

DOI: 10.19650/j.cnki.cjsi.J2614838

基于空间度量原型网络的小样本军事目标识别方法^{*}

林渤然¹, 王 辉², 凌 军², 黄宇轩², 翁璐斌³, 廉鹏飞¹

(1. 华东师范大学集成电路科学与工程学院 上海 200241; 2. 上海航天电子技术研究所 上海 201109;
3. 中科院自动化研究所 北京 100190)

摘 要:小样本军事目标识别旨在标注样本极其有限条件下实现对新型军事目标的快速、准确识别,在军事遥感解译、战场态势感知及辅助决策等领域具有重要意义。基于度量学习的方法通过构建类别原型并度量查询样本与原型之间的相似性完成识别,因结构简洁、训练灵活且迁移能力较强,已成为小样本学习的主流方法。然而,现有方法在类别原型构建中多采用均值估计,易受遥感图像中背景杂波、成像噪声及离群样本影响,导致原型偏移;同时,对特征空间各方向通常采用等权处理,难以表征不同方向对分类判别的贡献差异,在类间特征分布高度重叠时模型区分能力受限。针对上述问题,提出一种基于空间度量原型网络的小样本军事目标识别方法。该方法首先利用特征提取器将样本映射至嵌入空间,并通过特征平移与归一化增强特征表示的鲁棒性与稳定性;随后设计原型增强模块,在低秩子空间内对类别原型进行自适应优化,通过强化主判别方向、抑制冗余噪声信息,缓解低维判别特征纠缠;最后结合空间投影误差构建度量函数,实现对查询样本的精细化识别。Ship、MAR20 和 NWPU-RESISC45 数据集实验结果表明,所提方法在 5-way 1-shot 任务下平均识别准确率分别提升 24.49%、2.07% 和 4.03%,在 5-way 5-shot 任务下分别提升 26.98%、8.92% 和 5.43%,验证了其在复杂遥感场景下的有效性与泛化能力。

关键词:军事目标识别;度量学习;小样本学习;类别原型;遥感图像

中图分类号: TH74 TP751.1 **文献标识码:** A **国家标准学科分类代码:** 510.40

Spatial metric prototypical network for few-shot military target recognition

Lin Boran¹, Wang Hui², Ling Jun², Huang Yuxuan², Weng Lubin³, Lian Pengfei¹

(1. School of Integrated Circuits Science and Engineering, East China Normal University, Shanghai 200241, China;
2. Shanghai Institute of Astronautics Electronic Technology, Shanghai 201109, China;
3. Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: Few-shot military target recognition aims to achieve fast and accurate recognition of novel military targets with extremely limited labeled samples, and is of great significance in military remote sensing interpretation, battlefield situation awareness, and decision support. Metric learning-based methods perform recognition by constructing class prototypes and measuring the similarity between query samples and prototypes. Owing to their simple structure, flexible training, and strong transferability, these methods have become a mainstream approach in few-shot learning. However, most existing methods construct class prototypes by mean estimation, which is easily affected by background clutter, imaging noise, and outliers in remote sensing image, leading to prototype deviation. Moreover, equal weighting is usually assigned to all dimensions in the feature space, making it difficult to characterize their different contributions to classification. Consequently, when the feature distributions of different classes highly overlap, the discriminative ability of the model is constrained. To address these problems, a spatial metric prototypical network for few-shot military target recognition is proposed. First, a feature extractor is employed to map samples into the embedding space, and feature translation and normalization are introduced to enhance the robustness and stability of feature representations. Subsequently, a prototype enhancement module is designed to adaptively optimize class prototypes within a low-rank subspace. By enhancing the principal discriminative directions and suppressing redundant

收稿日期: 2026-01-08 Received Date: 2026-01-08

^{*} 基金项目: 国家自然科学基金项目(62541408)、抗辐射应用技术创新中心创新基金项目(KFZC2025020401)、上海科委关键技术研发计划“技术标准”项目(25DZ2200700)、上海市“科技创新行动计划”启明星项目(扬帆专项)(24YF2717600)资助

noise information, the proposed network alleviates the entanglement of low-dimensional discriminative features. Finally, a metric function is constructed by incorporating spatial projection error to achieve fine-grained recognition of query samples. Experimental results on the Ship, MAR20, and NWPU-RESISC45 datasets demonstrate that the proposed method improves the average recognition accuracy by 24.49%, 2.07%, and 4.03% under the 5-way 1-shot setting, and by 26.98%, 8.92%, and 5.43% under the 5-way 5-shot setting, respectively. The results demonstrate the effectiveness and generalization capability of the proposed network in complex remote sensing scenarios.

Keywords: military target recognition; metric learning; few-shot learning; class prototype; remote sensing image

0 引言

随着现代战场态势的快速演变,及时准确地识别新型军事目标对于战略决策和作战行动至关重要^[1-2]。然而,新型军事目标真实可用的标注样本稀缺,无法为现有的深度卷积网络训练过程中提供大规模数据集,即使采用迁移学习或参数微调策略,其性能提升仍然受到明显的限制^[3],小样本学习通过挖掘有限标注样本中的判别信息快速适配样本受限条件下的新类别任务,为解决上述问题提供了可行途径^[4-6]。近年来,基于度量学习的方法结构相对简单且具有良好泛化能力,逐渐成为小样本目标识别领域的研究热点之一^[7-8]。

这类方法旨在学习一个可迁移的相似性衡量标准有效缓解有限样本下的模型泛化性难题^[9-11],通常可以表述为一个通用的两阶段学习范式,特征提取器和度量分类器^[12]。特征提取器通常采用在 ImageNet 等大型基础数据集上预训练的深度卷积网络,度量分类器通过度量特征空间中未标记图像与样本图像间的距离预测类别标签。Snell 等^[13]提出的原型网络(prototypical network, ProtoNet)是该范式下最经典的方法,在特征空间中为每个类别构建代表性原型,通过迭代训练使同类样本靠近原型、异类样本远离原型,进而利用欧式距离度量原型与样本的远近作为分类依据,因此类别原型的表征能力直接决定了分类性能。

围绕如何构建更具判别性的类别原型,大致可以分为基于特征预处理的方法和基于原型结构优化的方法两类。基于特征预处理的方法通过调整样本特征的统计分布,抑制异常样本干扰,准确反映类内样本的共性特征。Xu 等^[14]利用变分自编码器将样本特征解耦为类间判别和类内变化两部分,将类内变化建模为各类别共享的高斯分布,通过重复采样生成多样化的类内特征;吴捷等^[7]通过离散小波变换将图像分解为不同频率子带,提取时域特征无法捕获的频谱信息,并结合无监督聚类挖掘样本间的内在结构,从多个维度丰富特征表示。然而,当前的方法主要从扩充类内特征多样性的角度出发,而对特征分布的统计稳定性关注较少,军事遥感图像中常见的背景杂波和成像噪声易产生离群样本^[15-16],基于这些样

本扩充的特征可能继承甚至放大偏差,后续处理仍采用均值和逐维方差估计时,这些异常特征会进一步拉偏类别原型影响目标识别准确性。基于原型结构优化的方法通过改进原型的生成方式或表示形式,使类别原型能够捕获更丰富的类内分布信息,增强对类间相似目标的区分能力。Zhang 等^[11]通过编码器将基于均值的类别原型和属性特征映射到低维特征中,聚合器对不同的属性特征进行重要性评估并通过加权和补全类别原型;Nguyen 等^[17]使用欧几里德距离平方根和范数距离的相异度测度迫使嵌入点被吸引到其正确的原型上,而排斥所有其他原型,使超平面球上保持所有点的范数相同。文献[18]表明二阶统计信息通常比一阶统计信息具有更强的泛化能力,高维约束扩展了类别原型的几何表达。但军事遥感图像复杂的特征分布未能区分不同方向对分类的贡献差异,难以精准刻画类别特征的低维流形结构,当类间特征在某些方向上高度重叠时难以有效分离。

针对上述问题,提出一种基于空间度量原型网络(subspace metric prototypical network, SM-ProtoNet)的小样本军事目标识别方法。从特征空间的几何结构入手,将类别原型扩展为能够代表样本分布方向的高维子空间,从而充分利用有限样本间的关联性以及提高类别特征的判别性表达。其核心思想是利用结合类别样本的统计特性与几何结构自适应地构建高维子空间,并采用方向加权和投影重构捕获类内主方向能量来补充类别空间原型的判别性信息,最后通过对比样本在不同类别的原型上的投影误差实现军事目标识别。

本文主要贡献包括:1)提出特征平移模块,采用中位数中心估计后进行全局尺度因子归一化,减少离群样本导致的类别原型偏移;2)提出原型增强模块,针对奇异值分解扩展的类别原型,使用奇异值加权聚焦主能量方向,在低维投影空间中筛选出判别性最强的方向进行重构,使不同类别在重叠方向上能够有效分离。

1 方法

提出了一种空间度量原型网络模型,该模型遵循两阶段的传统度量学习框架,如图1所示。特征提取器使用 ResNet18 网络结构将支持集样本映射到特征空间,度

量分类器度量查询集样本与原型的关系实现目标识别,主要包括特征平移模块、原型生成模块、原型增强模块和空间度量模块4个部分。特征平移模块基于中位数估计的特征平移和归一化提升类别特征的鲁棒性;原型生成

模块生成多种类别空间原型;原型增强模块通过建立低维特征子空间捕获类别空间主要变化方向生成类别增强空间原型;空间度量模块以投影误差为度量函数,评估样本在类别增强空间原型的重构质量。




图1 空间度量原型网络模型

Fig. 1 A subspace metric prototypical network model

1.1 特征提取器

特征提取器采用深度卷积神经网络,由于舰船、飞机等军事目标纹理细节差异大、尺寸差异大、同时背景也会给其信息带有一定的干扰,在自然场景的小样本上的自然情况下的传统浅层网络(比如 Conv4、ResNet12 等)的特征提取和特征空间信息提取效果都很弱,不易于将边缘、纹理等底层特征区分出来;稍微大的深层网络(如 ResNet34、VGG19 等)特征提取的时候也能提取得到较好的特征空间信息,但容易造成过拟合。相比之下,ResNet18 网络结构适中,多尺度残差网络连接可以捕捉更大的高层语义感受野,具有较高的深层特征参数共享,在小样本下可以具有一个相对稳定的结果。采用的 ResNet18 网络去掉最末层分类全连接层,保留入卷连接层、4 个残差模块组和 1 个全局平均池化层,每个残差模块组由 2 个 3×3 卷积的恒等映射组成。

1.2 度量分类器

1) 特征平移模块

在经过嵌入函数的特征提取后,支持集样本的每个类别都可以获得一组类别高维特征向量 $\mathbf{F}_i = [\mathbf{f}_{i,1}, \mathbf{f}_{i,2}, \dots, \mathbf{f}_{i,n_i}]^T$, $\mathbf{f}_{i,j} \in \mathbb{R}^{1 \times C}$, 其中, n_i 表示第 i 类样本的数量, j 表示第 j 个样本, C 表示特征图的通道数。军事目标的特征图往往呈现非高斯性与重尾特征,当类别样本数量 n_i 较小时,基于均值的中心估计容易受到极值样本的影响,从而使传统原型网络难以稳定反映类别的真实特征中心。

提出一种原型生成模块,以特征向量的特征通道 C

为索引对 n_i 个样本进行排序,并选取其中位数值,最终输出一个 C 维向量 $\mathbf{M}_i$, 该向量上的每个元素为对应特征通道上所有样本的中位数作为类别的中心估计量:

$$\mathbf{M}_i = \text{median}(\mathbf{F}_i) = \text{median}(\{\mathbf{f}_{i,1}(C), \mathbf{f}_{i,2}(C), \dots, \mathbf{f}_{i,n_i}(C)\}) \quad (1)$$

对第 i 类样本第 j 个特征向量 $\mathbf{f}_{i,j}$ 进行逐元素的中心化变换:

$$\tilde{\mathbf{f}}_{i,j} = \mathbf{f}_{i,j} - \mathbf{M}_i \quad (2)$$

中心化的类别特征向量 $\tilde{\mathbf{F}}_i = [\tilde{\mathbf{f}}_{i,1}, \tilde{\mathbf{f}}_{i,2}, \dots, \tilde{\mathbf{f}}_{i,n_i}]^T$, 特征归一化的过程中,原型网络直接的逐维估计方差会导致统计不稳定性与高维相关的结构损失,为获取稳定且具代表性的尺度度量,将 $\tilde{\mathbf{f}}_{i,j}$ 在特征空间中到原点的平均欧式距离的倒数 σ_i 作为全局尺度因子以反应类内所有特征的平均能量水平,设置特征尺寸约束后获得归一化的类别特征向量 $\hat{\mathbf{F}}_i$:

$$\sigma_i = \frac{1}{\sqrt{\frac{1}{n_i d} \sum_{p=1}^{n_i} \sum_{q=1}^d (\tilde{\mathbf{f}}_{i,j})^2}} \quad (3)$$

$$\hat{\mathbf{F}}_i = \max(1, \sigma_i) \tilde{\mathbf{F}}_i \quad (4)$$

特征平移模块作用于特征提取器输出的高维嵌入向量,通道数为特征提取器 ResNet18 输出的 512 维,特征平移模块不对特征维度进行改变,也不固定类别形态数量,特征平移模块的中心估计使用中位数对特征进行平移,再使用全局尺度因子做全局缩放,减轻部分异常样本对各类中心估计的扰动性并保证类别空间原型的稳定性。

2) 原型生成模块

对归一化的类别特征向量 $\hat{\mathbf{F}}_i$ 进行奇异值分解:

$$\hat{\mathbf{F}}_i = \mathbf{U}_i \mathbf{S}_i \mathbf{V}_i^T \quad (5)$$

其中, $\mathbf{U}_i$ 是表示样本方向正交基的左奇异矩阵, $\mathbf{S}_i$ 是表示不同方向重要性的奇异值矩阵, $\mathbf{V}_i$ 是表示特征空间方向的正交基的右奇异矩阵。取前 r 个左奇异向量作为对应的类别原型 $\mathbf{U}_i^{(r)}$ 。

对 N 个样本进行中心化后,样本矩阵的秩至多为 $N-1$, 超出该维度的方向主要由噪声或数值误差主导,因此保留前 $N-1$ 个主方向即可有效捕获类内主要变化。同时,奇异值分解中前 $N-1$ 个主方向对应的奇异值通常远大于剩余方向,因此截断维度在一定范围内波动对子空间的主方向影响有限。事实上,本文的方法对 r 的选择具有强鲁棒性,在 Ship 数据集和 MAR20 数据集上使用 ResNet18 骨干网络时,当 r 在 2 到 $N-1$ 范围内变化,5-way 5-shot 任务的平均识别准确率波动不超过 0.6%。

在特征空间中,传统的低维类别原型由一个均值点表示,只反应类别中心位置,如图 2(a) 所示。各类别空间原型被表示为一组正交基向量,在高维嵌入空间中实现类间的互相分离,在不同平面几何上形成各自的分布区域,如图 2(b) 所示。




图2 传统的低维类别原型与类别空间原型对比

Fig. 2 Comparison between conventional low-dimensional class prototype and class subspace prototype

原型生成模块使用奇异值分解并选取主成分方向,在特征空间中为不同类别构建相互正交的不同分布区域,这种从“点”到“面”的转变可以利用更多的特征信息来捕捉类内样本的分布结构。

3) 原型增强模块

特征空间中的类别决策边界处汇聚了高度相似度的样本,度量函数往往在这一区域内出现决策模糊,同样高维特征也带来了低维特征纠缠和脆弱的分类边界的问题,提出一种原型增强模块,通过方向加权投影实现类别空间中的原型自适应增强,具体如算法 1 所示。

算法 1: 原型增强模块

输入: 类别空间原型 $\mathbf{U}_i^{(r)}$; 奇异值 $s_{i,k}$; 类别 i 的右奇异矩阵前 r 个特征向量 $\mathbf{V}_i^{(r)} \mathbf{V}_i^{(r)T}$; 归一化类别特征向量 $\hat{\mathbf{F}}_i$
 输出: 类别增强空间原型 $\mathbf{P}_i$

- 1 初始化: $\mathbf{P}_i \leftarrow \Phi$;
- 2 for $i = 1$ to n_i do
- 3 //步骤 1: 通过 Softmax 归一化计算注意力权重
- 4 for $K = 1$ to r do
- 5 $w_{i,k} = e^{s_{i,k}} / \sum_j e^{s_{i,j}}$
- 6 end for
- 7 //步骤 2: 加权重构类别原型子空间 $\tilde{\mathbf{U}}^{(r)}$
- 8 $\{w_{i,k}\} \leftarrow \text{diag}(w_{i,k}^{(1)}, w_{i,k}^{(2)}, \dots, w_{i,k}^{(r)})$
- 9 $\tilde{\mathbf{U}}^{(r)}_i = \mathbf{U}_i^{(r)} \{w_{i,k}\}$
- 10 //步骤 3: 将类别协方差矩阵投影到类别原型子空间 $\tilde{\mathbf{U}}^{(r)}$
- 11 $\mathbf{c}_i = \hat{\mathbf{F}}_i^T \mathbf{V}_i^{(r)} \mathbf{V}_i^{(r)T} \hat{\mathbf{F}}_i$
- 12 $\tilde{\mathbf{c}}_i = \tilde{\mathbf{U}}^{(r)}_i^T \mathbf{c}_i \tilde{\mathbf{U}}^{(r)}_i$
- 13 //步骤 4: 特征值分解并按照降序排列
- 14 $\tilde{\mathbf{c}}_i \mathbf{E}_i = \mathbf{E}_i \mathbf{\Lambda}_i$ // 求解特征方程
- 15 for $K = 1$ to r do
- 16 $\lambda_{i,k} \leftarrow \mathbf{\Lambda}_i[k, k]$ // 提取第 k 个特征值
- 17 $\mathbf{e}_{i,k} \leftarrow \mathbf{E}_i[:, k]$ // 第 k 个特征向量
- 18 end for
- 19 //步骤 5: 按照特征值降序排列
- 20 $\lambda_{i,k}, \mathbf{e}_{i,k=1}^r \leftarrow \text{sort}(\mathbf{\Lambda}_i, \mathbf{E}_i, \text{descending})$
- 21 //步骤 6: 选取前 K 个判别性方向组成方向矩阵 $\mathbf{Q}_i^{(K)}$
- 22 if $K \leq r$ then
- 23 $\mathbf{Q}_i^{(K)} \leftarrow [\hat{\mathbf{e}}_{i,1}, \hat{\mathbf{e}}_{i,2}, \dots, \hat{\mathbf{e}}_{i,K}]$
- 24 else
- 25 $\mathbf{Q}_i^{(K)} \leftarrow [\hat{\mathbf{e}}_{i,1}, \hat{\mathbf{e}}_{i,2}, \dots, \hat{\mathbf{e}}_{i,r}]$
- 26 end if
- 27 //步骤 7: 计算增强空间原型
- 28 $\mathbf{P}_i = \tilde{\mathbf{U}}^{(r)}_i \mathbf{Q}_i^{(K)}$
- 29 return $\mathbf{P}_i$

奇异值反映每个方向在总体样本中方差所占比重大小,使用 Softmax 函数来对奇异值 $s_{i,k}$ 进行归一化获得该方向权重 $\{w_{i,k}\}$:

$$w_{i,k} = \frac{e^{s_{i,k}}}{\sum_j e^{s_{i,j}}} \quad (6)$$

利用各个方向的权重对类别空间原型 $U_i^{(r)}$ 进行加权获得类别原型子空间 $\tilde{U}_i^{(r)}$,通过对子空间进行各向调整,使原型在关键方向上得到突出,从而在类别空间原型中获得更具判别性的方向分布:

$$\tilde{U}_i^{(r)} = U_i^{(r)} \{w_{i,k}\} \quad (7)$$

在类别层面建立一种描述样本分布结构的类别协方差矩阵:

$$c_i = \hat{F}_i^T V_i^{(r)} V_i^{(r)T} \hat{F}_i \quad (8)$$

其中, $V_i^{(r)}$ 表示类别 i 的右奇异矩阵前 r 个特征向量, $V_i^{(r)} V_i^{(r)T}$ 为投影算子,能够捕获类内样本在主要能量方向上的空间聚集性。右奇异矩阵的列向量表示了类别样本在特征空间中比较显著的变化方向,在 $V_i^{(r)}$ 上对该列向量做限定和加权,从而使类别协方差矩阵能够更好地反映特征在主能量方向上的统计变化。将类别协方差矩阵 c_i 投影到类别原型子空间中得到类别投影协方差矩阵 $\tilde{c}_i$, 限制协方差计算的特征空间,在低维特征空间中观察样本的分布情况,增强类间区分性,缓解低维特征纠缠:

$$\tilde{c}_i = \tilde{U}_i^{(r)T} c_i \tilde{U}_i^{(r)} \quad (9)$$

为解析投影协方差在类别原型子空间中的能量分布,对类别投影协方差矩阵 $\tilde{c}_i$ 进行特征值分解,特征值越大表示该方向上类别特征分布中所占能量越高,并选择前 K 个特征向量组成方向矩阵 $Q_i^{(K)}$ 作为类别 i 低维特征的主要方向。

类别投影协方差矩阵 $\tilde{c}_i$ 的维度为 $r \times r$,对其特征值分解后得到的全部 r 个特征向量构成了该子空间内的一组完备正交基,完整刻画了类别特征的能量分布结构,若 $K < r$,则会丢失部分潜在判别信息;若 $K > r$,则超出的维度方向无定义。因此,选择 $K = r$ 是基于子空间投影的数学性质,不依赖于特定数据集或任务,具有良好的普适性。同时,原型增强模块已通过奇异值加权对方向重要性进行重新标定,使得大奇异值对应的主方向被强化、小奇异值对应的噪声方向被抑制,因此保留全部 r 个特征向量不会引入额外噪声干扰,反而确保了信息的完整性。

最后,将方向矩阵 $Q_i^{(K)}$ 在类别空间原型 $\tilde{U}_i^{(r)}$ 中进行结构还原得到类别增强空间原型 P_i ,这种对类间模糊区域的进行空间非线性伸展,使原本在高维空间中重叠的部分类别特征被重新拉开距离:

$$P_i = \tilde{U}_i^{(r)} Q_i^{(K)} \quad (10)$$

军事目标中同一类别通常包含的多形态分布在特征

空间中往往表现为同一类别下的子簇或沿某些方向的连续变化,此类结构并非由离散的通道分别编码,而是通过原型增强模块的低秩子空间重构隐式建模,提取类内主变化方向,使类别空间原型能够覆盖样本的主要分布区域,从而容纳多种形态的共性特征。

原型增强模块在特征空间中对不同方向的类间区分能力自适应地分配不同的权重,使对于类间区分最有利的主要变化方向得以增强,而对于类间区分性较小的特征次要方向淡化。增强后的类别原型会有更高的判别力和鲁棒性。

4) 空间度量模块

对于类别增强空间原型,使用欧式距离和余弦相似度作为度量函数存在判别性和几何稳定性较差的问题,欧氏距离随着维度增加会出现集中效应,真实的类间结构差异难以体现,余弦相似度仅通过特征间的方向角度而无法准确描述真实几何度量关系。因此,提出了一种适用于高维度特征空间的度量函数。

特征分类器将查询集样本映射为一组原始查询特征 $Z_i = [z_{i,1}, z_{i,2}, \dots, z_{i,n_i}]^T, z_{i,j} \in \mathbb{R}^{1 \times C}$,再经过特征平移模块获取归一化查询特征向量 $\hat{Z}_i$,将其映射到各类别增强空间原型中获取几何一致性的坐标体系,获取查询投影特征 $\tilde{Z}_i^{\text{proj}}$:

$$\tilde{Z}_i^{\text{proj}} = P_i (P_i^T P_i)^{-1} P_i^T \hat{Z}_i \quad (11)$$

查询投影特征是样本在类内主方向上相关性的表征,同时压制了次要扰动维度上的能量分布,因而具有较好的噪声鲁棒性和结构聚合性,但此时的特征只反映了类结构的相对方向信息,在原特征域中缺乏全局性几何关系,需要对其进行查询投影特征逆变换映射回原空间:

$$\bar{Z}_i = \frac{\tilde{Z}_i^{\text{proj}}}{\max(1, \sigma_i)} + M_i \quad (12)$$

为了评估查询样本与各种不同空间原型的几何一致性,采用基于原始查询特征 Z_i 和投影特征 $\tilde{Z}_i$ 的误差进行相似度测量:

$$A_i = -\|Z_i - \bar{Z}_i\|^2 = -\sqrt{\sum_k (z_{i,k} - \bar{z}_{i,k})^2} \quad (13)$$

其中, $z_{i,k}$ 为第 i 类第 k 维的原始查询特征, $\bar{z}_{i,k}$ 为第 i 类第 k 维的投影特征, A_i 为最终相似度得分,当 A_i 值较大时,查询集样本能被类别空间原型更好地重构。

5) 损失函数

基于元学习的训练方式,通过正交损失将不同的类别空间原型向正交靠拢,拉大类间的距离,相比直接在特征空间施加欧式距离约束,能更好地捕获高维特征的几何结构。对于任意两个不同类别 j 和 k ,首先,计算其类别空间原型 P_j 和 P_k 的内积矩阵描述类别 j 与 k 的子空间方向重叠程度,再对所有的类别空间原型内积平方和进

行累积得到正交损失:

$$L_{\text{disc}} = \sum_{j=1}^c \sum_{\substack{k=1 \\ k \neq j}}^c \| \boldsymbol{U}_j^T \boldsymbol{U}_k \|^2$$

(14)

2 实验验证

在两个军事目标相关的遥感图像数据集中评估了提出的空间度量原型网络,并在一个公开的遥感图像场景分类数据集中验证了该模型的泛化性。

2.1 数据集

1) 公开基准数据集

MAR20^[19]: MAR20 数据集由包含 20 个类别的 22 341 张飞机图像组成。主要是从 Google Earth 上美国、俄罗斯等国家的军用机场采集的高分辨率遥感图像数据,由于 MAR20 数据集主要面向目标识别,按标签的边界框裁剪出多尺度的飞机目标以便分类使用。

NWPU-RESISC45^[20]: NWPU-RESISC45 数据集包含 31 500 张图像,包含为 45 个场景类别,该数据集的图像分辨率为 0.20~30 m/pixel,每个类别包含 700 张光学图像,尺寸为 256 pixels×256 pixels,场景类别多,更适合作为补充数据集进行泛化性实验。

2) 自建数据集

Ship: 为了更贴近真实军事目标识别任务,自主构建了名为 Ship 的小样本舰船图像数据集,该数据集的图像均来自吉林一号高分辨率光学遥感卫星在轨真实拍摄的数据,图像经过筛选和裁剪后保存为 JPG 格式,共有 1 462 张图像,将其划分为 17 个目标类别,每个类别包含的样本数量如表 1 所示,大约 40 景亚米级图像,分辨率为 0.50~0.75 m/pixel,成像区域覆盖多个目标港口所在

位置,该数据集的舰船目标相似性高,存在港口和海面等背景干扰。

表 1 数据集中各类目标数量

Table 1 Number of samples for each target category in the dataset

类型/种	数量/艘
阿利·伯克号驱逐舰	255
货船	143
集装箱船	55
自由级濒海战斗舰	30
独立号航空母舰	83
刘易斯和克拉克级物资补给舰	62
刘易斯·B·普勒号	28
尼米兹号航空母舰	46
其他舰船	99
圣安东尼奥级船坞运输舰	100
先锋级联合高速船	35
潜艇	115
油船	64
提康德罗加级巡洋舰	154
黄蜂级两栖攻击舰	60
惠特贝岛级船坞登陆舰	114
朱姆沃尔特级驱逐舰	19

各数据集的训练集、验证集和测试集的划分如表 2 所示,其中 NWPU-RESISC45 数据集划分与文献[21]保持一致。

表 2 3 个数据集的详细划分

Table 2 Detailed divisions on three datasets

数据集	训练集	验证集	测试集
Ship	刘易斯和克拉克级物资补给舰;油船; 提康德罗加级巡洋舰;黄蜂级两栖攻击舰; 阿利·伯克号驱逐舰;集装箱船;独立号航空母舰	圣安东尼奥级船坞运输舰; 惠特贝岛级船坞登陆舰; 货船;其他舰船;潜艇	阿利·伯克号驱逐舰; 刘易斯·B·普勒号; 尼米兹号航空母舰; 先锋级联合高速船; 朱姆沃尔特级驱逐舰
MAR20 ^[19]	SU-35 战斗机;C-5 运输机;B-52 轰炸机; E-8 战场联合监视机;TU-22 轰炸机; KC-135 空中加油机;KC-10 空中加油机; SU-24 战斗轰炸机;P-3C 反潜机;F-15 战斗机	FA-18 战斗机;TU-95 轰炸机; SU-34 战斗轰炸机; C-130 运输机;TU-160 轰炸机	E-3 预警机;B-1B 轰炸机; F-22 战斗机;F-16 战斗机; C-17 运输机
NWPU-RESISC45 ^[20]	飞机;棒球场;海滩;灌木林;教堂;云;沙漠; 高速公路;高尔夫球场;港口;岛屿;湖泊;草地; 移动房屋公园;山;宫殿;铁路;矩形农田;环岛; 海冰;船舶;稀疏住宅区;体育场;湿地	火车站;跑道;雪山;储水罐; 网球场;露台;火力发电厂; 商业区;工业区;立交桥	机场;篮球场;圆形农田; 密集住宅区;森林;河流; 田径场;中密度住宅区; 交叉口;停车场

2.2 实验参数设置

实验采用 pytorch 框架编写训练模型,训练设备为 NVIDIA RTX 4070 Ti GPU。采用标准的元学习范式,由于测试集的图像数量不同,Ship 数据集采用 5-way 5-shot 10-query 和 5-way 1-shot 10-query 的任务配置,MAR20 数据集和 NWPU-RESISC45 数据集采用 5-way 5-shot 15-query 和 5-way 1-shot 15-query 的任务配置对模型进行训练和评估,所有遥感图像均调整尺寸至 84 pixels×84 pixels,采用 SDG 优化器训练模型,初始学习率设为 1×10^{-4} 。

2.3 对比实验

采用识别准确率(所有正确预测图像数量与图像总数之比)作为实验评估指标,将测试集中的样本随机生成 600 个 K -way N -shot 的 Episodes,并计算平均识别准确率。选择多种基于度量的方法在 Ship 数据集和 MAR20 数据集上与方法进行结果进行对比,包括 ProtoNet^[13]、匹配网络^[22](matching networks, MatchingNet)、关系网络^[23](relation network, RelationNet)、关系嵌入网络^[24](relational embedding network, RENet)、深度子空间网络^[25](deep subspace networks, DSN)、自监督学习原型网络^[26](self-supervised learning prototypical networks, SSL-ProtoNet),其中,ProtoNet 利用类别原型与查询样本的欧氏距离进行分类;MatchingNet 使用注意力机制,用加权的方式计算出每个支持样本与查询样本的相似度;RelationNet 用可学习的神经网络替代固定距离度量;RENet 使用自相关和交叉相关模块捕捉样本间的结构关系;DSN 通过查询样本到高维的类别原型的距离进行度量;SSL-ProtoNet 则在 ProtoNet 基础上引入了自监督学习任务增强特征表示。

如表 3 所示,SM-ProtoNet 在 5-way 5-shot 和 5-way 1-shot 的任务配置下分别在 Ship 数据集上得到 88.09% 和 69.41% 的平均识别准确率,相比于准确率最高的模型分别提升了 26.98% 和 24.49%。

表 3 Ship 数据集的小样本识别结果

Table 3 Few-shot recognition accuracies on the Ship dataset			
方法	主干网络	准确率/%	
		5-way 5-shot	5-way 1-shot
ProtoNet ^[13]	Resnet18	56.53	41.51
MatchingNet ^[22]	Resnet18	42.34	36.43
RelationNet ^[23]	Resnet12	50.64	39.89
RENet ^[24]	Resnet12	58.45	45.37
DSN ^[25]	Resnet12	64.32	52.41
SSL-ProtoNet ^[26]	Resnet18	55.23	45.51
SM-ProtoNet	Resnet18	88.09	69.41

如表 4 所示,SM-ProtoNet 在 5-way 5-shot 和 5-way 1shot 的任务配置下分别在 MAR20 数据集上得到 94.03% 和 81.15% 的平均识别准确率,相比于准确率最高的模型分别提升了 2.70% 和 8.92%。

表 4 MAR20 数据集的小样本识别结果

Table 4 Few-shot recognition accuracies on the MAR20 dataset			
方法	主干网络	准确率/%	
		5-way 5-shot	5-way 1-shot
ProtoNet ^[13]	Resnet18	84.81	67.97
MatchingNet ^[22]	Resnet18	73.75	54.06
RelationNet ^[23]	Resnet12	76.21	40.32
RENet ^[24]	Resnet12	91.49	71.73
DSN ^[25]	Resnet12	86.13	70.34
SSL-ProtoNet ^[26]	Resnet18	86.03	73.91
SM-ProtoNet	Resnet18	94.03	81.15

实验结果显示,SM-ProtoNet 在两个数据集上结果的平均识别准确率高于现有方法,很好地证明了类别增强空间原型能体现了更加丰富的类内信息,并通过协方差分析获得了更具判别性的方向,并且由于 ProtoNet 和 MatchingNet 仅考虑单一均值原型,SM-ProtoNet 能够获得更有效的类别特征信息;与 RelationNet 和 RENet 的隐式学习方法相比,SM-ProtoNet 的分类边界更加清晰;与同样使用高维原型的 DSN 相比,SM-ProtoNet 对高维原型进行了更有效的二次特征选择;SSL-ProtoNet 使用了一种两阶段训练方式,同时 SM-ProtoNet 采用了一阶段的端到端训练,比 SSL-ProtoNet 这种两阶段的训练方式具有更小的误差积累,训练过程更快、更有效。

为了更好地观察 SM-ProtoNet 对所有类别的平均识别准确率,图 3(a)和(b)分别给出了 SM-ProtoNet 在 Ship 数据集上 5-way 5-shot、5-way 1-shot 两个任务测试结果的混淆矩阵形式,图 3(c)和(d)分别给出了 SM-ProtoNet 在 MAR20 数据集上 5-way 5-shot、5-way 1-shot 两个任务测试结果的混淆矩阵形式,其中,混淆矩阵中的每一个元素所在行号第 i 列号第 j 个元素表示来自第 i 类的测试样本被归类至第 j 类的比例。在每个混淆矩阵中,对任意的正确类别的一类样例来说被错估计为其他类别的概率分布相对平均,这说明 SM-ProtoNet 能够较好地划分类间边界。

对 SM-ProtoNet 在 ship 数据集上测试的结果进行了 t-SNE 可视化分析,并与基准方法 ProtoNet 进行了对

比,如图 4 所示。图 4(a)展示了 ProtoNet 获取的同类别样本特征在特征空间中分布散乱,没有明显的类间分界。然而从图 4(b)可以看到,SM-ProtoNet 对应的结果中同类别的特征更加聚合,特征学习和判别能力明显优于 ProtoNet,证明了其在小样本军事目标识别上的有效性。


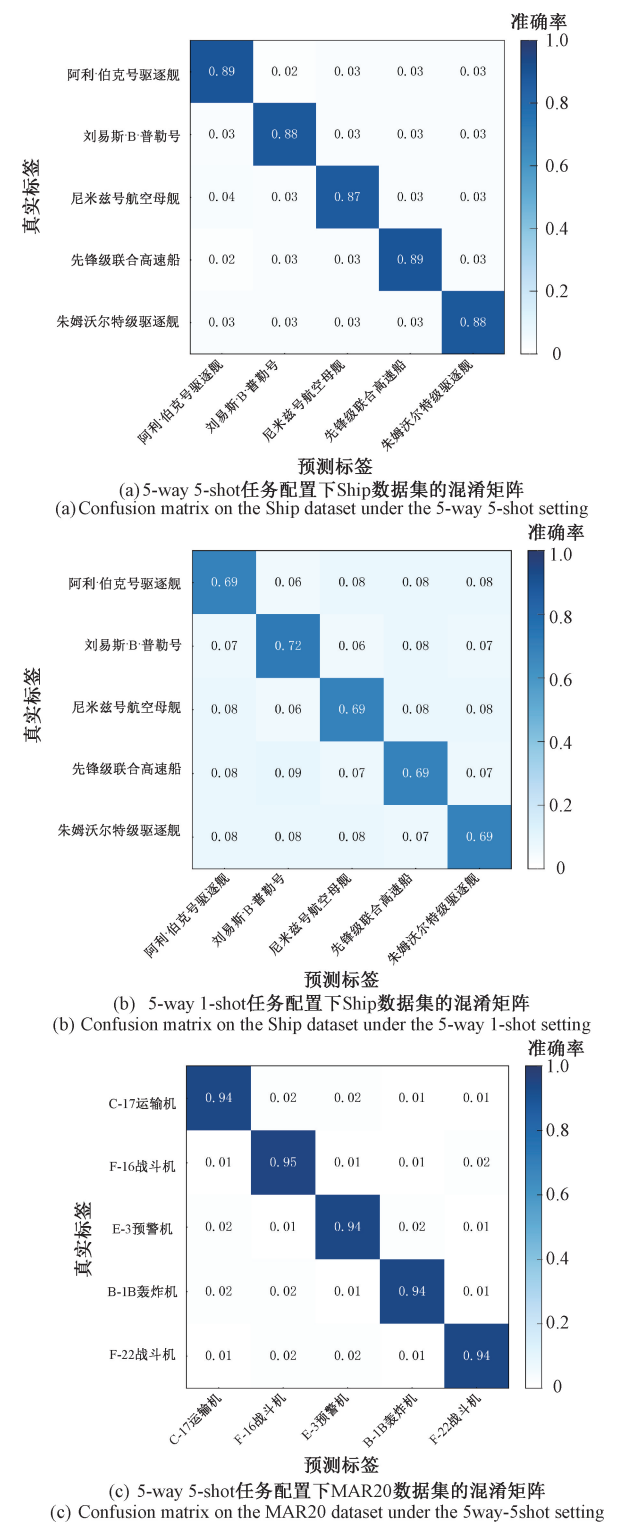


图 3 在 Ship 数据集和 MAR20 数据集上测试的混淆矩阵结果

Fig. 3 Confusion matrix results on the Ship and MAR20 datasets




图 4 两种方法的 t-SNE 可视化结果对比

Fig. 4 Comparison of t-SNE visualization results between two methods

2.4 消融实验

1) 模块的有效性

为了进一步研究模型对军事目标分类性能的影响,在 Ship 数据集上进行了模型框架的消融实验。如表 5 所示,基础网络不包含特征平移模块和原型增强模块,第 2 和第 3 行表示将基础网络与特征平移模块和原型增强模块相结合的实验结果;第 4 行表示同时使用特征平移模块和原型增强模块的 SM-ProtoNet 的实验结果。与基础网络相比,在 5-way 1-shot 和 5-way 5-shot 两种任务配置下,只使用特征平移模块或原型增强模块的识别率均进行了不同程度的提升,且在同时使用两个模块的情况下均表现出了最好的性能。在 5-way 5-shot 的任务配置下,只使用特征平移模块带来的识别率提升比只使用原型增强模块高出 0.54%,说明特征平移模块能够对齐不同样本的特征分布,增强原型生成的鲁棒性;在 5-way 1-shot 的任务配置下,只使用原型增强模块带来的识别率提升比只使用特征平移模块高出 0.51%,说明原型增强模块能够在样本稀疏的情况下获取到更有代表性的类别空间原型。实验结果说明了原型增强模块和特征平移模块的有效性,两个模块可以互补提升小样本军事目标识别的准确率。

表 5 模块有效性验证结果

Table 5 Results of module effectiveness validation			
特征平移模块	原型增强模块	准确率/%	
		5-way 5-shot	5-way 1-shot
×	×	84.81	67.97
√	×	87.06	67.88
×	√	86.52	68.39
√	√	88.09	69.41

2) 原型增强信息的选取方式

为了验证原型增强模块中所使用的奇异值和右奇异矩阵作为补充信息对类别空间原型的影响,在 Ship 数据集上进行了消融实验,实验结果如表 6 所示。

表 6 原型增强信息选取验证结果

Table 6 Validation results of prototype enhancement information selection				
左奇异矩阵	奇异值	右奇异矩阵	准确率/%	
			5-way 5-shot	5-way 1-shot
×	×	×	84.81	67.97
√	√	×	88.09	67.89
√	×	√	87.24	68.68
√	√	√	88.09	69.41

考虑以下场景:

(1) 左奇异矩阵:不使用原型加强模块,将左奇异矩阵直接作为类别空间原型;

(2) 左奇异矩阵+奇异值:跳过右奇异矩阵,采用 $c_i = \hat{F}_i^T \hat{F}_i$ 直接构建标准的类别协方差矩阵;

(3) 左奇异矩阵+右奇异矩阵:不使用奇异值加权获取类别原型子空间;

(4) 左奇异矩阵+奇异值+右奇异矩阵:即使用的原型增强模块。

“左奇异矩阵+奇异值+右奇异矩阵”相比于“左奇异矩阵+奇异值”,5-way 5-shot 的任务配置下差别不大,相比于“左奇异矩阵+右奇异矩阵”提高了 0.85%,说明当样本个数较多时模型的性能趋于饱和。“左奇异矩阵+奇异值+右奇异矩阵”相比于“左奇异矩阵+奇异值”,在 5-way 1-shot 的任务配置下提高了 1.52%,相比于“左奇异矩阵+右奇异矩阵”提高了 1.06%,说明完整的奇异三分量建模样本稀疏时对类别空间原型表示的有效改善。

2.5 泛化性实验

为了验证模型的泛化性,采用 NWPU-RESISC45 数据集与多种小样本学习方法进行实验比较,包括 ProtoNet、孪生原型网络^[27] (Siamese-prototype network, SPNet)、自适应判别学习的匹配网络^[21] (discriminative learning of adaptive match network, DLA-MatchNet)、多前置任务原型引导的动态对比学习网络^[28] (multipretext-task prototypes guided dynamic contrastive learning network, MPCL-Net)、直推式小样本学习框架 (TransDuctive few-shot learning framework, TDNet)^[29]、面向文本感知的少样本遥感图像场景分类框架^[30] (text-aware framework for few-shot remote sensing image scene classification, TeAW),除基准网络 ProtoNet 外均为近年来专用于遥感图像分类的方法,结果如表 7 所示,可以看到,在 5-way 5-shot 和 5-way 1-shot 的任务配置下,SM-ProtoNet 取得了 89.16% 和 74.26% 的最高的准确率,比第 2 名 TeAW 高出 4.03% 和 5.43%。

表 7 NWPU-RESISC45 数据集的小样本识别结果

Table 7 Few-shot recognition accuracies on the NWPU-RESISC45 dataset			
方法	年份	准确率/%	
		5-way 5-shot	5-way 1-shot
ProtoNet ^[13]	NeurIPS-2017	69.55	40.35
SPNet ^[27]	TGRS-2021	83.94	67.84
DLA-MatchNet ^[21]	TGRS-2021	81.63	68.80
MPCL-Net ^[28]	TGRS-2023	76.24	55.94
TDNet ^[29]	TGRS-2023	86.13	70.34
TeAW ^[30]	ICASSP 2023	85.57	70.23
SM-ProtoNet	本文	89.16	74.26

利用 SM-ProtoNet 在 NWPU-RESISC45 数据集的测试结果绘制混淆矩阵,如图 5 所示。混淆矩阵仅对角线上出现较深的颜色,说明类别间的混淆程度较小,SM-ProtoNet 能够对小样本遥感图像识别具有较强的泛化能力。

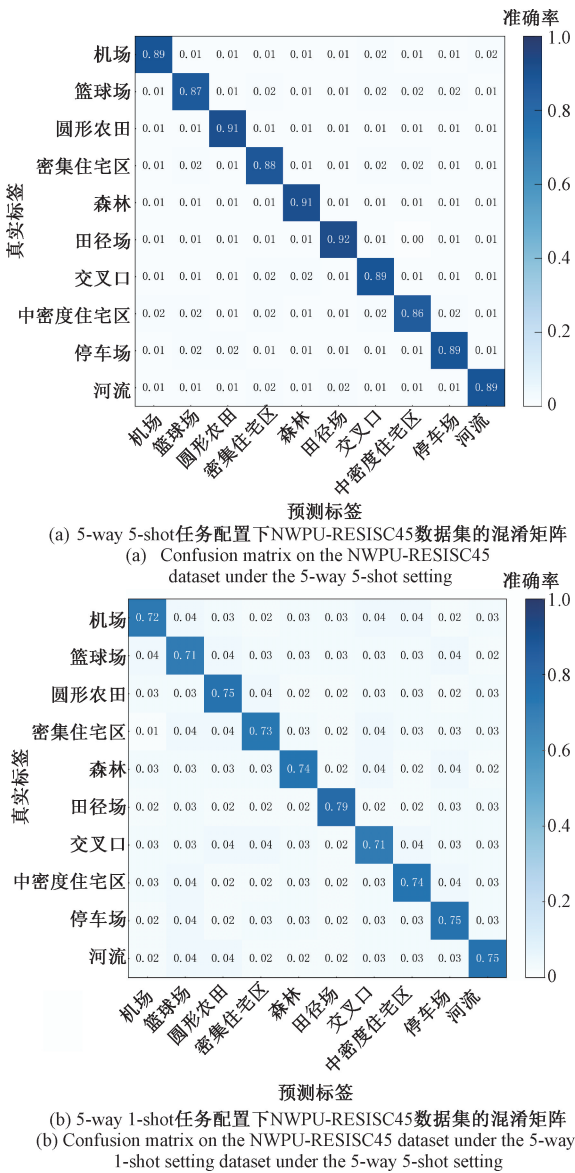


图 5 在 NWPU-RESISC45 数据集上测试的混淆矩阵结果

Fig. 5 Confusion matrix results on the NWPU-RESISC45 dataset

实验结果显示,SM-ProtoNet 在各种数据集的提升幅度比较随机,Ship 数据集种的舰船目标背景杂波强、类间相似性高,特征空间中类间重叠比较大,现有方法在该任务上准确率很低,使用类别增强空间原型能够更有效地估计出类内主要方向,平均准确率提升幅度高,同时由于每类目标所对应的图像数量少,不同的任务配置的平均

准确率提升差异不会太大。MAR20 数据集上的飞机目标经过人工裁剪,目标位置均居中且背景干净,同一类型所对应的图像数量多,现有方法在多样本 5-way 5-shot 的任务配置上性能就比较饱和,提升幅度小,然而在 5-way 1-shot 的任务配置下,SM-ProtoNet 能够构建更具代表性的类别原型,从而获得更高的准确率提升。WPU-RESISC45 数据集识别难度主要来自类别内变化丰富和类间的边界模糊,导致即使是 5-way 5-shot 配置下仍然无法完全覆盖类内全部变化,相比现有方法,SM-ProtoNet 能够生成高维的类别增强空间原型挖掘类内深层次共性特征,因此两种配置下识别准确率的提升幅度相近。

3 结 论

本文提出了一种基于空间度量原型网络的小样本军事目标识别方法,特征提取器采用 Resnet18 进行特征提取,特征平移模块通过聚合类别特征分布来削弱极端样本的影响,原型生成模块通过奇异值分解生成类别空间原型,并通过原型增强模块在低维空间重塑特征补充原型信息,空间度量模块利用几何投影误差预测标签。将提出的方法在小样本数据集 Ship、MAR20 和 NWPU-RESISC45 上进行了测试,测试结果取得了最优表现,验证了所提方法在小样本军事目标分类上的有效性和泛化性。

参考文献

[1] SUN Y, WANG J ZH, YOU Y, et al. YOLO-E: A lightweight object detection algorithm for military targets[J]. Signal, Image and Video Processing, 2025, 19(3): 241.

[2] 杨瑞君, 张浩, 叶璟. 改进 YOLOv8n 的轻量级遥感图像军用飞机检测算法[J]. 电子测量技术, 2025, 48(1): 154-165.

YANG R J, ZHANG H, YE J. Improved light weight military aircraft detection algorithm for remote sensing images with YOLOv8n [J]. Electronic Measurement Technology, 2025, 48(1): 154-165.

[3] ZHANG F H, SHI Y L, XIONG ZH T, et al. Few-shot object detection in remote sensing: Lifting the curse of incompletely annotated novel objects [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1-14.

[4] 熊鹏文, 胡慕烨, 黄雨轩, 等. 面向小样本纹理分类的多模态证据融合框架[J]. 仪器仪表学报, 2025, 46(6): 154-165.

XIONG P W, HU M Y, HUANG Y X, et al. Small-sample multi-modal evidence fusion framework for texture classification [J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 154-165.

- [5] 仲林林, 吴奇, 叶俊杰, 等. 基于元学习的变电设备小样本缺陷图像检测[J]. 仪器仪表学报, 2024, 45(10): 154-167.
- ZHONG L L, WU Q, YE J J, et al. Meta-learning-based few-shot image detection of defects in substation equipment[J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 154-167.
- [6] 陈望, 李志玲, 王前, 等. 基于原型嵌入图网络的小样本图像分类[J]. 电子测量技术, 2024, 47(5): 133-141.
- CHEN W, LI ZH L, WANG Q, et al. Few-shot image classification based on prototype embedding graph network[J]. Electronic Measurement Technology, 2024, 47(5): 133-141.
- [7] 吴婕, 张海翔. 基于特征增强的小样本图像分类算法研究[J]. 智能计算机与应用, 2024, 14(7): 37-42.
- WU J, ZHANG H X. Feature enhancement based algorithm for few-shot image classification[J]. Intelligent Computer and Applications, 2024, 14(7): 37-42.
- [8] 韩延, 李超, 黄庆卿, 等. 小样本下时序注意力边界增强原型网络的齿轮箱故障诊断方法[J]. 电子测量与仪器学报, 2023, 37(2): 90-98.
- HAN Y, LI CH, HUANG Q Q, et al. Boundary-enhanced prototype network with time-series attention for gearbox fault diagnosis under limited samples [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 90-98.
- [9] 唐东林, 刘铭璇, 何媛媛, 等. 基于融合度量策略的小样本金属缺陷识别研究[J]. 电子测量技术, 2023, 46(4): 107-113.
- TANG D L, LIU M X, HE Y Y, et al. Research on few-shot learning of metal defect recognition based on fusion distribution metric strategy[J]. Electronic Measurement Technology, 2023, 46(4): 107-113.
- [10] 黄友文, 胡燕芳, 魏国庆. 结合原型校准分布的小样本学习方法[J]. 电子测量技术, 2022, 45(5): 132-139.
- HUANG Y W, HU Y F, WEI G Q. Prototype-based calibration distribution for few-shot learning [J]. Electronic Measurement Technology, 2022, 45(5): 132-139.
- [11] ZHANG B Q, LI X T, YE Y M, et al. Prototype completion for few-shot learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(10): 12250-12268.
- [12] SONG Y SH, WANG T, CAI P Y, et al. A comprehensive survey of few-shot learning: Evolution, applications, challenges, and opportunities [J]. ACM Computing Surveys, 2023, 55(13s): 1-40.
- [13] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning [C]. 31st International Conference on Neural Information Processing Systems, 2017: 4080-4090.
- [14] XU J Y, LE H, HUANG M ZH, et al. Variational feature disentangling for fine-grained few-shot classification [C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 8792-8801.
- [15] OUYANG Y, WANG X Q, HU R ZH, et al. Military vehicle object detection based on hierarchical feature representation and refined localization[J]. IEEE Access, 2022, 10: 99897-99908.
- [16] SINGH S, RATNA G N. Military based object detection in satellite imagery by optimising YOLOv8 [C]. 2024 IEEE Space, Aerospace and Defence Conference, 2024: 165-168.
- [17] NGUYEN V N, LØKSE S, WICKSTRØM K. SEN: A novel feature normalization dissimilarity measure for prototypical few-shot learning networks [C]. European Conference on Computer Vision, 2020: 118-134.
- [18] XIE J T, LONG F, LYU J M, et al. Joint distribution matters: Deep Brownian distance covariance for few-shot classification [C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 7962-7971.
- [19] 禹文奇, 程堃, 王美君, 等. MAR20: 遥感图像军用飞机目标识别数据集[J]. 遥感学报, 2023, 27(12): 2688-2696.
- YU W Q, CHENG G, WANG M J, et al. MAR20: A benchmark for military aircraft recognition in remote sensing images [J]. National Remote Sensing Bulletin, 2023, 27(12): 2688-2696.
- [20] CHENG G, HAN J W, LU X Q, et al. Remote sensing image scene classification: Benchmark and state of the art[J]. Proceedings of the IEEE, 2017, 105(10): 1865-1883.
- [21] LI L J, HAN J W, YAO X W, et al. DLA-MatchNet for few-shot remote sensing image scene classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(9): 7844-7853.
- [22] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning [C]. 30th International Conference on Neural Information Processing Systems, 2016, 29: 3637-3645.
- [23] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for fewshot learning [C]. 2018 IEEE/CVF Conference on Computer Vision and

- Pattern Recognition, 2018; 1199-1208.
- [24] KANG D, KWON H, MIN J, et al. Relational embedding for few-shot classification [C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021; 8802-8813.
- [25] SIMON C, KONIUSZ P, NOCK R, et al. Adaptive subspaces for few-shot learning [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020; 4135-4144.
- [26] LIM J Y, LIM K M, LEE C P, et al. SSL-ProtoNet: Self-supervised learning prototypical networks for few-shot learning [J]. Expert Systems with Applications, 2024, 238; 122173.
- [27] CHENG G, CAI L M, LANG CH B, et al. SPNet: Siamese-prototype network for few-shot remote sensing image scene classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60; 1-11.
- [28] MA J J, LIN W Q, TANG X, et al. Multipretext-task prototypes guided dynamic contrastive learning network for few-shot remote sensing scene classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61; 1-16.
- [29] WANG B, WANG ZH R, SUN X, et al. TDNet: A novel transductive learning framework with conditional metric embedding for few-shot remote sensing image scene classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16; 4591-4606.
- [30] CHEN K H, YANG CH L, FAN Z L, et al. TeAw: Text-aware few-shot remote sensing image scene classification [C]. 2023 IEEE International Conference on Acoustics, Speech and Signal Processing, 2023, 6296-6300.

作者简介



林渤然, 2022 年于合肥工业大学获得学士学位, 现为华东师范大学集成电路科学与工程学院硕士研究生, 主要研究方向为小样本学习和遥感图像处理。

E-mail: branlin@163.com

Lin Boran received his B.Sc. degree from Hefei University of Technology in 2022. He is currently a master's student in the School of Integrated Circuits Science and Engineering at East China Normal University. His main research

interests include few-shot learning remote sensing image processing.



王辉, 2015 年于湖南工业大学获得学士学位, 2018 年于安徽大学获得硕士学位, 2023 年于东南大学获得博士学位, 现为上海航天电子技术研究所工程师, 主要研究方向为智能计算、图像处理和故障诊断。

E-mail: wanghuihu@126.com

Hui Wang received his B.Sc. degree from Hunan University of Technology in 2015, his M.Sc. degree from Anhui University in 2018, and his Ph.D. degree from Southeast University in 2023. He is currently an engineer at the Shanghai Aerospace Electronic Technology Institute, China. His main research interests include intelligent computing, image processing and fault diagnosis.



翁璐斌, 2008 年于中国科学院自动化研究所获得博士学位, 现为中国科学院自动化研究所高级工程师, 硕士生导师, 主要研究方向为计算机视觉、目标检测识别、多源信息融合等。

E-mail: lubin.weng@ia.ac.cn

Weng Lubin received his Ph.D. degree from the Institute of Automation, Chinese Academy of Sciences in 2008. He is currently a senior engineer and master's supervisor at the Institute of Automation, Chinese Academy of Sciences. His main research interests include computer vision, object detection and recognition, multi-source information fusion, etc.



廉鹏飞 (通信作者), 2017 年于中国科学技术大学获得博士学位, 中国人民解放军国防科技大学博士后, 现为华东师范大学集成电路科学与工程学院研究员、博士生导师, 主要研究方向为航天集成电路与系统、卫星系统研制及数字化研究等。

E-mail: lianpf@mail.ustc.edu.cn

Lian Pengfei (Corresponding author) received his Ph.D. degree from the University of Science and Technology of China in 2017, and then worked as a postdoctoral fellow at the National University of Defense Technology. He is currently a professor and Ph.D. supervisor in the School of Integrated Circuits Science and Engineering at East China Normal University. His main research interests include aerospace integrated circuits and systems, satellite system development, and digitalization research.