

基于自监督复数域深度学习网络的SAR有源压制 干扰抑制方法

化青龙,魏晨曦,张云,张倩,冀振元,姜义成

(哈尔滨工业大学电子与信息工程学院,黑龙江哈尔滨 150001)

摘要: 合成孔径雷达(Synthetic Aperture Radar, SAR)具有全天时、全天候、高分辨率对地观测的优势,但在成像过程中容易受到电磁干扰,进而严重影响SAR图像的判读与解译. 针对复杂对抗环境下的强有源压制干扰问题,本文提出一种基于自监督复数域深度学习的SAR有源压制干扰抑制方法,以及一种新型复数域干扰抑制网络,对权值、激活函数及卷积运算等进行了复数域处理设计,挖掘SAR复数域图像中目标和干扰在幅度和相位两方面的不同信息表征,实现对干扰的抑制. 同时本文提出一种自监督训练策略,解决传统网络训练过程严重依赖人工标注样本的问题,其适用于复杂干扰下样本难以标注的应用场景. 开展仿真分析与实测数据验证,实验结果表明所提方法可有效地抑制复杂背景下的有源压制干扰,具有自监督智能干扰抑制能力.

关键词: 合成孔径雷达;复数域深度学习;自监督;干扰抑制;压制性干扰

基金项目: 国家自然科学基金(No.61201304, No.61201308)

中图分类号: TP751

文献标识码: A

文章编号: 0372-2112(2023)04-0965-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220551

Active Jamming Suppression for SAR Images Based on Self-Supervised Complex-Valued Deep Learning

HUA Qing-long, WEI Chen-xi, ZHANG Yun, ZHANG Qian, JI Zhen-yuan, JIANG Yi-cheng

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

Abstract: Synthetic aperture radar (SAR) has the advantages of all-day, all-weather, and high-resolution in the earth observation, but it is susceptible to electromagnetic interference during the imaging process, which seriously affects the subsequent interpretation of SAR images. To this end, this paper proposes a suppression method for SAR blanketing jamming based on self-supervised complex-valued deep learning, and proposes a novel complex-valued interference suppression network, which can make full use of the amplitude and phase information of SAR complex images. The weights, activation functions and convolution operations of the network are designed for complex domain processing, and the different information representations of target and clutter in amplitude and phase in SAR images are mined to achieve interference suppression. Meanwhile, a self-supervised training strategy is proposed to solve the problem of relying heavily on manually labeled samples in the traditional network training process, and is suitable for application scenarios where samples are difficult to be labeled under complex interference. The simulation analysis and experimental verification are carried out. The experimental results show that the proposed method can effectively suppress the active jamming of complex backgrounds, and has the ability of self-supervised intelligent interference suppression.

Key words: synthetic aperture radar (SAR); complex-valued deep learning; self-supervision; interference suppression; blanketing jamming

Foundation Item(s): National Natural Science Foundation of China (No.61201304, No.61201308)

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)作为主动式对地观测雷达系统,可实现全天时、全天候的高

分辨成像,在海洋监测、地表测绘、战场侦察等方面发挥着巨大的作用^[1]. 然而SAR常常受到有源和无源的电磁干扰,导致其成像效果与信息获取能力受到破坏,

极大影响 SAR 目标高分辨成像与识别能力^[2]。特别是近几年新型干扰手段和干扰形式不断涌现,使得 SAR 系统的稳定、可靠成像受到威胁,因此研究 SAR 干扰抑制技术具有重要的现实意义和应用价值。

对于 SAR 成像系统,有源压制干扰一直是难以解决的问题。有源压制干扰通常在时域或者频域,利用强功率的干扰信号淹没 SAR 接收机的回波,以达到抑制目标、降低发现及检测概率,甚至使 SAR 丧失其信息获取能力的目的。根据干扰的来源和方式,压制干扰可分为射频噪声干扰、噪声调幅干扰、噪声调频干扰、噪声调相干扰和组合噪声干扰等^[3]。目前,干扰抑制技术主要有参数化干扰抑制、半参数化干扰抑制、非参数化干扰抑制三种。参数化方法通过构建干扰信号的数学模型,对回波信号逐方位单元估计干扰参数,进而提取干扰信号。如 Djukanovic 等学者^[4]利用高阶模糊度函数估计干扰系数,提出了一种分段多项式拟合方法来抑制多分量干扰信号。Liu 等学者^[5]提出了一种基于迭代自适应方法(Iterative Adaptive Approach, IAA)和正交子空间投影(Orthogonal Subspace Projection, OSP)的射频干扰抑制方法。该方法不需要进行参数搜索和模型阶数估计,仅 2~3 次迭代即可快速收敛。在此基础上, Yang 等学者^[6]进一步利用 IAA 提高短时傅里叶变换中的瞬时频率分辨率,再利用 OSP 来抑制干扰。研究表明,参数化方法的干扰抑制效果严重依赖于模型的准确性,通常仅适用于单一类型的干扰信号抑制问题,并且计算量较大。半参数化方法将真实信号和干扰信号的分离问题转换为超参数的优化问题,如可以通过稀疏重构理论构造优化模型,并迭代求解最优的超参数。Liu 等学者^[7]提出了一种联合估计方法,在时频域对干扰信号进行稀疏重构表示,通过求解优化模型完成干扰抑制。Su 等学者^[8]利用稳健主成分分析(Robust Principal Component Analysis, RPCA)方法通过低秩恢复对抗 SAR 干扰,具备更稳健的抗干扰性能。Huang 等学者^[9]提出了一种“低秩+稀疏”分解模型来提取干扰信号并保留有用信号。半参数化方法不仅利用优化模型来约束干扰,同时还在优化模型中保护了真实信号,故理论上其抗干扰性较优。但是其抗干扰性能的优劣取决于超参数取值和优化模型的选取,且计算量较大。非参数化方法无需进行精细建模和参数估计,利用干扰信号与真实信号在回波域、空域、频域和时频域的特征差异,通过滤波器或特征分解滤除干扰信号,如陷波法^[10,11]、特征分解法^[12]和子空间投影法^[13]等。大多数非参数化方法具有一定局限性,并且由于缺乏对真实回波的约束,容易对有用信号造成一定的损失。传统的干扰抑制方法需要针对特定问题进行具体分析,一定程度上限制了传统方法在实际场景中的应用。

随着深度学习的快速发展,卷积神经网络(Convolutional Neural Network, CNN)在 SAR 干扰抑制领域表现出卓越的性能^[14]。Zhang 等学者^[15]提出了一个端到端的 CNN 架构,采用特征融合滤波器抑制干扰,可同时实现干扰抑制与目标检测。Qu 等学者^[16]提出了一种基于鲁棒功率谱特征的干扰识别网络 JRNet,可以识别十种干扰信号。通过整合残差卷积和非对称卷积, JRNet 能够解决退化问题并增强对干扰信号的特征提取能力。周峰等学者^[17]提出了一种基于深度残差网络的 SAR 干扰抑制方法,利用短时傅里叶变换将原始回波逐方位向单元变换到时频域,对存在干扰的信号通过干扰抑制网络进行干扰抑制,再利用逆短时傅里叶变换得到无干扰的信号。以上研究利用 CNN 构造“端到端”的网络架构,并需要大量成对的有干扰与无干扰 SAR 样本进行监督训练。在实际应用中,干扰变化复杂,难以预测,因此成对的有干扰与无干扰标注 SAR 样本难以获取,限制了基于深度学习的干扰抑制方法的性能发挥。其次, SAR 图像是带有相位信息的复数数据,而以上研究大多仅考虑 SAR 图像的幅度信息,缺乏对 SAR 复数图像蕴含相位信息的感知能力。

因此,本文提出一种基于自监督复数域深度学习的 SAR 有源压制干扰抑制方法。相比于传统干扰抑制方法,所提方法既不需要对干扰进行精细建模,也不需要设计滤波结构。针对现有网络缺乏相位信息处理能力的问题,本文提出一种复数域 UNet++(Complex-Valued UNet++, CV-UNet++) 干扰抑制网络。CV-UNet++ 中的全部元素均属于复数域,充分利用 SAR 复数域图像目标和干扰在幅度和相位信息表征。相对于基于监督学习的干扰抑制方法,本文设计一种自监督训练策略,避免了实际应用中成对的有干扰与无干扰标注样本难以获取的问题,仅利用被干扰的 SAR 图像即可进行网络训练。本文结合压制干扰的信号特点和均方误差(Mean Squared Error, MSE)损失函数,通过数学推导验证了所提自监督训练策略的合理性;通过与传统干扰抑制方法进行性能比较,验证了所提方法对 SAR 有源压制干扰抑制的有效性。

2 SAR 有源压制干扰抑制

本文所提 SAR 有源压制干扰抑制方法的基本思路是:首先,挖掘 SAR 图像中目标和干扰的相位与幅度信息,构建 SAR 图像干扰抑制网络 CV-UNet++;其次,提出自监督训练策略,利用被干扰的 SAR 图像样本进行网络训练;最后,针对复杂对抗环境下的强有源压制干扰,采用复数域深度学习网络 CV-UNet++ 进行 SAR 图像干扰抑制。

2.1 CV-UNet++干扰抑制网络

基于复数域深度学习网络 CV-UNet++可以有效进行SAR单视复图像域的干扰抑制,CV-UNet++的结构图如图1所示. CV-UNet++是对传统UNet++^[18]网络在复数领域的扩展与延拓,该网络可以充分利用现有SAR单视复图的幅度和相位信息. 从CV-UNet++网络架构看其分为五层. 第一层由5个复数域残差卷积单元(Complex-valued Residual Unit, CvRU)组成,第二层由4个复数域残差卷积单元组成,以此类推. CV-UNet++同层之间的CvRU采用密集跳跃连接,上层CvRU的输出经下采样后输入到下层的CvRU,下层CvRU的输出经上采样后输入到上层的CvRU. 第一层至第五层中CvRU的卷积核个数依次为8,16,32,64和128.

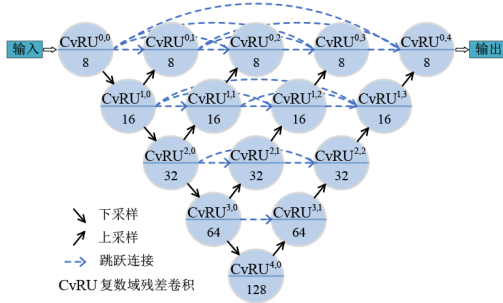


图1 CV-UNet++架构图

2.1.1 CV-UNet++前向传播

首先给出复数域深度学习网络 CV-UNet++的前向传播理论分析. 假设 $CvRU^{i,k}$ 表示第 i 层第 k 个 CvRU, $\boldsymbol{o}^{i,k}$ 表示 $CvRU^{i,k}$ 的输出, 则 $\boldsymbol{o}^{i,k}$ 的计算公式为

$$\boldsymbol{o}^{i,k} = \begin{cases} d(CvRU(\boldsymbol{o}^{i-1,k})), & k=0 \\ CvRU(c(\boldsymbol{o}^{i,0}, \dots, \boldsymbol{o}^{i,k-1}, u(\boldsymbol{o}^{i+1,k-1}))), & k>0 \end{cases} \quad (1)$$

其中, $CvRU(\cdot)$ 表示取复数域残差卷积运算, $d(\cdot)$ 表示下采样, $u(\cdot)$ 表示上采样, $c(\cdot)$ 表示矩阵拼接运算. 除了最后一层的 CvRU 外, 第一到四层 CvRU 的输入都包含同一层其他 CvRU 的输出以及下一层对应 CvRU 的上采样值.

CvRU 如图 2 所示. CvRU 将残差卷积扩展到复数域, 可增强网络的特征提取能力, 避免深层网络梯度消失. CvRU 的计算过程如下: 对于输入特征图 \boldsymbol{X} , 进行二维卷积、批归一化(Batch Normalization, BN)以及非线性激活得到中间变量 \boldsymbol{Z} , 计算过程如式(2)所示.

$$\boldsymbol{Z} = f(\text{BN}(\boldsymbol{W}_1^{\Re} * \boldsymbol{X}^{\Re} - \boldsymbol{W}_1^{\Im} * \boldsymbol{X}^{\Im})) + j \cdot f(\text{BN}(\boldsymbol{W}_1^{\Re} * \boldsymbol{X}^{\Im} + \boldsymbol{W}_1^{\Im} * \boldsymbol{X}^{\Re})) \quad (2)$$

其中, \Re 和 \Im 分别代表实部和虚部, \boldsymbol{W}_1 为与输入特征图 \boldsymbol{X} 连接的权值矩阵, $*$ 表示卷积操作, j 为虚数单位, $\text{BN}(\cdot)$ 表示批归一化操作, $f(\cdot)$ 代表激活函数, 采用

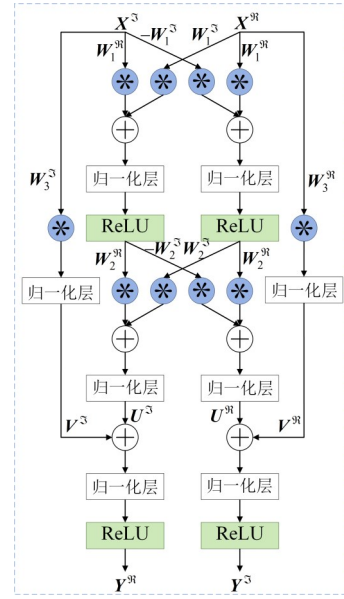


图2 复数域残差卷积单元 CvRU

ReLU 激活函数.

\boldsymbol{Z} 进行二维卷积以及批归一化得到中间变量 \boldsymbol{U} .

$$\boldsymbol{U} = \text{BN}(\boldsymbol{W}_2^{\Re} * \boldsymbol{Z}^{\Re} - \boldsymbol{W}_2^{\Im} * \boldsymbol{Z}^{\Im}) + j \cdot \text{BN}(\boldsymbol{W}_2^{\Re} * \boldsymbol{Z}^{\Im} + \boldsymbol{W}_2^{\Im} * \boldsymbol{Z}^{\Re}) \quad (3)$$

\boldsymbol{X} 的实部和虚部分别进行二维卷积和批归一化得到 \boldsymbol{V}^{\Re} 和 \boldsymbol{V}^{\Im} .

$$\boldsymbol{V} = \text{BN}(\boldsymbol{W}_3^{\Re} * \boldsymbol{X}^{\Re}) + j \cdot \text{BN}(\boldsymbol{W}_3^{\Im} * \boldsymbol{X}^{\Im}) \quad (4)$$

\boldsymbol{V}^{\Re} 与 \boldsymbol{U} 的实部相加, 得到 CvRU 输出 \boldsymbol{Y} 的实部 \boldsymbol{Y}^{\Re} , \boldsymbol{V}^{\Im} 与 \boldsymbol{U} 的虚部相加得到 \boldsymbol{Y} 的虚部 \boldsymbol{Y}^{\Im} .

$$\boldsymbol{Y} = f(\boldsymbol{U}^{\Re} + \boldsymbol{V}^{\Re}) + j \cdot f(\boldsymbol{U}^{\Im} + \boldsymbol{V}^{\Im}) \quad (5)$$

2.1.2 CV-UNet++反向传播

CV-UNet++采用均方误差构造损失函数. 令 \boldsymbol{Y} 为最后一个复数域残差卷积单元 $CvRU^{0,4}$ 的输出, $\hat{\boldsymbol{Y}}$ 为期望输出, 则总的均方误差可以表示为

$$\mathcal{L}_{\text{MSE}} = \frac{1}{2} \|\boldsymbol{Y} - \hat{\boldsymbol{Y}}\|_2^2 \quad (6)$$

定义 \mathcal{L}_{MSE} 对 \boldsymbol{Y} 的误差项为

$$\boldsymbol{\delta}_Y = \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{Y}^{\Re}} + j \cdot \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{Y}^{\Im}} = \boldsymbol{Y}^{\Re} - \hat{\boldsymbol{Y}}^{\Re} + j \cdot (\boldsymbol{Y}^{\Im} - \hat{\boldsymbol{Y}}^{\Im}) \quad (7)$$

由式(5), 根据链式求导法则可得 \mathcal{L}_{MSE} 对 \boldsymbol{U} 的误差项为

$$\begin{aligned} \boldsymbol{\delta}_U &= \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{U}^{\Re}} + j \cdot \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{U}^{\Im}} \\ &= \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{Y}^{\Re}} \frac{\partial \boldsymbol{Y}^{\Re}}{\partial \boldsymbol{U}^{\Re}} + \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{Y}^{\Im}} \frac{\partial \boldsymbol{Y}^{\Im}}{\partial \boldsymbol{U}^{\Re}} \\ &\quad + j \cdot \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{Y}^{\Re}} \frac{\partial \boldsymbol{Y}^{\Re}}{\partial \boldsymbol{U}^{\Im}} + j \cdot \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial \boldsymbol{Y}^{\Im}} \frac{\partial \boldsymbol{Y}^{\Im}}{\partial \boldsymbol{U}^{\Im}} \\ &= \boldsymbol{\delta}_Y^{\Re} \odot f'(\boldsymbol{U}^{\Re} + \boldsymbol{V}^{\Re}) + j \cdot \boldsymbol{\delta}_Y^{\Im} \odot f'(\boldsymbol{U}^{\Im} + \boldsymbol{V}^{\Im}) \end{aligned} \quad (8)$$

其中, $f'(\cdot)$ 代表激活函数 $f(\cdot)$ 的导数, \odot 是哈达玛积, 表示矩阵对应元素相乘的运算. 同理可得 V 的误差项为

$$\begin{aligned} \delta_V &= \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial V^{\text{Re}}} + j \cdot \frac{\partial \mathcal{L}_{\text{MSE}}}{\partial V^{\text{Im}}} \\ &= (Y^{\text{Re}} - \hat{Y}^{\text{Re}}) \odot f'(U^{\text{Re}} + V^{\text{Re}}) \\ &\quad + j \cdot (Y^{\text{Im}} - \hat{Y}^{\text{Im}}) \odot f'(U^{\text{Im}} + V^{\text{Im}}) \end{aligned} \quad (9)$$

由式(3)和(8), 可得 Z 的误差项为

$$\begin{aligned} \delta_Z &= \delta_U^{\text{Re}} * W_2^{\text{Re}} + \delta_U^{\text{Im}} * W_2^{\text{Im}} \\ &\quad - j \cdot \delta_U^{\text{Re}} * W_2^{\text{Im}} + j \cdot \delta_U^{\text{Im}} * W_2^{\text{Re}} \end{aligned} \quad (10)$$

由式(2)和(10), 可得权值矩阵 W_1 的误差项为

$$\begin{aligned} \delta_{W_1} &= \delta_Z^{\text{Re}} * X^{\text{Re}} + \delta_Z^{\text{Im}} * X^{\text{Im}} \\ &\quad - j \cdot \delta_Z^{\text{Re}} * X^{\text{Im}} + j \cdot \delta_Z^{\text{Im}} * X^{\text{Re}} \end{aligned} \quad (11)$$

同理可得, \mathcal{L}_{MSE} 对权值矩阵 W_2 和 W_3 的误差项分别为

$$\begin{aligned} \delta_{W_2} &= \delta_U^{\text{Re}} * Z^{\text{Re}} + \delta_U^{\text{Im}} * Z^{\text{Im}} \\ &\quad - j \cdot \delta_U^{\text{Re}} * Z^{\text{Im}} + j \cdot \delta_U^{\text{Im}} * Z^{\text{Re}} \end{aligned} \quad (12)$$

$$\delta_{W_3} = \delta_V^{\text{Re}} * X^{\text{Re}} + j \cdot \delta_V^{\text{Im}} * X^{\text{Im}} \quad (13)$$

在得到权值矩阵 W_1 , W_2 和 W_3 的误差项后, 可通过式(14)完成 CvRU 的权值更新.

$$W_q \leftarrow W_q - \eta \delta_{W_q} \quad (14)$$

其中, q 取 1, 2, 3, η 代表学习率.

2.2 自监督干扰抑制训练策略

经过前向传播与深层特征提取后, CV-UNet++ 的输出是与输入尺寸相同的复值数据. 因此, CV-UNet++ 本身可看作一个映射函数, 实现从被干扰 SAR 图像到无干扰 SAR 图像的映射. 根据式(6), 如果使用标注的无干扰 SAR 图像作为期望输出 \hat{Y} , 则上述前向与反向传播算法属于监督学习范畴. 但由于成对的有干扰与无干扰标注样本难以获取, 因此本文提出一种自监督训练策略, 整体流程如图3所示. 该策略通过伯努利采样构造 SAR 图像对, 并输入 CV-UNet++ 进行训练, 仅利用被干扰的 SAR 图像样本训练使网络具备干扰抑制能力.

令 $S \in \mathbb{C}^{W \times H}$ 为受到干扰的 SAR 复数域图像, 图像尺寸为 $W \times H$. $T \in \mathbb{C}^{W \times H}$ 为无干扰的真实 SAR 图像, $J \in \mathbb{C}^{W \times H}$ 为干扰, $N \in \mathbb{C}^{W \times H}$ 为噪声. 则 S 可以由如下加

性模型得到:

$$S = T + J + N \quad (15)$$

以射频噪声干扰为例, 干扰信号的表达式为

$$J(t) = U_n(t) \cos[\omega_0 t + \varphi(t)] \quad (16)$$

其中, $U_n(t)$ 为服从瑞利分布的噪声, $\varphi(t)$ 为服从 $(0, 2\pi)$ 的均匀分布相位函数, 且和 $U_n(t)$ 相互独立, ω_0 为载频. 则干扰信号的概率密度函数为

$$p(\|J\|) = \frac{\|J\|}{\sigma^2} \exp\left(-\frac{\|J\|^2}{2\sigma^2}\right) \quad (17)$$

其中, σ 表示瑞利分布参数, $\|\cdot\|$ 表示幅度. 干扰的相位服从均匀分布, 可表示为

$$p(\arg(J)) \sim U(0, 2\pi) \quad (18)$$

对于 SAR 复数域图像 S , 定义两个与 S 尺寸一致的伯努利采样矩阵 B_1 与 B_2 为

$$(B_1)_{w,h} = \begin{cases} 1, & \text{probability } 1-p \\ 0, & \text{probability } p \end{cases} \quad (19)$$

$$(B_2)_{w,h} = \begin{cases} 0, & \text{if } (B_1)_{w,h} = 1 \\ 1, & \text{if } (B_1)_{w,h} = 0 \end{cases} \quad (20)$$

其中, $(B_1)_{w,h}$ 和 $(B_2)_{w,h}$ 分别为 B_1 与 B_2 中第 h 行第 w 列的像素值, $p \in (0, 1)$ 表示伯努利分布的概率.

然后, 根据 SAR 图像 S 和采样矩阵 (B_1, B_2) 生成用于网络训练的 SAR 干扰图像对 $(\tilde{S}_1, \tilde{S}_2)$, \tilde{S}_1 是经采样矩阵 B_1 采样的结果, \tilde{S}_2 是经 B_2 采样的结果, 即

$$(\tilde{S}_1, \tilde{S}_2) = (S \odot B_1, S \odot B_2) \quad (21)$$

其中, \tilde{S}_1 作为 CV-UNet++ 的输入图像, \tilde{S}_2 作为对应的标签图像. 伯努利采样图像对 $(\tilde{S}_1, \tilde{S}_2)$ 的示例如图4所示.




图4 伯努利采样图像

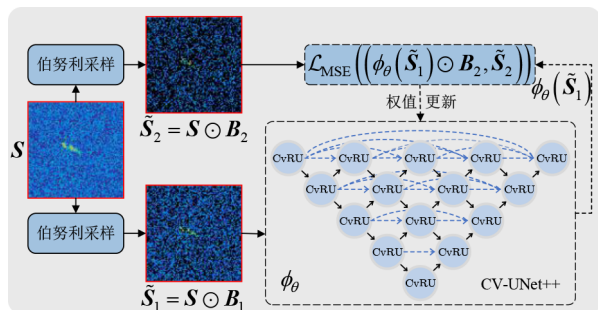


图3 自监督训练策略流程图

利用采样得到的 SAR 干扰图像对 $(\tilde{S}_1, \tilde{S}_2)$, 可以训练干扰抑制网络 CV-UNet++. 为了后续表述方便, 用 ϕ_θ 代表 CV-UNet++, θ 为 ϕ_θ 的参数. 将 \tilde{S}_1 作为 ϕ_θ 训练输入, \tilde{S}_2 作为训练目标. ϕ_θ 的训练可以看作使网络输出图像 $\phi_\theta(\tilde{S}_1)$ 与 \tilde{S}_2 之间达到最小损失函数 \mathcal{L}_{MSE} 的参数 θ 的优化过程, 其本质上是通过对 S 的一部分像素信息去拟合 S 的其他像素信息. 由于 SAR 原始

图像相邻像素之间具有相干性,而噪声干扰信号却不具相干性,因此网络可根据 \mathbf{S} 的部分像素信息实现对 \mathbf{T} 的拟合,却无法拟合干扰 \mathbf{J} 和噪声 \mathbf{N} .对于无法拟合的信号分量,在统计上将被拟合为理论期望值(即为零),从而实现干扰抑制^[19].

在此,利用数学推导证明该训练策略的合理性.假设有一个包含大量SAR干扰图像的数据集. ϕ_θ 的训练过程可以表述为

$$\begin{aligned} & \arg \min_{\theta} \left\{ \mathcal{L}_{\text{MSE}} \left(\left(\phi_{\theta}(\tilde{\mathbf{S}}_1) \odot \mathbf{B}_2, \tilde{\mathbf{S}}_2 \right) \right) \right\} \\ & = \arg \min_{\theta} \left\{ \frac{1}{2} \cdot \frac{1}{N} \cdot \sum_{n=1}^N \left(\phi_{\theta}(\tilde{\mathbf{S}}_1^{(n)}) \odot \mathbf{B}_2^{(n)} - \tilde{\mathbf{S}}_2^{(n)} \right)^2 \right\} \end{aligned} \quad (22)$$

其中, N 为训练数据集中的样本个数, $\tilde{\mathbf{S}}_1^{(n)}$ 和 $\tilde{\mathbf{S}}_2^{(n)}$ 表示第 n 个训练图像样本 $\tilde{\mathbf{S}}^{(n)}$ 经伯努利采样后的图像对, $\mathbf{B}_2^{(n)}$ 为第 n 个训练图像样本 $\tilde{\mathbf{S}}^{(n)}$ 的伯努利采样矩阵.由于均方误差损失函数是凸函数,为了求解式(22),可以进行如下推导:

$$\begin{aligned} & \frac{d\mathcal{L}_{\text{MSE}}}{d\phi_{\theta}(\tilde{\mathbf{S}}_1)} = 0 \\ & \Downarrow \\ & \frac{1}{N} \sum_{n=1}^N \left(\phi_{\theta}(\tilde{\mathbf{S}}_1^{(n)}) \odot \mathbf{B}_2^{(n)} - \tilde{\mathbf{S}}_2^{(n)} \right) = 0 \\ & \Downarrow \\ & \frac{1}{N} \sum_{n=1}^N \left(\phi_{\theta}(\tilde{\mathbf{S}}_1^{(n)}) \odot \mathbf{B}_2^{(n)} \right) = \frac{1}{N} \sum_{n=1}^N \left(\tilde{\mathbf{S}}_2^{(n)} \right) \\ & \Downarrow \\ & \mathbb{E} \left(\phi_{\theta}(\tilde{\mathbf{S}}_1) \odot \mathbf{B}_2 \right) = \mathbb{E} \left(\tilde{\mathbf{S}}_2 \right) \end{aligned} \quad (23)$$

其中, \mathbb{E} 是期望算子.由式(21)得 $\tilde{\mathbf{S}}_2 = \mathbf{S} \odot \mathbf{B}_2$,所以 $\mathbb{E}(\tilde{\mathbf{S}}_2) = \mathbb{E}(\mathbf{S} \odot \mathbf{B}_2)$.又干扰 \mathbf{J} 与噪声 \mathbf{N} 的期望为零,所以 \mathbf{S} 和 \mathbf{T} 的期望相同,即

$$\begin{aligned} \mathbb{E}(\mathbf{S} \odot \mathbf{B}_2) &= \mathbb{E}((\mathbf{T} + \mathbf{J} + \mathbf{N}) \odot \mathbf{B}_2) \\ &= \mathbb{E}(\mathbf{T} \odot \mathbf{B}_2 + \mathbf{J} \odot \mathbf{B}_2 + \mathbf{N} \odot \mathbf{B}_2) \\ &= \mathbb{E}(\mathbf{T} \odot \mathbf{B}_2) \end{aligned} \quad (24)$$

根据式(23)和(24)可得

$$\mathbb{E} \left(\phi_{\theta}(\tilde{\mathbf{S}}_1) \odot \mathbf{B}_2 \right) = \mathbb{E}(\mathbf{T} \odot \mathbf{B}_2) \quad (25)$$

所以

$$\mathbb{E} \left(\phi_{\theta}(\tilde{\mathbf{S}}_1) \right) \approx \mathbb{E}(\mathbf{T}) \quad (26)$$

由式(26)可得,当 \mathcal{L}_{MSE} 取最小值时,干扰抑制网络 ϕ_θ 输出的期望与无干扰的真实SAR图像 \mathbf{T} 的期望近似相同.所以,理论上当样本的数量足够大时(即 $N \rightarrow \infty$),实际采用五万量级的SAR干扰样本,则无需成对的有干扰与无干扰标注样本,仅利用被干扰的SAR图像样本进行训练,干扰抑制网络 ϕ_θ 即可获得最优权

值参数 θ^* ,并具备良好的干扰抑制能力.

最后,利用训练好的CV-UNet++对测试集进行测试,实现SAR干扰抑制.在测试过程中,由于图像经过伯努利采样后会随机丢失图像的部分像素信息,因此在测试过程中,对图像进行多次伯努利采样后输入到CV-UNet++进行干扰抑制,并将CV-UNet++的多个输出结果进行平均作为最终的干扰抑制结果.在深度学习中,对多次输出结果进行平均作为最终结果的处理方式并不鲜见^[20].假设对被干扰图像 \mathbf{S} 进行 K 次伯努利采样,采样结果记为集合 $\{\tilde{\mathbf{S}}_1, \tilde{\mathbf{S}}_2, \dots, \tilde{\mathbf{S}}_K\}$,将 $\{\tilde{\mathbf{S}}_1, \tilde{\mathbf{S}}_2, \dots, \tilde{\mathbf{S}}_K\}$ 输入到训练好的CV-UNet++中得到 K 个网络输出 $\{\phi_{\theta}(\tilde{\mathbf{S}}_1), \phi_{\theta}(\tilde{\mathbf{S}}_2), \dots, \phi_{\theta}(\tilde{\mathbf{S}}_K)\}$,再对网络的所有输出结果进行平均得到最终的干扰抑制结果 $\tilde{\mathbf{S}}_{\text{ave}}$,即

$$\tilde{\mathbf{S}}_{\text{ave}} = \frac{1}{K} \sum_{k=1}^K \phi_{\theta}(\tilde{\mathbf{S}}_k) \quad (27)$$

基于自监督复数域深度学习网络的SAR有源压制干扰抑制方法具体步骤如算法1所列.

算法1 基于自监督复数域深度学习网络的SAR有源压制干扰抑制方法

输入: 被干扰的SAR回波信号.

输出: CV-UNet++最佳模型参数 θ^* 与SAR干扰抑制结果.

1. 初始化CV-UNet++参数,学习率 η ,迭代次数 $l \leftarrow 0$,最大迭代次数 L_{max} ,伯努利采样次数 K ;
 2. SAR回波进行距离压缩与成像处理,构造训练集 \mathcal{S}_1 和测试集 \mathcal{S}_2 ;
 - 训练阶段**
 3. While $l < L_{\text{max}}$ Do
 4. $l \leftarrow l + 1$;
 5. 随机从训练集 \mathcal{S}_1 中选取小批量样本;
 6. CV-UNet++前向传播并计算均方误差损失 \mathcal{L}_{MSE} ;
 - (a) 根据式(19)-(21)进行伯努利采样构造SAR图像对;
 - (b) 根据式(1)-(5)进行前向传播;
 - (c) 根据式(6)计算均方误差损失 \mathcal{L}_{MSE} ;
 7. 根据式(7)-(13)进行误差反向传播,并根据式(14)更新网络权值 θ ;
 8. End While
 - 干扰抑制阶段**
 9. 根据训练所得最佳模型参数 θ^* 构建干扰抑制网络CV-UNet++;
 10. 从测试集 \mathcal{S}_2 中选取被干扰的SAR样本进行 K 次伯努利采样,并输入到CV-UNet++前向传播,根据式(27)得到最终干扰抑制结果;
 11. 分析CV-UNet++干扰抑制性能.
-

3 实验结果分析

为了验证所提方法的有效性,本文在GF-3卫星实测SAR回波数据的基础上,叠加仿真的压制性噪声干扰信号,从而得到被干扰的SAR回波数据.实测数据

选取中国大连附近海域的 SAR 数据,其脉冲重复频率为 1 388 Hz,雷达平台高度为 755 km,发射信号带宽为 200 MHz,中心频率为 5.4 GHz.此外,采用与 CV-UNet++配置相同的实数域网络 UNet++、基于特征分解的干扰抑制方法、RPCA 进行对比分析.为了进行比较,UNet++的自由度与 CV-UNet++相同,其卷积核个数分别为 16,32,64,128 和 256.在 UNet++中,需要将 SAR 图像的实部和虚部作为两个独立的通道输入到网络中.

本文先以射频噪声干扰为例详细分析所提方法在不同伯努利采样次数 K 、不同瑞利分布参数 σ 、不同伯努利采样概率 p 、不同训练样本量下的性能表现,再探究所提方法在噪声调幅干扰、噪声调频干扰、噪声调相干扰和组合噪声干扰情况下的干扰抑制效果.

3.1 模型训练

实验所用原始 SAR 图像如图 5(a)所示(水平方向为距离向,垂直方向为方位向,下同),从图中可以看到,海面上有较多舰船,海岸线附近有大面积建筑群.对受到压制性干扰信号的回波数据采用距离-多普勒算法进行成像处理,结果如图 5(b)所示,可以看出,由于干扰的存在,舰船、建筑等地面目标被干扰信号掩盖,严重降低了 SAR 获取信息的能力.




图5 实验 SAR 数据

在被干扰的 SAR 图像上选取一个训练区域 R_0 ,三个测试区域 R_1 , R_2 和 R_3 .在训练区域 R_0 中随机裁剪尺寸为 128×128 的 SAR 切片,构造训练样本集.训练样本集包含被干扰的 SAR 切片 50 000 个.训练参数设置为:迭代次数 10,每批次训练样本数目为 16,初始学习率 0.000 1,迭代 6 次学习率降为 0.000 01,优化算法为 Adam,伯努利分布概率为 0.3.环境架构为:Python3.6, CUDA10.0, cudnn7.5, Tensorflow1.14.

利用所构造的训练样本集,通过自监督训练策略训练 UNet++ 和 CV-UNet++,损失函数收敛曲线如图 6 所示.从收敛曲线可以看出,两者的收敛过程均较为稳定.在初始阶段,UNet++的损失低于 CV-UNet++,但在训练中后期,UNet++的损失基本稳定在 0.51,而 CV-

UNet++的损失仍持续收敛,并逐渐低于 UNet++,收敛曲线在一定程度上体现了复数域神经网络的优越性.





图6 损失函数收敛曲线

3.2 射频噪声干扰抑制结果分析

采用传统特征分解方法、RPCA、UNet++ 和 CV-UNet++对三个测试区域 R_1 , R_2 和 R_3 进行干扰抑制的结果如图 7 所示.射频噪声干扰信号的瑞利分布参数 σ 取 600.瑞利分布参数 σ 越大,干扰信号的功率越大,SAR 数据受干扰程度越严重.UNet++ 和 CV-UNet++ 的伯努利采样次数 K 取 16.由图 7 可以看出,特征分解方法具有一定的干扰抑制效果,但仍残留相当一部分的干扰信号能量.RPCA 对背景较为单一的测试区域 R_1 , R_2 具有较好的干扰抑制效果,但是对背景较为复杂的测试区域 R_3 的干扰抑制效果较差.UNet++ 和 CV-UNet++ 干扰抑制后的图像质量均得到了极大改善,被强干扰掩盖的舰船、建筑等地物目标得以有效恢复.CV-UNet++ 的干扰效果最好,在最大程度上保留了感兴趣目标的原始性和完整性,并且几乎不会造成目标中包含的信息或能量的损失,充分反映了所提自监督训练策略和 CV-UNet++ 对 SAR 图像干扰抑制的优势.

采用信干噪比(Signal-to-Interference plus Noise Ratio, SINR)、文献[21]定义的改善因子、文献[22]定义的干扰能量抑制比(Interference Energy Suppression Ratio, IESR)、图像熵共四个指标对上述干扰抑制结果进行定量分析.改善因子为处理后图像的 SINR 与被干扰 SAR 图像 SINR 的差值.SINR 越大、图像熵越小,则图像的质量越好.测试区域 R_1 , R_2 和 R_3 的干扰抑制统计结果如表 1~3 所示.由表 1~3 可得,与原始图像相比,被干扰图像的 SINR 下降近 20 dB,图像熵变大,图像质量被严重破坏;经过特征分解方法的干扰抑制处理后,SINR 提升 5~8 dB,IESR 为 -1~2 dB,图像熵略有下降;RPCA 对测试区域 R_1 , R_2 的干扰抑制效果优于特征分解方法,SINR 提升近 7 dB,IESR 为 6~8 dB,图像熵下降较为明显,但对测试区域 R_3 的干扰抑制效果劣于特征分解方法,SINR 提升仅 1.45 dB,IESR 为 2.28;UNet++ 干扰抑制结果的 SINR 提升超过 9 dB,IESR 为 5~11 dB,图像质量得到了较好的改善;CV-UNet++ 干扰抑制结果在各个指



(a) 原始图像 (b) 被干扰图像 (c) 特征分解 (d) RPCA (e) UNet++ (f) CV-UNet++
图7 干扰抑制结果

标上均有最优表现, SINR 提升在 10~12 dB 之间, IESR 为 11~13 dB, 图像熵与原图最为接近. 定量实验结果体现了所提自监督训练策略与 CV-UNet++ 在压制干扰抑制方面的相对优势.

表1 测试区域 R1 干扰抑制统计结果

指标	原始图像	被干扰图像	特征分解	RPCA	UNet++	CV-UNet++
SINR/dB	37.32	9.89	14.96	16.64	19.38	21.92
改善因子/dB	—	—	5.07	6.75	9.49	12.03
IESR/dB	—	—	2.45	7.34	11.13	13.45
图像熵	1.08	4.98	4.61	3.76	3.21	2.82

表2 测试区域 R2 干扰抑制统计结果

指标	原始图像	被干扰图像	特征分解	RPCA	UNet++	CV-UNet++
SINR/dB	32.15	6.32	11.94	13.28	16.96	18.16
改善因子/dB	—	—	5.62	6.96	10.64	11.84
IESR/dB	—	—	0.71	6.23	9.80	11.85
图像熵	1.37	5.51	5.39	4.47	3.95	3.60

表3 测试区域 R3 干扰抑制统计结果

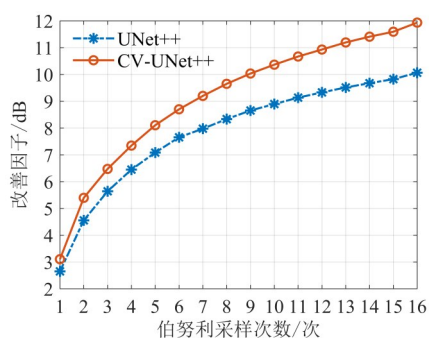
指标	原始图像	被干扰图像	特征分解	RPCA	UNet++	CV-UNet++
SINR/dB	20.26	1.03	9.44	2.48	10.79	11.40
改善因子/dB	—	—	8.41	1.45	9.76	10.37
IESR/dB	—	—	-1.30	2.28	4.89	10.52
图像熵	2.36	4.55	4.22	3.85	3.39	2.46

为了进一步阐述所提复数域网络 CV-UNet++ 相对于实数域网络 UNet++ 的性能优势, 实验统计了不同伯努利采样次数 K 下的改善因子, 以及不同干扰强度下的 SINR, 如图 8 所示. 由图 8(a) 可得, 随着 K 的增大, 改

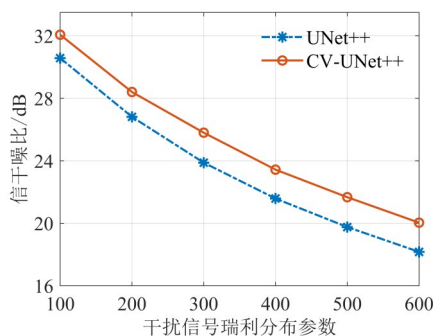
善因子呈显著的上升趋势, 且 CV-UNet++ 上升速度明显优于 UNet++. 但是 K 越大意味着计算量的增大, 在实际应用时应综合考虑干扰抑制效果和计算效率的影响, 选取较为合适的伯努利采样次数. 由图 8(b) 可得, 随着 σ 的增大, 即干扰强度的不断增强, 两种干扰抑制方法的 SINR 均有所下降, 即各干扰抑制方法的干扰抑制效果与干扰信号的强度呈负相关. 但在不同干扰强度下, CV-UNet++ 均具有最优的 SINR, 这表明了所提 CV-UNet++ 在干扰性能上优于实数域网络 UNet++.

为了进一步分析伯努利采样概率 p 对 CV-UNet++ 和 UNet++ 的性能影响, 实验统计了不同伯努利采样概率 p 下的改善因子, 如图 9 所示. 瑞利分布参数 σ 取 600, 伯努利采样次数 K 取 16. 由图 9 可得, 随着 p 的增大, 改善因子呈显著的先缓慢上升后急速下降的趋势, 最大值点在 $p=0.3$ 附近. 当 $p < 0.3$ 时, 伯努利抽样的随机性不够强, 不足以训练出较好的干扰抑制模型; 当 $p > 0.3$ 时, 输入图像保留的像素又不足以构建干扰抑制图像. 因此, 伯努利采样概率应取 0.3. 同时, 在不同伯努利采样概率下, CV-UNet++ 均具有最优的改善因子, 进一步体现了 CV-UNet++ 的相对优势.

本文实验中设定训练样本集大小为 50 000, 为了进一步分析样本量对所提方法的性能影响, 实验统计了不同样本量下的改善因子, 如图 10 所示. 不同样本量的训练数据迭代次数相同, 且瑞利分布参数 σ 取 600, 伯努利采样次数 K 取 16. 由图 10 可得, 随着样本量的增大, 改善因子呈显著的上升趋势, 当样本量超过 40 000 时, 上升趋势逐渐减缓. 同时, 随着样本量的增大, CV-UNet++ 上升速度明显优于 UNet++. 样本量越大意味着训练时间越长, 在不同的应用场景中应对方法性能和训练时间进行综合考量, 选取较为合适的样本量.



(a) 不同伯努利采样次数 K 的改善因子统计图



(b) 不同瑞利分布参数 σ 的信干噪比统计图

图8 测试阶段 UNet++ 和 CV-UNet++ 性能对比

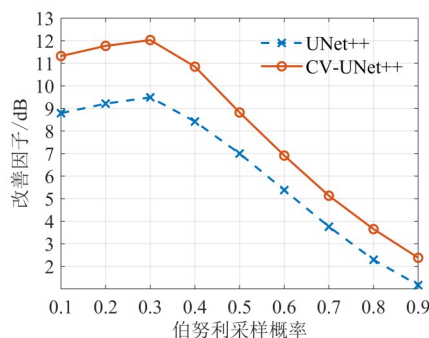


图9 不同伯努利采样概率 p 的改善因子统计图




图10 不同训练样本量的改善因子统计图

3.3 组合干扰抑制结果分析

为了探究所提方法对压制干扰中的其他干扰样式的干扰抑制结果,利用训练好的 CV-UNet++ 分别对受

到噪声调幅干扰、噪声调频干扰、噪声调相干扰、组合干扰的三个测试区域 R1, R2 和 R3 进行干扰抑制. 组合干扰由噪声调幅干扰、噪声调频干扰、噪声调相干扰组成. 伯努利采样次数 K 取 16. 不同类型干扰情况下测试区域 R3 的干扰抑制结果如图 11 所示. 测试区域 R3 的原始图像见图 7(a) 下方图像. 由图 11 可以看出, 被干扰图像中地面目标被严重掩盖, 且被噪声调幅信号干扰和噪声调频信号干扰的图像存在条纹状的干扰. 经 CV-UNet++ 干扰抑制后, 不同类型的干扰信号均被极大抑制, 图像质量也得到了很大改善.

对三个测试区域的干扰抑制结果, 统计平均 SINR 与图像熵, 分别如表 4 和表 5 所示. 三个测试区域的原图平均 SINR 为 29.92 dB, 平均图像熵为 1.57. 由表 4 和表 5 可得, 与原始图像相比, 被干扰图像的正信噪比下降范围在 22 dB 左右, 图像熵变大, 图像质量破坏严重; 经 CV-UNet++ 干扰抑制后, 干扰抑制结果的 SINR 和图像熵两个指标均进一步提升, SINR 平均提升了约 12 dB, 其中组合干扰的正信噪比提升 11.56 dB, 图像熵相较于被干扰图像下降范围在 2 左右, 与原始图像的图像熵较为接近. 定量实验结果体现了所提方法对不同样式的压制干扰甚至是组合干扰均有较好的干扰抑制效果.




图11 不同类型干扰及组合干扰抑制结果

表4 CV-UNet++ 不同噪声调制类型干扰及组合干扰下的图像与干扰抑制后图像的正信噪比统计结果 单位: dB

图像类型	噪声调幅干扰	噪声调频干扰	噪声调相干扰	组合干扰
原被干扰图像	7.43	7.74	7.47	7.46
干扰抑制后的图像	19.22	19.15	19.10	19.02

3.4 计算效率分析

在配置为 Intel®Xeon(R) Silver 4110 CPU, 显卡为

表5 CV-UNet++不同噪声调制类型干扰及组合干扰下的图像与干扰抑制后图像的图像熵统计结果 单位: dB

图像类型	噪声调幅干扰	噪声调频干扰	噪声调相干扰	组合干扰
原被干扰图像	4.69	4.66	4.69	4.67
干扰抑制后的图像	2.60	2.58	2.58	2.64

NVIDIA GeForce RTX 2080Ti 的计算机上对不同方法的计算效率进行统计分析. 统计各个方法对测试区域 R1, R2 和 R3 的处理时间, 结果如下表 6 所示. 由表 6 可得, 对测试区域处理时间中, UNet++ 的处理时间最短, RPCA 的处理时间最长. RPCA 需要迭代求解模型参数, 计算复杂度较大. 由于复数运算的复杂性, CV-UNet++ 的处理时间略长于 UNet++. UNet++ 与 CV-UNet++ 两个深度学习方法的处理时间优于基于特征分解或 RPCA 的传统干扰抑制方法.

表6 各算法运算时间统计 单位: s

测试区域	特征分解	RPCA	UNet++	CV-UNet++
R1	57.30	2.10×10^4	13.84	15.33
R2	9.86	9.30×10^3	8.48	8.99
R3	58.87	2.32×10^4	15.54	16.73

4 结论

有源压制干扰极大地损害了 SAR 对地获取信息的能力. 本文研究了基于复数域深度学习网络 CV-UNet++ 与自监督训练策略的 SAR 有源压制干扰抑制方法, 设计了 CV-UNet++ 网络架构, 并应用复数域残差卷积单元 CvRU, 以增强 CV-UNet++ 的特征提取能力, 推导了 CV-UNet++ 的前向传播与反向传播算法, 同时采用伯努利采样构造图像对的方式进行自监督训练, 并论证了该训练策略的合理性. 实验结果表明, 所提方法的干扰抑制结果在多个指标上均优于传统的特征分解算法和 RPCA, 在进一步提高干扰抑制效果的同时, 最大限度上保留了感兴趣目标的信息完整, 在实际应用中具有重要价值.

参考文献

- [1] 黄岩, 赵博, 陶明亮, 等. 合成孔径雷达抗干扰技术综述[J]. 雷达学报, 2020, 9(1): 86-106.
HUANG Y, ZHAO B, TAO M L, et al. Review of synthetic aperture radar interference suppression[J]. Journal of Radars, 2020, 9(1): 86-106. (in Chinese)
- [2] 粟嘉, 陶海红, 宋大伟, 等. 基于 WD 和时频滑窗掩膜的 SAR 干扰抑制算法[J]. 电子学报, 2015, 43(12): 2345-2351.
SU J, TAO H H, SONG D W, et al. Interference suppression algorithm for SAR based on WD and sliding window masking technique time-frequency domain[J]. Acta Electronica Sinica, 2015, 43(12): 2345-2351. (in Chinese)
- [3] 袁冠杰, 王虹, 陈静, 等. 基于特征提取融合判决的卫星干扰识别算法[J]. 微波学报, 2021, 37(S1): 241-244.
YUAN G J, WANG H, CHEN J, et al. Satellite jamming recognition algorithm based on feature extraction and fusion decision[J]. Journal of Microwaves, 2021, 37(S1): 241-244. (in Chinese)
- [4] DJUKANOVIC S, POPOVIC V. A parametric method for multicomponent interference suppression in noise radars[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(3): 2730-2738.
- [5] LIU Z, LIAO G, and YANG Z. Time variant RFI suppression for SAR using iterative adaptive approach[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(6): 1424-1428.
- [6] YANG Z, DU W, LIU Z, et al. WBI suppression for SAR using iterative adaptive method[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 9(3): 1008-1014.
- [7] LIU H, LI D, ZHOU Y, et al. Joint wideband interference suppression and SAR signal recovery based on sparse representations[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(9): 1542-1546.
- [8] SU J, TAO H, TAO M, et al. Narrowband interference suppression via RPCA-based signal separation in time-frequency domain[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(11): 5016-5025.
- [9] HUANG Y, LIAO G, XU J, et al. Narrowband RFI suppression for SAR system via efficient parameter-free decomposition algorithm[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6): 3311-3322.
- [10] MEYER F J, NICOLL J B, and DOULGERIS A P. Correction and characterization of radio frequency interference signatures in L-band synthetic aperture radar data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(10): 4961-4972.
- [11] NABIL H, CHEN J, KAMEL H, et al. Bidirectional notch filter for suppressing pulse modulated radiofrequency-interference in SAR data[C]. 2014 IEEE Geoscience and Remote Sensing Symposium. Quebec City: IEEE, 2014: 1136-1139.
- [12] 于春锐, 张永胜, 董臻, 等. 基于特征分解的 SAR 射频干扰抑制方法[J]. 信号处理, 2011, 27(11): 1696-1700.
YU C R, ZHANG Y S, DONG Z, et al. RFI suppression for SAR based on Eigen-decomposition method[J]. Signal Processing, 2011, 27(11): 1696-1700. (in Chinese)
- [13] 周春晖, 李飞, 李宁, 等. 改进的基于特征子空间的 SAR 图像射频干扰抑制算法[J]. 雷达学报, 2018, 7(2): 235-243.

ZHOU C H, LI F, LI N, et al. Modified eigensubspace-based approach for radio-frequency interference suppression of SAR image[J]. Journal of Radars, 2018, 7(2): 235-243. (in Chinese)

- [14] 张云, 化青龙, 王军, 等. 基于C2C的自监督SAR海杂波抑制方法、系统、存储介质及设备: CN114114261A[P]. 2022-03-01.

ZHANG Y, HUA Q L, WANG J, et al. C2C-based self-supervised SAR sea clutter suppression method, system, storage medium and device: CN114114261A[P]. 2022-03-01. (in Chinese)

- [15] ZHANG Y, JIU B, WANG P, et al. An end-to-end anti-jamming target detection method based on CNN[J]. IEEE Sensors Journal, 2021, 21(19): 21817-21828.

- [16] QU Q, WEI S, LIU S, et al. JRNet: Jamming recognition networks for radar compound suppression jamming signals[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15035-15045.

- [17] 周峰, 荣鹏帅, 樊伟伟, 等. 基于深度残差网络的SAR干扰抑制方法: CN110221256A[P]. 2019-09-10.

ZHOU F, RONG P S, FAN W W, et al. SAR interference suppression method based on deep residual network: CN110221256A[P]. 2019-09-10. (in Chinese)

- [18] ZHOU Z, SIDDIQUEE M M R, TAJBAKHS N, et al. Unet++: Redesigning skip connections to exploit multi-scale features in image segmentation[J]. IEEE transactions on medical imaging, 2019, 39(6): 1856-1867.

- [19] LEHTINEN J, MUNKBERG J, HASSELGREN J, et al. Noise2Noise: Learning image restoration without clean data[C]//2018 International Conference on Machine Learning (ICML). Stockholm: Proceedings of Machine Learning Research, 2018: 2965-2974.

- [20] BAUER E, KOHAVI R. An empirical comparison of voting classification algorithms: Bagging, boosting, and variants[J]. Machine learning, 1999, 36(1): 105-139.

- [21] 于春锐, 张永胜, 董臻, 等. SAR有源压制干扰抑制效果评估方法研究[J]. 应用基础与工程科学学报, 2012, 20(4): 725-738.

YU C R, ZHANG Y S, Dong Z, et al. ECCM effectiveness measure for SAR noise jamming[J]. Journal of Basic Science and Engineering, 2012, 20(4): 725-738. (in Chinese)

- [22] 周智敏, 黄晓涛, 常文革, 等. UWB-SAR抑制RFI算法性能评估与测试[J]. 国防科技大学学报, 2002(2): 49-53.

ZHOU Z M, HUANG X T, CHANG W G, et al. Performance evaluation and test of RFI suppression algorithms for UWB-SAR[J]. Journal of National University of Defense Technology, 2002(2): 49-53. (in Chinese)

作者简介




化青龙 男, 1995年出生, 安徽阜阳人. 现为哈尔滨工业大学博士. 主要研究方向为雷达图像处理和深度学习网络框架.

E-mail: huaqinglong_hit@163.com



魏晨曦 女, 1998年出生, 辽宁沈阳人. 现为哈尔滨工业大学硕士. 主要研究方向为SAR图像处理和目标检测.

E-mail: weicxjlu@163.com



张云(通讯作者) 女, 1975年出生, 黑龙江虎林人. 现为哈尔滨工业大学教授、博士生导师. 主要研究方向为雷达信号处理、SAR成像、机器学习和遥感模式分析.

E-mail: zhangyunhit@hit.edu.cn



张倩 女, 1999年出生, 河北廊坊人. 现为哈尔滨工业大学硕士. 主要研究方向为SAR抗干扰波形设计与优化.

E-mail: 21S005086@stu.hit.edu.cn



冀振元 男, 1972年出生, 黑龙江五常人. 现为哈尔滨工业大学教授. 主要研究方向为海态遥感、雷达成像与目标识别. 中国电子学会会员编号: E190001887M.

E-mail: jizhenyuan@hit.edu.cn



姜义成 男, 1964年出生, 黑龙江哈尔滨人. 现为哈尔滨工业大学教授、博士生导师. 主要研究方向为雷达信号处理. 中国电子学会会员编号: E190004807S.

E-mail: jiangyc@hit.edu.cn