

# 基于关键部件特征关联的ISAR空间目标 多角度识别方法

袁浩轩, 张云, 黄艳堃, 田金, 孔维民, 陈李田

(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:** 在空间态势感知任务中常存在绕飞机动航天器,其持续的自旋、自旋轴变化和绕飞机动矢量构成了三维转动,导致相邻逆合成孔径雷达(Inverse Synthetic Aperture Radar, ISAR)图像帧间散射特性差异较大,难以识别. 为此本文提出基于关键部件特征关联的ISAR空间目标多角度识别模型,构建基于自监督学习策略的对比学习模块,减少成像和目标姿态参数变化对图像识别的影响;构建关键部件特征关联模块,利用图信息推理方法挖掘图像关键部件之间的局部关联信息;构建复数域Transformer层,提取图像区域块之间的全局上下文特征,并通过特征融合实现对目标的有效表达. 基于实测雷达数据的实验结果表明所提方法可显著提升多角度识别效果,在相同数据量识别条件下,与现有目标识别方法相比识别率提高了5.58%,验证了对目标多角度识别的性能.

**关键词:** 逆合成孔径雷达;空间目标;机动目标;复数域网络;目标识别

**基金项目:** 中国博士后科学基金(No.2023M734272);国家自然科学基金(No.62371170, No.62201612)

**中图分类号:** TP751

**文献标识码:** A

**文章编号:** 0372-2112(2025)07-2401-17

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

**DOI:** 10.12263/DZXB.20240860

## Multi-Angle ISAR Recognition Method for Space Targets Based on Feature Correlation of Key Components

YUAN Hao-xuan, ZHANG Yun, HUANG Yan-kun, TIAN Jin, KONG Wei-min, CHEN Li-tian

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

**Abstract:** The geosynchronous space situational awareness program (GSSAP) satellite of the USA has repeatedly orbited and detected our satellites in recent years, which is a great threat. For this kind of orbiting maneuvering spacecraft, its continuous spin, spin axis change and orbiting motion vector constitute a three-dimensional rotation, and the scattering characteristics between adjacent inverse synthetic aperture radar (ISAR) image frames are greatly different, making it difficult to recognize it. To this end, this paper proposes a multi-angle ISAR recognition model for space targets based on feature correlation of key components. A contrast learning module based on self-supervised learning strategy is constructed to reduce the impact of parameter changes in imaging and target attitude on image recognition. A key component feature correlation module is constructed to mine local correlation information between key components of the images using graph information reasoning methods. Finally, a complex-valued transformer layer extracts global contextual features between image blocks and achieves effective expression of the target through feature fusion. Experimental results based on real radar data show that the proposed method can significantly improve the effect of multi-angle recognition. Under the same recognition condition of data volume, the recognition rate is increased by 5.58% compared with the existing recognition method, verifying the performance of multi-angle recognition.

**Key words:** inverse synthetic aperture radar; space target; maneuvering target; complex-valued network; target recognition

**Foundation Item(s):** China Postdoctoral Science Foundation (No.2023M734272); National Natural Science Foundation of China (No.62371170, No.62201612)

## 1 引言

雷达是空间监视系统中不可或缺的传感器,逆合成孔径雷达(Inverse Synthetic Aperture Radar, ISAR)通过合成孔径和发射宽带信号的方式可以获得较高的图像方位和距离分辨率,是探测领域目标特征信息获取的重要手段。

近年来,深度学习方法逐渐成为基于雷达图像的目标识别领域的热点<sup>[1]</sup>. Zhou 等人<sup>[2]</sup>针对传统卷积神经网络(Convolutional Neural Networks, CNN)感受野较小导致目标全局特征无法提取的问题,提出了一种注意力增强的形变鲁棒 ISAR 识别模型,在仿真的 ISAR 数据集上得到了比同类方法更高的识别精度. 最近,国防科技大学的 Li 等人<sup>[3]</sup>提出了一种基于多视角 ISAR 成像和融合的 ISAR 识别网络,在仿真和实测数据实验中验证了方法的可靠性. 还有研究者在深度卷积神经网络中加入了卷积块注意力模块,可以抑制冗余特征从而提升模型的训练效率和识别精度<sup>[4]</sup>.

但是深度学习方法的识别效果极大地依赖于对大量有效数据的特征提取,在空间目标探测任务中,由于观测条件受限,ISAR 识别常面临小样本问题,为了解决小样本条件下网络对图像的特征提取能力较弱的问题,有研究人员在 CNN 中提出自适应多模态机制,并集成到图架构中来提高识别精度<sup>[5]</sup>. 文献<sup>[6]</sup>将堆叠算法和迁移学习相结合,克服了识别精度低的缺陷. 文献<sup>[7]</sup>提出了一种基于神经架构搜索和知识蒸馏的超轻量级 CNN 架构,在一定程度上缓解了小样本识别的问题. 还有研究者设计了一种半监督算法来生成用于辅助训练的伪标签,仅利用少量的标记回波即可获得较高的识别精度<sup>[8]</sup>.

对于变轨机动航天器,常存在对目标的绕飞探测,如美国的地球同步轨道空间态势感知计划(Geosynchronous Space Situational Awareness Program, GSSAP)卫星,近年来多次对我方卫星进行抵近绕飞探测,最近距离小于 10 km,具有极大的威胁性. 在对其成像识别过程中,本星对其形成多角度观测模型,其姿态持续变化,导致相邻 ISAR 图像帧间散射特性差异较大,一般的特征提取模型难以实现对目标的有效表征. 与此同时,随着太空活动和任务的增加,航天器的类别和数量不断增多,在空间态势感知应用中常常会出现新型目标,对这类新目标进行多角度观测可挖掘目标更丰富的信息,为此亟待研究基于元学习的小样本识别问题,设计在未见过的测试图像数据集上具有强泛化能力的识别模型.

为解决上述问题,本文结合 Transformer 网络提出基于关键部件特征关联的复数域转换器网络(Complex-valued Transformer based on Feature Correlation of key

components, CvTFC),构建基于自监督学习策略的对比学习模块,减少成像和目标姿态参数变化对图像识别的影响;构建关键部件特征关联模块(Feature Correlation of Key Components, FCKC),利用图信息推理方法提取图像区域块之间的局部上下文特征;构建复数域 Transformer 层,提取图像区域块之间的全局上下文特征,并通过特征融合实现对目标的有效表达,克服了多角度观测目标姿态变化较大带来的识别困难问题;最后构建复数域图识别模块,构建节点的邻近矩阵,通过非线性映射的方法进行节点特征更新,并利用节点的幅相特性关联实现对节点数据的精准识别.

本文主要工作如下:

(1)提出一种基于目标图像关键部件特征关联的机动空间目标多角度识别模型,构建 FCKC 模块,有效聚合图像关键部件之间的局部上下文信息,增强网络对目标的特征表示,解决小样本条件下由于训练数据有限导致的识别泛化能力弱的问题;

(2)构建了一个基于自监督学习策略的对比学习模块,利用自监督策略使正样本图像块间距离更小、负样本图像块间距离更大,以减少对目标多角度观测时目标机动和 ISAR 成像参数变化对识别网络的影响,提升了特征提取的鲁棒性;

(3)所提网络的特征提取、特征关联和节点识别三个阶段都扩展为适用于 ISAR 数据处理的复数域形式,解决一般识别模型中输入数据关键相位信息丢失的问题,有助于挖掘 ISAR 数据幅相深层信息,提升网络对目标的有效表达;

(4)综合机动目标多角度仿真数据集和实验室实测数据集对本文提出的识别模型进行验证,与其他小样本学习方法相比,CvTFC 在上述数据的实验中取得了更高的识别准确率,证明提出的方法可有效解决机动空间目标的多角度识别.

## 2 相关工作

### 2.1 基于深度学习的雷达识别

现有的深度学习识别方法按作用机理可分为样本增强法、多输入数据法和创新融合法. 其中样本增强法是通过网络模型进行优化以增强样本对外部变化的适应能力,或提升对样本数量不足的适应性<sup>[9-11]</sup>. 多输入数据法通过输入多视角或者连续帧的雷达图像,提取目标的多视角或者时空维度关联,以提供更多的识别信息<sup>[12,13]</sup>. 创新融合法是将先进概念或架构融合到现有深度神经网络模型中,以达到优势互补、提升网络识别精度的目的<sup>[14-16]</sup>. 虽然这些方法利用不同的先进手段或者架构达到了良好的识别效果,但是其将雷达数据作为一种实数域数据进行处理,只利用其幅度信

息,导致信息量的丢失。

越来越多的研究者开始研究复数域网络,想要避免相位信息丢失的同时,提高对复数域数据的整体识别率<sup>[17]</sup>。Akira 等人<sup>[18]</sup>率先详细介绍了复数神经网络,并将其应用在了雷达信号的识别领域。国防科技大学的 Li 等人<sup>[19]</sup>提出了一个复数转换器网络,利用多头自注意力整合信号的同相和正交分量,在自动信号调制识别中取得了很好的效果。Zeng 等人<sup>[20]</sup>提出多流复数网络,可有效利用目标 SAR 图像的相位信息,在 MSTAR 数据集中取得了较好的识别效果。Zhou 等人<sup>[21]</sup>提出一个多尺度复数特征注意力 CNN,通过解耦 SAR 图像的幅度和相位特征,减少了网络训练时间的同时保留了更多特征,实验证明对于相同的数据集,复数域网络比实值架构具有更好的识别准确度。然而对于这些数据驱动的深度神经网络而言,在空间探测的小样本数据条件下,识别精度很难保证。

## 2.2 小样本识别

空间目标变轨机动速度快,雷达对其观测时间有限,并且图像对 ISAR 成像参数和复杂空间环境敏感、标注成本较高,从而限制了空间目标样本尤其是机动目标的有效样本量。度量学习是解决小样本识别问题的常见方法,主要有匹配网络(Matching Network, MatchNet)<sup>[22]</sup>、原型网络(Prototypical Network, ProtoNet)<sup>[23]</sup>、关系网络(Relation Network, RN)<sup>[24]</sup>以及图神经网络(Graph Neural Network, GNN)<sup>[25]</sup>等。除此之外还有基于元学习的识别方法,可以实现仅在少量标注样本的任务上完成快速的优化,并得到较强泛化能力。代表性的方法有模型无关化元学习(Model-Agnostic Meta-Learning, MAML)<sup>[26]</sup>、潜在嵌入优化模型(Latent Embedding Optimization Model, LEOM)<sup>[27]</sup>、记忆增强神经网络(Memory-Augmented Neural Network, MANN)<sup>[28]</sup>以及简单神经注意力学习器(Simple Neural Attentive Learner, SNAIL)<sup>[29]</sup>等。

针对在空间态势感知应用中常出现新型目标的问题,本文主要研究基于元学习的识别,与一般的小样本识别模型不同,基于元学习的小样本识别模型具有自动学习能力,可识别训练样本以外的新目标类型,对于这种识别问题,可以把输入数据集  $\mathcal{Y}$  分成三部分:

$$\mathcal{Y} = \left\{ \left[ (x_1, l_1), \dots, (x_s, l_s) \right], \left[ \tilde{x}_1, \dots, \tilde{x}_r \right], \left[ \bar{x}_1, \dots, \bar{x}_t \right] \right\} \quad (1)$$

其中,  $l_i \in \{1, 2, \dots, N\}$ ,  $x_i, \tilde{x}_j, \bar{x}_t \sim P_l$ ,  $x$  表示输入的样本,这里指的是 ISAR 图像,  $l$  是样本的标签,  $s$  是已标注的样本(支撑集)的数量,  $r$  是未标注的样本的数量(对于半监督和主动学习,  $r > 0$ ),  $t$  是未标注的验证集(查询集)中样本的数量,  $N$  是要识别的类别的数量。当每次任务只用一个样本验证时  $t=1$ ,  $P$  是一个遵循着已定类别识别

规则的 ISAR 图像集合。当  $r=0, t=1, s=C \times K$  时,集合中只有一个图像的标签未知,此外,如果每个标签正好出现  $K$  次,则此时的数据集设置称为  $C$ -way,  $K$ -shot 的小样本识别问题。

虽然利用元学习的自动识别能力可实现未观测目标的识别,但对于本文针对的多角度观测识别任务,目标整体姿态异构容易引发特征超出网络库内特征边界问题,因此亟需一种可以实现对绕飞目标稳定表征的模型。

## 3 多角度观测模型构建及难点分析

### 3.1 绕飞机动场景及成像模型分析

对目标的多角度观测常常处于目标航天器的绕飞机动探测过程中,主动绕飞指的是绕飞航天器存在脉冲机动,对被观测目标进行快速受控绕飞,是目标探测领域的常见绕飞形式,一般主动绕飞的周期在被观测目标轨道周期的 0.1 到 0.5 之间,对于 GSSAP 卫星等存在的主动绕飞场景,本文将对其成像的几何关系示意图描述为图 1,其中目标航天器通过机动进入绕飞轨道,航天器和被观测目标的轨道都呈椭圆轨迹,其中  $a_t$  和  $a_c$  分别是航天器和被观测目标轨道的长半轴,从本星成像雷达的视角来看,绕飞航天器相对于被观测目标进行绕飞运动。




图1 主动绕飞几何关系

在目标的绕飞探测过程中,航天器存在自旋和自旋轴变化矢量,而它们一般和目标机动产生的绕飞转动矢量不平行,因此这三个矢量构成了目标的三维转动变化,以三个自由度的形式存在,分别表示为滚转(Roll)、俯仰(Pitch)以及偏航(Yaw),目标星的三维转动模型和本星雷达对其成像几何关系如图2所示。




图2 本星雷达对绕飞目标的成像几何关系

在 ISAR 成像过程中,首先以目标星的质心作为原点  $O$  建立三维笛卡尔坐标系  $O-XYZ$ ,其中  $XYZ$  轴分别与滚转  $R_{\text{ool}}$ 、俯仰  $P_{\text{ich}}$  以及偏航  $Y_{\text{aw}}$  轴平行,假设本星雷达观测绕飞目标的斜视角为  $\theta$ 、侧视角为  $\varphi$ ,本星相对目标在距离方向上的单位矢量表示为  $\mathbf{R}$ ,则本星雷达相对于绕飞目标的观测视线矢量可以表示为

$$\mathbf{V}_{\text{tar}} = \mathbf{R} \cdot [\cos \theta \sin \varphi, \sin \theta, \cos \theta \cos \varphi] \quad (2)$$

由于 ISAR 成像时间短以及本星的合作性,本星转动引起的观测视线矢量的大小和方向变化较小,可忽略不计,此外目标星平动引起的相对距离变化可以通过距离徙动矫正方法进行矫正. 假设在 ISAR 成像的一段时间内目标的转动矢量不变,表示为  $\mathbf{w}$ ,由于 ISAR 成像结果相当于目标在距离-多普勒平面上的投影,距离维就沿着观测视线矢量的方向投影,而方位维散射点会沿着  $\mathbf{w} \times \mathbf{V}_{\text{tar}}$  的方向. 投影初始时刻目标星上的任意一散射点  $\mathbf{S}_0 = [x_0, y_0, z_0]$  在距离-多普勒平面上的投影表示为

$$\begin{aligned} \mathbf{R}_{\mathbf{S}_0} &= \mathbf{S}_0 \cdot \mathbf{V}_{\text{tar}} \\ \mathbf{D}_{\mathbf{S}_0} &= \mathbf{S}_0 \cdot (\mathbf{w} \times \mathbf{V}_{\text{tar}}) \end{aligned} \quad (3)$$

其中,  $\mathbf{R}_{\mathbf{S}_0}$  和  $\mathbf{D}_{\mathbf{S}_0}$  分别为散射点  $\mathbf{S}_0$  在距离维和多普勒维的投影结果. 假设 ISAR 成像过程中距离维采样点数为  $N_R$ ,方位维脉冲数为  $N_D$ ,则绕飞目标质心  $O$  对应二维 ISAR 图像上的位置为  $[N_R/2, N_D/2]$ ,然后将距离维矢量和多普勒维矢量展开得到  $\mathbf{V}_{\text{tar}} = [\zeta_x, \zeta_y, \zeta_z]$  和  $\mathbf{w} \times \mathbf{V}_{\text{tar}} = [\tau_x, \tau_y, \tau_z]$ ,则成像后散射点  $\mathbf{S}_0$  对应到 ISAR 图像上的像素点位置为

$$\begin{aligned} \mathbf{R}_{\mathbf{S}_0} &= (\zeta_x x_0 + \zeta_y y_0 + \zeta_z z_0) + N_R/2 \\ \mathbf{D}_{\mathbf{S}_0} &= (\tau_x x_0 + \tau_y y_0 + \tau_z z_0) + N_D/2 \end{aligned} \quad (4)$$

$t$  时刻后,散射点  $\mathbf{S}_0$  在三维笛卡尔坐标系的新坐标为

$$\mathbf{S}(t) = \begin{bmatrix} x(t) \\ y(t) \\ z(t) \end{bmatrix} = \boldsymbol{\Phi}_r(t) \cdot \boldsymbol{\Phi}_p(t) \cdot \boldsymbol{\Phi}_y(t) \cdot \mathbf{S}_0 \quad (5)$$

其中,  $\boldsymbol{\Phi}_r(t)$ 、 $\boldsymbol{\Phi}_p(t)$  和  $\boldsymbol{\Phi}_y(t)$  分别是滚转、俯仰以及偏航方向的旋转矩阵,则  $t$  时刻后目标星上的散射点在距离-多普勒平面上的投影结果为

$$\begin{aligned} \mathbf{R}_{\mathbf{S}_0} &= (\zeta_x x(t) + \zeta_y y(t) + \zeta_z z(t)) + N_R/2 \\ \mathbf{D}_{\mathbf{S}_0} &= (\tau_x x(t) + \tau_y y(t) + \tau_z z(t)) + N_D/2 \end{aligned} \quad (6)$$

由式(6)可以看到,在对目标星平动补偿之后,ISAR 图像在不同时刻的成像结果差异主要由目标星本身的三维转动引起,并随着转动角度的增大而变大.

### 3.2 多角度识别难点分析

图3展示了两个不同的绕飞机动目标不同姿态下的 ISAR 图像,其中保持俯仰和偏航角度不变,仅将滚转角  $\phi_r$  设为  $0^\circ$ 、 $90^\circ$  和  $-90^\circ$ ,可以看到不同目标的相同姿态间的图像直观差距比相同目标间的图像差距更小,因此会导致不同目标图像的特征很接近,导致识别错误. 为了计算这两者间哪一对图像的特征差异更小,使用预训练好的图神经网络的特征提取层对图3中的 ISAR 图像进行特征提取,图像的特征差异曲线如图4所示,其中图4(a)显示了图3(a)、图3(b)以及图3(a)、图3(d)的特征差异曲线,图4(b)显示了图3(b)、图3(c)以及图3(b)、图3(e)的特征差异,由图可见,不同目标的相同姿态的图像特征差异更小.






图3 不同空间目标的各姿态 ISAR 图像

除此之外,还计算滚转角每隔  $4^\circ$  变化导致的 ISAR 图像整体特征幅度变化,目标1和目标2的特征幅度变化分别如图5(a)和图5(b)所示,可见随着滚转角越来越大,与初始姿态目标的 ISAR 图像的特征差异也越来越大,整体是单调上升的趋势. 通过上述分析可知,绕飞机动目标的 ISAR 图像在目标处于轨道不同位置上时姿态具有较大变化,从而导致 ISAR 成像结果存在外形和散射特性上的差异,此时如果模型只提取图像的整体特征,很容易导致过拟合和目标识别错误.

为了解决上述问题,考虑利用目标关键部件的特征之间的相关性和稳定性获得目标的有效表征<sup>[30]</sup>,利用图6中的图像区域块特征构建思路对其稳定性和有效性进行初步证明. 首先在具有不同滚转角的空目标 ISAR 图像上分割出相邻的图像块,利用同样的预训练特征提取模型产生对应图像块的特征,通过对其进行特征相减并取绝对值和的操作,获得图像块对目标的初步表征. 然后与整体图像的特征差异计算思路相同,每隔  $4^\circ$  滚转角计算上述图像区域块特征的幅度变化,得到的两个空间目标对应的结果如图7所示,可




(a) 图3的(a)(b)和(a)(d)的特征差异




(b) 图3的(b)(c)和(b)(e)的特征差异

图4 不同目标的不同姿态的特征差异曲线



(a) 目标 1



(b) 目标 2

图5 空间目标图像的特征幅度变化

以看到图像区域块特征幅度变化的二次函数拟合曲线的平均梯度更小,表示其稳定性和表征能力更强。

#### 4 基于关键部件特征关联的 ISAR 空间目标多角度识别模型

针对多角度观测目标的识别问题,本文提出了一种复数域的基于关键部件特征关联的端到端识别网




图6 图像区域块特征的构建流程

络框架 CvTFC, 利用对比学习方法, 减少了图像散焦、目标姿态变化以及雷达成像参数变化对提取特征的影响, 增强提取特征的有效性; 构建了一个可以提取图像块间空间关联信息的 FCKC 特征提取模块, 利用图信息推理方法获得图像块之间的局部上下文特征关联; 同时, 为了防止模型过多地关注某些局部图像块而陷入局部最优, 网络中构建了复数 Transformer 层来提取图像块之间的全局上下文信息, 受益于多头注意力机制的并行计算方法和有效寻址方法, Transformer 模型中的编码器可以快速有效地获取图像块之间的全局上下文关系, 可以用于解决上述的局部最优问题, 将全局上下文特征与局部关联相结合, 得到目标的有效特征表达, 降低了目标姿态差异引发的识别错误率. 最后, 在图网络中节点及其相邻边通过图识别模块更新. 本文提出的 CvTFC 框架的整体网络结构如图 8 所示.

#### 4.1 基于自监督学习策略的对比学习模块

本文提出一个对比学习模块以降低参数变化对 ISAR 图像块特征的影响, 如图 9 所示. 利用图中的成像参数, 训练从仿真和分割成对的图像块开始, 其中  $\varphi_a$  表示积累角, 使网络适应不同分辨率的 ISAR 图像识别,  $\omega_r$  表示旋转加速度, 用于捕捉短时间内机动变化带来的散焦效应, 使网络适应一定范围内散焦图像识别,  $\theta_r$  表示在小范围内随机产生的图像旋转角度, 其变化让网络适应目标在一定范围内的姿态变换, 通过设置上述不同的成像参数, 每个图像块都产生两个扩展的图像块  $p_i$  和  $p_j$ , 根据实际 ISAR 系统特性和预先实验验证, 本文中积累角、旋转加速度和图像旋转角度的选取范围分别设定为  $[0.5^\circ, 3^\circ]$ 、 $[0.5^\circ/s^2, 2^\circ/s^2]$  和  $[-10^\circ, 10^\circ]$ .

从同一目标的同一位置仿真的一对扩展图像块可以被视为一对正图像块, 对于大小为  $N$  的训练批次, 总共有  $2N$  个扩展图像块, 则其他  $2N-2$  个图像块可以被视为该批次中的负图像块. 构建复数 ResNet18 网络模块, 利用自监督策略使正样本图像块间距离更




图7 空间目标图像的特征幅度变化

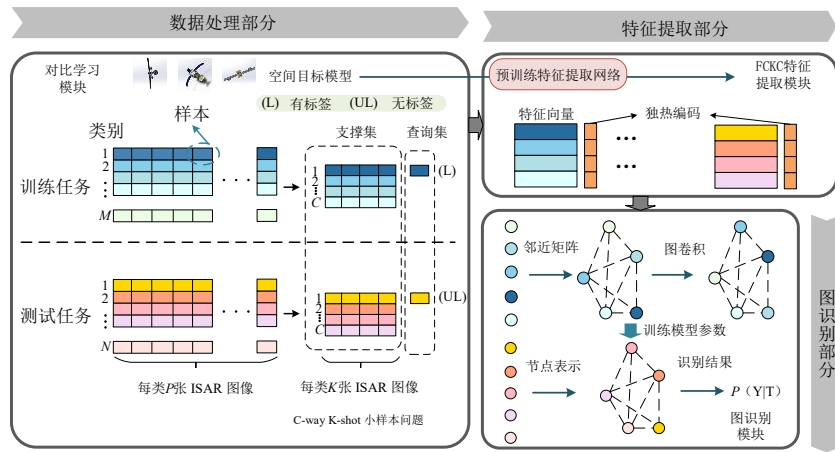


图8 本文提出的CvTFC模型的架构

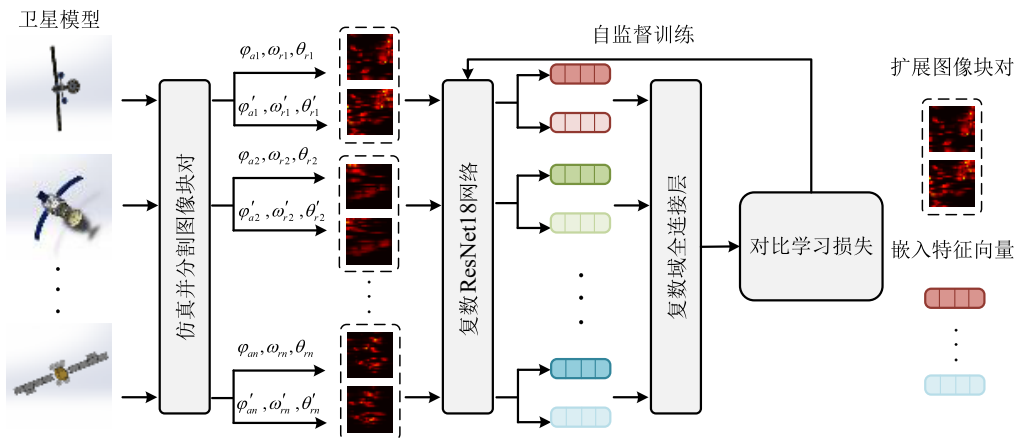


图9 本文提出的对比学习模块的流程

小、负样本图像块间距离更大,从而有效将图像块特征嵌入潜在特征空间  $u_i$  和  $u_j$  中. 一对正图像块的损失定义为

$$L_{i,j} = -\log \frac{\exp[\kappa^2 \text{dis}(u_i, u_j)]}{\sum_{n=1}^{2N} S_{[n \neq i]} \exp[\kappa^2 \text{dis}(u_i, u_n)]} \quad (7)$$

其中,

$$\text{dis}(u_i, u_j) = \frac{\Re(u_i)^T \cdot \Re(u_j)}{\|\Re(u_i)\|_2 \cdot \|\Re(u_j)\|_2} \cdot \frac{\Im(u_i)^T \cdot \Im(u_j)}{\|\Im(u_i)\|_2 \cdot \|\Im(u_j)\|_2} \quad (8)$$

$$S_{[n \neq i]} = \begin{cases} 1, & n \neq i \\ 0, & n = i \end{cases} \quad (9)$$

其中,  $\kappa$  表示温度系数, 用于调节网络输出分布的平滑

程度. 网络收敛后, 特征提取模块的参数被保留作为预训练网络参数.

#### 4.2 关键部件特征关联模块

本文提出的 FCKC 特征提取模块的详细计算流程如图 10 所示. 特征提取过程通过两条路线并行处理, 即针对图像块的基于区域的特征提取和针对整体图像的全局特征提取.

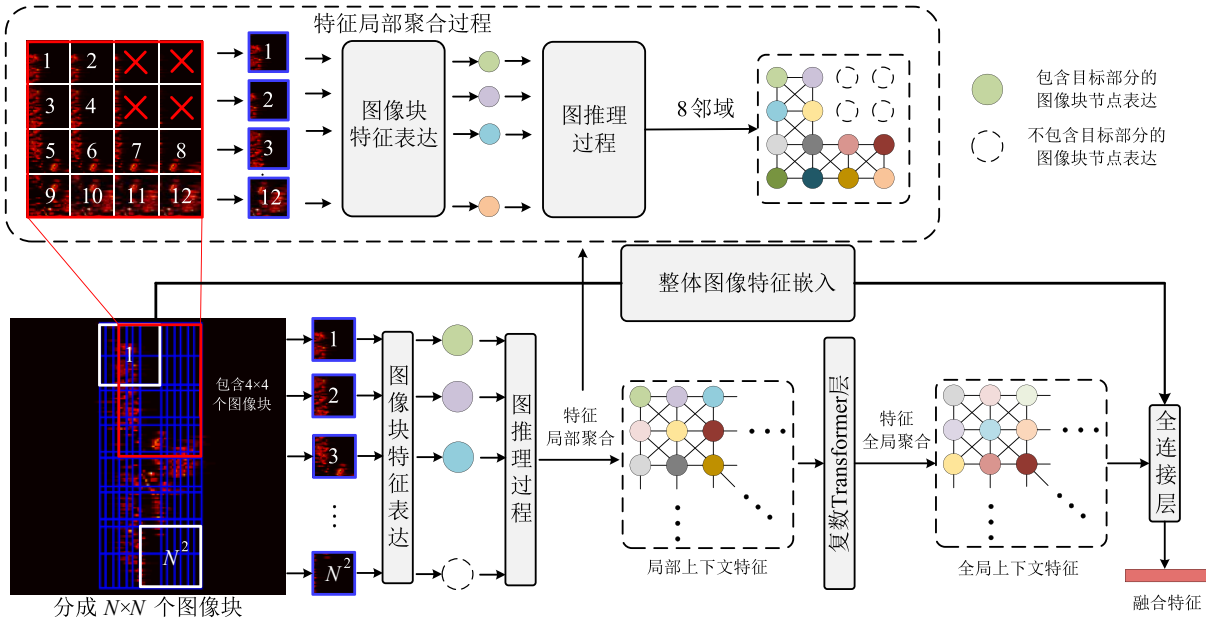


图 10 关键部件特征关联模块的示意图

在基于区域的特征提取中, 首先通过阈值分割方法在整个 ISAR 图像中定位包含目标的像素位置, 并利用这些位置来计算目标的外接矩形. 然后根据整星目标和关键部件的相对比例确定分割图像块数量, 最后基于外接矩形大小、关键部件的像素占比以及分割图像块数量确定图像块分割方式, 分割为有重叠的  $N \times N$  个图像块. 利用对比学习获得的预训练特征提取网络计算每个图像块的特征向量, 形成特征矩阵  $\mathbf{F} = [f_1, f_2, \dots, f_{N^2}]$ ,  $\mathbf{F} \in \mathbb{C}^{N^2 \times D}$ , 其中  $f_i$  表示一个  $D$  维的嵌入向量. 为此在本文构建的图网络中, 节点是预训练网络提取的图像块的特征, 再根据图像块空间关联计算节点的边. 如果图像块  $P_i$  位于图像块  $P_j$  的 8 邻域内, 并且两个图像块的像素幅度之和都大于预先设置的阈值 (这证明两个图像块中都存在空间目标的某些部分, 而不是纯背景), 那么 FCKC 模块就会在节点  $N_i$  和节点  $N_j$  之间创建一条边  $A_{ij} = 1$ ,  $A_{ji} = 1$ , 否则  $A_{ij} = 0$ ,  $A_{ji} = 0$ .

由于图推理方法对数据间的复杂关系和非欧几里得结构特征的有效捕捉能力, 以及其强适应性和灵活性, 本文在 FCKC 模块中使用图推理方法更新图数据,

信息传播和聚合过程可以表示为

$$\mathbf{N}_{j+1} = \text{CvReLU} \left( \text{CvBN l d} \left( \Gamma_{\hat{N}_j} \right) \right), j = 1, 2, \dots \quad (10)$$

$$\Gamma_{\hat{N}_j} = \Re(\hat{N}_j) \Re(\mathbf{w}_j) - \Im(\hat{N}_j) \Im(\mathbf{w}_j) + j \left[ \Re(\hat{N}_j) \Im(\mathbf{w}_j) + \Im(\hat{N}_j) \Re(\mathbf{w}_j) \right] \quad (11)$$

$$\hat{N}_j = \tilde{\mathbf{A}} \mathbf{N}_j + \mathbf{N}_j \quad (12)$$

其中,  $\text{CvReLU}(\cdot)$  表示复数域 ReLU 激活函数;  $\tilde{\mathbf{A}}$  表示由边组成的邻近矩阵;  $\mathbf{N}_j$  是 GRA 模型第  $j$  层的输入, 第 1 层的输入由节点特征矩阵初始化;  $\mathbf{w}_j \in \mathbb{C}^{D_j \times D_{j+1}}$  表示可学习的权重,  $D_j$  和  $D_{j+1}$  是输入和输出的维度;  $\text{CvBN l d}(\cdot)$  表示复数一维 BatchNorm 函数.

上述节点更新过程可以有效聚合图像块之间的局部上下文信息, 以获得更准确的目标的内部特征表示. 然而, 仅聚合局部特征很容易导致识别结果陷入局部最优, 为了捕捉不相邻的关键部件间的全局上下文特征关联, 构建远距离依赖关系, 本文在 FCKC 模块中添加了一个复数域 Transformer 层, 将其自注意力机制、全连接、多层感知器以及层归一化部分都扩展到复数域, 以提升对 ISAR 图像特征提取的能力.

在该模块的另一条特征提取路线中,利用卷积和池化层结合的方法提取整图的特征.该嵌入层与上述全局聚合特征不同,全局聚合是为了增强对更重要的局部图像块的全局注意力,其输出仍然代表局部图像块间的上下文特征信息.然而,该嵌入层的输出是整个 ISAR 图像的特征嵌入,这可以避免忽略不在彼此 8 邻域内的图像块之间的关联信息,其详细结构如图 11 所示.

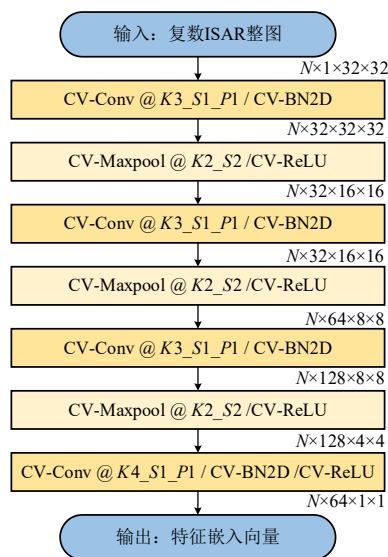


图 11 特征嵌入网络的详细计算流程

图 11 中的  $K$ 、 $S$  分别代表卷积核大小、步长,  $P1$  表示在卷积时进行补零使输出特征图和输入特征图的大小相同. 首先将输入图像的尺寸调整为  $32 \times 32$ , 通过该特征嵌入网络, 输出一维特征向量  $E_w$ , 与第一条路线的输出特征  $E_p$  连接起来形成最终的表示特征  $E_f$ , 表示为

$$E_f = [E_w, E_p] \omega_f, \omega_f \in \mathbb{C}^{(D_w + D_p) \times D_f} \quad (13)$$

$$E_p = \text{fla}(o_{l+1}) \omega_p, \omega_p \in \mathbb{C}^{(N_p \times D) \times D_p} \quad (14)$$

其中,  $o_{l+1}$  表示复数域 Transformer 层的输出特征,  $l$  表示层的索引,  $D_w$ 、 $D_p$  和  $D_f$  分别是特征  $E_w$ 、 $E_p$  和  $E_f$  的尺寸, 函数  $\text{fla}(\cdot)$  表示将 Transformer 空间的输出展平至一维.

### 4.3 基于多角度识别模型的 ISAR 目标识别

上述的特征提取可以实现对目标稳定和有效的表征, 因此在面对新类型目标的识别时, 网络可以准确将查询集中的新目标识别到支撑集中对应的类别中, 实现元学习. 最后在图识别模块中,  $E_f$  首先与独热编码连接, 串联结果被视为识别过程中的节点, 然后构建节点的邻近矩阵, 再通过非线性映射的方法进行节点特征更新, 最后利用交叉熵损失函数对节点进行识别, 得到待识别图像对应各个标签的识别概率, 网络详细训练过程如算法 1 所示.

### 算法 1 基于 CvTFC 模型的 ISAR 空间目标多角度识别方法

输入: 训练集  $D_{\text{train}}$

输出: 指定查询集图像数据的识别结果

步骤:

1. 通过图 9 中的成像参数仿真成对的 ISAR 图像块  $\rho_i$  和  $\rho_j$
2. 通过式(7)~(9)定义的对比学习去生成一个预训练的特征嵌入模型  $M_e$
3. 随机从  $D_{\text{train}}$  中生成训练任务  $T_{\text{train}}$
4. 如图 10 将  $T_{\text{train}}$  中的图像分成  $N \times N$  个图像块
5. 通过式(10)~(12)计算图像块的局部上下文特征  $E_p$
6. 通过图 11 中定义的嵌入网络计算图像块的上下文特征  $E_w$
7. 通过式(13)~(14)获取联合特征  $E_f$
8. 联合独热编码和  $E_f$  生成图数据的节点
9. 从  $l=1$  到  $L$  执行
10. 计算节点间的邻近矩阵
11. 进行节点特征更新
12. 利用交叉熵损失公式更新网络参数
13. 结束循环
14. 利用最佳网络参数获得查询集图像的识别结果

## 5 实验结果与分析

### 5.1 数据集描述与实验设置

首先建立多角度观测目标 ISAR 图像的小样本仿真数据集, 利用 STK 构建本星和绕飞航天器的轨道, 对 MRO 等八类空间目标模型生成仿真 ISAR 图像, 结果如图 12 所示.

由于在绕飞过程中, 目标的俯仰、偏航和滚转角的改变对识别的影响是等效的, 因此假设目标与本星雷达的轨道共面, 在成像过程中, 目标的偏航角和俯仰角不变, 仅有滚转角以  $12^\circ$  的间隔从  $0^\circ$  变化到  $348^\circ$ , 满足绕飞目标一个周期的姿态变化, 每变化 1 次产生 1 张 ISAR 图像数据, 每类目标得到 30 张 ISAR 图像数据, 满足小样本识别问题的数据量. 在训练初始阶段采用数据增强方法, 改变信噪比、图像对比度、目标旋转姿态、方位和距离维的尺度等参数, 数据增强后每类目标包含 330 张 ISAR 图像数据.

由于目标航天器施加了速度脉冲产生主动绕飞, 因此除了姿态的变化外, 目标还存在着旋转速度和旋转加速度, 本文以一个恒定的加速度去描述自旋速度的变化. 为了验证所提方法的泛化能力, 本文通过组合不同的旋转速度和加速度创建四个数据集, 图像的积累角受该参数影响, 图像的分辨率和散焦程度有所区别. 由于本文研究元学习策略, 数据的训练集和测试集包含的目标种类不同. 为验证模型的泛化能力, 训练集仅包含一种参数组合的数据集, 测试集包含上述所有参数组合的数据集, 训练和测试数据集的详细参数设置分别如表 1 和表 2 所示.

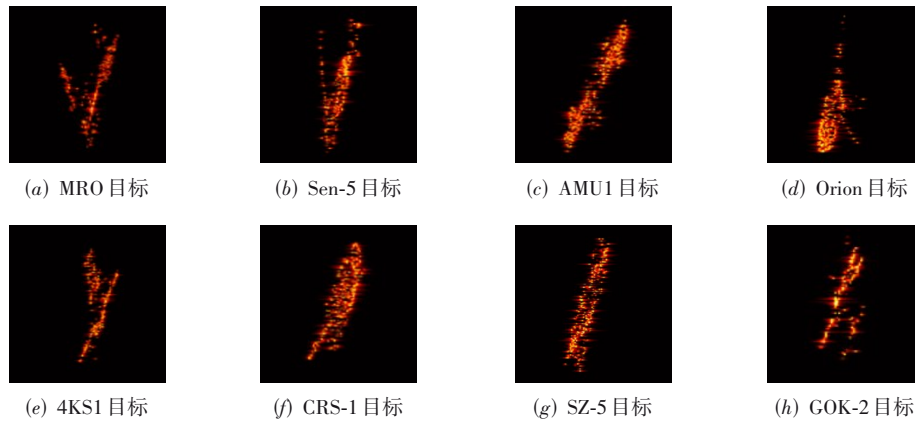


图 12 空间目标 ISAR 仿真图像

表 1 训练数据集的参数和数量

目标类别	旋转速度 /(rad/s)	旋转加速度 /(rad/s <sup>2</sup> )	原始数据量
MRO Sen-5 AMU1 Orion 4KS1	0.1	0.3	30

表 2 测试数据集的参数和数量

目标类别	旋转速度 /(rad/s)	旋转加速度 /(rad/s <sup>2</sup> )	原始数据量
CRS-1	0.1	0.3	30
SZ-5	0.1	0.5	
GOK-2	0.2	0.3	
GOK-2	0.2	0.5	

表 3 训练集中识别任务对应参数

识别任务	支撑集旋转速度 /(rad/s)	支撑集旋转加速度 /(rad/s <sup>2</sup> )	查询集旋转速度 /(rad/s)	查询集旋转加速度 /(rad/s <sup>2</sup> )
1	0.1	0.3	0.1	0.3
2				
3				
4				

表 4 测试集中识别任务对应参数

识别任务	支撑集旋转速度 /(rad/s)	支撑集旋转加速度 /(rad/s <sup>2</sup> )	查询集旋转速度 /(rad/s)	查询集旋转加速度 /(rad/s <sup>2</sup> )
1	0.1	0.3	0.1	0.3
2	0.1	0.5	0.1	0.5
3	0.2	0.3	0.2	0.3
4	0.2	0.5	0.2	0.5

在本文的实验中,  $C$  设置为 3,  $K$  设置为 1 和 5. 本文中的所有实验均在配备 Intel Core i7、3.39 GHz CPU 和 NVIDIA GeForce RTX 3080 GPU 的计算机上实现. 在训

在本文的小样本识别任务中, 训练和测试过程共享相同的  $C$ -way,  $K$ -shot 任务模式. 在构建训练任务  $T_{train}$  时, 首先从训练集中随机选择  $C$  个目标类别, 并为每个类别随机选择  $K$  个图像, 经过数据增强, 形成支撑集  $S_{train}$ , 然后从上述类中随机选择一个类, 在该类中, 多选择出一张图像作为有标签的查询集  $Q_{train}$ . 标签和网络的输出一起计算, 生成有监督学习的损失. 重复上述过程  $B$  次, 生成训练任务, 其中  $B$  表示训练批次.

在测试任务的构建中, 利用不同成像参数的数据集生成 4 个不同的测试任务, 支撑集  $S_{test}$  和查询集  $Q_{test}$  的构造与上述过程类似, 不同之处在于  $Q_{test}$  中的图像是没有标签的. 在任务 2 到任务 4 中, 支撑集中的数据和查询集中的数据的参数是一致的, 但它们与训练集中数据的参数不同, 目的是验证网络对不同机动参数目标的识别效果, 训练集和测试集对应的不同任务包含的参数如表 3 和表 4 所示.

练过程中, 首先利用 Xavier 实现模型的参数初始化, 学习率方面, 特征嵌入层的学习率设为  $5 \times 10^{-5}$ , weight\_decay 设为 0, 对于其他层学习率设为  $1 \times 10^{-3}$ ,

weight\_decay 设为  $1 \times 10^{-6}$ , 迭代 100 次后学习率衰减为 0.8 倍, 每次训练包含 3 000 次迭代, 每批包含 32 个数据, 采用 AdamW 优化器, 自注意力机制中头的数量选择 8, 每个头的维度选择 32.

实验中利用准确率、召回率和  $F_1$  值对模型的识别性能进行评估, 计算方法如下:

$$P_r = \frac{TP}{TP + FP} \quad (15)$$

$$R_e = \frac{TP}{TP + FN} \quad (16)$$

$$F = \frac{2 \cdot (P_r \cdot R_e)}{P_r + R_e} \quad (17)$$

其中,  $P_r$  表示准确率,  $R_e$  表示召回率,  $F$  表示  $F_1$  值, TP 表示被正确地预测为正例的样本数, FP 表示被错误地预测为正例的样本数, FN 表示被错误地预测为负例的样本数, 上述指标的数值越大, 说明模型的识别能力越强.

## 5.2 仿真数据集实验结果

### 5.2.1 实验结果分析

即使识别模型的参数相同, 对于不同分辨率和散焦程度的数据集, 也会获得不同的识别准确率. 因此, 本文构建了 100 个独立重复实验, 每次对测试集中的所有图像进行识别. 表 5 显示了不同任务的识别准确率, 识别结果表明, 对于这四个不同的数据集, 当任务从 1-shot 模式变为 5-shot 模式时, 最低识别准确率从 42.22% 提高到 81.11%. 此外, 在 1-shot 模式下, 最低的平均识别精度也超过了 70%, 而在 5-shot 模式下, 平均识别精度超过 95%, 这证明了所提出的 CvTFC 模型对于 ISAR 多角度观测目标识别的有效性.

表 5 不同识别任务的识别准确率

任务	任务场景	最小值/%	最大值/%	平均值/%	标准差
1	1-shot	56.67	96.67	78.74	9.20
	5-shot	81.11	98.89	96.47	4.01
2	1-shot	46.67	93.33	75.26	8.40
	5-shot	84.44	98.89	97.79	3.43
3	1-shot	42.22	93.33	79.47	9.52
	5-shot	81.11	97.78	95.58	4.45
4	1-shot	46.67	90.00	73.94	10.16
	5-shot	84.44	98.89	95.68	4.36

图 13 进一步显示了 1-shot 和 5-shot 模式下不同数据集的识别准确率统计直方图, 可以直观地看出, 5-shot 模式下识别准确率分布的方差小于 1-shot 模式的方差. 此外, 5-shot 模式下的准确率更集中在 95% 以上的区间, 这证明提出的 CvTFC 模型的识别泛化能力较强, 对于不同机动参数的数据均有较好的识别效果, 并且增加支撑集

中的数据量还可以显著提高识别的准确率.

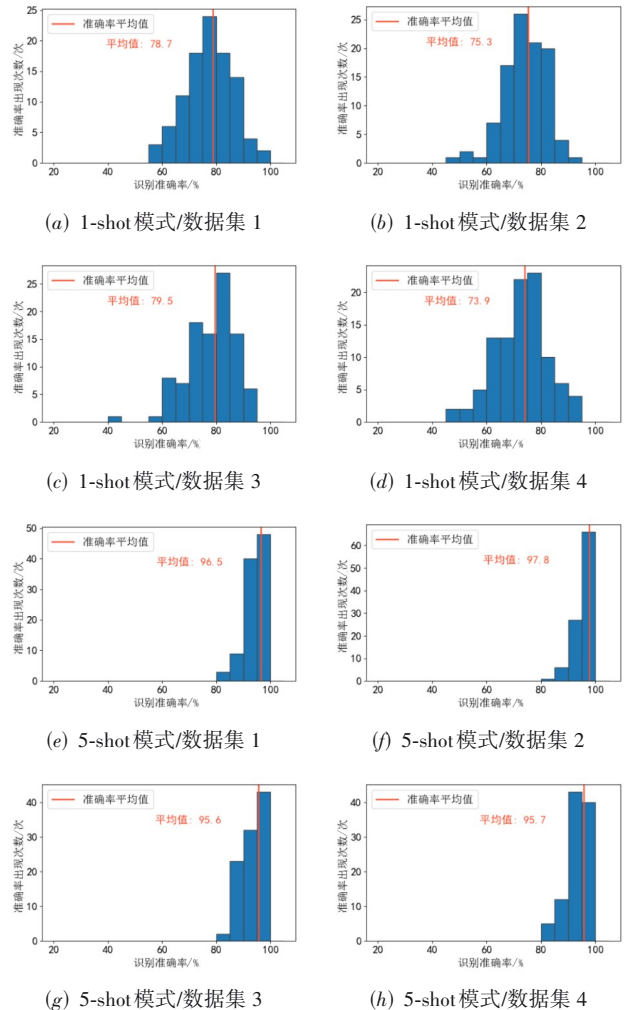



图 13 1-shot 和 5-shot 任务中不同数据集的识别准确率直方图


在测试时连续取 100 个随机批次的的数据, 对其进行识别准确率混淆矩阵的计算, 图 14 展示了 3way-1shot 模式下不同识别任务的平均混淆矩阵, 其中横轴代表输出, 纵轴代表标签, 可见模型对每个目标的正确识别率都较高. 表 6 展示了基于上述混淆矩阵得到的 1-shot 模式下网络对不同数据集的识别性能, 包含识别准确率、召回率和  $F_1$  值, 由表可见各项识别性能指标的数值均超过 70%, 可见 CvTFC 模型可有效用于小样本条件下的 ISAR 多角度观测目标识别.

图 15 展示了 3-way 5-shot 模式下不同识别任务的识别准确率混淆矩阵, 由矩阵结果可见当任务从 1-shot 模式变为 5-shot 模式时, 每个目标对应的正确识别率提高, 错误的识别率降低. 表 7 展示了 5-shot 模式下网络对不同数据集的识别性能, 由表可见不同数据集的各项识别性能指标比起 1-shot 场景明显增高, 并且数值均在 93% 以上, 可见随着训练数据量的增加, 提出模型的



(a) 1-shot 模式/数据集 1

(b) 1-shot 模式/数据集 2



(c) 1-shot 模式/数据集 3

(d) 1-shot 模式/数据集 4

图 14 3-way 1-shot 模式下不同数据集的平均识别准确率混淆矩阵

表 6 1-shot 模式下对不同数据集的识别性能 单位: %


数据集	指标	目标 1	目标 2	目标 3	平均
数据集 1	准确率	79.30	74.12	81.13	78.18
	召回率	75.33	77.33	81.67	78.11
	$F_1$ 值	77.26	75.69	81.40	78.12
数据集 2	准确率	78.01	72.12	80.07	76.73
	召回率	73.33	75.00	81.67	76.67
	$F_1$ 值	75.60	73.53	80.86	76.66
数据集 3	准确率	79.72	72.21	83.70	78.54
	召回率	74.67	84.00	75.33	78.00
	$F_1$ 值	77.11	77.66	79.30	78.02
数据集 4	准确率	74.63	72.33	72.90	73.29
	召回率	67.67	76.67	75.33	73.22
	$F_1$ 值	70.98	74.43	74.10	73.17

识别性能有了明显提升.

### 5.2.2 消融实验


通过在仿真数据集上进行消融实验来证明所提出的 CvTFC 模型中的对比学习模块、FCKC 特征提取模块、复数 Transformer 层和整体复数域架构的有效性. 表 8 显示了在 3-way 1-shot 和 3-way 5-shot 任务模式中分别进行了 100 次独立重复实验的平均识别准确率, 其中状态值为 0 表示不利用对比学习, 状态值为 1 表示利用对比学习. 可以看出利用对比学习后, 1-shot 和 5-shot 任务的平均识别准确率分别提高了约 20% 和 14%, 证明目标的机动和 ISAR 成像的参数对识别任务影响较大, 而对比学习可以有效抑制 ISAR 图像的散焦、分辨率变化和姿态变化引起的识别准确率下降.

表 9 显示了利用和不利用 FCKC 特征提取模块时模型的平均准确率. 由表 9 可见, 在利用了 FCKC 特征



(a) 5-shot 模式/数据集 1

(b) 5-shot 模式/数据集 2



(c) 5-shot 模式/数据集 3

(d) 5-shot 模式/数据集 4

图 15 3-way 5-shot 模式下不同数据集的平均识别准确率混淆矩阵

表 7 5-shot 模式下对不同数据集的识别性能 单位: %

数据集	指标	目标 1	目标 2	目标 3	平均
数据集 1	准确率	94.12	95.21	92.38	93.90
	召回率	96.00	92.67	93.00	93.89
	$F_1$ 值	95.05	93.92	92.69	93.89
数据集 2	准确率	92.83	94.39	96.21	94.48
	召回率	95.00	95.33	93.00	94.44
	$F_1$ 值	93.90	94.86	94.58	94.45
数据集 3	准确率	95.32	94.04	93.31	94.22
	召回率	95.00	94.67	93.00	94.22
	$F_1$ 值	95.16	94.35	93.16	94.22
数据集 4	准确率	94.37	91.35	96.15	93.96
	召回率	95.00	95.00	91.67	93.89
	$F_1$ 值	94.68	93.14	93.86	93.89

表 8 是否运用对比学习方法的识别准确率对比 单位: %

模式	状态	任务 1	任务 2	任务 3	任务 4
3-way 1-shot	0	54.69	49.12	58.88	59.91
	1	78.74	75.26	79.47	73.95
3-way 5-shot	0	82.53	83.60	84.08	80.56
	1	96.47	97.79	95.58	95.68


提取模块后, 1-shot 和 5-shot 任务的平均准确率分别提高了约 12% 和 5%, 证明 FCKC 提取模块在识别任务上的有效性.

为了进一步直观地看出 FCKC 特征提取模块中复数 Transformer 层在识别过程中的作用, 采用 Grad-CAM 方法<sup>[31]</sup>分别计算在该层加入前后的网络注意力图, 以 Sen-5、AMU1 和 CRS-1 目标为例, 网络对其注意力图的对比如图 16 所示. 由图可见, 加入本文提出的复数域


Transformer 层后,网络对目标的注意力变得更加全局化,而没有该层会让网络的注意力更集中于一些关键部件上,可能导致识别率的下降.因此本文提出的复数域 Transformer 层可有效增强网络对图像块的全局注意力.

表 9 是否运用 FCKC 模块的识别准确率对比 单位:%


模式	状态	任务 1	任务 2	任务 3	任务 4
3-way 1-shot	0	64.33	67.25	62.21	65.17
	1	78.74	75.26	79.47	73.95
3-way 5-shot	0	92.83	95.16	89.25	89.86
	1	96.47	97.79	95.58	95.68



(a) 不同目标的原始 ISAR 图像



(b) 加入复数 Transformer 层时对不同目标的注意力图



(c) 不加入复数 Transformer 层时网络对不同目标的注意力图

图 16 目标的 ISAR 图像及网络对其注意力图的对比

为了验证所提出的 CvTFC 模型中的复数域架构的有效性,图 17 显示了所提出的 CvTFC 网络以及具有相同层的实数域关键部件特征关联网络 (Real-valued TFC, RvTFC) 的训练损失曲线.

由图 17 可以看出,CvTFC 网络的损失曲线下降得更早、更快,并且可以收敛到较低的位置,这证明所提出的 CvTFC 网络可以更有效地学习复数 ISAR 图像的特征.而 RvTFC 网络丢失了复数 ISAR 图像的相位信息,导致特征提取过程变慢且效率低下.表 10 中展示了在 3-way 1-shot 和 3-way 5-shot 两种不同识别模式下实数和复数网络架构在 4 个任务数据集上的识别准确率,可见两种识别模式下的实数网络架构的识别准确

率均低于复数网络架构.在 3-way 1-shot 模式下,RvTFC 的识别平均准确率为 71.88%,CvTFC 的识别平均准确率为 76.86%,低了约 4.98%;在 3-way 5-shot 模式下,RvTFC 的识别平均准确率为 93.52%,CvTFC 的识别平均准确率为 96.38%,低了约 2.86%.可见,随着在识别过程中每类目标的图像数量增加,稍微减少了实数域架构在 ISAR 图像特征提取上的不利影响,其与复数域架构的识别准确率差距稍有减小.上述对比证明了所提出的 CvTFC 网络中复数网络框架对 ISAR 图像特征提取的适用性.




图 17 不同网络架构对应的训练损失曲线

表 10 不同网络的识别准确率对比 单位:%

模式	网络架构	任务 1	任务 2	任务 3	任务 4
3-way 1-shot	实数	73.42	69.97	74.82	69.31
	复数	78.74	75.26	79.47	73.95
3-way 5-shot	实数	93.35	95.14	92.88	92.72
	复数	96.47	97.79	95.58	95.68

最后,通过实验分析滚动角的步长对识别准确率的影响,如图 18 所示,随着图像滚动角的增加,图像的嵌入特征发生更多变化,导致两幅输入图像对应的关联矩阵之间的距离更大.最后,全连接层获得的特征向量之间存在更多差异,使得将两幅图像识别为同一类别变得更加困难.




图 18 滚转角步长对识别影响

为了验证上述理论,以  $4^\circ$  为间隔将滚转角步长从  $4^\circ$  增加到  $44^\circ$ ,3-way 5-shot 和 3-way 1-shot 场景下的识别准确率及其二次函数的拟合曲线如图 19 和图 20 所示.从图

中可以看出,为了保证两种场景下的最小识别准确率达到 70%,所需的滚转角最小步长至少为 32°和 12°,对于较大的滚动角步长,需要更多的训练图像数据来保证其识别准确率. 因此考虑到实际空间场景中可以获得的 ISAR 图像数量有限,本文采用 12°步长进行实验验证.




图 19 3-way 5-shot 场景下的识别率及其二次函数拟合曲线




图 20 3-way 1-shot 场景下的识别率及其二次函数拟合曲线


### 5.3 实验室实测数据集实验结果

为了进一步证明所提出的 CvTFC 框架的有效性,利用实验室获得的真实雷达图像进行了一系列实验. 实验采用图 21 中的二维滑轨和成像平台,利用如表 11 中的发射信号参数对神舟十三号(SZ-13)、嫦娥二号(CE-2)和天宫二号(TG-2)三种空间目标模型进行雷达成像,目标对应的光学图像和实验室获得的雷达图像如图 22 所示. 在实验过程中,同样将模型相对雷达的滚转角以 12°的间隔从 0°变化到 348°,每类目标产生 30 张雷达图像数据,以满足多角度观测场景中目标大姿态变化和小样本数据量的要求. 与仿真数据集中的模型相比,三个真实模型的差异较小,因此实测雷达图像的识别更加困难,对识别模型的有效性提出了更高的要求.

由于实测模型的类别数量较少,实验中使用了交叉验证的思想. 如表 12 所示,实验中设置 3 个测试集,每个测试集包含一个真实目标和两个仿真目标,相应的训练集包含剩余的真实目标和仿真目标,其中加粗部分对应的是实测目标.

与仿真实验类似,分别针对 3-way 1-shot 和 3way 5-shot 任务模式进行 100 次独立重复实验,计算识别准确率时只计算实测目标对应的准确率,测试准确率的最小值、最大

值、平均值和标准差分别如表 13 所示.



(a) 二维滑轨 (b) 目标成像平台

图 21 实验室成像设备

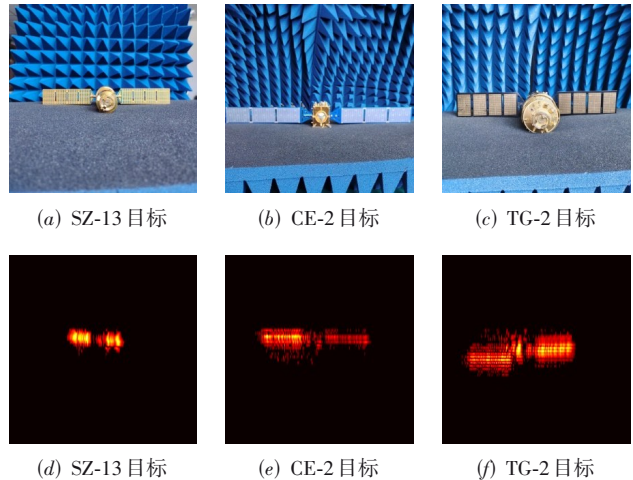


图 22 三个真实空间目标的光学和雷达图像

表 11 发射信号参数

起始频率/ GHz	带宽/GHz	Chirp 采样点数	采样率/ MHz	Chirp 斜率/ (MHz/ $\mu$ s)
77	3.997	512	9.121	66.626

表 12 实验室实测数据集的划分

测试任务	目标类别	每个目标样本数量
1	<b>SZ-13</b>	30
	MRO	
	Sentinel-5	
2	<b>CE-2</b>	30
	MRO	
	Sentinel-5	
3	<b>TG-2</b>	30
	MRO	
	Sentinel-5	

表 13 不同识别任务的准确率

任务模式	最小值/%	最大值/%	平均值/%	标准差
1-shot	51.11	84.44	70.07	7.044 515
5-shot	60.00	86.67	76.27	6.268 715

图 23 直观地显示了实验室实测数据集的识别准确率及其直方图,由结果可见,CvTFC 模型在 1-shot 和 5-shot 模式下的平均识别准确率分别达到 70.07% 和 76.27%,并且在 5-shot 条件下标准差更小,这证明了在

小样本条件下,提出的模型对于多角度观测目标雷达图像的识别具备有效性.取 100 个随机批次的数据进行混淆矩阵的计算,得到实测数据集的平均识别准确率混淆矩阵如图 24 所示.




图 23 1-shot 和 5-shot 任务中实测数据集的识别准确率直方图




图 24 1-shot 和 5-shot 任务中实测数据集的识别准确率混淆矩阵

可见模型对每个目标的正确识别率较高,并且从 1-shot 任务场景变到 5-shot 场景时,目标的识别准确率上升.表 14 展示了网络对实测数据集的识别性能,由表可见在 1-shot 任务场景中网络对实测数据集的平均识别准确率、召回率、 $F_1$  值分别为 72.11%、72.11%、72.09%,在 5-shot 任务场景中网络对实测数据集的平均识别准确率、召回率、 $F_1$  值分别为 79.67%、79.63%、79.62%,两种任务场景的识别性能指标值均超过 70%,证明 CvTFC 模型对实测目标数据具有较好的识别性能.

### 5.4 对比实验与结果分析

表 15 和表 16 分别显示了 3-way 1-shot 和 3-way 5-shot

模式下所提出的 CvTFC 网络和其他小样本识别模型在仿真数据集上的识别准确率,其中 RN、MAML、时序卷积元学习 (Meta-Learning with Temporal Convolutions, TCML)<sup>[32]</sup>和 GNN 是光学领域的通用目标识别算法,GNN 通过其图结构表征能力也可用于 ISAR 目标识别领域,复数域图神经网络 (Complex-valued GNN, CVGNN)<sup>[33]</sup>是专门扩展于 ISAR 领域的识别算法,其对复数据的特征提取能力更强.它们对应的各识别模型的测试准确率曲线分别如图 25(a) 和图 25(b) 所示.

表 15 3-way 1-shot 模式下仿真数据集上不同识别方法的对比

单位: %					
任务模式	识别模型	任务 1	任务 2	任务 3	任务 4
3-way 1-shot	RN <sup>[24]</sup>	63.10	65.18	67.47	65.86
	GNN <sup>[25]</sup>	70.12	70.95	69.75	64.26
	MAML <sup>[26]</sup>	77.78	72.52	74.47	70.53
	TCML <sup>[31]</sup>	76.38	73.27	73.58	71.26
	CVGNN <sup>[32]</sup>	76.95	74.70	73.93	72.21
	CvTFC	78.74	75.26	79.47	73.95

表 16 3-way 5-shot 模式下仿真数据集上不同识别方法的对比

单位: %					
任务模式	识别模型	任务 1	任务 2	任务 3	任务 4
3-way 5-shot	RN <sup>[24]</sup>	66.21	70.36	69.14	74.96
	GNN <sup>[25]</sup>	74.34	77.77	80.90	75.84
	MAML <sup>[26]</sup>	88.89	89.48	91.32	87.68
	TCML <sup>[31]</sup>	89.37	90.28	91.38	90.95
	CVGNN <sup>[32]</sup>	92.17	94.38	91.27	90.65
	CvTFC	96.47	97.79	95.58	95.68

表 14 网络对实测数据集的识别性能 单位: %

识别场景	指标	目标 1	目标 2	目标 3	平均
1-shot	准确率	76.67	69.67	70.00	72.11
	召回率	74.43	68.98	72.92	72.11
	$F_1$ 值	75.53	69.32	71.43	72.09
5-shot	准确率	84.00	74.33	80.67	79.67
	召回率	80.51	78.25	80.13	79.63
	$F_1$ 值	82.22	76.24	80.40	79.62

可以看出,本文提出的 CvTFC 模型在 3-way 1-shot 和 3-way 5-shot 场景中的仿真和实验室实测数据集上都具有更高的识别准确率. 与其他模型相比,关系网络 RN 在 3-way 1-shot 和 3-way 5-shot 场景中的识别精度最低,这表明对于姿态变化较大的目标图像,单纯计算图像间欧式距离的识别效果是最差的,且不适用于新类型目标的元学习小样本识别. 而由于 GNN 能够更好地捕获图结构

中的复杂关系,使其更适用于 ISAR 多角度观测目标的识别任务,识别结果优于 RN;在两个任务场景中 CVGNN 都取得了比 GNN 更好的识别结果,证明其复数网络架构与 ISAR 图像的特性更契合,对其表征能力更强;对于 MAML、TCML 等元学习方法,在两种任务模式下都取得了较好的识别结果,但是准确率仍低于本文提出的 CvTFC 模型,证明 CvTFC 对于本文研究的姿态变化较大的 ISAR 图像具有更强的适应能力.

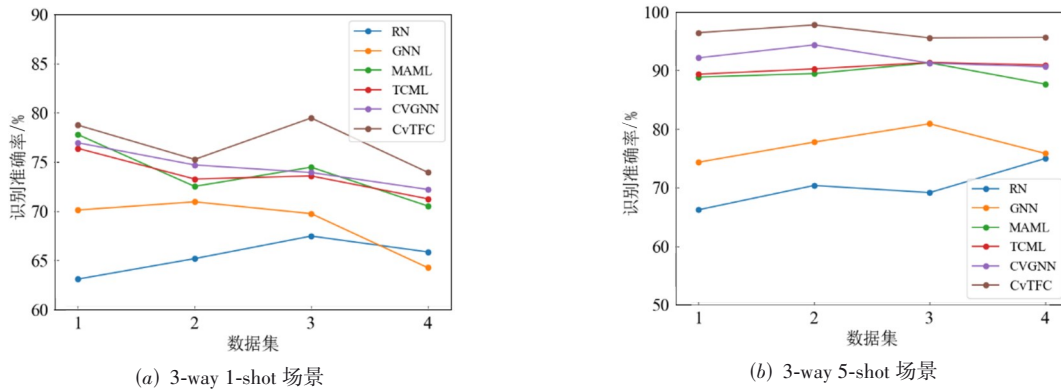


图 25 不同场景下不同数据集对应识别精度曲线

表 17 显示了上述对比方法在实测数据集上的识别准确率. 由表可见在 3-way 1-shot 和 3-way 5-shot 场景中, CvTFC 模型与其他对比模型相比分别提高了 5.18%~11.44% 和 5.58%~12.49%, 证明提出的模型可有效应用于天基观测时绕飞等多角度观测目标的识别.

表 17 实测数据集上不同方法的对比 单位: %

模型	3-way 1-shot	3-way 5-shot
RN <sup>[24]</sup>	58.63	63.78
GNN <sup>[25]</sup>	59.87	62.35
MAML <sup>[26]</sup>	60.65	65.76
TCML <sup>[31]</sup>	63.76	71.27
CVGNN <sup>[32]</sup>	64.89	70.69
CvTFC	70.07	76.27

## 6 结论

本文针对多角度观测的绕飞机动目标的 ISAR 图像识别进行研究,由于观测条件受限,加上受到复杂空间环境干扰以及 ISAR 成像参数的影响,绕飞航天器的有效 ISAR 图像的数量受限,并且在实际的目标探测场景中常常会出现未经训练的新目标,为此本文研究基于元学习的小样本识别问题. 更关键的是,由于绕飞目标的姿态持续变化,成像雷达的目标图像帧间姿态差距较大,一般的识别方法只能提取图像整体特征的嵌入,对于这类目标的表征能力受限. 为了解决上述问题,本文提出了 CvTFC 网络架构,构建对比学习模块,

通过自监督的手段去减少目标机动和 ISAR 成像参数变化对识别网络的影响;构建 FCKC 特征提取模块,通过图推理获得目标区域之间丰富的空间关系和局部上下文信息;构建复数的 Transformer 层来增强网络对目标图像的全局注意力,与局部上下文信息一起形成对目标的稳定和有效的表征. 仿真和实验室实测数据集的实验结果表明,在相同的小样本识别条件下,所提出的 CvTFC 模型对于多角度观测目标的识别表现出更强的泛化能力和更高的识别精度.

致谢 感谢空间目标感知全国重点实验室开放基金对本研究的资助支持.

## 参考文献

- [1] WANG Q, YUAN Z H, DU Q, et al. GETNET: A general end-to-end 2-D CNN framework for hyperspectral image change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(1): 3-13.
- [2] ZHOU X N, BAI X R, WANG L, et al. Robust ISAR target recognition based on ADRISAR-net[J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(6): 5494-5505.
- [3] LI X H, RAN J H, WEN Y B, et al. MVFRnet: A novel high-accuracy network for ISAR air-target recognition via multi-view fusion[J]. Remote Sensing, 2023, 15(12): 3052.

- [4] ZHANG M, AN J B, YU D H, et al. Convolutional neural network with attention mechanism for SAR automatic target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 19: 1-5.
- [5] XUE B, TONG N N. Real-world ISAR object recognition using deep multimodal relation learning[J]. *IEEE Transactions on Cybernetics*, 2019, 50(10): 4256-4267.
- [6] YANG H, ZHANG Y S, DING W Z. Multiple heterogeneous P-DCNNs ensemble with stacking algorithm: A novel recognition method of space target ISAR images under the condition of small sample set[J]. *IEEE Access*, 2020, 8: 75543-75570.
- [7] YANG H, ZHANG Y S, YIN C B, et al. Ultra-lightweight CNN design based on neural architecture search and knowledge distillation: A novel method to build the automatic recognition model of space target ISAR images[J]. *Defence Technology*, 2022, 18(6): 1073-1095.
- [8] LI C X, LI Y G, ZHU W G, et al. Semisupervised space target recognition algorithm based on integrated network of imaging and recognition in radar signal domain[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 60(1): 506-524.
- [9] DING J, CHEN B, LIU H W, et al. Convolutional neural network with data augmentation for SAR target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 364-368.
- [10] KWAK Y, SONG W J, KIM S E. Speckle-noise-invariant convolutional neural network for SAR target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 16(4): 549-553.
- [11] LIN Z, JI K F, KANG M, et al. Deep convolutional highway unit network for SAR target classification with limited labeled training data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(7): 1091-1095.
- [12] BAI X R, XUE R H, WANG L, et al. Sequence SAR image classification based on bidirectional convolution-recurrent network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 9223-9235.
- [13] ZHANG Y K, GUO X S, REN H H, et al. Multi-view classification with semi-supervised learning for SAR target recognition[J]. *Signal Processing*, 2021, 183: 108030.
- [14] GUO Y R, PAN Z X, WANG M M, et al. Learning capsules for SAR target recognition[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 4663-4673.
- [15] ZAIED S, TOUMI A, KHENCHAF A. Target classification using convolutional deep learning and auto-encoder models[C]// 2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). Piscataway: IEEE, 2018: 1-6.
- [16] DENG S, DU L, LI C, et al. SAR automatic target recognition based on Euclidean distance restricted autoencoder[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(7): 3323-3333.
- [17] SHI C W, ZHANG Q, LIN T, et al. Recognition of micro-motion jamming based on complex-valued convolutional neural network[J]. *Sensors*, 2023, 23(3): 1118.
- [18] AKIRA H. *Complex-Valued Neural Networks: Advances and Applications*[M]. New York: John Wiley & Sons Inc, 2013.
- [19] LI W H, DENG W, WANG K, et al. A complex-valued transformer for automatic modulation recognition[J]. *IEEE Internet of Things Journal*, 2024, 11(12): 22197-22207.
- [20] ZENG Z Q, SUN J P, HAN Z, et al. SAR automatic target recognition method based on multi-stream complex-valued networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-18.
- [21] ZHOU X Q, LUO C, REN P, et al. Multiscale complex-valued feature attention convolutional neural network for SAR automatic target recognition[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 17: 2052-2066.
- [22] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[J]. *Advances in Neural Information Processing Systems*, 2016: 3637-3645.
- [23] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[J]. *Advances in Neural Information Processing Systems*, 2017, 30(1): 4077-4087.
- [24] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 1199-1208.
- [25] ZHOU J, CUI G Q, HU S D, et al. Graph neural networks: A review of methods and applications[J]. *AI Open*, 2020, 1: 57-81.
- [26] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//International Conference on Machine Learning. New York: PMLR, 2017: 1126-1135.
- [27] RUSU A A, RAO D, SYGNOWSKI J, et al. Meta-learning with latent embedding optimization[EB/OL]. (2018-07-16)[2024-09-10]. <https://arxiv.org/abs/1807.05960>.
- [28] SANTORO A, BARTUNOV S, BOTVINICK M, et al. Meta-learning with memory-augmented neural networks[C]//International Conference on Machine Learning. New York:


- PMLR, 2016: 1842-1850.
- [29] MISHRA N, ROHANINEJAD M, CHEN X, et al. A simple neural attentive meta-learner[EB/OL]. (2017-07-11) [2024-09-10]. <https://arxiv.org/abs/1707.03141v3>.
- [30] 袁浩轩, 张云, 李沐遥, 等. 基于复数区域图 Transformer 的机动空间目标识别方法: 202311044597[P]. 2025-07-15.
- [31] SELVARAJU R R, COGSWELL M, DAS A, et al. Gradcam: Visual explanations from deep networks via gradient-based localization[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE, 2017: 618-626.
- [32] MISHRA N, ROHANINEJAD M, CHEN X, et al. Meta-learning with temporal convolutions[EB/OL]. (2018-07-11) [2024-09-10]. <https://arxiv.org/abs/1707.03141>.
- [33] ZHANG Y, YUAN H X, LI H B, et al. Complex-valued graph neural network on space target classification for defocused ISAR images[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.

### 作者简介



袁浩轩 男, 1997 年生, 黑龙江哈尔滨人. 2024 年毕业于哈尔滨工业大学信息与通信工程专业, 现为哈尔滨工业大学副研究员. 主要研究方向为雷达信号智能处理和深度学习识别框架.

E-mail: hxyuan@hit.edu.cn



张云 女, 1975 年生, 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