

雷达属性散射中心的快速目标分类和参数估计^{*}宋坚毅^{1,2} 胡承鑫³ 黄 瑶³ 管 灵⁴ 董纯柱⁴ 曾曙光³ 田卫新¹(1.三峡大学计算机与信息学院 宜昌 443002; 2.水电工程智能视觉监测湖北省重点实验室 宜昌 443000;
3.三峡大学理学院 宜昌 443002;4.北京环境特性研究所 北京 100854)

摘要:雷达属性散射中心模型的属性参数能够提供目标更为丰富的重要信息,属性散射中心参数估计对解析雷达目标有着极其重要的研究意义。针对雷达属性散射中心模型,提出了基于深度学习的雷达属性散射中心快速目标分类和参数估计的技术。首先利用 ViT (vision transformer)深度学习网络将雷达属性散射中心分类为局部式和分布式两类,然后基于 TS2Vec 框架构建针对属性散射中心参数估计的卷积神经网络(convolutional neural network for attribute scattering centers, ASC-NN),最后分别对两种数据进行训练以实现局部式和分布式属性散射中心的参数估计。基于属性散射中心模型展开数值实验,实验结果表明,该方法对雷达属性散射中心目标分类的准确率高达 99%以上;雷达属性散射中心参数估计的速度超过传统方法的 10 000 倍以上,且精度更高,验证了所提方法的有效性和优越性。

关键词:属性散射中心;深度学习;目标分类;参数估计

中图分类号: TN957 文献标识码:A 国家标准学科分类代码: 510.70

Fast target classification and parameter estimation of radar attribute scattering centers

Song Jianyi^{1,2} Hu Chengxin³ Huang Yao³ Guan Ling⁴ Dong Chunzhu⁴ Zeng Shuguang³ Tian Weixin¹(1. School of Computer and Information Science, China Three Gorges University, Yichang 443002, China;
2. Hubei Key Laboratory of Intelligent Visual Monitoring for Hydropower Engineering, Yichang 443000, China;
3. College of Science, China Three Gorges University, Yichang 443002, China;
4. Beijing Institute of Environmental Characteristics, Beijing 100854, China)

Abstract: The attribute parameters of the radar attribute scattering center model can provide richer and more important information about the target, and the attribute scattering center parameter estimation is of great research significance for resolving radar targets. Aiming at the radar attribute scattering center model, this paper proposes the technique of fast target classification and parameter estimation of radar attribute scattering center based on deep learning. Firstly, the vision transformer (ViT) deep learning network is used to classify the radar attribute scattering centers into two categories: Localized and distributed, Then a convolution neural network for parameter estimation of attribute scattering centers (ASCNN) is constructed based on TS2Vec framework, and finally the two kinds of data are trained separately for parameter estimation of localized and distributed attribute scattering centers. Based on the attribute scattering center model, numerical experiments are carried out, the experimental results show that the accuracy of this method for radar attribute scattering center target classification is over 99%. The speed of radar attribute scattering center parameter estimation is more than 10 000 times higher than that of traditional methods, and the accuracy is higher, which verifies the effectiveness and superiority of the proposed method.

Keywords: attribute scattering center; deep learning; target classification; parameter estimation

收稿日期:2023-08-01

*基金项目:国家自然科学基金(U2031202)项目资助

0 引言

高频区目标后向散射特性可等效为若干局部现象的叠加效应,即散射中心。目标的散射中心可以作为描述目标高频散射机理的有效特征,主要产生于目标的边缘、拐角、棱角及尖端等不连续点部位,代表了目标精细的物理结构^[1]。散射中心参数提取在雷达目标识别、RCS 外推整合、目标三维重构等军事领域具有广泛的研究和应用价值^[2-4]。为了改善点散射模型在描述目标内在特性时的不足、无法为目标分类和识别提供充分的信息的问题,基于几何绕射理论(geometrical theory of diffraction, GTD)和属性散射中心(attributed scattering center, ASC)等参数化散射模型被相继提出^[5]。ASC 模型是 Gerry 等^[5]基于几何绕射理论和物理光学理论提出的一种较为先进的属性散射中心模型,模型根据目标散射强度对方位角的依赖关系,将散射中心分为局部式和分布式两种类型,同时保留了 GTD 模型对频率依赖关系的描述^[1]。ASC 模型的属性参数提供了目标更为丰富的重要信息,因此基于 ASC 模型的参数估计被广泛应用于分析目标的散射特性^[1,6]。

早期,研究者利用图像域解耦这种“分治”策略实现单个散射中心的序惯估计。首先对 SAR 图像进行分割分离出单个散射中心,再对单个散射中心进行逐一估计,将参数估计问题转化为多维非线性无约束优化问题^[1,6]。如粒子群(particle swarm optimization, PSO)算法^[7]、狼群算法(wolf pack algorithm, WPA)^[7]、烟花算法^[8]等优化算法取得了不错的效果。但由于 ASC 模型的形式复杂、参数较多,并且这些优化算法需要进行不断迭代导致计算量较大,使得这些传统方法在属性散射中心参数估计中的效率有待提高^[1,7-9]。近年来,深度学习由于其强大的学习能力、灵活的表达能力、快速的应变能力和自主的感知能力被广泛应用于科研任务中^[10-12]。不少学者尝试利用深度学习解决雷达领域的问题。Lin 等^[13]将重采样参数估计问题重新表述为多分类问题,使用卷积神经网络的分类功能对重采样参数进行估计。Su 等^[14]基于 WVD-CNN (Wigner-Ville distribution complex-valued convolutional neural network)提出一种线性调频信号的调频率估计方法。罗宇航等^[15]基于卷积神经网络和前馈神经网络,提出了一种基于散射中心时频像特征的目标类型自动识别和目标几何参数自动提取的方法。Dosovitskiy 等^[16]为了使纯 Transformer 结构^[17]适用于图像而提出的 ViT (vision transformer)深度学习网络模型,在图像分类任务中取得良好效果^[18-20]。Yue 等^[21]提出了一种针对参数估计、回归、分类、预测、异常检测等任务的通用模型 TS2Vec 框架^[22-24]。但是,目前鲜少有直接将深度学习应用于雷达属性散射中心目标分类和参数估计的任务中。

本文利用深度学习网络对雷达属性散射中心实现快速、智能化目标分类和参数估计。首先利用 ViT 深度学习网络将雷达属性散射中心分类为局部式和分布式两类,

再基于 TS2Vec 框架构建针对属性散射中心参数估计的卷积神经网络(convolutional neural network for attribute scattering centers, ASCNN)分别利用两种数据进行训练实现局部式和分布式属性散射中心的参数估计。

1 属性散射中心模型

基于几何绕射理论和物理光学理论,属性散射中心模型认为目标的电磁散射响应是由 p 个独立的散射中心叠加而成,用于表示高频区复杂目标的散射特性,表达式^[25]如下:

$$E(f, \phi; \theta) = \sum_{i=1}^p E_i(f, \phi; \theta_i) \quad (1)$$

$$E_i(f, \phi; \theta_i) = A_i \left(j \frac{f}{f_c} \right)^{\alpha_i} \cdot \exp \left[\frac{-j4\pi f}{c} (x_i \cos \phi + y_i \sin \phi) \right] \cdot \text{sinc} \left[\frac{2\pi f}{c} L_i \sin(\phi - \bar{\phi}_i) \right] \cdot \exp(-2\pi f \gamma_i \sin \phi) \quad (2)$$

式中: $E(f, \phi; \theta)$ 表示目标的电磁响应,可由单个散射中心 $E_i(f, \phi; \theta_i)$ 叠加而成, $E_i(f, \phi; \theta_i)$ 是关于频率 f 和方位角 ϕ 以及散射中心参数集 $\theta_i = [A_i, \alpha_i, x_i, y_i, L_i, \bar{\phi}_i, \gamma_i]$ 的函数,其中 A_i 表示第 i 个散射中心的复幅度, x_i, y_i 分别表示第 i 个散射中心相对于零相位参考点在距离向和方位向的坐标, α_i 表示频率依赖, L_i 表示分布散射中心的长度, $\bar{\phi}_i$ 表示分布散射中心的方位角, γ_i 表示局部散射中心散射幅度的方位角依赖性。当 $L_i = \bar{\phi}_i = 0$ 时,该散射中心为局部式散射中心;当 $L_i \neq 0, \gamma_i = 0$ 时,该散射中心为分布式散射中心。局部式和分布式散射中心如图 1 所示。

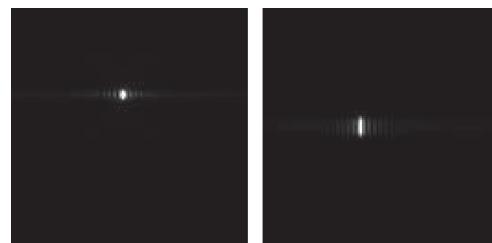


图 1 属性散射中心图像

图 1 为利用属性散射中心模型生成的图像,其中图 1(a)为局部式散射中心,其能量较为集中,图 1(b)为分布式散射中心,具有一定长度。对应参数如表 1 所示,可以看到局部式属性散射中心中 $L = \bar{\phi} = 0$; 分布式属性散射中心中 $L \neq 0$ 。

基于属性散射中心模型批量仿真生成数据集 1 和数据集 2,数据集 1 和数据集 2 均有 20 000 组独立的训练样本和 2 000 组独立的测试样本组成。数据集 1 中的每组数据样本由局部式散射中心和其标签构成,数据集 2 中的每组数据样本由分布式散射中心和其标签构成。样本标签的参数分布空间如表 2 所示,其中, $A, x, y, L, \bar{\phi}$ 的取值在参数分布空间内随机生成, α 的取值在 $(-1, -0.5, 0, 0.5, 1)$ 之间随机生成。由于 γ 是一个十分接近于 0 的

表1 散射中心参数

ASC	A	α	x/m	y/m	L/m	$\bar{\phi}/(\circ)$	γ
Localized	4.259	0.5	-0.765	-3.438	0	0	0
Distributed	6.641	-0.5	-2.173	0.030	1.569	0.295	0

表2 参数分布空间

Data	A	α	x/m	y/m	L/m	$\bar{\phi}/(\circ)$	γ
Data1	(1,5)	(-1,1)	(-6,6)	(-6,6)	0	0	0
Data2	(5,9)	(-1,1)	(-6,6)	(-6,6)	(1,2)	(0.2,0.8)	0

数^[6],为了方便实验,在仿真过程中将其直接赋值为0。

2 算法介绍

首先利用图像分割算法将雷达图像分割为单个的散

射中心^[7-9],然后利用ViT将雷达属性散射中心分类为局部式和分布式两类,最后利用ASCNN分别对局部式和分布式属性散射中心进行参数估计。实验流程如图2所示。

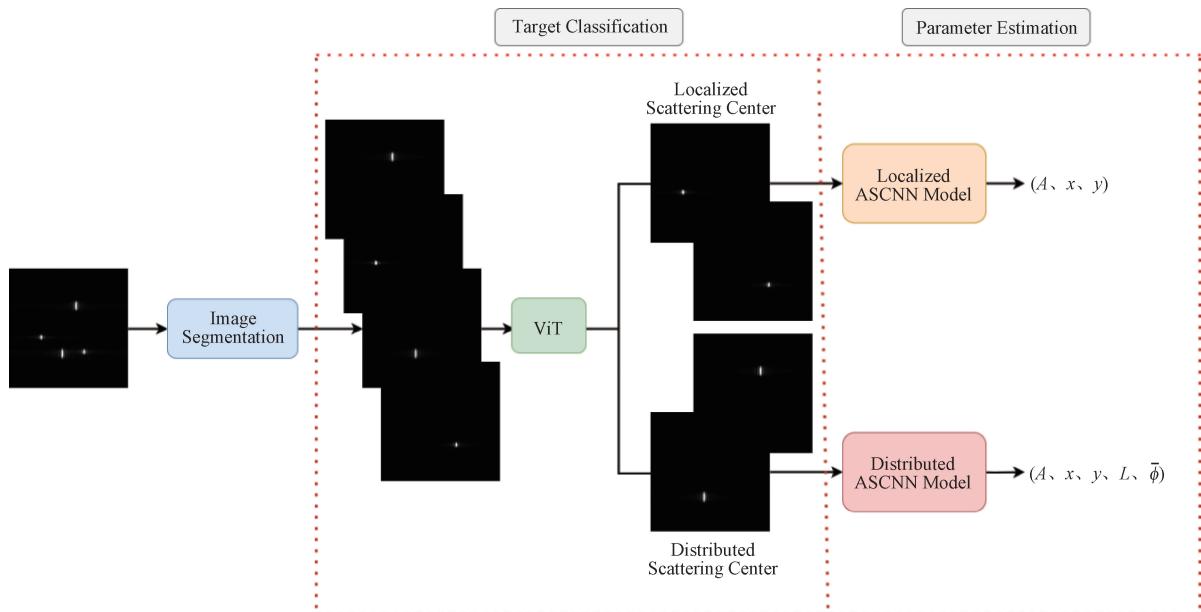


图2 实验流程

局部式ASCNN模型的3个输入参数是散射中心的复幅度A、距离向和方位向的坐标x、y;分布式ASCNN模型的5个输入参数是散射中心的复幅度A、距离向和方位向的坐标x、y及长度L、方位角 $\bar{\phi}$ ^[26]。ViT和ASCNN均采用均方误差(mean square error, MSE)作为训练时的损失函数,表达如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (q_i - \bar{q}_i)^2 \quad (3)$$

式中: q_i 表示标签值; \bar{q}_i 表示网络输出结果。

2.1 ViT 网络

ViT的总体思想是基于纯Transformer结构来做图像分类任务,核心流程主要包括图像分块处理、图像块嵌入、位置编码、Transformer编码器和多层次感知机(multi-layer perception, MLP)分类处理等部分^[16-17],模型原理如图3所示。

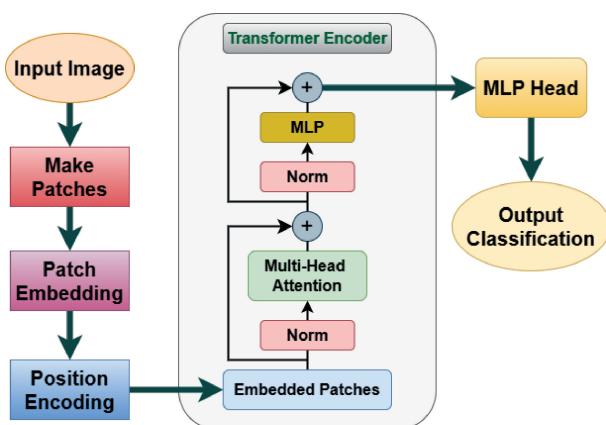


图3 ViT网络原理

1)对输入图像 $I \in H \times W \times C$ 进行分块处理,将其分

成 $S=P \times P \times C$ 的 $N=HW/P^2$ 个图像块。全部图像块的维度就可以写为 $N \times P \times P \times C$, 对每个图像块进行展平, 得到 $N \times (P^2 \times C)$ 表示的数据维度。这里 N 可以理解为输入到 Transformer 的序列长度, C 为输入图像的通道数, P 为图像块的尺度。

2) 对每一个展平后的图像块向量做一个线性变换(全连接层), 将大小为 $S=P \times P \times C$ 图像块嵌入网络模型中, 降维后的维度为 D 。同时追加一个分类向量, 用于 Transformer 训练过程中的类别信息学习。

3) 对图像块嵌入中添加一个位置编码向量, 以保持输入图像块之间的空间位置信息。

4) 完成图像分块处理、图像块嵌入和类别向量追加、以及位置编码后得到的向量即可进入 Transformer 编码器。Transformer 编码器由交替的多头自注意力层(multi-headed self-attention, MSA)和 MLP 块构成。ViT 不断前向通过由 Transformer 编码器模块串行堆叠构成的 Transformer 编码器, 最后提取可学习的类别嵌入向量, 并将对应的特征用于图像分类。

2.2 ASCNN 网络

ASCNN 网络基于 TS2Vec 框架搭建, 用于实现局部式和分布式属性散射中心的参数估计。ASCNN 网络主要由输入层, 隐藏层和输出层组成, 模型结构如图 4 所示。

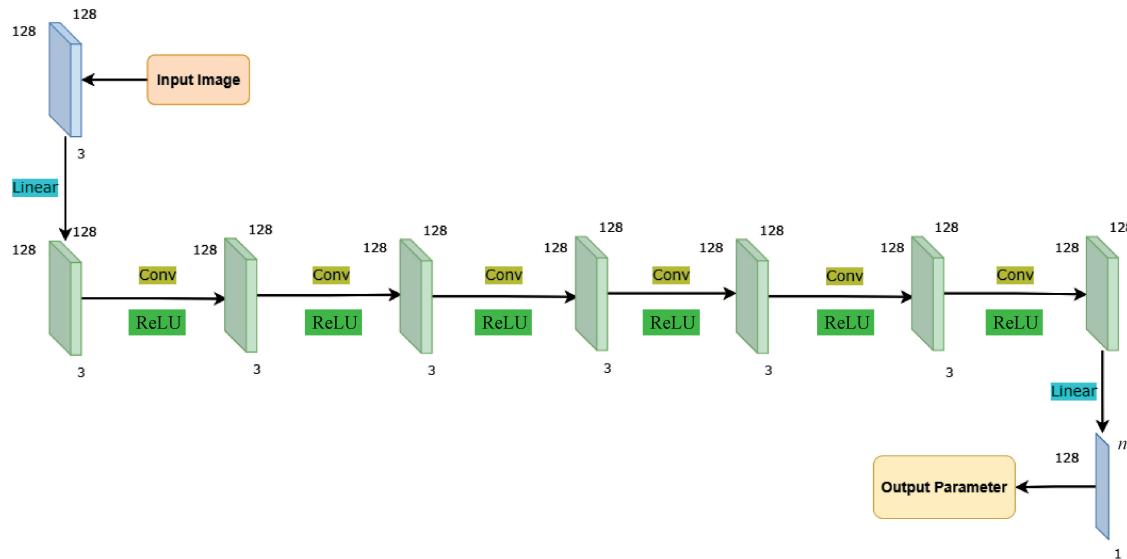


图 4 ASCNN 网络结构

图 4 中, 输入层和输出层由全连接层 Linear 组成, 全连接层的每一个结点都与上一层的所有结点相连, 负责将二维图像转化成特征向量, 由此实现了端到端的学习过程。隐藏层由 6 个卷积模块组成, 主要用于提取图像特征, 卷积模块内部由多个卷积层 Conv 和激活函数 ReLU 组成。图 4 中 128 表示图像的尺度; 3 表示图像的通道数; n 表示需要估计的参数数量, 局部式模型中 $n=3$, 需要估计的参数为散射中心的复幅度 A 、相对于零相位参考点在距离向和方位向的坐标 x 和 y ; 分布式模型中 $n=5$, 需要估计的参数为散射中心的复幅度 A 、相对于零相位参考点在距离向和方位向的坐标 x 和 y 、长度 L 和方位角 $\bar{\phi}$ 。

3 实验

3.1 目标分类性能

本文数据集 1 和数据集 2 的训练样本中各取 10 000 组数据组成 20 000 组分类训练样本(训练集和验证集的比例为 19 : 1)。将分类训练样本输入 ViT 网络中进行训练, 利用验证集的损失值来验证从训练集获得的模型, 并

最终获得最优的模型, 再利用测试样本对模型进行批量测试, 得到 ViT 网络的分类准确率均高于 99%。训练时的超参数如表 3 所示, 其中 Epochs、Loss function、Initial_learning_rate 和 depth 分别为 ViT 网络的训练次数、损失函数、学习率和 Transformer encode 层数。

表 3 ViT 的超参数

超参数	取值
Epochs	50
Loss function	MSE
Initial_learning_rate	0.000 1
depth	4

通过损失函数的梯度下降来更新模型的权重, 选择最小化损失函数以获得最期望的模型。训练过程中训练集和验证集的损失函数变化曲线如图 5 所示。

由图 5 可以看到, 训练集的损失函数稳步下降, 验证集的损失函数先抖动上升再稳步下降, 在第 40 个 epoch 左右时训练集和验证集的损失函数趋于平稳。通过查询

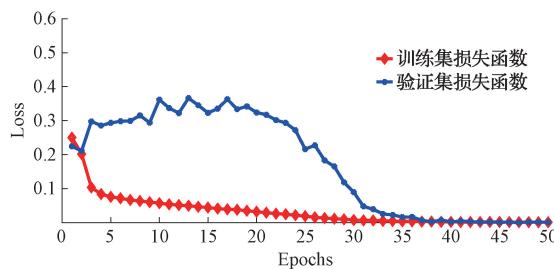


图 5 ViT 网络训练损失函数变化曲线

损失函数记录,此时验证集在第 47 个 epoch 时损失函数达到最小值为 4×10^{-6} ,训练集的损失函数值为 0.001 1,模型达到最优。

3.2 参数估计性能

分别对数据集 1 和数据集 2 的训练样本(训练集和验证集的比例为 19:1)使用局部式 ASCNN 模型和分布式 ASCNN 模型进行训练,利用验证集的损失值来验证从训练集获得的模型,并最终获得最优的模型,再利用测试样本对模型进行批量测试。训练时的超参数如表 4 所示,其中 num_class、Epochs、Loss function、Initial_learning_rate 和 depth 分别为 ASCNN 网络估计参数的数量、训练次数、损失函数、学习率和深度。

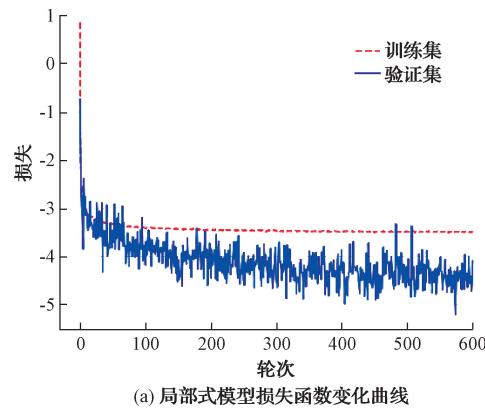
表 4 ASCNN 的超参数

超参数	局部式模型取值	分布式模型取值
num_class	3	5
Epochs	600	1 200
Loss function	MSE	MSE
Initial_learning_rate	0.000 1	0.000 1
depth	6	6

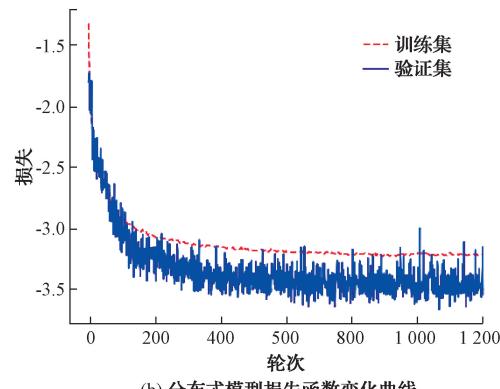
局部式 ASCNN 模型和分布式 ASCNN 模型训练过程中训练集和验证集的损失函数变化曲线如图 6 所示。

由图 6 可以看到,局部式和分布式模型训练集的损失函数均稳步下降,验证集的损失函数均抖动下降,局部式模型和分布式模型分别在第 100 和 200 个 epoch 左右时,训练集的损失函数趋于平稳,验证集的损失函数依然处于抖动下降的趋势。通过查找损失函数记录,训练模型的最优损失函数值如表 5 所示,局部式 ASCNN 模型在训练过程中,验证集的损失函数在第 574 个 epoch 时达到最小值为 0.005 4,对应训练集的损失函数值为 0.030 4;分布式 ASCNN 模型在训练过程中,验证集的损失函数在第 1 068 个 epoch 时达到最小值为 0.025 5,对应训练集的损失函数值为 0.040 4,此时模型达到最优。

利用测试样本对最优模型进行测试,选取部分结果进行展示,属性散射中心参数设定的标签如表 6 所示,基于 ASCNN 网络参数估计的结果如表 7 所示。对比表 6、7 可以发现,ASCNN 参数估计的结果与参数设置的标签十分接近,相对误差较小。分别将表 6 中原始参数设定的标



(a) 局部式模型损失函数变化曲线



(b) 分布式模型损失函数变化曲线

图 6 ASCNN 网络训练损失函数变化曲线

表 5 ASCNN 的最优损失函数

模型	验证集损失	训练集损失	训练轮数
局部式 ASCNN 模型	0.005 4	0.030 4	574
分布式 ASCNN 模型	0.025 5	0.040 4	1 068

表 6 属性散射中心参数设定的标签

ASC	A	x / m	y / m	L / m	$\bar{\phi}$ / (°)
S1	1.240	2.148	-2.212	0	0
S2	3.568	-0.711	-3.175	0	0
S3	6.141	-4.572	-1.85	1.588	0.321
S4	5.568	-3.506	3.087 0	1.269	0.365

表 7 属性散射中心参数估计的结果

ASC	A	x / m	y / m	L / m	$\bar{\phi}$ / (°)
S1	1.085	2.250	-2.321	0	0
S2	3.453	-0.626	-3.261	0	0
S3	6.369	-4.478	-1.762	1.557	0.323
S4	5.616	-3.377	3.121	1.244	0.349

签、表 7 中模型参数估计的结果分别代入式(1)和(2)中,生成散射中心原始图像和重构图像并对二者进行差分,如图 7 所示。

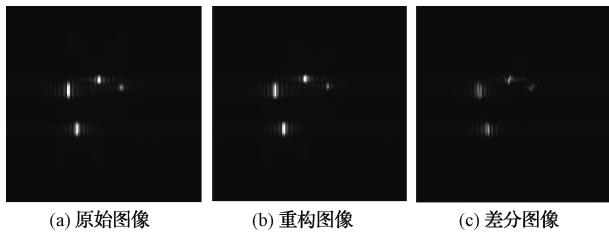


图 7 ASCNN 参数估计效果

图 7(a)为利用散射中心标签参数生成的原始图像,分布在图像左边的两个较长的散射中心为分布式散射中心,从上到下分别为 S3 和 S4;另外两个能量较为聚集的散射中心为局部式散射中心,从上到下分别为 S2 和 S1。图 7(b)是基于散射中心参数估计结果的重构图像,对比图 7(a)可以发现,重构图像和原始图像中散射中心的大小形状、分布位置、图像亮度基本一致,表明基于本文方法估计结果的重构图像有效保留了原始图像中的目标成分,如散射中心分布规律、外形尺寸等。图 7(c)为图 7(a)和(b)的残差分量,二者的残差图像能量非常低。实验表明,ASCNN 能够较为准确的实现雷达属性散射中心参数估计。

为了进一步验证所提方法在属性散射中心参数估计的有效性,随机生成相互独立的局部式和分布式散射中心数据各 100 组,选取 PSO^[7] 和 WPA^[9] 与本文 ASCNN 方法进行批量测试,结果如表 8 所示。

表 8 算法性能对比

算法	MSE	(平均)时间/s
PSO ^[7]	0.026 9	191. 6
WPA ^[9]	0.018 0	273. 4
ASCNN	0.016 2	0.015 1

从表 8 可以看出,本文方法的 MSE 较小,算法准确性较高;在计算时间方面,本文方法的速度超过 PSO 和 WPA 算法 10 000 倍以上。基于 PSO 和 WPA 等属性散射中心参数估计的传统方法需要进行不断迭代计算,导致算法需要消耗大量时间成本。本文方法能够准确且快速实现属性散射中心参数估计得益于深度学习强大的学习能力,能够通过大量训练学习到经验知识,并且通过调用 GPU 实现并行运算,极大加快了复杂计算任务的速度。

4 结 论

本文提出了基于深度学习的雷达属性散射中心快速目标分类和参数估计的技术。首先利用 ViT 深度学习网络将雷达属性散射中心分类为局部式和分布式两类,然后基于 TS2Vec 框架构建 ASCNN 深度学习网络分别对局部式和分布式属性散射中心进行参数估计。本文在雷达属性散射中心的仿真数据上进行实验验证,属性散射中心

目标分类的准确率达到 99% 以上,参数估计的误差小于基于 PSO 和 WPA 等属性散射中心参数估计的传统方法,并且计算速度超过传统方法的 10 000 倍以上。因此,本文方法可以较为快速且准确地实现雷达属性散射中心的目标分类和参数估计。下一步需要开展的工作是将本文方法用于雷达实测数据的目标分类和参数估计。

参 考 文 献

- [1] 马聪慧,文贡坚,刘晓明,等. 散射中心提取方法研究[J]. 信息技术,2012,36(6):176-181.
- [2] 来雨. 基于属性散射中心的 SAR 图像重构及在目标识别中的应用[J]. 火力与指挥控制,2021,46(2):46-52.
- [3] GERRY M J, POTTER L C, GUPTA I J, et al. A parametric model for synthetic aperture radar measurements[J]. IEEE Transactions on Antennas and Propagation, 1999(7):47.
- [4] 刘阳. 基于属性散射中心多层次匹配的 SAR 目标识别方法[J]. 电子测量与仪器学报,2019,33(11):192-198.
- [5] 徐嘉华,张小宽,郑舒予,等. 基于改进 3D-ESPRIT 算法的 GTD 模型参数估计与目标识别[J]. 系统工程与电子技术,2021,43(2):336-342.
- [6] 徐嘉华,张小宽,郑舒予,等. 基于改进正交匹配追踪算法的属性散射中心提取[J]. 系统工程与电子技术,2021,43(8):2076-2082.
- [7] 张华,张素莉,何树吉. 基于幅相分离和动态粒子群算法的 SAR 图像属性散射中心参数估计[J]. 中国电子科学研究院学报,2019,14(9):993-1000.
- [8] 周志洪,陈秀真,马进,等. 烟花算法在 SAR 图像属性散射中心参数估计中的应用[J]. 红外与激光工程,2022,51(8):481-487.
- [9] 陈丛. 基于狼群算法的 SAR 图像属性散射中心参数估计[J]. 红外与激光工程,2021,50(4):258-264.
- [10] 侯学良,单鹏飞,薛靖国. 深度学习的目标检测典型算法及其应用现状分析[J]. 国外电子测量技术,2022,41(6):165-174.
- [11] 唐晓彬,沈童. 深度学习框架发展综述[J]. 调研世界,2023 (4):83-88.
- [12] 李星华,艾文浩,冯蕊涛,等. 遥感影像深度学习配准方法综述[J]. 遥感学报,2023,27(2):267-284.
- [13] LIN P, XIN L, CHEN M L. Resampling parameter estimation via dual-filtering based convolutional neural network[J]. Multimedia Systems, 2021, 27:363-370.
- [14] SU H, PAN J, BAO Q, et al. Parameter estimation of linear frequency modulated signals based on a Wigner-Ville distribution complex-valued convolutional neural network[J]. Journal of Applied Remote Sensing, 2020, DOI:10.1117/1.JRS.14.036512.

- [15] 罗宇航,陈彦锡,郭琨毅,等. 基于神经网络和散射中心模型的目标参数提取[J]. 系统工程与电子技术, 2023, 45(1):9-14.
- [16] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [J]. Computer Science, 2020 DOI: 10.48550/arXiv. 2010,11929.
- [17] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need [J]. Computer Science, 2017, DOI:10.48550/arXiv. 1706. 03762.
- [18] 孙天宇,朱庆涛,杨健,等. 基于改进 Vision Transformer 的血细胞图像识别方法研究[J]. 生物医学工程学杂志,2022,39(6):1097-1107.
- [19] 韩亮,罗统军,蒲秀娟,等. 使用多尺度递归图和视觉转换器的心律失常分类[J]. 仪器仪表学报,2022, 43(12):149-157.
- [20] 高泽铭,刘桂雄,陈国宇,等. 基于 ViT 燃气表外观零件识别与定位方法研究[J]. 电子测量技术,2023, 46(11):7-12.
- [21] YUE Z H, WANG Y J, DUAN J Y, et al. TS2Vec: Towards universal representation of time series[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(8): 8980-8987.
- [22] LUO D, CHENG W, WANG Y, et al. Time series contrastive learning with information-aware augmentations[J]. Computer Science, 2023, DOI:10.48550/arXiv. 2303. 11911.
- [23] BHASKARPANDIT S, GUPTA P, GUPTA M. LETS-GZSL: A latent embedding model for time series generalized zero shot learning[J]. Computer Science, 2022, DOI:10.48550/arXiv. 2207. 12007.
- [24] YANG L, HONG S, ZHANG L. Unsupervised time-series representation learning with iterative bilinear temporal-spectral fusion [C]. International Conference on Machine Learning,2022.
- [25] 丁柏圆,钟金荣,马聪慧,等. 基于属性散射中心模型的 SAR 目标重构可视化增强方法[J]. 雷达学报, 2013,2(4):499-506.
- [26] LIU C, TAO S, DING D, et al. Multi-radar target parameter estimation and fusion based on attribute scattering centre model [J]. The Journal of Engineering, 2019(20): 6894-6897.

作者简介

- 宋坚毅,硕士研究生,主要研究方向为雷达图像处理。
E-mail: 202108120021020@ctgu.edu.cn
- 曾曙光(通信作者),博士,副教授,硕士生导师,主要研究方向为数字图像处理及机器视觉。
E-mail: zengshuguang@163.com