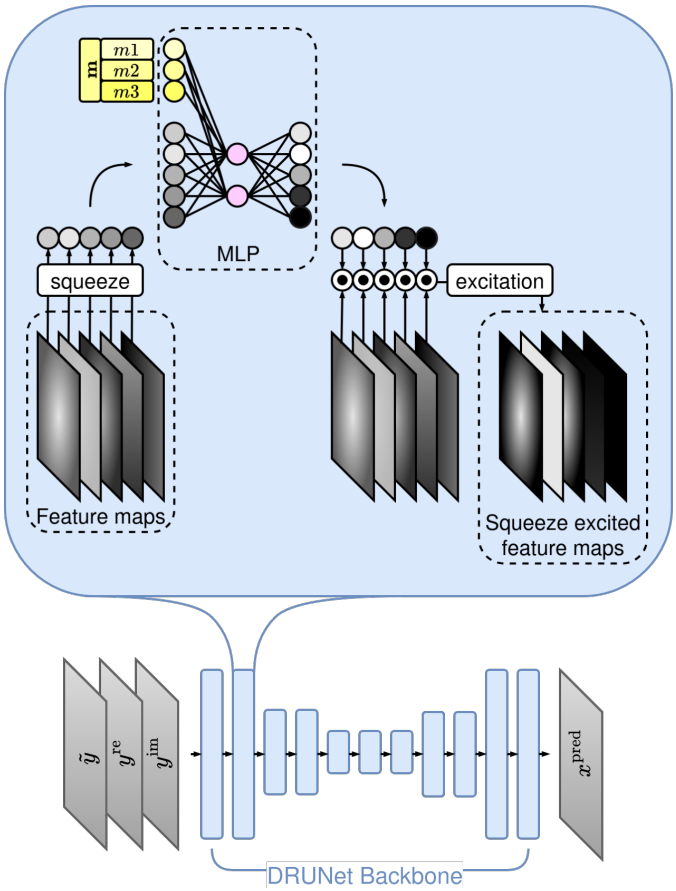


图2：M-SEDRUNet 架构概览。

最后，我们还利用数据集中可用的元数据来提升模型的复原效果。在此背景下，$\boldsymbol{v} = (\tilde{\boldsymbol{y}}, \boldsymbol{y}^{\text{re}}, \boldsymbol{y}^{\text{im}}, \boldsymbol{m})$ 和 $\boldsymbol{w} = \boldsymbol{x}$与之前保持不变。我们提出了两种不同的方法来纳入元数据。我们称之为 M-DRUNet 的简单方法，是通过输入映射传入元数据，这与图像元数据映射类似。对于每个元数据参数 m_i，都会创建一张空间尺寸与输入振幅 $\tilde{\boldsymbol{y}}$ 相同的映射

并用相应的单个元数据值填充。第二种方法称为 M-SEDRUNet，受 Plutenko 等人 [30]的研究启发，通过 SE 模块纳入元数据。随后，元数据被注入 SE 模块的多层感知机中，使其能够根据上下文动态调整。图 2 展示了 M-SEDRUNet 的元数据注入原理。

III. 实验

A. 数据准备

如前所述，我们使用了一个由 MOCEM 软件模拟生成的合成孔径雷达图像数据集。尺寸为 $n = 256 \times 256$ 的真实值图像由背景图构成，其中插入了各种 CAD模型。为确保场景多样性，我们将共计 78 个不同的 CAD模型——代表飞机、船只、天线、陆地车辆和建筑物等军用及民用物体——以不同的比例和朝向随机放置在背景图像上。背景图像本身呈现了多种环境，包括森林、道路、田野和机场。随后，使用 MOCEM 从这些合成场景中模拟真实的合成孔径雷达采集。需要注意的是，在这种情况下，MOCEM 仅准确模拟 CAD 物体的电磁散射行为；背景图像并不反映真实的雷达后向散射特性，仅用于增强场景的真实感。为使采集场景多样化，模拟过程对场景和传感器参数进行均匀采样，其中包括斜视角、空间分辨率和噪声水平等雷达采集设置。这种变化有助于生成丰富多样的数据集，使训练后的神经网络更好地适应真实场景并实现泛化。最终生成的数据集包含 5,000 个四元组（$\boldsymbol{y}$，$\boldsymbol{z}$，$\boldsymbol{x}$，$\boldsymbol{m}$）$\in \mathcal{Y}\times\mathcal{Z}\times\mathcal{X}\times\mathcal{M}$，其中 4,631 个为训练样本，369 个为验证样本。如表 I 所示，数据集划分通过隔离特定的采集参数范围来完成，以确保验证集包含训练集中未出现过的条件。这种设计明确测试神经网络对未见过的雷达采集配置的泛化能力。请注意，所有图像均根据训练集划分的统计数据进行标准化。每个元数据变量也分别采用相同的标准化流程。

元数据 \ 数据集	训练集	验证集
方位角（°）	$[0, 150[\cup]155, 360]$	$[150, 155]$
入射角（°）	$[15, 55[\cup]55.7, 75]$	$[55, 55.7]$
斜视角 (°)	$[0, 15[\cup]15.5, 45]$	$[15, 15.5]$
分辨率 (m^2)	$[0.2, 0.35[\cup]0.36, 0.6]$	$[0.35, 0.36]$
噪声水平 (db)	$[-40, -32[\cup] - 31.7, -20]$	$[-32, -31.7]$

表 I：基于模拟采集的互不重叠元数据区间划分训练集和验证集。

最后，我们使用真实的 UMBRA[1] 和 CAPELLA[2] SLC 图像作为测试集。这些图像具有与训练数据相似的统计特性，从而缩小了域差距。

[1]https://umbra.space/open-data/ [2]https://www.capellaspace.com/earth-observation/gallery

B. 实验设置

在性能评估中，我们将所提出的方法主要与 SARCAM [31]，这一专为SAR图像去斑设计的深度学习架构进行比较，同时也与最初为通用图像复原开发的 AdaIR [32] 和 IRNeXt [33]，进行比较。由于这些方法非常适合联合SAR去斑与旁瓣抑制问题，因此将其纳入比较。此外，我们还考虑了 MERLIN [22] 和 MuLoG-DRUNet [24],这两种成熟且有效的真实SAR数据去斑方法。尽管它们并未明确针对旁瓣抑制进行设计，但将其纳入能够使我们以稳健的去斑基线为参照评估所提出的方法。需要注意的是，这两个模型仅使用公开可用的预训练权重在真实 SAR 图像上进行评估。

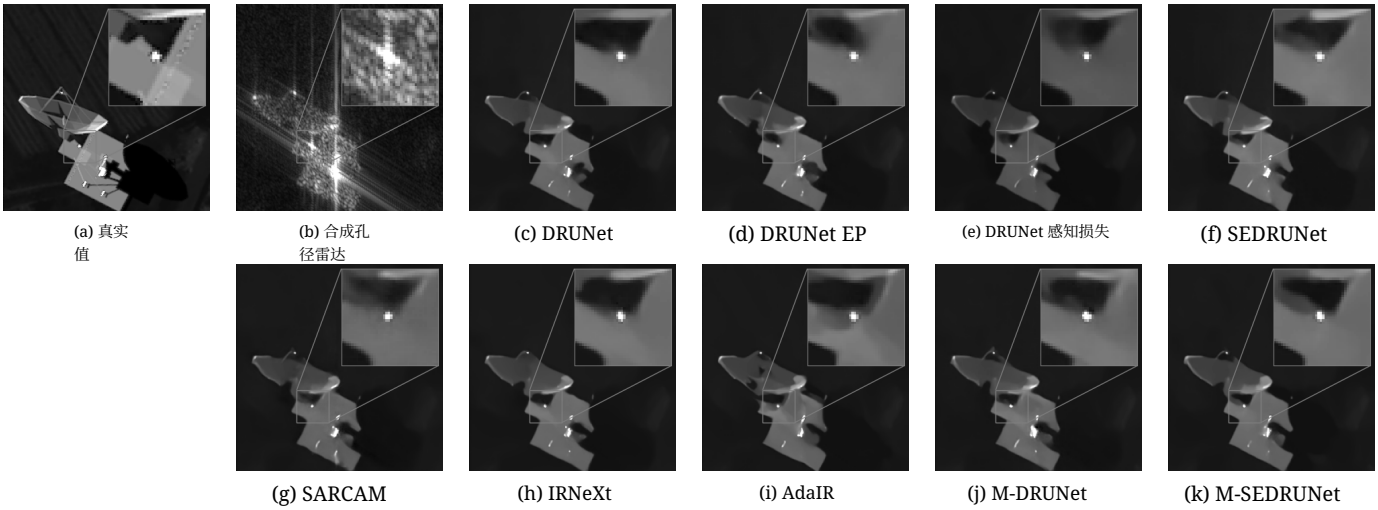
所有模型均使用 Adam优化器进行训练，初始学习率为 1×10^{-4}，并结合指数衰减计划。训练持续 200 到 400 个训练轮次，具体取决于在验证集上观察到收敛的时间。批量大小根据可用的 GPU内存进行调整。为提高泛化能力，我们采用了随机翻转和旋转等数据增强技术。我们使用峰值信噪比（PSNR）和结构相似性指数（SSIM）等经典图像复原指标评估图像质量。此外，我们还采用特征相似性指数（FSIM） [34] 和学习感知图像块相似度（LPIPS） [35],，这两种指标能够反映感知保真度，并与人类视觉感知更加一致。为评估真实 SAR 图像上的去斑性能，我们使用等效视数（ENL），该指标用于衡量均匀SAR图像区域中的斑点噪声抑制程度。由于目前尚无公认的旁瓣抑制指标，因此未使用旁瓣抑制的定量指标。

C. 模拟*SAR*图像上的结果

模型 \ 指标	峰值信噪比 ↑	结构相似性指数 ↑	特征相似性指数 ↑	学习感知图像块相似度 ↓
SARCAM	29.915	0.897	0.877	0.347
IRNeXt	30.023	0.899	0.874	0.342
AdaIR	30.040	0.899	0.878	**0.333**
DRUNet	29.794	0.897	0.876	0.338
SEDRUNet	30.012	0.899	0.874	0.339
DRUNet 感知损失	29.919	0.897	0.879	0.341
DRUNet 边缘保持损失	29.836	0.896	**0.880**	0.340
M-DRUNet	30.272	0.899	0.878	0.339
M-SEDRUNet	**30.461**	**0.901**	0.874	0.335

表 II：模拟合成孔径雷达验证集上的定量评估。

就峰值信噪比而言，表现最佳的模型是融入元数据的模型，这凸显了元数据集成对图像复原任务的影响。另一方面，根据结构相似性指数、特征相似性指数等感知度量，



(a) 真实值 (b) 合成孔径雷达 (c) DRUNet (d) DRUNet EP (e) DRUNet 感知损失 (f) SEDRUNet

(g) SARCAM (h) IRNeXt (i) AdaIR (j) M-DRUNet (k) M-SEDRUNet

图 3：真实值和恢复后的模拟SAR图像。

以及学习感知图像块相似度，各模型的表现都相当。对比 DRUNet、SEDRUNet 及其元数据驱动的对应模型可见，注入元数据能够提升模型性能，尽管提升幅度仍然有限。从视觉效果来看，所有模型复原的图像都相似（见图 3）。所有复原结果中的斑点噪声都被完全抑制，旁瓣也被清晰消除。

D. 真实 *SAR* 图像上的结果

表 III 使用等效视数指标总结了所有模型在真实 SAR 图像上的定量评估结果。面向去斑的方法 MERLIN 和 MuLoG-DRUNet 表现出优异性能，其中 MuLoG-DRUNet 达到了总体最佳的等效视数，证实了它们在真实数据上的有效性。元数据驱动的 M-SEDRUNet 获得了第二高的等效视数，超过了所有基于 DRUNet 的基线方法（DRUNet、DRUNet EPL、DRUNet PL），并证明融入获取元数据有助于提升对真实图像的泛化能力。IRNeXt 和 AdaIR 也取得了具有竞争力的结果，表明通用图像恢复模型能够很好地适用于 SAR 去斑。总体而言，这些结果表明，元数据感知架构能够达到接近专用去斑方法的性能，同时实现旁瓣抑制。

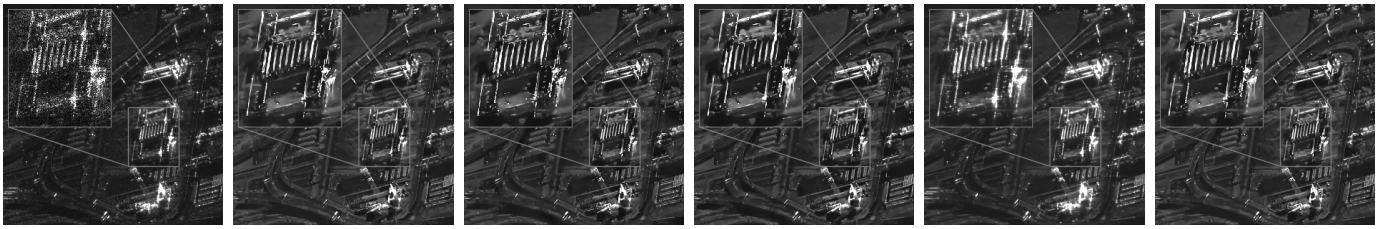
模型 \ 指标	等效视数 ↑
MERLIN	257.6
MuLoG DRUNet	**367.7**
SARCAM	121.9
IRNeXt	242.1
AdaIR	173.1
DRUNet	83.35
SEDRUNet	175.7
DRUNet 感知损失	73.71
DRUNet EPL	60.15
M-DRUNet	121.2
M-SEDRUNet	286.2

表 III：真实 SAR 图像上的定量评估。

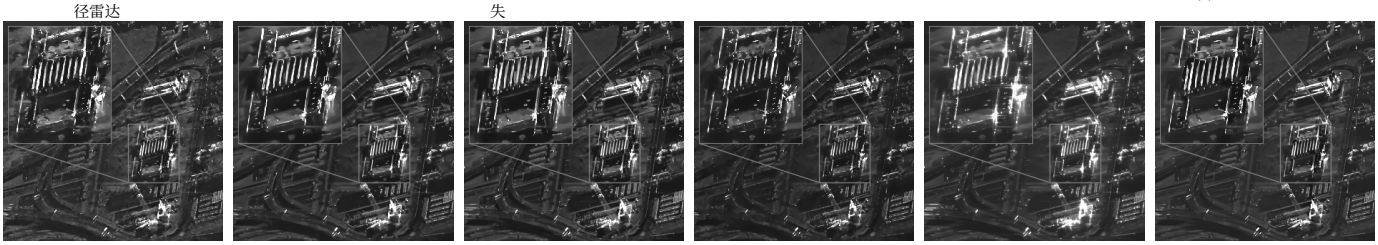
尽管等效视数无法体现 SAR 图像复原的其他关键方面，例如旁瓣抑制或结构化区域中的细节保留，但仅依赖等效视数可能无法全面评估模型的性能。因此，目视检查对于评估 SAR 图像复原的整体质量仍然至关重要。

从图 4 所示的结果来看，仅用于去斑的方法 MERLIN 和 MuLoG-DRUNet 在真实 SAR 图像上具有出色的斑点噪声抑制效果，但无法去除旁瓣伪影，因为它们并非为联合恢复而设计。相比之下，本文提出的方法以及 IRNeXt 和 AdaIR 等通用模型，均展现出去斑和旁瓣抑制能力。尽管大多数方法都能有效平滑均匀区域，但 IRNeXt 往往会过度平滑某些区域，以牺牲纹理保真度为代价实现较强的旁瓣抑制。基于 DRUNet 的模型通常能保留更多结构细节，但在存在重复图案的区域中仍会出现一定的信息损失，DRUNet PL 尤为明显。增强了元数据的变体在恢复质量方面与未使用元数据的对应方法相当，在噪声抑制和细节保留之间实现了较为均衡的权衡。更多视觉效果见图 5。

即使元数据的影响并不总能在复原图像中直接观察到，一个有趣的结果是，由元数据驱动的模型能够隐式地理解采集参数背后的物理原理，并将其用于复原任务。例如，注入一个与传感器采集原始合成孔径雷达图像时所用参数不同的分辨率参数，会影响复原图像的有效分辨率。图 6 清楚地表明，提供更高的分辨率参数会使图像细节明显增强。这一能力虽然前景可期，但也存在一些缺点。具体而言，当注入的元数据与原始采集参数显著不同时，可能会引入新的旁瓣或伪影。尽管如此，这种自适应功能为动态图像分析和复原调优开辟了新的可能性。改变入射角时也会观察到类似现象。

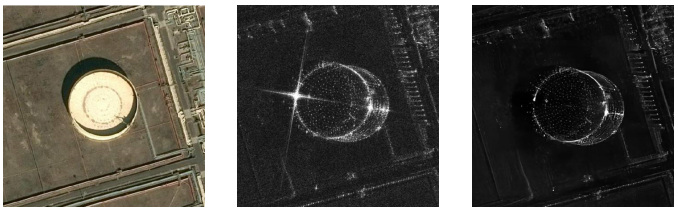


(a) 合成孔径雷达 (b) DRUNet (c) DRUNet 边缘保持损失 (d) DRUNet 感知损失 (e) MERLIN (f) SEDRUNet



(g) SARCAM (h) IRNeXt (i) AdaIR (j) M-DRUNet (k) MuLoG DRUNet (l) M-SEDRUNet

图4：真实 UMBRA 单视复数数据的复原图像。



(a) (b) (c)

图5：光学真值（a）、CAPELLA SAR图像（b）以及使用 SEDRUNet 复原的图像（c）。



(a) (b) (c)

图6：UMBRA SAR图像（a），以及使用 M-SEDRUNet 复原的结果：真实传感器分辨率设为 0.40m^2 （b），另一个分辨率设为 0.25m^2 （c）。

IV. 讨论

本研究展现了仿真到真实方法的潜力，以及将合成孔径雷达采集参数整合到神经网络中以提升性能的价值。然而，仍有若干局限性亟待解决。

在 DRUNet 和 SEDRUNet 中引入元数据已展现出性能提升，尤其是在可获取真值数据的仿真环境中。采用相同的架构基线进行比较，证实了这种方法的优势。然而，我们尚未探索在 AdaIR 和 IRNeXt 等其他先进模型中注入元数据。将元数据集成到这些架构中有望进一步提升其性能，这仍是未来值得研究的方向。

尽管当前结果证实，元数据可以根据采集条件调节网络行为，从而引导复原过程，但对这种调控的定量表征仍然有限。具体而言，元数据影响程度与伪影引入风险之间的权衡尚未得到系统评估。因此，未来工作应研究元数据权重或条件强度的变化如何影响定量指标和感知保真度。

一项主要挑战是训练期间使用的模拟图像与真实 SAR 图像之间存在域差距。对于某些 SAR 图像提供方（例如 TerraSAR-X[3],），真实图像的统计特性与训练数据中的特性有所偏离，导致图像复原效果不佳。目前尚未找到有效方法来弥合这些统计差异，这凸显了监督式训练策略在此情境下的局限性。因此，有必要探索无监督方法。近年来，深度后验采样（DPS）方法 [36] 在求解逆问题方面受到关注，其通过扩散模型学习先验信息。BlindDPS 等方法 [37] 旨在联合估计前向算子和潜在干净图像 $\boldsymbol{x}$。将此类技术应用于 SAR领域，或可实现 SAR传递函数与底层图像的联合估计，为未来研究提供一个有前景的方向。

V. 结论

在本研究中，我们提出了一种统一的深度学习框架，用于同时对合成孔径雷达图像进行去斑和旁瓣抑制。我们利用

[3]https://earth.esa.int/eogateway/missions/terrasar-x-and-tandem-x/ 样本数据

MOCEM 生成的逼真的SAR模拟数据集，其中包含真实值，使我们能够进行监督训练，有效处理 SAR 图像中的固有噪声和伪影。结果表明，将采集元数据作为辅助输入，可以提升图像复原性能，并实现对图像复原过程的引导控制。

致谢

本研究获得法国军备总局和法国国防人工智能部际局的资助。

参考文献

[1]A. Nuttall。具有优异旁瓣特性的若干窗函数。*IEEE*声学、语音与信号处理汇刊，29(1):84–91，1981年。[2] H.C. Stankwitz、R.J. Dallaire和J.R. Fienup。用于控制SAR图像旁瓣的非线性加权。*IEEE Transactions on Aerospaceand Electronic Systems*，31(1):267–279，1995年。[3] R´emy Abergel、Lo¨ıc Denis、Sa¨ıd Ladjal和Florence Tupin。用于抑制旁瓣并提取强目标的单视复数SAR图像亚像素方法。*IEEE*应用地球观测与遥感精选主题期刊，11(3):759–776，2018年。[4]Sen Yuan、Ze Yu、Chunsheng Li和Shusen Wang。一种基于CNN的全新SAR旁瓣抑制方法。*IEEE*地球科学与遥感快报，18(1):132–136，2021年。[5]Shuyi Liu、Yan Jia、Yongqing Liu、Limin Zhai和Xiangkun Zhang。一种新的BiRNN-SVA方法用于旁瓣抑制。*IEEE*应用地球观测与遥感精选主题期刊，17:1167–1175，2024年。[6] J. W. Goodman。激光散斑及相关现象。，章节：激光散斑图样的统计特性。Springer Berlin.，1984年。[7]Jos´e M. Bioucas-Dias和M´ario A. T. Figueiredo。通过变量分裂和约束优化去除乘性噪声。*IEEE*图像处理汇刊，19(7):1720–1730，2010年。[8] Charles-Alban Deledalle、Loic Denis、Sonia Tabti和Florence Tupin。Mulog，或如何将高斯去噪器应用于多通道SAR散斑抑制？*IEEE*图像处理汇刊，26(9):4389–4403，2017年9月。[9]G. Chierchia、D. Cozzolino、G. Poggi和L. Ver- doliva。通过卷积神经网络进行SAR图像去斑。载于*2017IEEEInternationalGeoscienceand RemoteSensing Symposium(IGARSS)*，第5438–5441页，2017年。[10] Puyang Wang、He Zhang和Vishal M. Patel。使用卷积神经网络进行SAR图像去斑。*IEEE*信号处理快报，24(12):1763–1767，2017年。

[11] Kai Zhang、Wangmeng Zuo、Yunjin Chen、Deyu Meng 和 Lei Zhang. 超越高斯去噪器：用于图像去噪的深度CNN残差学习. *IEEE*图像处理汇刊, 26(7):3142–3155, 2017年7月.[12] Olaf Ronneberger、Philipp Fischer 和 Thomas Brox. U-Net：用于生物医学图像分割的卷积网络. 收录于 Nassir Navab、Joachim Hornegger、William M. Wells 和 Alejandro F. Frangi 编，医学图像计算与计算机辅助手术——*MICCAI 2015*，第234–241页，Cham，2015年。施普林格国际出版公司.[13]Javier Gurrola-Ramos、Oscar Dalmau 和 Teresa E. Alarc´on. 用于图像去噪的残差密集U-Net神经网络. *IEEE Access*, 9:31742–31754, 2021年.[14] Fan Jia、Wing Hong Wong 和 Tieyong Zeng. DDUNet：用于图像去噪的密集密集U-Net. 收录于*2021 IEEE/CVF*计算机视觉国际会议研讨会（*ICCVW*），第354–364页，2021年.[15]Chi-Mao Fan、Tsung-Jung Liu 和 Kuan-Hsien Liu. SUNet：用于图像去噪的Swin Transformer U-Net. 收录于*2022*年*IEEE*国际电路与系统研讨会（*ISCAS*）. IEEE，2022年5月.[16] Jindong Jiang、Lunan Zheng、Fei Luo 和 Zhijun Zhang. REDNet：用于室内RGB-D语义分割的残差编码器-解码器网络，2018年.[17] Jaekyun Ko 和 Sanghwan Lee. 使用连续注意力模块进行SAR图像去斑. *IEEE*地球观测与遥感应用专题汇刊, 15:3–19, 2022年.[18] Puyang Wang、He Zhang 和 Vishal M. Patel. 基于生成对抗网络的斑点SAR图像复原. 收录于*2017*年第七届*IEEE*多传感器自适应处理计算进展国际研讨会（*CAMSAP*），第1–5页，2017年.[19] Ruijiao Liu、Yangyang Li 和 Licheng Jiao. 基于生成对抗网络的SAR图像斑点抑制. 收录于*2020*年国际神经网络联合会议（*IJCNN*），第1–6页，2020年.[20]Malsha V. Perera、Nithin Gopalakrishnan Nair、Wele Gedara Chaminda Bandara 和 Vishal M. Patel. 使用去噪扩散概率模型进行SAR去斑. *IEEE*地球科学与遥感快报, 20:1–5, 2023年.[21] Xuran Hu、Ziqiang Xu、Zhihan Chen、Zhengpeng Feng、Mingzhe Zhu 和 LJubisa Stankovic. 通过区域去噪扩散概率模型进行SAR去斑，2024年.[22] Emanuele Dalsasso、Lo¨ıc Denis 和 Florence Tupin. 仿佛施了魔法：利用MERLIN对深度去斑网络进行自监督训练. *IEEE*地球科学与遥感汇刊, 60:1–13, 2022年.[23] Liang Chen、Yifei Yin、Hao Shi、Qingqing Sheng 和 Wei Li. 一种基于参数共享卷积神经网络的自监督SAR图像去斑策略. 2023年.[24] Cristiano Ulondu Mendes、Lo¨ıc Denis、Charles Deledalle,

和 Florence Tupin. 即插即用极化合成孔径雷达去斑中对空间相关斑点噪声的鲁棒性. *IEEE*地球科学与遥感汇刊, 2024年.[25] Christian COCHIN、Philippe POULIGUEN、Benoit DE-LAHAYE、Daniel le HELLARD、Philippe GOSSELIN 和 Franck AUBINEAU. MOCEM——一种“多合一”的SAR图像模拟工具. 收录于第七届欧洲合成孔径雷达会议，第1–4页，2008年.[26]Kai Zhang、Yawei Li、Wangmeng Zuo、Lei Zhang、Luc Van Gool 和 Radu Timofte. 借助深度去噪器先验实现即插即用图像复原，2021年.[27] Jie Hu、Li Shen、Samuel Albanie、Gang Sun 和 Enhua Wu. 挤压激励网络，2019年.[28] Justin Johnson、Alexandre Alahi 和 Li Fei-Fei. 用于实时风格迁移和超分辨率的感知损失. 收录于欧洲计算机视觉会议，第694–711页。施普林格，2016年.[29]Ram Krishna Pandey、Nabagata Saha、Samarjit Karmakar 和 AG Ramakrishnan. MSCE：一种用于提升超分辨率算法的边缘保持鲁棒损失函数. 收录于国际神经信息处理会议，第566–575页。施普林格，2018年.[30] Iaroslav Plutenko、Mikhail Papkov、Kaupo Palo、Leopold Parts 和 Dmytro Fishman. 元数据通过多任务诱导提升分割性能. 收录于*MICCAI*领域自适应与表征迁移研讨会，第147–155页。施普林格，2023年.[31] Jaekyun Ko 和 Sanghwan Lee. 使用连续注意力模块进行SAR图像去斑. *IEEE*地球观测与遥感应用专题汇刊, 15:3–19, 2021年.[32] Yuning Cui、Syed Waqas Zamir、Salman Khan、Alois Knoll、Mubarak Shah 和 Fahad Shahbaz Khan. AdaIR：通过频率挖掘与调制实现自适应一体化图像复原. *arXiv*预印本 *arXiv:2403.14614*, 2024年.[33] Yuning Cui、Wenqi Ren、Sining Yang、Xiaochun Cao 和 Alois Knoll. IRNeXt：重新思考用于图像复原的卷积网络设计. 2023年.[34] Lin Zhang、Lei Zhang、Xuanqin Mou 和 David Zhang. FSIM：用于图像质量评估的特征相似性指数. *IEEE*图像处理汇刊, 20(8):2378–2386, 2011年.[35] Richard Zhang、Phillip Isola、Alexei A Efros、Eli Shechtman 和 Oliver Wang. 深度特征作为感知度量的惊人有效性. 收录于*IEEE*计算机视觉与模式识别会议论文集，第586–595页，2018年.[36] Hyungjin Chung、Jeongsol Kim、Michael T Mccann、Marc L Klasky 和 Jong Chul Ye. 面向一般噪声逆问题的扩散后验采样. *arXiv*预印本 *arXiv:2209.14687*, 2022年.[37]Hyungjin Chung、Jeongsol Kim、Sehui Kim 和 Jong Chul Ye. 面向盲逆问题的算子与图像并行扩散模型. 收录于论文集 *IEEE/CVF*计算机视觉与模式识别会议，第6059–6069页，2023年。