

融合电磁散射特征的SAR目标识别方法综述

邢孟道^{1,2}, 韩青¹, 张金松²

1. 西安电子科技大学 雷达信号处理全国重点实验室, 西安 710071;

2. 西安电子科技大学 前沿交叉研究院, 西安 710071

摘要: 合成孔径雷达SAR (Synthetic Aperture Radar) 图像的自动化解译是SAR技术应用的重要发展方向之一。SAR识别方法主要分为两类: 传统机器学习方法和基于深度学习的方法。对于大多数传统的机器学习方法, 基于电磁散射特性提取的目标特征是可解释且稳定的。然而, 有效特征的提取过程往往复杂, 且计算效率低。与传统方法相比, 基于深度学习的方法可以直接学习目标的高维特征, 获得更高的目标识别精度。然而, 深度学习方法泛化性能差, 难以解释。因此综合考虑两种方法的优势, 融合电磁散射特征和神经网络特征的深度学习方法应运而生。该文讨论了基于电磁散射特征和神经网络特征融合的目标识别方法的研究成果, 详述了这种融合电磁散射特征的思想在车辆、飞机和舰船目标识别方面的应用, 展望了未来目标识别检测研究的发展趋势并做出总结。

关键词: 遥感, 合成孔径雷达, 目标识别, 卷积神经网络, 电磁散射特征, 参数估计

中图分类号: TP701/P2

引用格式: 邢孟道, 韩青, 张金松. 2025. 融合电磁散射特征的SAR目标识别方法综述. 遥感学报, 29(6): 1598–1613

Xing M D, Han Q and Zhang J S. 2025. A review of SAR target recognition methods fusing electromagnetic scattering features. National Remote Sensing Bulletin, 29(6): 1598–1613 [DOI: 10.11834/jrs.20254592]

1 引言

合成孔径雷达SAR (Synthetic Aperture Radar) 是以电磁波为载体探测目标电磁特性的微波遥感成像系统, 具有全天时、全天候、作用距离远等优势, 在军用和民用等领域都得到广泛应用 (保铮等, 2005)。在当前数据密集型时代, 机器学习ML (Machine Learning) 对数据处理尤为重要, 有学者将机器学习方法扩展到地形分类 (Tirandaz等, 2020)、目标检测 (Modava等, 2019)、变化检测 (Samadi等, 2019) 和自动目标识别ATR (Automatic Target Recognition) (Smillie, 1966) 等SAR图像处理领域。ATR尝试使用专门面向SAR数据或计算机视觉领域现有的机器学习方法, 来最大限度地提高目标识别性能 (Kechagias–Stamatis和Aouf, 2021)。在当前的目标识别技术体系中, 主要聚焦于两大核心技术: 一是特征提取技术, 旨

在从目标数据中精准提炼出具有代表性和区分性的关键特征; 二是分类器设计, 其作用是依据所提取的特征对目标进行准确分类。在众多分类器中, 有几种较为常用, 例如由Cover和Hart (1967) 提出的最近邻NNs (Nearest Neighbors) 分类器, 它基于数据样本之间的距离度量, 将待分类样本判定为与其最近邻类别; 还有Zhang等 (2006) 所研究的支持向量机SVM (Support Vector Machine) 分类器, 有效地对不同类别数据进行分类, 在许多复杂分类场景中表现出良好的性能; 此外, Wright等 (2009) 提出了一种基于稀疏表示的目标识别通用分类算法, 这种框架可以统一处理由于遮挡或残缺造成的误差, 稀疏表示理论有助于预测识别算法能处理多少遮挡, 以及如何选择训练图像以最大限度地提高对遮挡目标的鲁棒性。这些分类器在各自的应用场景中都发挥着重要作用, 为目标识别的准确性和高效性提供了有力支持。特

收稿日期: 2024-12-31; 预印本: 2025-02-13

基金项目: 国家自然科学基金(编号: 62331020, 62301403)

第一作者简介: 邢孟道, 研究方向为雷达成像技术、稀疏信号处理、激光合成孔径成像、微波光子合成孔径成像等。E-mail: xmd@xidian.edu.cn

通信作者简介: 张金松, 研究方向为雷达遥感(SAR)智能感知与识别、雷达目标自动识别等。E-mail: zhangjinsong@xidian.edu.cn

征提取技术主要用于获取目标的几何特征、变换域特征、电磁散射特征和神经网络特征。从SAR成像的角度描述复数图像的电磁散射特征，其代表了目标的固有物理特性，例如几何形状、结构和材料信息（张征，2023）。电磁散射特征不受方位角变化和分辨率差异的影响，以及对信噪比SNR（Signal-to-Noise Ratio）具有鲁棒性，因此基于电磁散射特征的方法可以有效识别SAR目标（Wu等，2024），在实际应用中具有较高的稳定性以及可解释性。但这种方法也存在特征设计复杂、计算效率低、识别精度低等方面的问题。

近些年来，深度学习DL（Deep Learning）凭借其强大的数据分析与特征提取能力，在SAR图像处理领域获得了极为广泛的应用。深度学习方法的优势在于可以自主学习目标的高维特征，不需要进行复杂的人工特征提取工作，且具有较高的计算效率和识别精度，但基于深度学习的特征没有反映SAR数据的独特性，构建的目标识别模型缺乏对SAR目标的可解释性和泛化能力。结合上述电磁散射特征和神经网络特征的优点，可以进一步提高SAR图像目标识别的性能和泛化能力。Zhang等（2021a）首次提出了一种新颖的SAR ATR融合框架FEC（Feature Fusion Framework based on Electromagnetic Scattering Features and Deep CNN Features），该方法分别从深度学习模型和属性散射中心ASC（Attributed Scattering Center）模型中提取目标特征，然后将电磁散射特征和神经网络特征相结合获得融合特征，最后通过分类器得到分类结果，该方法在不同实验条件下验证了其有效性和鲁棒性。因此与单一提取电磁散射特征或使用神经网络特征相比，这种特征融合的方法利用了二者的互补性，显著提高了SAR目标的识别性能，成为目前研究SAR图像目标识别方法的热点。

因此本文以基于电磁散射特征融合的SAR目标识别方法为基础，重点回顾近些年来以融合散射特征思想为基础进行车辆目标（Feng等，2021）、飞机目标（Guo等，2021）和舰船目标（Yu等，2021）识别相关领域的进展。并尝试讨论SAR目标识别领域未来的发展趋势，展望其发展方向。本文研究内容的整体框架如图1所示。




图1 本文的整体框架

Fig.1 The overall framework of this review

2 基于电磁散射特征融合的目标识别方法

近年来，机载与星载SAR系统的数据获取能力持续增强，其全天时、全天候对目标区域进行观测的优势，使得高分辨率SAR图像的获取成为可能。然而传统依赖人工判读的SAR图像解译方法存在耗时费力、解译准确度易受环境因素干扰等明显弊端，并且难以契合当下的任务需求。在此背景下，自动目标识别技术逐渐成为遥感领域的研究热点，如何高效、自动化地解译SAR图像，已然成为遥感领域亟待攻克的重要课题之一，因此探索创新的解译方法与技术路径，推动SAR图像解译向更快速、更精准、更智能的方向迈进，以满足日益增长的实际应用需求（邢孟道等，2022）。目标识别技术是SAR ATR系统的重要组成部分之一（Dudgeon和Dudgeon，1993）。目前SAR目标识别方法主要分为两类：传统机器学习方法和深度学习方法。

传统机器学习方法是指通过人工提取目标特征后再进行识别，SAR目标识别技术中广泛使用图像域特征、变换域特征以及电磁散射特征等。

对于典型的图像域特征,包括二进制鲁棒不变可扩展关键点特征(Liu等,2022a)、方向梯度直方图特征(Zhang等,2022a)以及目标轮廓和形状特征(Li等,2022b),它们直观反映了SAR图像的特征;对于变换域特征,主成分分析(Zhang和Ren,2011)、线性判别分析(Liu等,2006)、独立成分分析(Li等,2005)及其变体已广泛应用于SAR图像特征提取技术(Sun等,2021b)。同时,基于信号分析的方法,例如小波变换和Gabor滤波器(Akbarizadeh,2012)也能精确识别SAR目标。SAR目标原始数据蕴含着丰富的特征信息,其中电磁散射特征尤为关键,它从本质上反映了目标所具有的材料特质、结构形态以及几何轮廓等内在物理属性,这些属性构成了目标独特的散射表现。并且目标的后向散射回波可以建模为各个ASC响应的总和。ASC模型通过位置和属性信息有效刻画了目标局部散射点的结构特性。

近年来,深度学习已广泛应用于SAR图像处理领域。例如,Morgan(2015)在MSTAR(The Moving and Stationary Target Acquisition and Recognition)(Keydel等,1996)数据集上使用深度卷积神经网络DCNN(Deep Convolutional Neural Networks)进行目标分类,该方法可以直接从训练数据中学习可区分的特征,不需要人工的预先提取,并且有效地结合了DCNN和Softmax(Kiviluoto和Oja,1998)分类器,这种方法可以学习到目标判别性特征,该方法利用这一特性并有效地适配现有分类器,识别出了以前未察觉的目标。Chen等(2016)首次提出了一种新的全卷积网络A-ConvNet(All-Convolutional Networks),该网络只由稀疏连接层组成,它在实现超过99%识别精度的同时,显著减少了网络参数。Du等(2016)提出了一个无位移和旋转的卷积神经网络,利用增广数据集训练对位移和旋转不敏感的神经网络。Ding等(2016)提出了一种结合3种数据增强操作的目标识别方法,试图通过旋转、平移和添加噪声来训练图像。Wagner(2016)提出了将先验知识融入分类器的训练方法,进一步提高了分类器对成像误差和目标变化的鲁棒性,通过弹性失真和仿射变换产生人工训练数据,使用卷积神经网络从输入图像中提取特征,并使用SVM作为分类器。Kang等(2017a)提出了一种基于堆叠自动编码器的特征融合算法SAE(Stacked

Auto Encoder)的SAR目标识别特征融合算法,提取了23个基线特征和三片局部二值模式TPLBP(Three-Patch Local Binary Pattern)特征,这些特征能够以较少的冗余度和较强的互补性描述图像的全局和局部信息,为特征融合提供更丰富的信息,并且设计了一种有效的特征融合网络。将基线和TPLBP特征级联并输入到SAE中,使用非监督式学习算法,通过贪婪分层训练方法对SAE进行预训练,最后,利用Softmax分类器对模型进行了微调,并应用于目标分类。Malmgren-Hansen等(2017)首次研究转移学习相关的模拟数据集和真实的SAR图像之间的关系,其中模拟数据集是通过模拟目标雷达反射率添加到单个点散射体的地形模型中得到的。SAR ATR开发改进大规模和复杂场景的模拟数据集,为后续在真实SAR ATR应用中构建鲁棒的算法奠定基础。Lin等(2017)提出了一种用于训练有限SAR数据的深层高速单元卷积网络,该网络由高速卷积单元层、最大池化层和正则化层组成,并且通过堆叠单元结构来提取用于分类的深度特征。Zalpour等(2020)提出了一种新的分阶段检测方法,共分为感兴趣区域提取、循环目标检测提取、特征提取和分类4部分。通过一个改进RCNN(Girshick等,2014)来提取目标特征,并通过快速循环检测方法从提取的感兴趣区域中选取目标的候选对象,然后利用CNN输出特征模块提取高级特征,提取方向梯度直方图作为低级特征,最后使用SVM进行分类。Sharifzadeh等(2019)提出了一种融合卷积神经网络和多层感知机的算法,该算法具有更好的目标分类性能。经过良好训练的卷积神经网络可以从输入的SAR幅度图像中提取对噪声更鲁棒和更具代表性的特征(Chen等,2016)。

由于在标准工作条件SOC(Standard Operating Condition)和扩展工作条件EOC(Extended Operating Condition)下图像之间存在较大差异,在EOC下基于CNN的方法的识别精度会严重下降(Ding等,2018)。CNN在进行识别任务时,精度出现下降情况,主要归因于两点:其一是CNN的输入为SAR数据的幅度图像,缺少相位信息,致使无法获取SAR数据的完整特征;其二是在基于幅度图像的卷积神经网络架构里,卷积层存在局限性,难以有效捕捉SAR目标特征与雷达工作参数间的独特关联,进而影响了识别精度。相比依

靠卷积神经网络从幅度图像中提取轮廓特征的传统方式，基于电磁散射特征的方法站在SAR成像原理的视角，对SAR复图像中的散射中心进行精准描述，这种方式突破了幅度图像的限制，挖掘了SAR图像中的隐藏信息，为提升识别精度提供了新的角度（Potter和Moses，1997）。散射中心特征反映了雷达目标的局部电磁现象，可以将提取散射中心看作对不同散射中心模型参数的优化，例如几何绕射理论GTD（Geometrical Theory of Diffraction）（Keller等，1962）和属性散射中心ASC（Attributed Scattering Center）（Gerry等，1999）。散射中心的提取结果通常取决于多个因素，主要包括空间位置、复数强度以及其他物理参数，这些因素相互影响、相互关联。已经存在基于散射中心的SAR目标识别方法。例如，Chiang等（2000）提出了一种用于SAR目标识别的贝叶斯匹配方法，其中属性散射特征采用高频雷达散射参数模型。Dungan和Potter（2010）使用最小修剪平方豪斯多夫距离来匹配散射中心集，采用多维缩放技术在低维欧几里得空间中表示点模型，以便进行可视化和实验分析。Ding等（2017b）提出了一种基于匈牙利算法的匹配方法，该方法在EOC条件下对图像具有稳定性和高识别精度。电磁散射特征的构成较为特殊，由多个参数集整合而成，这与由特征向量表征的其他类型特征有着显著的区别，这种构成上的差异，使得电磁散射特征与其他类型特征难以实现融合，进一步限制了SAR目标识别方法在性能上的提升，使其无法充分发挥作用，难以实现更为精准高效的目标识别。

考虑到基于CNN特征的方法可以在SOC条件下获得很好的效果，而基于电磁散射特征的方法对EOC下的图像分类稳定性更高，Zhang等（2021a）首次提出了一种新的融合散射中心特征和网络特征的目标识别框架FEC，所提出的FEC框架示意图如图2所示，FEC方法由3个模块组成：基于视觉词袋模型的散射特征向量化模块、基于深度CNN的特征提取模块和特征融合模块（张金松，2022）。为了使提取到的属性散射中心特征能更好地作用于后续的特征融合与分类任务，采用K均值算法对其进行处理，将其转化为维数固定的视觉词袋特征向量。在网络结构方面，鉴于属性散射中心特征的维度特性，对经典的VGG网络进行轻量化改进，构建MVGG网络模型，通

过合理减少网络全连接层的数量，使其与属性散射中心特征的维度更加适配。在有限的训练样本条件下，尽可能充分地挖掘数据中的有效信息，确保网络能够在不损失关键特征的前提下，高效地完成训练与预测任务，最大程度地发挥训练样本的价值，提升模型的性能。为了进一步提升特征与分类器结合效率，引入判别相关分析方法，对特征进行并联融合处理。不仅有效地降低了特征的维度，减少了数据冗余，同时还增强了特征的判别能力，使得经过处理后的特征在与分类器结合时能够更加快速、准确地完成分类决策，提高整个目标识别模型的运行效率和准确性。表1给出了不同方法在SOC和EOC条件下的MSTAR数据集识别性能对比，可以看出FEC充分结合了基于属性散射中心特征提取方法的高鲁棒性和基于卷积神经网络方法的高准确性，实现了更有效和稳定的目标识别。

3 基于电磁散射特征融合的车辆目标识别方法

自动目标检测和识别在SAR系统中发挥着至关重要的作用。SAR目标识别是一个典型的图像模式识别问题，其目的是对SAR图像中感兴趣的目标进行检测和分类（El-Darymli等，2016）。在这个过程中，如何从SAR图像数据中提取强大且具有代表性的特征对后续目标识别精度有极大的影响。目前，广泛应用且公开的数据集为美国国防高等研究计划署所发布的MSTAR数据集，该数据集源自X波段HH极化聚束模式的SAR系统，通过该系统的精密采集，形成了丰富的数据资源，其涵盖了10种不同类别地面静止车辆目标的复数图像，这些复数图像能够拆分为幅度以及相位两部分，图像的距离分辨率和方位分辨率均为0.3 m。该数据集有力地推动了SAR图像车辆目标识别技术的发展与进步，成为众多科研人员在该领域深入研究不可或缺的关键资源之一，对整个SAR车辆目标识别技术体系的发展产生了深远的影响和重要的支撑作用。

卷积神经网络通过堆叠多个卷积层，具有强大特征表示能力，在目标识别方面取得了优异的性能（Gao等，2019）。对于散射特征而言，从SAR复数据中提取得到散射中心参数，将提取的散射中心参数与图像中的散射中心进行匹配，然

后对目标进行识别分类。由于散射中心反映了目标数据的物理特性，例如几何形状和结构，因此基于电磁散射中心的识别方法可以提供更稳健的

精度。基于这些分析，如果将卷积神经网络特征和散射特征融合，可以提高模型的识别精度（Zhang等，2021a）。




图2 Zhang等(2021a)所提方法FEC网络结构示意图

Fig. 2 Schematic diagram of the network structure of the method FEC proposed by Zhang et al. (2021a)

表1 Zhang等(2021a)所提方法FEC和其他方法的识别准确度

Table 1 Identification accuracy of the method FEC proposed by Zhang et al.(2021a) and other methods			/%
方法类型	SOC	EOC	
BFM	95.62	97.90	
SVM	96.78	96.64	
ACN	99.13	98.12	
SRC	96.29	95.12	
FGL	99.08	98.46	
FEC(所提方法)	99.59	98.48	

许多研究尝试提取多个特征并将它们融合到统一的特征空间中，再将这些特征用于SAR目标识别。Amrani和Jiang（2017）利用CNN提取SAR图像深度特征的优势，为SAR图像引入更强大的判别特征和鲁棒表征能力，并使用特征串联策略和判别相关性分析算法来融合深度CNN特征。Kechagias–Stamatis和Aouf（2019）将AlexNet的聚类与稀疏编码理论相融合。虽然这些基于幅度图像的特征融合方法比传统的单一特征方法具有更好的性能，但这些研究忽略了目标的散射中心特征。为了解决这个问题，Zhang等（2021a）首次提出了一种新的融合散射中心特征向量和网络特征向量的目标识别框架FEC，显著提高了目标识别精度（图2）。然而在这种方法中，散射中心特

征和CNN特征被转换为特征向量，这导致了特征图的几何信息退化，并且特征提取网络中的加权参数无法根据训练损失进行实时更新。

为了解决上述问题，Zhang等（2022a）在FEC的基础上提出了一种融合散射中心特征和深度卷积神经网络特征的复数网络。该方法包含散射中心提取模块、重建模块、CNN特征提取模块、特征融合与分类模块，其中散射中心特征和CNN特征在特征图层进行融合，保留了二维特征图的空间信息。与Zhang等（2021a）中将特征图转换为固定维向量进行特征融合相比，所提出的融合策略不仅可以保留散射中心和CNN特征的位置信息，还可以促进后续的半端到端学习过程。此外，全卷积VGGNet和特征融合子网络被组合成端到端结构，在这种结构中，虽然散射中心提取中的权重参数是固定的，但VGGNet和各个子网络中权重参数的自适应和自动更新使网络具有更好的识别性能。所提融合识别网络结构示意图如图3所示。表2给出了不同方法在MSTAR数据集上的识别准确度，可以看出所提算法在识别准确度和识别泛化能力上展现了优秀的性能。

受Zhang等（2021a）融合电磁散射特征和深度网络特征进行目标识别的启发。Feng等（2021）提出一种基于集成部件模型和深度学习算法的SAR目标分类方法。首先，利用基于属性散射中心的部件模型，通过部件卷积和改进的双向卷积

循环网络提取目标的局部特征。然后，利用改进的全卷积网络提取目标的全局特征。通过局部特征和全局特征的决策融合得到最终的分类结果。Li 等（2022b）将从目标回波中提取的 ASC 作为 SAR ATR 的目标分量，根据 ASC 的几何散射类型对 SAR 目标进行划分，不仅能使分类结果更加稳健，还能准确表征目标的电磁散射特性，将多尺度 CNN 特征与 ASC 特征融合以增强特征描述能力。

在 MSTAR 数据集上进行的大量实验，证明了所提方法的卓越性能。Liu 等（2022b）提出了一种新的特征融合学习框架 SDF-Net，将 ASC 视为集合数据，而非多个独立的点，这样可以更好地挖掘散射体之间的拓扑关系，将可提供中层语义和结构信息的散射特征与 CNN 特征互补融合，形成端到端的高层特征学习框架，增强网络在复杂观测条件下的泛化能力。




图3 Zhang等(2022a)所提方法网络结构示意图

Fig. 3 Schematic diagram of the network structure of the method proposed by Zhang et al. (2022a)

表2 Zhang等(2022a)所提方法和其他方法的识别准确度
Table 2 Identification accuracy of the method proposed by Zhang et al. (2022a) and other methods

方法类型	准确度/%
BFM	95.62
SVM	96.78
ACN	99.13
SRC	96.29
FGL	99.08
所提方法	99.51

虽然许多学者将属性散射特征与 CNN 特征融合，并提高了 SAR 图像目标识别结果。但他们将 SAR 图像中提取的 ASC 视为多个组件或整体，忽略了 ASC 的分布关系。Li 等（2022a）有效地将全局视觉特征、局部 ASC 结构特征以及局部视觉特征相结合，进一步提高了 SAR ATR 的性能，探索 ASC 信息提取物理结构特征的有效方法，更好地利用 SAR 目标的电磁散射特性。在 Li 等（2022a）的基础上，Li 等（2023）提出了一种结合 CNN 和多尺度图卷积网络的新型 SAR ATR 方法 MSGCN，

该方法同时提取全局视觉特征和局部结构特征，这里的局部结构特征包含局部物理结构信息和局部视觉信息。考虑到仅仅依靠提取的 ASC 参数不足以进行图卷积网络学习，因此通过将浅层 CNN 特征图中每个 ASC 的对应局部视觉特征与 ASC 重建图相乘构建节点特征，这些特征进一步输入到图卷积网络中学习局部结构特征。最后将学习到的局部结构特征与全局视觉特征融合。

SAR 数据中除了当前使用的 ASC 特征和图像特征之外，还具有其他的雷达相关特征，如果有效利用这些特征（Wen 等，2024），可进一步提高目标识别的准确性、可靠性和泛化能力。Wen 等（2024）提出了一种多模态特征融合学习框架 MoFFL，从不同的目标数据域中捕获全面的雷达特性、散射拓扑和图像特征，并实现特征融合以增强互补性。Zhao 等（2025）开发了一种自适应散射特征感知和融合网络 ASAF-Net，该网络滤波并整合了目标的散射信息和方位角知识，以获得更全面、更具判别性的目标特征。

4 基于电磁散射特征融合的飞机目标识别方法

在SAR图像的智能化解译中,目标检测与识别占据着关键地位(Sun等,2022a)。飞机作为SAR图像中的典型目标,不仅数量可观、种类繁多,而且其蕴含颇高的观测价值(Fu等,2018)。借助SAR图像开展飞机目标的检测识别工作,精准提取飞机目标的型号、种类、所处位置以及运行状态等关键信息,这些信息在实际应用场景中具有不可估量的价值(王智睿等,2023)。因此,深入开展SAR图像飞机目标检测识别研究具有极为重要的学术价值和现实意义(Du等,2020)。目前公开的SAR飞机目标检测识别数据集较为有限,公开报道的数据集有SADD(SAR Aircraft Detection Dataset)(Zhang等,2022c)和MSAR-1.0(large-scale Multi-class SAR image target detection dataset-1.0)(Xia等,2022)。

深度学习模型是靠数据驱动的,然而SAR数据获取方式受限,SAR目标特征随不同目标姿态角变化显著,SAR目标解译需要专业经验和先验知识,以上原因都会导致SAR目标样本不足,因此将通用的深度学习方法应用于SAR目标识别任

务仍面临的挑战(Sun等,2022a;Wang等,2020)。与SAR车辆、舰船目标相比,SAR飞机的成像结果由许多离散的强散射点组成,强散射点代表SAR图像中局部散射区域的最大像素值,具有优越的显著性和稳定性(Fu等,2021),飞机的离散结构使其能更有效地利用散射特征。因此,结合强散射点是优化SAR飞机分类性能的一种可行方法,Guo等(2021)提出了一种散射信息增强SIE(Scattered Information Enhancement)与注意力金字塔网络APN(Attention Pyramid Network)相结合的方法。Sun等(2022a)针对SAR飞机分类设计了一种新型基于散射特征分析网络的少样本学习框架,该网络利用散射提取模块将目标成像机制与网络相结合,并通过监督学习获取每种类型目标的散射点数量和分布。Zhao等(2023)提出了一种创新的散射特征空间结构关联网SFSA,所提SFSA网络结构示意图如图4所示,将提取的飞机的强散射点SSP转换为图结构数据,采用图卷积神经网络GCN(Graph Convolutional Networks)提取电磁散射特征高级语义,使用改进的VGGNet提取飞机的图像域特征,该方法融合了飞机结构的电磁散射特征和更具辨别力的图像域特征,实现了更高的识别性能。




图4 Zhao等(2023) SFSA网络结构示意图

Fig. 4 Schematic diagram of the network structure of the method SFSA proposed by Zhao et al. (2023)

虽然融合电磁散射特征可以准确地识别目标的关键点,但上述方法只将关键点作为一种监督信息,而没有充分利用散射点的位置和空间信息。只关注目标的整体,忽略了独立的部件特征。受可变形部件模型DPM(Deformable Part Model)方

法中同一类别的物体总是具有相似部件的启发(Felzenszwalb等,2010),虽然由成像条件的不同造成飞机的纹理特征并不完全相同,然而它们都包含具有稳定分布的显著离散结构。在高分辨率SAR图像中,飞机中具有二面角和三面角部件的

关键组件表现为强散射点的离散簇 (Zhang 等, 2021a)。因此这些具有局部区域大像素值的散射点簇具有重要的研究意义 (Pan 等, 2017)。这些散射点簇的位置连接构成了每个类别中飞机的独特分布, 有助于提高飞机目标分类精度。Kang 等 (2023) 将拓扑和组件分布的概念引入 SAR 飞机模型。有效地提取和利用散射点的结构特征进行 SAR 图像的细粒度分类。Ye 和 Du (2024) 提出了一种散射点幅度自适应检测识别网络 SADRN, 并构造多任务头, 解决了同时执行检测与识别任务时相互干扰导致性能下降的问题, 实现了检测和识别的集成, 提升了模型的性能。

5 基于电磁散射特征融合的舰船目标识别方法

近年来, 随着 SAR 图像数据的不断增长, SAR 舰船识别作为 SAR 图像解译的一个重要分支, 在海洋监测、国防安全等方面有重要价值 (He 等, 2024)。舰船作为海上的重要人造物体, 其构造包含许多复杂的金属部件。从雷达探测的角度来看, 这些金属部件使舰船目标具有较大的雷达散射截面 RCS (Radar Cross Section), 这种较大的 RCS 特性会使得舰船在 SAR 图像中呈现出高于其他目标以及背景的能量, 在图像中表现出较为明显的特征 (Touzi 等, 1988)。正是 SAR 在探测舰船时所展现的独特优势, 能够清晰地捕捉到舰船目标的显著特征, 使其成为现代海上监视领域中极具价值的手段。

目前, 公开的 SAR 图像舰船目标识别所常用的数据集为中国的 OpenSARShip 数据集 (Huang 等, 2018)、SSDD (Zhang 等, 2021c)、AIR SARShip-1.0 (孙显 等, 2019)、LS SSDD-v1.0 (Zhang 等, 2020)。其中 OpenSARShip 数据集主要聚焦亚洲地区的 5 个港口, 这些港口能够反映特定区域内的舰船分布情况, 包含 17 种不同类型的舰船, 由 41 幅 SAR 图像组成, 复数数据记录了 VV 和 VH 极化通道下的幅度和相位信息, 虽然地距数据丢弃了相位信息, 仅保留幅度信息, 但在一些只关注舰船位置和大致轮廓等情况的研究中, 地距数据的这种形式可以满足基本需求, 节省更多的计算资源。AIR SARShip-1.0 数据集来源于高分三号卫星的 SAR 图像, 共包含 31 景图像。涵盖了多种场景类型, 包括港口、岛礁以及不同级别海况的海面等;

其背景场景多样, 包含近岸和远海等不同环境, 能为船舶检测研究提供更接近真实世界的场景, 从而更好地测试和优化算法。LS SSDD-v1.0 数据集共包含 15 张大场景 SAR 图像, 这些图像取自 15 幅原始大场景星载 SAR 图像, 极化模式包含 VV 和 VH 两种模式, 可用于开发和评估各种 SAR 舰船检测算法, 以提高在大场景、复杂背景下舰船的检测精度和效率。

若要实现舰船的精确识别, 需要有效的提取各类别舰船的特征 (Yao 等, 2020)。在舰船检测领域, 依据所用特征的差异, 其检测方法大致归类为两类: 一类是以统计模型为基础的方法, 这类方法通过对数据的统计特性进行分析和建模, 实现对舰船目标的检测; 另一类则是依托 DL 技术的方法, 深度学习从大量数据中自动学习舰船目标的特征后完成检测任务, 由 Wang 等 (2016) 提出的谱残差 SR 方法, 以及由 Leng 等 (2015) 研究的恒虚警率 CFAR 方法, 在实际应用中展现出了一定的有效性, 促使科研人员开发出了众多改进算法, 并在相关领域得到了广泛的实践应用。例如, 单元平均 CFAR 方法 (Barkat 和 Varshney, 1991) 针对并行拓扑和串联拓扑两种分布式传感器网络拓扑结构, 研究了自适应平均 CFAR 检测问题。同时, CFAR (Gao 等, 2009; Kang 等, 2017b) 方法已与各种模块相结合。随着 SAR 舰船检测对精度的要求不断提高, 基于图像特征的方法受到了广泛关注, 其中就包括 Chen 等 (2011) 提出的边缘增强最大稳定极值区域方法 EMSERs。这些依赖于统计或手工提取特征的方法, 在海面环境较为单一、杂波较少的情况下, 检测效果显著, 能够较为准确地识别出舰船目标。但在复杂 SAR 图像中, 经常会出现散落岛屿、海岸线以及强海情等复杂背景, 这些方法就会容易产生较高的虚警率, 严重影响检测结果的准确性和可靠性, 从而限制了其在复杂场景中的应用 (Zhai 等, 2016)。这也促使科研人员不断探索更有效的检测手段, 以克服复杂背景带来的挑战, 推动 SAR 舰船检测技术向更精准、更稳定的方向发展, 进而满足在复杂多变的海洋环境下舰船检测日益增长的需求。

近年来, 深度学习因其强大的特征表示能力受到广泛关注 (Zhang 等, 2021b)。特别 CNN 在光学自然图像处理中表现出高鲁棒性和高效率性, He 等 (2022) 提出了一种实现对复杂云的高精度

检测的轻量级网络 DABNet。在当前的技术发展进程中, 基于 CNN 的目标检测方法在学术研究领域以及实际应用场景中都具有极大的价值与潜力。从检测头的结构特性出发进行分类, 基于 CNN 的目标检测方法能够被划分为两阶段检测模式以及单阶段检测模式。对于两阶段检测方法而言, 以 R-CNN (Girshick 等, 2014) 和 Faster R-CNN (Ren 等, 2017) 为代表的一系列方法及其衍生变体在 SAR 舰船检测的实际应用场景中发挥了显著优势, 能够更为精准地从复杂的 SAR 图像数据中识别出舰船目标, 为海上目标监测、海事安全保障等领域提供了强有力的技术支持, 也为后续相关检测方法的改进与创新提供了宝贵的思路和经验借鉴。Li 等 (2017) 提出了一种改进的 Faster R-CNN 方法, 并提供了一个公开的 SAR 舰船检测数据集 SSDD。Kang 等 (2017b) 创造性地将 Faster R-CNN 与 CFAR 相结合, 将 Faster R-CNN 生成的候选区作为 CFAR 的保护窗口。Cui 等 (2019) 提出了一种基于密集注意金字塔网络 DAPN (Dense Attention Pyramid Network) 的 SAR 图像多尺度舰船检测方法, DAPN 采用金字塔结构, 将卷积块注意模块 CBAM 密集地连接到金字塔网络上下的每个级联特征映射中, 提取了丰富的包含分辨率和语义信息的特征, 极大提高了多尺度舰船检测的准确度。Sun 等 (2021a) 提出了一种专门为遥感图像复合目标检测设计的基于部件的卷积神经网络 PBNNet, PBNNet 将复合目标视为一组部件, 并将部件信息整合到上下文信息中, 以提高复合目标检测的效果。同时, Cui 等 (2021) 提出了一种基于 CenterNet 的

大规模 SAR 图像舰船检测方法, 引入空间增强注意力模块, 用于大规模 SAR 图像中的舰船检测。两阶段船舶方法通常具有较高的检测性能, 而单阶段方法具有较快的运行速度 (Wei 等, 2020)。对于单阶段方法, 代表性方法是 SSD (Single Shot MultiBox Detector) (Liu 等, 2016)、YOLO (You Only Look Once) (Redmon 等, 2016) 和 RetinaNet (Zhao 等, 2020)。受单阶段 YOLO 系列算法的启发 (Xu 等, 2024), Zhang (2019) 提出了一种基于卷积神经网络的 SAR 图像实时舰船检测方法 G-CNN, G-CNN 是一种全新的网络结构, 它主要由一个骨干卷积神经网络 B-CNN 和一个检测卷积神经网络 D-CNN 组成。这种方法通过网格化输入图像来提高检测速度, 并使用了深度可分离卷积, 进一步提升了检测速度和精度。Zhang 等 (2022b) 提出了一种端到端无锚 SAR 舰船检测网络, 网络结构如图 5 所示, 在特征图的不同 FPN 层上检测不同尺寸的舰船目标, 这种方法大幅度提高了复杂背景下多尺度舰船目标检测的精度, 并提出与舰船目标的定向角度和尺度相关的定向非归一化高斯函数方差和协方差, 大幅度降低了对中心点位置漂移的敏感性, 提高舰船检测的召回率, 还引入了基于关键点的边界框感知向量 BBAV, 这些在笛卡尔坐标系 4 个象限中的分布向量结合 FPN 可以准确地检测多尺度船舶, 同时保持快速的检测速度。Zhang 等 (2021d) 提出了一种能够在小样本、高虚警率下实现鲁棒检测的相关滤波算法, 该方法在小样本数据集上取得了良好的性能。




图5 Zhang等(2022b)所提方法网络结构示意图

Fig. 5 Schematic diagram of the network structure of the method proposed by Zhang et al. (2022b)

在积极开发新的CNN模型的同时,研究人员也尝试通过融合传统特征和CNN提取的抽象特征来开发更好的SAR舰船分类方法(Guan等, 2023), Wang等(2017)提出了一种利用多个CNN进行目标分类的深度框架,该框架结合了SAR图像的强度和边缘信息。Zhang等(2021a)提出了一种新的融合散射中心特征向量和网络特征向量的目标识别框架。大量实验结果表明,这种融合电磁散射特征的CNN模型在舰船分类中可以取得较好的结果(Guan等, 2023)。Sun等(2022b)提出了一种结合散射特征船舶检测和分类网络,设计了一个强大的散射点感知网络SPAN,该网络根据通过捕获舰船存在区域的强散射点的分布特征区分舰船类别。Zhang等(2023b)提出了一种新的SAR船舶检测方法SPG-OSD,设计了一个基于散射特征的两级定向检测模块,在检测器中结合SAR散射特征来改善网络的性能,减少虚警和舰船漏检的问题。Zhang等(2023a)提出了一种基于散射关键点的散射特征拓扑网络SPT-FSC,设计了一个拓扑编码分支,并对散射点的拓扑信息进行一系列编码操作,实现了散射点拓扑结构嵌入,提高了网络对成像机制的鲁棒性,降低了SAR图像的成像可变性。Zhang等(2024)提出了一种用于SAR舰船目标识别的多尺度全局散射特征关联网络MGSFA-Net,利用精细分割将SAR图像中的舰船目标从背景中分离出来。基于k近邻算法提取舰船目标的散射中心,并将其转换为局部图结构。局部结构由多尺度模块和散射特征关联模块生成多尺度全局散射特征。利用多核深度特征提取模块获得目标的深度特征,最后,通过加权积分融合散射特征和深度特征,丰富特征的多样性。

6 展 望

基于散射中心特征和CNN特征融合的方法可以很大程度上提高SAR图像目标识别的可解释性和准确性。近年来,随着现代SAR ART技术的革新和发展,这种融合电磁散射特征的CNN模型在车辆、飞机和舰船等目标识别中都具有较高的性能。立足当下研究现状,后续研究的着力点将聚焦于如下几个关键方向。

6.1 超带宽高分辨率下电磁散射参数提取技术

现如今的方法大多是将SAR图像中提取的散

射中心特征看作多个组件或者整体,并结合散射中心特征的拓扑关系进行目标识别和分类,尽管这样可以较为全面和判别性的描述目标特征,但单从图像域考虑忽略了目标散射中心特征回波域的电磁响应和物理属性。在SAR数据处理中,电磁散射中心参数提取技术发挥着关键作用,它能够挖掘出目标点更为丰富的特征细节,极大地提升了SAR回波信息的可挖掘深度与利用价值,为后续的目标识别与分类工作打下坚实基础。国内外微波光子器件领域的蓬勃发展,推动着雷达成像分辨率实现了从分米级到厘米级的巨大跨越。这使得成像结果所蕴含的信息量呈爆炸式增长(Yang等, 2021; Deng等, 2022)。目标的电磁散射特性是其几何形态和材质的综合反映,高分辨率和超宽带雷达为散射特性的多尺度、全频段分析提供了可能,因此在超大带宽高分辨率下进行基于电磁散射模型的参数提取与研究尤为重要。目前电磁散射特征提取方法更多的集中在传统基于数学模型方法上,很少利用深度学习进行参数提取。深度神经网络虽然具有高效率与高准确性的优点,但是由于电磁散射特征参数复杂、相互耦合等特点,并且卷积神经网络这种黑匣子式的提取方法,使得基于深度学习的电磁散射特征参数提取效果不尽人意。因此如何使用卷积神经网络高效率的提取出独立解耦合的电磁散射特征参数是未来在超大带宽超高分辨率条件下研究的发展方向。

6.2 基于特征融合思想的零样本目标检测方法

在SAR目标检测识别领域,零样本目标检测是一种能够在缺乏目标样本标注的情况下,基于先验知识或其他间接信息实现目标检测的方法。在实际应用中,SAR图像中的目标标注复杂且成本高,尤其是军事目标或隐身目标,难以提供大规模的训练数据。并且实际场景中的目标种类繁多,无法在训练阶段覆盖所有类别,因此零样本在SAR领域具有重要意义。融合SAR图像的几何形状、材质特性等低级电磁散射特征和语义嵌入、场景信息等高级网络特征,有助于在数据稀缺的条件下实现对未知目标的高效检测。因此未来构建包含电磁散射特性、物理模型、语义描述的多模态知识库,为零样本目标检测提供更强的先验支持,实现更丰富的先验知识融合。还应该充分

利用散射特征之间的拓扑结构信息,挖掘目标类别之间的隐含关系,提升模型的推理能力。为以后开发自适应多场景、高分辨SAR图像的零样本检测模型打下坚实基础。

6.3 基于特征融合思想的轻量型网络模型

随着SAR数据处理任务复杂度的增加以及实际应用中计算效率和实时性的需求,设计高效的轻量型网络模型尤为重要。目前有许多常用的模型压缩与加速方法,比如将传统卷积分解为深度卷积和逐点卷积,可以大幅降低参数量和计算量;将卷积操作分成多个组并行计算,可减少计算复杂度;通过删除冗余通道或网络层,优化网络结构;也可以将模型权重从浮点数压缩为低位表示,保持关键特征信息的同时减少冗余。然而轻量网络模型在模型设计方面的牺牲导致复杂环境下目标识别缺乏鲁棒性。尽管基于特征融合的方法提高了识别准确性,但通常参数量大、计算复杂,网络结构复杂,训练和推理速度较慢,难以直接应用于资源受限的设备,因此未来需要在研究参数和计算量优化的同时实现目标电磁散射等多特征融合等方面取得突破。

7 结 语

随着电磁散射理论、机器学习和图像处理方法的发展,SAR目标的主动识别技术不断得到完善。考虑到传统机器学习方法和基于深度学习方法在SAR ATR中的优缺点,本文以融合电磁散射特征和神经网络特征的目标识别方法为圆心,分别讨论了这种融合电磁散射特征的思想在车辆、飞机与舰船目标识别的应用。并且简要探讨了未来目标识别方法的发展方向。本文旨在深入浅出地阐述SAR目标识别领域的关键要点,期望能够助力读者拓展对该领域的认知,为相关研究与应用提供有益的理论支撑与方向指引。

参考文献(References)

Akbarizadeh G. 2012. A new statistical-based kurtosis wavelet energy feature for texture recognition of SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11): 4358-4368 [DOI: 10.1109/TGRS.2012.2194787]

Amrani M and Jiang F. 2017. Deep feature extraction and combination for synthetic aperture radar target classification. *Journal of Applied Remote Sensing*, 11(4): 042616 [DOI: 10.1117/1.JRS.11.

042616]

Bao Z, Xing M D and Wang P. 2005. *Radar Imaging Technology*. Beijing: Publishing House of Electronics Industry (保铮, 邢孟道, 王彤. 2005. 雷达成像技术. 北京: 电子工业出版社)

Barkat M and Varshney P K. 1991. Adaptive cell-averaging CFAR detection in distributed sensor networks. *IEEE Transactions on Aerospace and Electronic Systems*, 27(3): 424-429 [DOI: 10.1109/7.81424]

Chen H Z, Tsai S S, Schroth G, Chen D M, Grzeszczuk R and Girod B. 2011. Robust text detection in natural images with edge-enhanced Maximally Stable Extremal Regions. 2011 18th IEEE International Conference on Image Processing. Brussels: IEEE: 2609-2612 [DOI: 10.1109/ICIP.2011.6116200]

Chen S Z, Wang H P, Xu F and Jin Y Q. 2016. Target classification using the deep convolutional networks for SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8): 4806-4817 [DOI: 10.1109/TGRS.2016.2551720]

Chiang H C, Moses R L and Potter L C. 2000. Model-based classification of radar images. *IEEE Transactions on Information Theory*, 46(5): 1842-1854 [DOI: 10.1109/18.857795]

Cover T and Hart P. 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1): 21-27 [DOI: 10.1109/TIT.1967.1053964]

Cui Z Y, Li Q, Cao Z J and Liu N Y. 2019. Dense attention pyramid networks for multi-scale ship detection in SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11): 8983-8997 [DOI: 10.1109/TGRS.2019.2923988]

Cui Z Y, Wang X Y, Liu N Y, Cao Z J and Yang J Y. 2021. Ship detection in large-scale SAR images via spatial shuffle-group enhance attention. *IEEE Transactions on Geoscience and Remote Sensing*, 59(1): 379-391 [DOI: 10.1109/TGRS.2020.2997200]

Deng Y H, Xing M D, Sun G C, Liu W K, Li R M and Wang Y. 2022. A processing framework for airborne microwave photonic SAR with resolution up to 0.03 m: motion estimation and compensation. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5121017 [DOI: 10.1109/TGRS.2022.3229302]

Ding B Y, Wen G J, Ma C H and Yang X L. 2018. An efficient and robust framework for SAR target recognition by hierarchically fusing global and local features. *IEEE Transactions on Image Processing*, 27(12): 5983-5995 [DOI: 10.1109/TIP.2018.2863046]

Ding B Y, Wen G J, Zhong J R, Ma C H and Yang X L. 2017b. A robust similarity measure for attributed scattering center sets with application to SAR ATR. *Neurocomputing*, 219: 130-143 [DOI: 10.1016/j.neucom.2016.09.007]

Ding J, Chen B, Liu H W and Huang M Y. 2016. Convolutional neural network with data augmentation for SAR target recognition. *IEEE Geoscience and Remote Sensing Letters*, 13(3): 364-368 [DOI: 10.1109/LGRS.2015.2513754]

Du K N, Deng Y K, Wang R, Zhao T and Li N. 2016. SAR ATR based on displacement- and rotation-insensitive CNN. *Remote Sensing Letters*, 7(9): 895-904 [DOI: 10.1080/2150704X.2016.1196837]

Du L, Dai H, Wang Y, Xie W T and Wang Z C. 2020. Target discrimination based on weakly supervised learning for high-resolution

- SAR images in complex scenes. *IEEE Transactions on Geoscience and Remote Sensing*, 58(1): 461-472 [DOI: 10.1109/TGRS.2019.2937175]
- Dudgeon D E and Dudgeon R T. 1993. An overview of automatic target recognition. *Lincoln Laboratory Journal*, 6(1): 3-10
- Dungan K E and Potter L C. 2010. Classifying transformation-variant attributed point patterns. *Pattern Recognition*, 43(11): 3805-3816 [DOI: 10.1016/j.patcog.2010.05.033]
- El-Darymli K, Gill E W, McGuire P, Power D and Moloney C. 2016. Automatic target recognition in Synthetic Aperture Radar imagery: a state-of-the-art review. *IEEE Access*, 4: 6014-6058 [DOI: 10.1109/ACCESS.2016.2611492]
- Felzenszwalb P F, Girshick R B, McAllester D and Ramanan D. 2010. Object detection with discriminatively trained part-based models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(9): 1627-1645 [DOI: 10.1109/TPAMI.2009.167]
- Feng S J, Ji K F, Zhang L B, Ma X J and Kuang G Y. 2021. SAR target classification based on integration of ASC parts model and deep learning algorithm. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 10213-10225 [DOI: 10.1109/JSTARS.2021.3116979]
- Fu K, Dou F Z, Li H C, Diao W H, Sun X and Xu G L. 2018. Aircraft recognition in SAR images based on scattering structure feature and template matching. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(11): 4206-4217 [DOI: 10.1109/JSTARS.2018.2872018]
- Fu K, Fu J M, Wang Z R and Sun X. 2021. Scattering-keypoint-guided network for oriented ship detection in high-resolution and large-scale SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 11162-11178 [DOI: 10.1109/JSTARS.2021.3109469]
- Gao F, Huang T, Sun J P, Wang J, Hussain A and Yang E F. 2019. A new algorithm for SAR image target recognition based on an improved deep convolutional neural network. *Cognitive Computation*, 11(6): 809-824 [DOI: 10.1007/s12559-018-9563-z]
- Gao G, Liu L, Zhao L J, Shi G T and Kuang G Y. 2009. An adaptive and fast CFAR algorithm based on automatic censoring for target detection in high-resolution SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 47(6): 1685-1697 [DOI: 10.1109/TGRS.2008.2006504]
- Gerry M J, Potter L C, Gupta I J and van der Merwe A. 1999. A parametric model for synthetic aperture radar measurements. *IEEE Transactions on Antennas and Propagation*, 47(7): 1179-1188 [DOI: 10.1109/8.785750]
- Girshick R, Donahue J, Darrell T and Malik J. 2014. Rich feature hierarchies for accurate object detection and semantic segmentation//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE: 580-587 [DOI: 10.1109/CVPR.2014.81]
- Guan Y N, Zhang X, Chen S W, Liu G W, Jia Y J, Zhang Y, Gao G, Zhang J, Li Z W and Cao C H. 2023. Fishing vessel classification in SAR images using a novel deep learning model. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5215821 [DOI: 10.1109/TGRS.2023.3312766]
- Guo Q, Wang H P and Xu F. 2021. Scattering enhanced attention pyramid network for aircraft detection in SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 59(9): 7570-7587 [DOI: 10.1109/TGRS.2020.3027762]
- He J Y, Su N, Xu C A, Yin L, Liao Y P and Yan Y M. 2024. From optical to SAR: A SAR ship detection algorithm based on multi-level cross-modality alignment. *National Remote Sensing Bulletin*, 28(7): 1789-1801 (何佳月, 宿南, 徐从安, 尹璐, 廖艳苹, 闫奕名. 2024. 从光学到SAR: 基于多级跨模态对齐的SAR图像舰船检测算法. *遥感学报*, 28(7): 1789-1801) [DOI: 10.11834/jrs.20243249]
- He Q B, Sun X, Yan Z Y and Fu K. 2022. DABNet: deformable contextual and boundary-weighted network for cloud detection in remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5601216 [DOI: 10.1109/TGRS.2020.3045474]
- Huang L Q, Liu B, Li B Y, Guo W W, Yu W H, Zhang Z H and Yu W X. 2018. OpenSARShip: a dataset dedicated to Sentinel-1 ship interpretation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(1): 195-208 [DOI: 10.1109/JSTARS.2017.2755672]
- Kang M, Ji K F, Leng X G, Xing X W and Zou H X. 2017a. Synthetic aperture radar target recognition with feature fusion based on a stacked autoencoder. *Sensors*, 17(1): 192 [DOI: 10.3390/s17010192]
- Kang M, Leng X G, Lin Z and Ji K F. 2017b. A modified faster R-CNN based on CFAR algorithm for SAR ship detection//2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP). Shanghai: IEEE: 1-4 [DOI: 10.1109/RSIP.2017.7958815]
- Kang Y Z, Wang Z R, Zuo H Y, Zhang Y D, Yang Z J, Sun X and Fu K. 2023. ST-Net: scattering topology network for aircraft classification in high-resolution SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5202117 [DOI: 10.1109/TGRS.2023.3236987]
- Kechagias-Stamatis O and Aouf N. 2019. Fusing deep learning and sparse coding for SAR ATR. *IEEE Transactions on Aerospace and Electronic Systems*, 55(2): 785-797 [DOI: 10.1109/TAES.2018.2864809]
- Kechagias-Stamatis O and Aouf N. 2021. Automatic target recognition on synthetic aperture radar imagery: a survey. *IEEE Aerospace and Electronic Systems Magazine*, 36(3): 56-81 [DOI: 10.1109/MAES.2021.3049857]
- Keller J B. 1962. Geometrical theory of diffraction. *Journal of the Optical Society of America*, 52: 116-130 [DOI: 10.1364/JOSA.52.000116]
- Keydel E R, Lee S W and Moore J T. 1996. MSTAR extended operating conditions: a tutorial//Proceedings Volume 2757, Algorithms for Synthetic Aperture Radar Imagery III. Orlando: SPIE: 228-242 [DOI: 10.1117/12.242059]
- Kiviluoto K and Oja E. 1998. Softmax-network and S-Map-models for density-generating topographic mappings//1998 IEEE International Joint Conference on Neural Networks Proceedings. IEEE World Congress on Computational Intelligence. Anchorage: IEEE: 2268-2272 [DOI: 10.1109/IJCNN.1998.687214]

- Leng X G, Ji K F, Yang K and Zou H X. 2015. A bilateral CFAR algorithm for ship detection in SAR images. *IEEE Geoscience and Remote Sensing Letters*, 12(7): 1536-1540 [DOI: 10.1109/LGRS.2015.2412174]
- Li C, Du L and Li Y. 2023. A novel method combining global visual features and local structural features for SAR ATR. *IEEE Geoscience and Remote Sensing Letters*, 20: 4013305 [DOI: 10.1109/LGRS.2023.3323655]
- Li C, Du L, Li Y and Song J L. 2022a. A novel SAR target recognition method combining electromagnetic scattering information and GCN. *IEEE Geoscience and Remote Sensing Letters*, 19: 4508705 [DOI: 10.1109/LGRS.2022.3178234]
- Li J W, Qu C W and Shao J Q. 2017. Ship detection in SAR images based on an improved faster R-CNN//2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA). Beijing: IEEE: 1-6 [DOI: 10.1109/BIGSAR DATA.2017.8124934]
- Li S Z, Lu X G, Hou X W, Peng X H and Cheng Q S. 2005. Learning multiview face subspaces and facial pose estimation using independent component analysis. *IEEE Transactions on Image Processing*, 14(6): 705-712 [DOI: 10.1109/TIP.2005.847295]
- Li Y, Du L and Wei D. 2022b. Multiscale CNN based on component analysis for SAR ATR. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5211212 [DOI: 10.1109/TGRS.2021.3100137]
- Lin Z, Ji K F, Kang M, Leng X G and Zou H X. 2017. Deep convolutional highway unit network for SAR target classification with limited labeled training data. *IEEE Geoscience and Remote Sensing Letters*, 14(7): 1091-1095 [DOI: 10.1109/LGRS.2017.2698213]
- Liu J M, Xing M D, Yu H W and Sun G C. 2022a. EFTL: complex convolutional networks with electromagnetic feature transfer learning for SAR target recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-11 [DOI: 10.1109/TGRS.2021.3083261]
- Liu Q S, Tang X O, Lu H Q and Ma S D. 2006. Face recognition using kernel scatter-difference-based discriminant analysis. *IEEE Transactions on Neural Networks*, 17(4): 1081-1085 [DOI: 10.1109/TNN.2006.875970]
- Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y and Berg A C. 2016. SSD: single shot MultiBox detector//14th European Conference on Computer Vision. Amsterdam: Springer: 21-37 [DOI: 10.1007/978-3-319-46448-0_2]
- Liu Z G, Wang L F, Wen Z D, Li K and Pan Q. 2022b. Multilevel scattering center and deep feature fusion learning framework for SAR target recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5227914 [DOI: 10.1109/TGRS.2022.3174703]
- Malmgren-Hansen D, Kusk A, Dall J, Nielsen A A, Engholm R and Skriver H. 2017. Improving SAR automatic target recognition models with transfer learning from simulated data. *IEEE Geoscience and Remote Sensing Letters*, 14(9): 1484-1488 [DOI: 10.1109/LGRS.2017.2717486]
- Modava M, Akbarizadeh G and Soroosh M. 2019. Hierarchical coastline detection in SAR images based on spectral-textural features and global - local information. *IET Radar, Sonar and Navigation*, 13(12): 2183-2195 [DOI: 10.1049/iet-rsn.2019.0063]
- Morgan D A E. 2015. Deep convolutional neural networks for ATR from SAR imagery//Proceedings Volume 9475, Algorithms for Synthetic Aperture Radar Imagery XXII. Baltimore: SPIE: 116-128 [DOI: 10.1117/12.2176558]
- Pan Z X, Qiu X L, Huang Z L and Lei B. 2017. Airplane recognition in TerraSAR-X images via scatter cluster extraction and reweighted sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 14(1): 112-116 [DOI: 10.1109/LGRS.2016.2628162]
- Potter L C and Moses R L. 1997. Attributed scattering centers for SAR ATR. *IEEE Transactions on Image Processing*, 6(1): 79-91 [DOI: 10.1109/83.552098]
- Redmon J, Divvala S, Girshick R and Farhadi A. 2016. You only look once: unified, real-time object detection//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE: 779-788 [DOI: 10.1109/CVPR.2016.91]
- Ren S Q, He K M, Girshick R and Sun J. 2017. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149 [DOI: 10.1109/TPAMI.2016.2577031]
- Samadi F, Akbarizadeh G and Kaabi H. 2019. Change detection in SAR images using deep belief network: a new training approach based on morphological images. *IET Image Processing*, 13(12): 2255-2264 [DOI: 10.1049/iet-ipr.2018.6248]
- Sharifzadeh F, Akbarizadeh G and Kaviani Y S. 2019. Ship classification in SAR images using a new hybrid CNN - MLP classifier. *Journal of the Indian Society of Remote Sensing*, 47(4): 551-562 [DOI: 10.1007/s12524-018-0891-y]
- Smillie S F. 1966. Automatic target recognition: some considerations. *IEEE Transactions on Aerospace and Electronic Systems*, AES-2(2): 187-191 [DOI: 10.1109/TAES.1966.4501740]
- Sun X, Lv Y X, Wang Z R and Fu K. 2022a. SCAN: scattering characteristics analysis network for few-shot aircraft classification in high-resolution SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-17 5226517 [DOI: 10.1109/TGRS.2022.3166174]
- Sun X, Wang P J, Wang C, Liu Y F and Fu K. 2021a. PBNNet: part-based convolutional neural network for complex composite object detection in remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173: 50-65 [DOI: 10.1016/j.isprsjprs.2020.12.015]
- Sun X, Wang Z R, Sun Y R, Diao W H, Zhang Y and Fu K. 2019. AIR-SARShip-1.0: high-resolution SAR ship detection dataset. *Journal of Radars*, 8(6): 852-862 (孙显, 王智睿, 孙元睿, 刁文辉, 张跃, 付琨). 2019. AIR-SARShip-1.0: 高分辨率 SAR 舰船检测数据集. *雷达学报*, 8(6): 852-862 [DOI: 10.12000/JR19097]
- Sun Y L, Lei L, Li X, Tan X and Kuang G Y. 2021b. Patch similarity graph matrixbased unsupervised remote sensing change detection with homogeneous and heterogeneous sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6): 4841-4861 [DOI: 10.1109/TGRS.2020.3013673]
- Sun Y R, Wang Z R, Sun X and Fu K. 2022b. SPAN: strong scattering point aware network for ship detection and classification in large-

- scale SAR imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15: 1188-1204 [DOI: 10.1109/JSTARS.2022.3142025]
- Tirandaz Z, Akbarizadeh G and Kaabi H. 2020. PolSAR image segmentation based on feature extraction and data compression using weighted neighborhood filter bank and hidden Markov random field-expectation maximization. *Measurement*, 153: 107432 [DOI: 10.1016/j.measurement.2019.107432]
- Touzi R, Lopes A and Bousquet P. 1988. A statistical and geometrical edge detector for SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 26(6): 764-773 [DOI: 10.1109/36.7708]
- Wagner S A. 2016. SAR ATR by a combination of convolutional neural network and support vector machines. *IEEE Transactions on Aerospace and Electronic Systems*, 52(6): 2861-2872 [DOI: 10.1109/TAES.2016.160061]
- Wang H P, Xu F and Chen S S. 2016. Saliency detector for SAR images based on pattern recurrence. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(7): 2891-2900 [DOI: 10.1109/JSTARS.2016.2521709]
- Wang N, Wang Y H, Liu H W, Zuo Q S and He J L. 2017. Feature-fused SAR target discrimination using multiple convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 14(10): 1695-1699 [DOI: 10.1109/LGRS.2017.2729159]
- Wang P J, Sun X, Diao W H and Fu K. 2020. FMSSD: feature-merged single-shot detection for multiscale objects in large-scale remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 58(5): 3377-3390 [DOI: 10.1109/TGRS.2019.2954328]
- Wang Z R, Kang Y Z, Zeng X, Wang Y L, Zhang D and Sun X. 2023. SAR-AIRcraft-1.0: high-resolution SAR aircraft detection and recognition dataset. *Journal of Radars*, 12(4): 906-922 (王智睿, 康玉卓, 曾璇, 汪越雷, 张汀, 孙显. 2023. SAR-AIRcraft-1.0: 高分辨率SAR飞机检测识别数据集. *雷达学报*, 12(4): 906-922) [DOI: 10.12000/JR23043]
- Wei S J, Zeng X F, Qu Q Z, Wang M, Su H and Shi J. 2020. HRSID: a high-resolution SAR images dataset for ship detection and instance segmentation. *IEEE Access*, 8: 120234-120254 [DOI: 10.1109/ACCESS.2020.3005861]
- Wen Z D, Yu Y L and Wu Q. 2024. Multimodal discriminative feature learning for SAR ATR: a fusion framework of phase history, scattering topology, and image. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5200414 [DOI: 10.1109/TGRS.2023.3340651]
- Wright J, Yang A Y, Ganesh A, Sastry S S and Ma Y. 2009. Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2): 210-227 [DOI: 10.1109/TPAMI.2008.79]
- Wu W Q, Chen H J, Li Y F, Chen Z W and Sun J. 2024. ESFFM: an electromagnetic scattering feature fusion model for SAR automatic target recognition. *IEEE Sensors Journal*, 24(19): 30424-30434 [DOI: 10.1109/JSEN.2024.3440016]
- Xia R F, Chen J, Huang Z X, Wan H Y, Wu B C, Sun L, Yao B D, Xiang H B and Xing M D. 2022. CRTransSar: a visual transformer based on contextual joint representation learning for SAR ship detection. *Remote Sensing*, 14(6): 1488 [DOI: 10.3390/rs14061488]
- Xing M D, Xie Y Y, Gao Y X, Zhang J S, Liu J M and Wu Z X. 2022. Electromagnetic scattering characteristic extraction and imaging recognition algorithm: a review. *Journal of Radars*, 11(6): 921-942 (邢孟道, 谢意远, 高悦欣, 张金松, 刘嘉铭, 吴之鑫. 2022. 电磁散射特征提取与成像识别算法综述. *雷达学报*, 11(6): 921-942) [DOI: doi:10.12000/JR22232]
- Xu D Q and Wu Y Q. 2024. Progress of research on deep learning algorithms for object detection in optical remote sensing images. *National Remote Sensing Bulletin*, 28(12): 3045-3073 (徐丹青, 吴一全. 2024. 光学遥感图像目标检测的深度学习算法研究进展. *遥感学报*, 28(12): 3045-3073) [DOI: 10.11834/jrs.20243166]
- Yang L C, Xing M D, Zhang L, Sun G C, Gao Y X, Zhang Z J and Bao Z. 2021. Integration of rotation estimation and high-order compensation for ultrahigh-resolution microwave photonic ISAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 59(3): 2095-2115 [DOI: 10.1109/TGRS.2020.2994337]
- Yao H G, Wang C, Yu J, Bai X J and Li W. 2020. Recognition of small-target ships in complex satellite images. *Journal of Remote Sensing(in Chinese)*, 24(2): 116-125 (姚红革, 王诚, 喻钧, 白小军, 李蔚. 2020. 复杂卫星图像中的小目标船舶识别. *遥感学报*, 24(2): 116-125) [DOI: 10.11834/jrs.20208238]
- Ye X Y and Du C. 2024. Integrated multi-scale aircraft detection and recognition with scattering point intensity adaptiveness in complex background clutter SAR images. *Remote Sensing*, 16(13): 2471 [DOI: 10.3390/RS16132471]
- Yu C L, Lai T, Ma Q, Han Y Q, Pan B and Huang H F. 2021. Multi-scale broad learning system for SAR automatic target recognition// 2021 CIE International Conference on Radar (Radar). Haikou: IEEE: 1450-1454 [DOI: 10.1109/Radar53847.2021.10028044]
- Zalpour M, Akbarizadeh G and Alaei-Sheini N. 2020. A new approach for oil tank detection using deep learning features with control false alarm rate in high-resolution satellite imagery. *International Journal of Remote Sensing*, 41(6): 2239-2262 [DOI: 10.1080/01431161.2019.1685720]
- Zhai L, Li Y and Su Y. 2016. Inshore ship detection via saliency and context information in high-resolution SAR images. *IEEE Geoscience and Remote Sensing Letters*, 13(12): 1870-1874 [DOI: 10.1109/LGRS.2016.2616187]
- Zhang B F, Su J S and Xu X. 2006. A class-incremental learning method for multi-class support vector machines in text classification// 2006 International Conference on Machine Learning and Cybernetics. Dalian: IEEE: 2581-2585 [DOI: 10.1109/ICMLC.2006.258853]
- Zhang J S, Xing M D and Xie Y Y. 2021a. FEC: a feature fusion framework for SAR target recognition based on electromagnetic scattering features and deep CNN features. *IEEE Transactions on Geoscience and Remote Sensing*, 59(3): 2174-2187 [DOI: 10.1109/TGRS.2020.3003264]
- Zhang J S, Xing M D, Sun G C and Bao Z. 2022a. Integrating the re-constructed scattering center feature maps with deep CNN feature maps for automatic SAR target recognition. *IEEE Geoscience and Remote Sensing Letters*, 19: 4009605 [DOI: 10.1109/LGRS.2021.

- 3054747]
- Zhang J S, Xing M D, Sun G C and Li N. 2022b. Oriented gaussian function-based box boundary-aware vectors for oriented ship detection in multiresolution SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5211015 [DOI: 10.1109/TGRS.2021.3095386]
- Zhang J S, Xing M D, Sun G C, Chen J L, Li M Y, Hu Y H and Bao Z. 2021b. Water body detection in high-resolution SAR images with cascaded fully-convolutional network and variable focal loss. *IEEE Transactions on Geoscience and Remote Sensing*, 59 (1): 316-332 [DOI: 10.1109/TGRS.2020.2999405]
- Zhang J S. 2022. Study on SAR Imagery Detection and Recognition Based on the Fusion of Domain Knowledge and Deep Learning. Xi'an: Xidian University (张金松. 2022. 领域知识融合深度学习的 SAR 图像检测与识别方法研究. 西安: 西安电子科技大学) [DOI: 10.27389/d.cnki.gxadu.2022.000071]
- Zhang P, Xu H, Tian T, Gao P, Li L F, Zhao T M, Zhang N and Tian J W. 2022c. SEFEPNet: scale expansion and feature enhancement pyramid network for SAR aircraft detection with small sample dataset. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15: 3365-3375 [DOI: 10.1109/JSTARS.2022.3169339]
- Zhang T W and Zhang X L. 2019. High-speed ship detection in SAR images based on a grid convolutional neural network. *Remote Sensing*, 11(10): 1206 [DOI: 10.3390/rs11101206]
- Zhang T W, Zhang X L, Ke X, Zhan X, Shi J, Wei S J, Pan D C, Li J W, Su H, Zhou Y and Kumar D. 2020. LS-SSDD-v1.0: a deep learning dataset dedicated to small ship detection from large-scale sentinel-1 SAR images. *Remote Sensing*, 12(18): 2997 [DOI: 10.3390/rs12182997]
- Zhang T W, Zhang X L, Li J W, Xu X W, Wang B Y, Zhan X, Xu Y Q, Ke X, Zeng T J, Su H, Ahmad I, Pan D C, Liu C, Zhou Y, Shi J and Wei S J. 2021c. SAR ship detection dataset (SSDD): official release and comprehensive data analysis. *Remote Sensing*, 13 (18): 3690 [DOI: 10.3390/rs13183690]
- Zhang X F and Ren X M. 2011. Two dimensional principal component analysis based independent component analysis for face recognition//2011 International Conference on Multimedia Technology. Hangzhou: IEEE: 934-936 [DOI: 10.1109/ICMT.2011.6002199]
- Zhang X H, Feng S J, Zhao C X, Sun Z Z, Zhang S Q and Ji K F. 2024. MGSFA-Net: multiscale global scattering feature association network for SAR ship target recognition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 4611-4625 [DOI: 10.1109/JSTARS.2024.3357171]
- Zhang Y P, Lu D D, Qiu X L and Li F. 2023a. Scattering-point topology for few-shot ship classification in SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 10326-10343 [DOI: 10.1109/JSTARS.2023.3328066]
- Zhang Y P, Lu D D, Qiu X L and Li F. 2023b. Scattering-point-guided RPN for oriented ship detection in SAR images. *Remote Sensing*, 15(5): 1411 [DOI: 10.3390/rs15051411]
- Zhang Y P, Xing M D and Zhang J S. 2021d. SAR ship targets detection based on correlation filters//2021 CIE International Conference on Radar (Radar). Haikou: IEEE: 1297-1300 [DOI: 10.1109/Radar53847.2021.10028184]
- Zhang Z. 2023. Research on SAR Image Features and Scattering Characteristics under Deep Learning Framework. Hangzhou: Zhejiang University (张征. 2023. 深度学习框架下 SAR 图像特征和散射特征研究. 杭州: 浙江大学) [DOI: 10.27461/d.cnki.gzjdx.2023.002947]
- Zhao C X, Wang D C, Zhang X H, Sun Y L, Zhang S Q and Kuang G Y. 2025. Adaptive scattering feature awareness and fusion for limited training data SAR target recognition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18: 206-220 [DOI: 10.1109/JSTARS.2024.3493856]
- Zhao C X, Zhang S Q, Luo R, Feng S J and Kuang G Y. 2023. Scattering features spatial-structural association network for aircraft recognition in SAR images. *IEEE Geoscience and Remote Sensing Letters*, 20: 4006505 [DOI: 10.1109/LGRS.2023.3280442]
- Zhao Y, Zhao L J, Xiong B L and Kuang G Y. 2020. Attention receptive pyramid network for ship detection in SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 2738-2756 [DOI: 10.1109/JSTARS.2020.2997081]

A review of SAR target recognition methods fusing electromagnetic scattering features

XING Mengdao^{1,2}, HAN Qing¹, ZHANG Jinsong²

1. National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China;

2. Academy of Advanced Interdisciplinary Research, Xidian University, Xi'an 710071, China

Abstract: Automated interpretation of Synthetic Aperture Radar (SAR) images is one of the important development directions in the application of SAR technology, the core of which lies in how to efficiently extract target information from complex SAR images and realize automatic recognition. SAR target recognition methods are mainly classified into two main categories: traditional Machine Learning (ML) methods and Deep Learning (DL) methods. Traditional methods usually rely on hand-designed features extracted from Electromagnetic

Scattering Features (ESF) that have clear physical meaning and high interpretability. For example, features such as the ESF, Radar Cross Section (RCS), and polarization characteristics of a target can directly reflect the target's geometric structure, material properties, and its interaction mechanism with electromagnetic waves. These features show strong stability in target classification and identification tasks, especially in complex environments or under low Signal Noise Ratio (SNR) conditions. However, the limitations of traditional methods are that the feature extraction process is often complex and computationally inefficient, while relying on the a priori knowledge of domain experts, which makes it difficult to adapt to large-scale data processing and diverse target recognition needs.

In contrast, DL methods are able to automatically extract high-dimensional features from SAR images through an end-to-end learning approach, avoiding the tedious process of manually designing features. DL methods usually outperform traditional methods in terms of target recognition accuracy, especially when dealing with SAR images with high resolution and complex backgrounds. However, DL methods also have obvious shortcomings, such as the poor interpretability of the model, which makes it difficult to explain its decision-making process; at the same time, the generalization performance of Neural Network Features (NNF) is often limited by the quality and diversity of the training data, and performance degradation may occur in the face of unseen targets or scenes.

In order to overcome the limitations of traditional ML methods and DL methods, researchers in recent years have proposed a DL method that fuses ESF and NNF. This fusion method aims to combine the advantages of both. On the one hand, the physical interpretability and stability of electromagnetic scattering features are utilized to enhance the model's understanding of the target's intrinsic attributes. On the other hand, the high-dimensional features extracted by neural networks are used to enhance the model's recognition accuracy and adaptability. For example, in the recognition task of targets such as vehicles, aircrafts and ships, the fusion method significantly improves the recognition accuracy by combining the ESF of the targets (e.g., strong scattering point distribution, polarization response) with the NNF, while improving the interpretability of the model to some extent.

The paper discusses the research results of target recognition methods based on the fusion of ESF and NNF, details the application of this idea of fusing ESF for target recognition of vehicles, aircraft and ships, and looks forward to and summarizes the future development trends of target recognition and detection research.

Key words: remote sensing, Synthetic Aperture Radar (SAR), target recognition, Convolutional Neural Networks (CNN), Electromagnetic Scattering Features (ESF), parameter estimation

Supported by National Natural Science Foundation of China (No. 62331020, 62301403)