DOI:10.11918/202412034

# 元数据增强驱动的多功能雷达及工作模式识别方法

普运伟[1,2],戴子瑜[1],杜 林[1],赵辉杰[1],李文康[1]

(1.昆明理工大学 信息工程与自动化学院,昆明 650500;2.昆明理工大学 图书馆,昆明 650500)

**摘 要:** 为解决复杂电磁环境中多功能雷达(multifunction radar,MFR)截获信号样本稀缺、增强数据质量不佳及识别性能受限等问题,提出一种基于元数据增强生成对抗网络(meta-data augmentation generative adversarial network,MetaDAGAN)模型的多功能雷达及工作模式识别方法。该模型通过生成对抗网络对小样本信号进行高质量增强,提升训练样本的多样性与代表性;引入具备结构共享的元学习判别器,实现不同雷达辐射源信号间的特征迁移与判别边界的自适应建模;构建多任务联合学习框架,融合特定雷达辐射源识别与工作模式识别两项任务,实现对特定多功能雷达及其工作模式的同步识别,以提升特定多功能雷达及其工作模式的识别准确率。对比实验和消融实验结果表明:基于MetaDAGAN的特定MFR识别与工作模式识别准确率分别达到了98.50%和97.24%,整体优于对比模型;在完整配置模型中移除Transformer和样本增强模块后,工作模式识别准确率分别下降至72.64%和52.06%,体现出二者在特征建模与泛化能力提升中具有关键作用。所提方法在小样本条件下仍具备特征表达能力和多任务泛化性能,展现出良好的鲁棒性与工程适应性,具有广泛的应用前景。

**关键词:** 多功能雷达;模式识别;小样本;元数据增强生成对抗网络;注意力机制;模型无关元学习

**中图分类号:** TN974 **文献标志码:** A **文章编号:** 0367-6234(2026)09-0144-10

# MetaDAGAN-driven approach for multifunction radar and operating mode recognition

Pu Yunwei[1,2], Dai Ziyu[1], Du Lin[1], Zhao Huijie[1], Li Wenkang[1]

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Library, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** To solve the problems of scarce intercepted signal samples, poor quality of augmented data, and limited recognition performance of multifunction radar (MFR) systems in complex electromagnetic environments, this paper proposed a multifunction radar and operating mode recognition method based on a meta-data augmentation generative adversarial network (MetaDAGAN) model. The model performs high-quality augmentation of small-sample signals through a generative adversarial network, thereby improving the diversity and representativeness of the training samples; introduces a meta-learning discriminator with shared structure to enable feature transfer among signals from different radar emitters and adaptive modeling of decision boundaries; and constructs a multi-task joint learning framework to integrate specific radar emitter recognition and operating mode recognition, enabling the simultaneous recognition of specific MFRs and their operating modes, so as to improve the recognition accuracies for specific MFRs and their operating modes. Comparative and ablation experiments results show that, based on MetaDAGAN, the accuracies of specific MFR recognition and operating mode recognition respectively reached 98.50% and 97.24%, which were overall superior to those of the comparative models. After the Transformer module and the sample augmentation module were respectively removed from the complete-configuration model, the operating mode recognition accuracy decreased to 72.64% and 52.06%, respectively, revealing that both of them play key roles in feature modeling and generalization capability improvement. The proposed method still maintains feature representation capability and multi-task generalization performance under small-sample conditions, demonstrating good robustness, engineering adaptability, and broad application prospects.

**Keywords:** multifunction radar; pattern recognition; small-sample signals; meta-data augmentation generative adversarial network; attention mechanism; model-agnostic meta-learning

多功能雷达(multifunction radar,MFR)具备精准的目标定位、跟踪及多模态感知和信息整合能力,在现代电子战中扮演着至关重要的角色。准确识别MFR及其工作模式对于预测其功能和行为、保障友

**收稿日期:** 2024-12-11;**录用日期:** 2025-03-04;**网络首发日期:** 2025-11-11
**网络首发地址:** https://link.cnki.net/urlid/23.1235.t.20251111.1144.002
**基金项目:** 国家自然科学基金(61561028)
**作者简介:** 普运伟(1972—),男,教授,博士生导师
**通信作者:** 普运伟,puyunwei@126.com

方通信和作战计划的安全性至关重要。然而，传统的雷达信号识别方法如脉冲描述字[1]、特征参数匹配法[2]、脉内分析[3]和时频分析[4]等主要依赖经典参数，如到达时间、到达方向和载波频率等。虽然在常规环境下有效，但随着新型复杂体制雷达的普及，这些方法由于信号特征提取过程中的信号损失等问题，在复杂环境中的实用性大幅下降。

针对 MFR 工作模式识别问题，研究者提出了多种方法，涵盖从传统机器学习到深度生成网络的不同范式，如支持向量机（support vector machine，SVM）[5]、基于加权辅助分类生成对抗网络（weighted auxiliary classifier generative adversarial network，WACGAN）[6]、合成少数类过采样技术与卷积神经网络结合（synthetic minority over-sampling technique combined with convolutional neural network，SMOTE + CNN）方法生成样本以扩充数据集[7]、基于 $k$ 近邻（$k$-nearest neighbors，KNN）的目标识别方法及其改进形式[8]等。然而，这些方法在实际应用中存在局限性。如 WACGAN 和 SMOTE + CNN 在样本生成中依赖人工特征设计，难以全面捕捉关键信息；KNN 则对样本质量具有较强依赖性，限制了模型的泛化能力。

针对特定雷达辐射源识别问题，研究者同样提出了多种方法，覆盖从特征协作建模到深度学习的不同思路，如基于联合协作[9]、变分模态分解[10]、基于卷积神经网络[11]等。然而，这些方法不足以满足针对多功能雷达辐射源的多任务识别需求。因此，探索适用于小样本条件且能够降低对高质量样本依赖的特定 MFR 及其工作模式的多任务识别方法已成为亟待解决的问题。

综上所述，在复杂雷达信号识别任务中，特定 MFR 及其工作模式样本数量有限、质量参差不齐，导致传统深度学习模型在小样本条件下难以获得稳定的识别性能。针对此问题，本文提出一种基于元数据增强生成对抗网络（meta-data augmentation generative adversarial network，MetaDAGAN）模型的多功能雷达及工作模式识别方法。该方法结合元学习在小样本条件下的快速泛化与跨任务迁移能力，通过生成对抗机制实现自适应建模与高质量样本生成，并结合多任务联合优化策略增强模型对 MFR 信号分布的适应性与特征表达能力，以提升训练数据的多样性与判别能力，从而探索特定 MFR 及其工作模式识别的新思路。

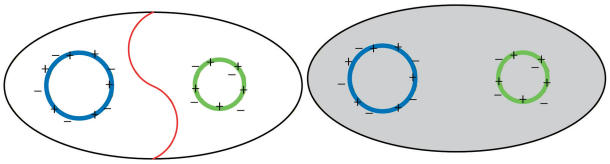
## 1　基于元学习的数据增强模型

在处理小样本问题时常采用生成对抗网络（generative adversarial network，GAN）[12]进行样本增强，生成更多训练样本，提升模型的泛化性能和识别准确率。进一步地，基于元学习的数据增强模型将元学习与生成对抗网络相结合，利用参数共享机制增强小样本建模能力，为 MFR 及其工作模式识别提供参考。

### 1.1　元生成对抗网络

在众多基于元学习的数据增强模型中，元生成对抗网络（meta-learning generative adversarial network，MetaGAN）[13]因能够有效处理小样本问题而受到关注。该模型沿用 GAN 模型的基本结构，其核心在于采用元学习方式更新生成器和判别器的参数，并构建一个 $K$-shot $N$-way 判别器，当遇到新的任务时，模型只需用 $K$ 个样本就能进行 $N+1$ 类别的分类。

MetaGAN 的核心在于利用生成器生成低质量的伪样本，为判别器提供额外的训练数据，并通过元学习的方法对模型进行优化。通过此策略，判别器能够获得更明确的决策边界，从而提升模型的识别准确率。MetaGAN 的训练过程如图 1 所示，其中红色曲线对应模型的判别边界，蓝色与绿色区域分别对应 A 类与 B 类样本分布，灰色区域表示假样本分布，“+”为真实样本，“-”为生成的假样本。MetaGAN 的判别器不仅需要区分 A（蓝色）、B（绿色）两类真实样本，还需要识别由生成器产生的假样本（灰色）。这些位于真实类别数据流形附近但略有偏离的生成样本，为判别器提供了额外的训练信号，从而促使模型学习更清晰、更尖锐的决策边界。



(a) 未引入MetaGAN时的决策边界　(b) 引入MetaGAN后的决策边界

**图 1　MetaGAN 训练过程**

Fig. 1　Illustration of the MetaGAN training process

MetaGAN 的生成器能够生成接近真实类别流形的数据，特别是在高密度区域有助于区分类别。结合少量真实数据，这些生成样本可帮助模型确定更准确的决策边界。然而，在复杂或高干扰环境中，常难以生成高质量样本，易出现模式崩溃或收敛不稳定的问题。

### 1.2　MetaDAGAN

基于 MetaGAN 改进的 MetaDAGAN 模型在继承原模型优势的基础上，进一步强化数据增强和识别能力。MetaDAGAN 由自注意力生成器、偏置生成器和判别器组成，其工作流程如图 2 所示。

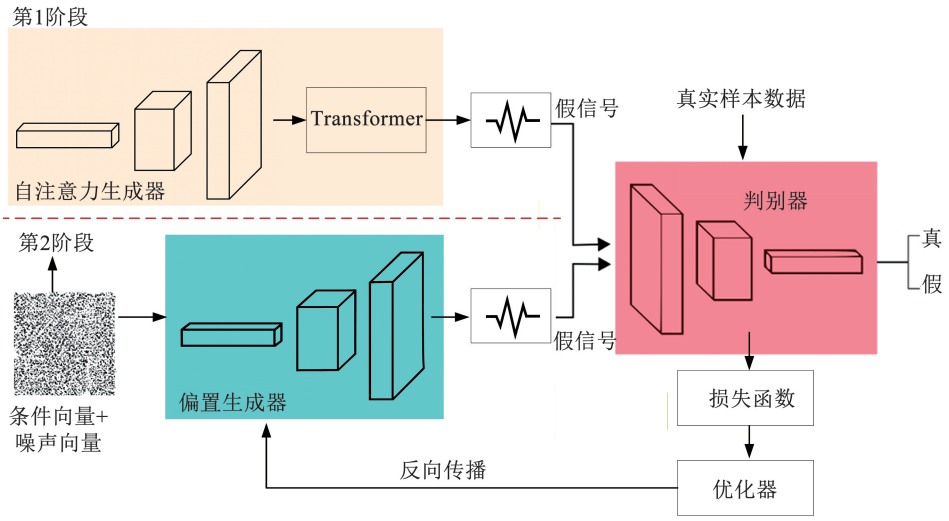



**图 2 MetaDAGAN 工作流程**

Fig. 2 Workflow of MetaDAGAN

MetaDAGAN 的工作流程分为两个阶段。第 1 阶段,模型调用自注意力生成器和判别器,通过内置的 Transformer 注意力机制增强序列建模及整合条件信息的能力,提高生成样本多样性,降低生成器的损失函数,实现高质量样本生成;第 2 阶段,模型调用偏置生成器和判别器,生成不同于真实数据的假数据,为判别器提供额外的训练数据,以促进决策边界的清晰化。判别器在第 2 阶段不仅进行真假判断,同时还输出样本的预测值以实现特定 MFR 和工作模式识别。通过此设计,模型可更好地利用生成器与判别器之间的交互关系,从而有望改善整体性能与泛化能力。

相较于 MetaGAN,改进后的 MetaDAGAN 在生成样本质量与小样本学习机制上进行结构性优化,以增强模型的生成稳定性与跨任务泛化能力,从理论上缓解 MetaGAN 在样本生成精度和小样本适应性方面的局限。

### 1.2.1 自注意力生成器

在第 1 阶段,针对 GAN 模型生成样本不可控、增强样本质量低以及模型不稳定等问题,引入 Transformer 模型[14]构建自注意力生成器,以实现在进行高质量数据增强的同时保持模型稳定,更好地保存 MFR 不同工作模式的特征,解决 MFR 工作模式样本不足的问题。

Transformer 模型对生成器损失函数的影响主要体现在其对生成器输出与目标之间差异度量方式的改进上。在引入 Transformer 模型的生成器中,损失函数的计算式为

$$L_{\mathrm{G}} = \frac{1}{N}\sum_{i=1}^{n}\left(G(\boldsymbol{z},\boldsymbol{c})_i - x_i\right)^2 \tag{1}$$

式中:$L_{\mathrm{G}}$ 为生成器损失函数,$N$ 为训练批次中的样本数量,$n$ 为单个样本的特征维度,$i$ 为当前样本的索引,$G(\boldsymbol{z},\boldsymbol{c})_i$ 为第 $i$ 个以输入噪声向量 $\boldsymbol{z}$ 和条件向量 $\boldsymbol{c}$ 生成的输出数据,$x_i$ 为第 $i$ 个真实样本。

与传统卷积生成结构不同,Transformer 通过自注意力机制对特征间的相关性进行显式建模,使损失优化过程能够更准确地表征全局依赖关系。依托该机制,Transformer 在特征序列中构建全局关联,使生成器能够同时捕获多位置间的语义联系,突破卷积模型的局部感受限制,从而提升上下文理解与长期依赖建模能力。同时,其编码-解码结构用于特征对齐与信息融合,在条件生成与多模态任务中承担特征交互与语义建模的功能。

在特征表示学习方面,Transformer 通过自注意力权重的动态调整实现多尺度特征融合与信息重分配,增强生成器在复杂纹理建模与语义结构表达中的能力。该全局建模机制通过在特征序列中建立全局关联关系,进一步完善细节一致性与语义连贯性的表达结构,同时在对抗训练过程中优化梯度传播路径,促进训练过程的稳定性与模型的有效收敛。

综上,将 Transformer 架构融入自注意力生成器设计中,预期可在特征学习、条件控制及训练优化等方面带来潜在优势,为生成样本的质量提升提供结构性支持。

### 1.2.2 偏置生成器

在第 2 阶段,模型利用偏置生成器生成相近于特定任务的假数据。该阶段旨在通过引入适度的生成偏差,丰富判别器的训练样本空间,从而提升模型对特征边界的辨识与泛化能力。

为实现这一目标,首先,构建实例编码器模块以实现输入样本的深层特征表达与潜在空间映射。该模块基于神经网络结构,与传统卷积特征提取方式

不同，其能够捕获样本间的长期依赖关系和全局结构信息，从而在高维潜在空间中形成更加鲁棒的特征表征。其输出嵌入向量在保留原始数据语义信息的同时，在特征分布上实现类间区分与类内均衡，为生成器后续输入的特征表达提供判别性和稳定性。随后，引入特征聚合模块以实现任务级特征的整合与全局语义建模。该模块以实例编码器生成的样本嵌入向量为输入，通过平均池化策略，对多个样本特征进行聚合，生成能够代表整体任务分布的全局表示向量。与单样本特征学习不同，特征聚合模块通过捕捉跨样本间的统计依赖与分布特征，构建出更高层次的语义抽象，为生成器提供任务层面的条件约束与上下文语义引导。当聚合表示与随机噪声向量拼接输入生成器后，模型能够在保留全局语义一致性的同时引入随机扰动，从而在生成阶段实现特征的可控多样化与细节层面的丰富性。

实例编码器与特征聚合模块的联合设计在模型体系中形成互补关系。前者侧重于个体特征的精确编码与语义分解，后者关注全局特征的统计融合与结构约束。二者的协同机制在结构层面建立特征学习与任务泛化之间的关联路径，预期可促进生成器在潜在空间中对目标分布的多尺度结构特征进行表达与建模。

## 2　基于 MetaDAGAN 的特定 MFR 及工作模式识别

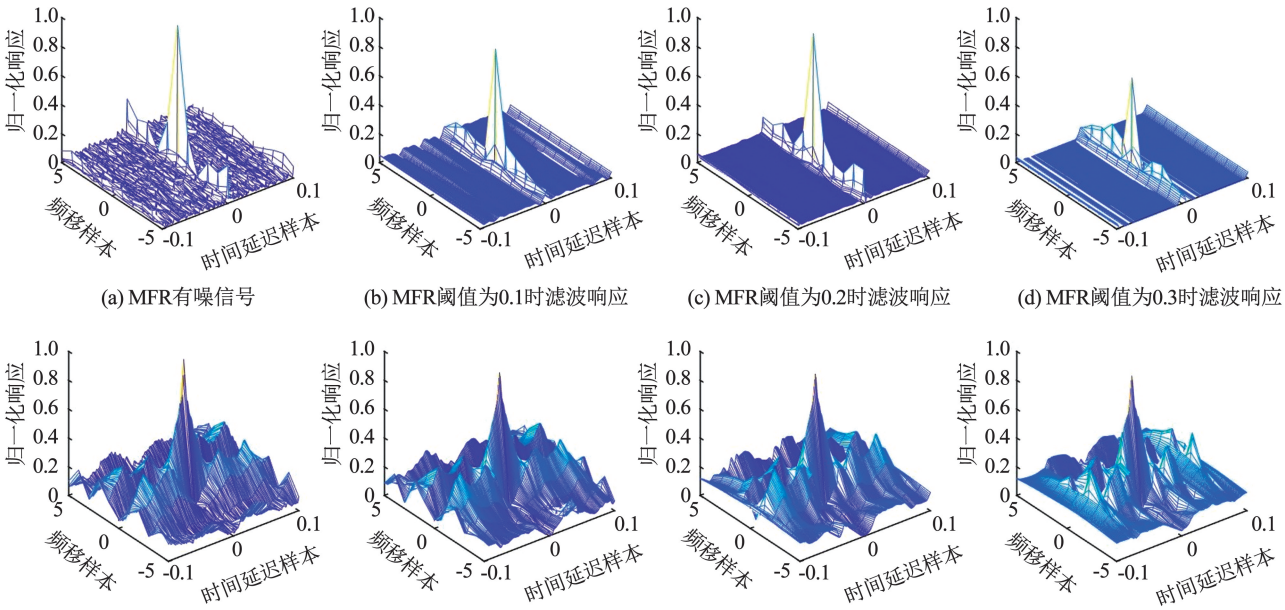
### 2.1　雷达脉冲数据预处理

在实际采集过程中，信号常受到环境或敌方干扰，导致信号产生毛刺和畸变，可采用小波阈值滤波算法以实现信号的降噪处理。设 $w$ 为小波系数，$\tau$ 为预设小波阈值，小波阈值滤波数学表达为

$$w_{\mathrm{k}}=\begin{cases}w, |w|\geqslant\tau\\ 0, |w|<\tau\end{cases} \tag{2}$$

实验中采用 Daubechies-4 小波基对输入信号进行 3 级二维小波分解，结合硬阈值处理方法获取不同分解层的小波系数。

为更好地体现信号滤波前后特征分布，按照基于数据流自监督的雷达信号在线分选方法[15]中所提方法，引入模糊函数进行信号的时频域可视化处理，通过三维图进行对比以确定阈值，分别取无量纲阈值为 0.1、0.2、0.3 进行滤波实验，图 3 展示了在相同信噪比（signal-to-noise ratio，$R_{\mathrm{SN}}$）条件下随机选取的多功能雷达信号与二进制相移键控（binary phase shift keying，BPSK）信号的对比结果。




(a) MFR有噪信号　(b) MFR阈值为0.1时滤波响应　(c) MFR阈值为0.2时滤波响应　(d) MFR阈值为0.3时滤波响应

(e) BPSK有噪信号　(f) BPSK阈值为0.1时滤波响应　(g) BPSK阈值为0.2时滤波响应　(h) BPSK阈值为0.3时滤波响应

**图 3　小波阈值滤波对比**

Fig. 3　Comparison of wavelet thresholding results

由图 3 可以看出：随机选取的 MFR 信号在阈值为 0.1 时仍然表现出明显的毛刺现象；当阈值为 0.2 时，信号趋于平滑，且波形特征得以较好保留；然而，在阈值为 0.3 时，信号的波形特征开始丢失。对于 BPSK 信号，阈值为 0.1 时，信号趋于平滑，但边缘区域仍然存在毛刺；当阈值为 0.2 时，信号波形平滑且特征完整；而在阈值为 0.3 时，信号的边缘出现了波形特征的丢失。因此，在本文后续实验中选取阈值为 0.2 进行信号滤波处理。

### 2.2 多任务联合学习框架

在雷达信号识别问题中,单一任务学习方法通常难以兼顾多类型信号的差异性与复杂性,尤其在 MFR 信号识别场景中,不同信号类型间存在时频特征差异与语义关联。为此,本文构建一种多任务联合学习框架,通过联合学习主任务与辅助任务,实现多层次特征共享与跨任务知识迁移,以提升模型的泛化能力与鲁棒性。

根据任务间的语义关联与特征依赖关系划分为主任务与辅助任务。主任务负责特定 MFR 信号的判别与识别,用于在多类型雷达信号中实现目标样本的区分与筛选;辅助任务基于主任务的输出进一步开展工作模式的细粒度分类与功能分析,通过建模不同运行状态下的信号特征,提炼其语义差异与操作属性。

#### 2.2.1 主任务设计与实现

主任务通过深度特征提取网络对输入信号的调制特征、时频结构及幅相变化进行建模,以获取其在潜在空间中的判别性表示。

在训练过程中,主任务的输出包括类别概率分布与嵌入特征向量,这些信息不仅用于信号分类,还为辅助任务提供先验特征输入。主任务采用交叉熵损失函数作为主要优化目标,用于度量模型预测分布与真实分布之间的差异,指导网络参数的反向优化,以实现生成器与判别器在识别阶段判别边界的有效调整与收敛。主任务损失函数的表达式为

$$L_1 = -\frac{1}{N}\sum_{i=1}^{N}\sum_{k=1}^{K} y_{i,k}\log(\hat{y}_{i,k}) \tag{3}$$

式中:$L_1$ 为主任务损失函数,$K$ 为类别数,$y_{i,k}$为第 $i$ 个样本在第 $k$ 类的真实标签,$\hat{y}_{i,k}$为模型预测的类别概率。

#### 2.2.2 辅助任务设计与实现

多任务联合学习框架将主任务输出的嵌入特征向量输入至辅助任务模块,通过特征重编码与模式分类层进行语义建模与决策预测。辅助任务同样采用交叉熵损失函数作为主要优化准则,用于最小化预测模式分布与真实分布之间的差异,从而提升模型在细粒度特征判别上的学习能力。辅助任务损失函数的表达式为

$$L_2 = -\frac{1}{N}\sum_{i=1}^{N}\sum_{m=1}^{M} y_{i,m}\log(\hat{y}_{i,m}) \tag{4}$$

式中:$L_2$ 为辅助任务损失函数,$M$ 为工作模式类别数,$y_{i,m}$为第 $i$ 个样本在第 $m$ 个模式下的真实标签,$\hat{y}_{i,m}$为辅助任务预测的概率输出。

#### 2.2.3 联合优化目标函数

在损失函数设计上,辅助任务的目标函数与主任务联合组成总损失项,可表示为

$$L = \alpha L_1 + \beta L_2 \tag{5}$$

式中:$L$ 为总损失项;$\alpha$ 和 $\beta$ 分别为主任务和辅助任务的损失权重,用于平衡两个任务的相对重要性。

$L_1$ 提升 MFR 信号的识别与判别性能,$L_2$ 强化任务间语义关联与特征共享。二者加权构成 $L$,在多任务学习框架下实现参数共享与梯度协同,从结构层面增强模型在全局识别与模式分析任务间的平衡性与泛化能力。

### 2.3 元学习训练流程

在 MetaDAGAN 模型中,采用模型无关元学习(model-agnostic meta-learning, MAML)[16] 对生成器和判别器的参数进行训练,以适应当前任务。该方式下,生成器和判别器的参数可以根据不同的任务进行调整,从而提高模型的泛化能力和性能。通过将元学习引入 GAN,可以使得模型在训练过程中更好地适应不同的任务和数据分布,从而提高模型在元测试阶段的性能和泛化能力。MAML 训练过程如图 4 所示,$\theta$ 为初始参数,$\nabla L_1$、$\nabla L_2$、$\nabla L_3$ 为任务梯度方向,$\theta_1^*$、$\theta_2^*$、$\theta_3^*$ 为任务适应后的参数。该机制通过参数共享与更新实现模型的快速泛化与适应。

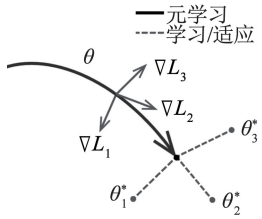



**图 4 MAML 训练过程**

Fig. 4 Illustration of the MAML training process

MAML 训练过程主要分 3 个阶段。首先是任务抽样阶段。模型从任务分布中随机采样多个子任务,每个子任务均包含独立的数据样本及相应的任务目标,用于模拟模型在不同场景下的学习需求。该阶段旨在构建多样化的任务环境,使模型能够在不同任务特征分布下积累通用的表示能力。其次是参数训练阶段。生成器与判别器分别在各自子任务的数据集上进行独立优化。生成器基于输入特征生成符合任务分布的伪样本,判别器对真实样本与生成样本进行对抗性判别,并将判别误差信息反馈至生成器以引导其特征学习。经过若干次内层训练后,模型在该任务下获得一组任务特定的最优参数近似,用以表征该任务的分布特征与对抗关系。最后是元优化阶段。模型汇总所有子任务的学习反馈,对全局共享参数进行统一训练。该阶段通过在参数空间中聚合跨任务梯度信息,使生成器与判别器在多个任务间形成共享的特征表示与参数先验。

经过多轮训练迭代后，模型能够在面对新的任务分布时快速适应其生成与判别特征，实现对不同任务环境的有效迁移。

通过上述双层优化机制，MetaDAGAN 模型在保持生成器与判别器对抗平衡的过程中实现跨任务结构知识的逐步积累与泛化能力的拓展。MAML 的引入使模型在训练过程中呈现出“学习如何学习”的特性，即在多任务训练中自适应地调整参数初始化与优化方向，从理论上增强模型在新任务中的适应性与收敛效率。

## 3　实验结果与分析

### 3.1　实验环境与信号参数设置

基于 MetaDAGAN 的特定 MFR 与工作模式识别流程如图 5 所示。在基于元数据增强的特定 MFR 及工作模式识别整体流程中，首先对 MFR 信号、常规雷达辐射源信号进行降噪等数据预处理。自注意力生成器用于样本增强，以提升特征空间的多样性与判别性。基于元学习共享结构的判别器对偏置生成器生成的样本进行边界优化，从而在多任务框架下实现多功能雷达及其工作模式的联合识别。

本文使用的 MFR 数据集来源于 MATLAB 雷达工具箱[17]。该雷达工作于 S 波段，中心频率为 2 GHz，发射信号为带宽 1 MHz 的线性调频波形，占空比为 10%。系统最大探测距离为 100 km，目标距离分布范围为 2 ~ 100 km，最小雷达散射截面积为 1 $m^2$。MetaDAGAN 框架中，模型训练采用 Python 3.8 和 PyTorch 2.1.0。仿真实验采用 Adam 优化器对生成器与判别器进行参数更新，学习率 $\eta$ 分别设定为 0.01、0.05、0.10 和 0.50，学习步长分别为 1、3、10 和 20。

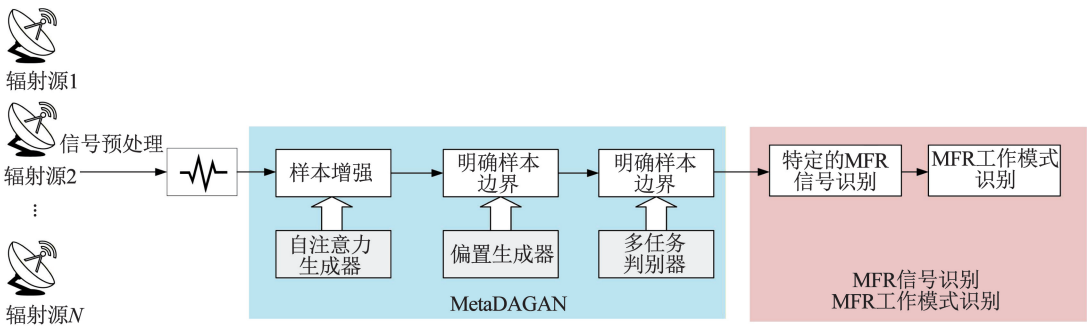



**图 5　基于 MetaDAGAN 的特定 MFR 与工作模式识别流程**

Fig. 5　Flowchart of specific MFR and working mode recognition based on MetaDAGA

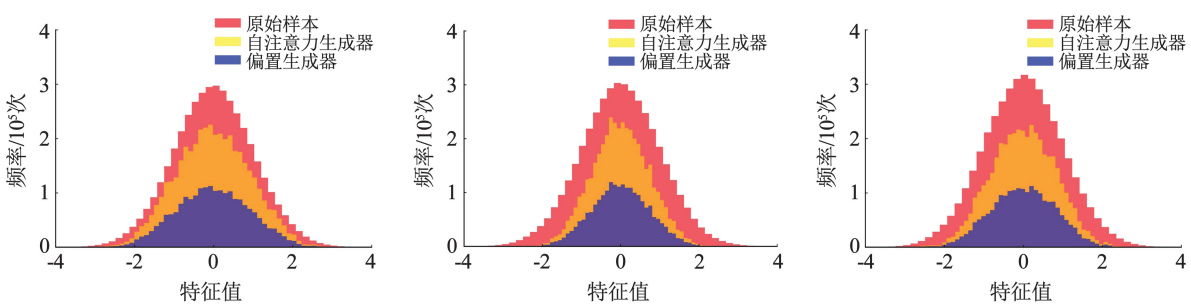
实验样本由 MFR 和 5 类常规雷达信号组成。其中，MFR 有 3 种工作模式，分别为 30 km 处跟踪模式（54 个样本）、50 km 处跟踪模式（36 个样本）和搜索模式（510 个样本），共计 600 个 MFR 信号样本。5 类常规雷达信号分别为连续波（continuous wave，CON）、二进制频移键控（binary frequency shift keying，BFSK）、BPSK、非线性调频（non-linear frequency modulation，NLFM）和线性调频（linear frequency modulation，LFM）。每类信号原始样本 600 个，增强样本 1 000 个，共计 1 600 个，样本尺寸均为 1 024 × 1，实验样本均按 7∶3 的比例划分训练集和测试集。

### 3.2　生成器样本增强效果分析

采用可视化与量化评估相结合的方式对自注意力生成器、偏置生成器生成的样本与原始样本进行比较和综合分析，以评估 Transformer 引入对生成器性能的影响。

#### 3.2.1　特征分布直方图可视化分析

采用 $R_{SN}$ 为 4、7、10 dB 的截获 MFR 数据作为原始样本，并采用 1∶1 的方式进行样本增强，实验结果如图 6 所示。




(a) $R_{SN}$=4 dB时特征分布　(b) $R_{SN}$=7 dB时特征分布　(c) $R_{SN}$=10 dB时特征分布

**图 6　信号数据增强前后对比**

Fig. 6　Comparison of signal data before and after augmentation

由图 6 可以看出,采用自注意力生成器和偏置生成器进行数据增强均未引入额外的不确定性特征。其中,自注意力生成器生成的样本更贴近原始数据,在不增加额外噪声或伪特征的前提下,能够有效保留原始数据的关键特性。而采用偏置生成器生成的样本与原始数据在特征分布上存在明显偏差,表明其增强效果相对不足。

此外,图 6 明确揭示了仅依赖偏置生成器无法实现高质量的样本增强。在小样本条件下,为确保增强数据的质量,仍需引入自注意力生成器。

3.2.2 散度量化分析

詹森 – 香农散度(Jensen-Shannon divergence, $D_{JS}$)是评估生成样本与原始数据分布相似性的常用方法,其本质是基于相对熵(Kullback-Leibler divergence, $D_{KL}$)的对称化与平滑化处理。$D_{JS}$的计算式为

$$D_{JS}(P \parallel Q) = \frac{1}{2} D_{KL}(P \parallel M) + \frac{1}{2} D_{KL}(Q \parallel M) \tag{6}$$

式中:$P$、$Q$ 为给定的两个概率分布,$M$ 为 $P$ 和 $Q$ 的平均分布。

对 $R_{SN}$分别为 4、7、10 dB 条件下的样本进行散度计算,结果见表 1。

**表 1 不同 $R_{SN}$条件下两种生成器生成样本的散度**

Tab. 1 Divergence of generated samples from two generators under different $R_{SN}$ conditions

| 模块 | $R_{SN}$/dB | $D_{JS}$/bit |
|---|---|---|
| 自注意力生成器 | 4 | 0.173 8 |
| | 7 | 0.120 0 |
| | 10 | 0.227 7 |
| 偏置生成器 | 4 | 0.185 8 |
| | 7 | 0.139 8 |
| | 10 | 0.237 6 |

散度值较小表示生成数据与真实数据在统计特性上的差异较小,即两者的信息熵距离更近;相反,散度值较大反映了生成数据分布与真实分布之间的偏离更明显。由表 1 可知,在相同 $R_{SN}$条件下,自注意力生成器的散度均低于偏置生成器的散度,说明其生成样本分布与真实数据分布的相似程度较高,表明引入自注意力机制能改善生成数据的分布一致性,从模型结构层面提升生成过程对真实分布的表达能力。

### 3.3 基于 MetaDAGAN 的特定 MFR 识别

在 5 类常规信号(CON、BFSK、BPSK、NLFM、LFM)的基础上,分别随机选取其中的 2 类、3 类、4 类和 5 类信号,与 MFR 信号共同构成识别样本集,用于特定 MFR 信号的识别实验。

通过对步长和学习率参数的系统设置与调优,开展模型识别准确率的对比分析,以检验模型在不同训练强度下的鲁棒性与泛化能力,实验结果见表 2。

**表 2 常规信号中特定 MFR 信号识别准确率**

Tab. 2 Recognition accuracy of specific MFR signals among conventional signal categories

| 步长 | 学习率 | 准确率/% | | | |
|---|---|---|---|---|---|
| | | 2 类 + MFR | 3 类 + MFR | 4 类 + MFR | 5 类 + MFR |
| 1 | 0.01 | 90.50 | 89.00 | 83.90 | 65.25 |
| | 0.05 | 92.16 | 88.87 | 84.50 | 64.50 |
| | 0.10 | 92.33 | 89.37 | 85.30 | 63.53 |
| | 0.50 | 90.16 | 88.75 | 84.20 | 64.91 |
| 3 | 0.01 | 99.50 | 100.00 | 100.00 | 77.75 |
| | 0.05 | 99.83 | 100.00 | 100.00 | 77.16 |
| | 0.10 | 99.50 | 100.00 | 100.00 | 77.75 |
| | 0.50 | 99.16 | 100.00 | 100.00 | 76.66 |
| 10 | 0.01 | 99.00 | 100.00 | 100.00 | 85.58 |
| | 0.05 | 100.00 | 100.00 | 100.00 | 84.25 |
| | 0.10 | 99.00 | 100.00 | 100.00 | 82.08 |
| | 0.50 | 99.16 | 100.00 | 100.00 | 86.50 |
| 20 | 0.01 | 100.00 | 100.00 | 100.00 | 97.75 |
| | 0.05 | 100.00 | 100.00 | 100.00 | 97.66 |
| | 0.10 | 100.00 | 100.00 | 100.00 | 98.50 |
| | 0.50 | 100.00 | 100.00 | 100.00 | 98.18 |

由表 2 可以看出,模型在不同步长和学习率组合下,对包含 2 ~ 5 类常规信号及 MFR 信号的识别准确率存在明显差异。当步长为 1 和 3 时,模型收敛速度慢,准确率受学习率影响较大;而当步长为 10 和 20 时,模型在各学习率下均能实现接近 100% 的识别精度,说明其在多任务条件下具有良好的收敛性与稳定性。总体来看,步长为 20,学习率为 0.10 组合可获得最佳性能,验证了 MetaDAGAN 在复杂信号识别场景中的鲁棒性与泛化优势。基于此结果,后续实验均采用该参数组合进行。

### 3.4 基于 MetaDAGAN 的 MFR 工作模式识别

基于已正确识别的 MFR 样本构建输入数据集,对后续 MFR 工作模式识别性能进行实验与分析。实验以 MetaGAN 作为对比模型,选取 CON、BFSK、BPSK、NLFM、LFM 5 类常规信号和 MFR 信号作为样本集,结果见表 3。

**表 3　特定识别完成后 MFR 工作模式识别准确率**

Tab. 3　MFR operational mode recognition accuracy after specific identification

| 信号类型 | 模型配置 | 准确率/% |
|---|---|---|
| 2 类 + MFR | MetaGAN | 87.75 |
| | MetaDAGAN | 98.86 |
| 3 类 + MFR | MetaGAN | 85.16 |
| | MetaDAGAN | 98.73 |
| 4 类 + MFR | MetaGAN | 77.75 |
| | MetaDAGAN | 98.71 |
| 5 类 + MFR | MetaGAN | 72.64 |
| | MetaDAGAN | 97.24 |

在特定 MFR 工作模式识别任务中，MetaDAGAN 整体性能优于 MetaGAN。由表 3 可以看出：MetaDAGAN 在各类任务中的识别准确率均超过 97%，表现出较好的稳定性和训练效率；相比之下，MetaGAN 的最高识别准确率为 87.75%。虽然随着类别数的增加，模型识别准确率会有所下降，但 MetaDAGAN 的性能波动较小，体现出较强的鲁棒性。总体而言，MetaDAGAN 在 MFR 工作模式识别中表现出更高的可靠性与稳定性。

### 3.5　样本增强数量和循环次数对准确率的影响

在基于 MetaDAGAN 模型的特定 MFR 及工作模式识别实验中，为考察样本增强数量与训练循环次数对识别性能的影响，设计了针对性实验。实验选取 5 类常规雷达信号与 MFR 信号的组合进行识别任务，以不同样本增强数量为变量，比较 MetaGAN 与 MetaDAGAN 两种模型在识别准确率方面的表现。在实验过程中，将训练循环次数固定为 100 次。实验结果如图 7 所示。

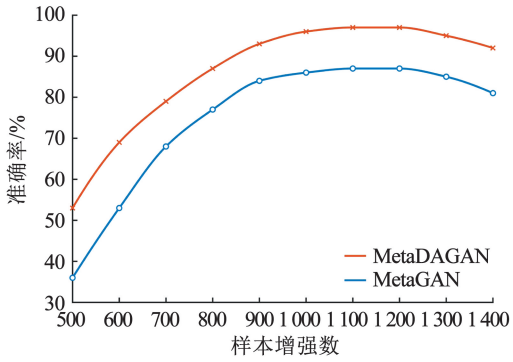



**图 7　样本增强数量对准确率的影响**

Fig. 7　Impact of the number of augmented samples on accuracy

由图 7 可以看出：随着样本增强数量的增加，两种模型的识别准确率均有所提升，但 MetaDAGAN 在各个样本增强数量范围内均表现出更高的准确率和更快的提升速度；当样本增强数量达到 1 000 时，MetaDAGAN 的识别准确率趋于稳定并接近 98%，而 MetaGAN 的最高识别准确率为 85%，说明 MetaDAGAN 在样本增强数量较少的情况下就能够实现较好的识别性能和稳定性，但过多的样本增强数量反而会增加模型的过拟合风险，从而导致准确率下降。

为验证训练周期对准确率的影响，固定每类样本 1 600 个数据进行实验，结果如图 8 所示。

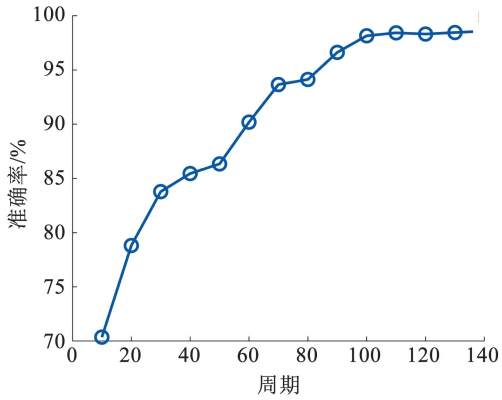



**图 8　识别准确率随训练周期的为化**

Fig. 8　Recognition accuracy across training epochs

由图 8 可以看出：随着训练周期的增加，模型的识别准确率逐渐提升，并在 100 个周期左右趋于稳定，接近 98%，说明 MetaDAGAN 在初期和中期阶段具有良好的学习能力，识别准确率迅速提升；在达到一定训练周期后，模型表现出较高的稳定性和可靠性，能够有效地完成识别任务。

### 3.6　消融实验

为进一步验证 MetaDAGAN 在小样本条件下对 MFR 及其工作模式识别的有效性，并分析模型中各模块对整体性能的贡献，进行了消融实验。该实验遵循标准设定方式，首先构建完整的基线模型配置，然后在其基础上每次仅移除一个模块，其他模块保持不变，从而明确每个模块对性能的独立贡献。选取 5 类雷达信号和 MFR 信号作为实验数据集，结果见表 4。

**表 4　消融实验结果**

Tab. 4　Results of ablation experiment

| 小波阈值滤波模块 | Transformer 模块 | 样本增强模块 | 准确率/% |
|---|---|---|---|
| √ | √ | √ | 97.24 |
| × | √ | √ | 87.31 |
| √ | × | √ | 72.64 |
| √ | √ | × | 52.06 |

注：√表示此模块参与模型训练，× 表示此模块未被启用。

由表 4 可以看出：完整配置下的 MetaDAGAN 在小样本条件下识别性能最优，准确率达到 97.24%；

移除样本增强模块后,准确率下降至 52.06%,表明该模块在提升样本多样性和模型泛化能力方面至关重要;移除 Transformer 模块亦导致识别率明显下降,尤其在多类别任务中表现尤为显著,降至 72.64%,验证其在复杂特征建模中的关键作用;滤波模块的移除虽引起性能下滑,但模型仍维持较高识别率,说明其在低 $R_{SN}$ 下提供了有效的预处理支撑。

### 3.7 模型复杂度分析

为评估 MetaDAGAN 计算代价,对模型的整体计算复杂度进行分析。采用 Big-$O$ 表示法描述计算复杂度的数量级。该表示方法可清晰地反映模型在不同结构和参数配置下计算量的增长规律,便于比较不同模块或不同模型的效率。MetaDAGAN 的整体复杂度主要由生成器、判别器及自适应模块的结构复杂度共同决定。

#### 3.7.1 生成器的复杂度

生成器的复杂度主要取决于输入特征维度 $r$,隐藏层单元 $h_1$、$h_2$、$h_d$ 及批量大小 $B$,可表示为 $O(B\cdot(n_z+r)\cdot h_1\cdot h_2\cdot h_d)$,其中 $n_z$ 为输入噪声维度数,$h_1$、$h_2$、$h_d$ 分别为生成器网络第 1、2、$d$ 层隐藏单元数。

若在生成器中引入 Transformer 结构,则整体复杂度扩展为 $O(B\cdot(n_z+n_c)\cdot H+L\cdot B\cdot H^2)$,其中 $n_c$ 为条件输入维度,$H$ 为隐藏层维度,$L$ 为 Transformer 层数,$O(B\cdot(n_z+n_c)\cdot H)$ 表示嵌入层的线性映射计算,$O(L\cdot B\cdot H^2)$ 为对应 Transformer 模块的自注意力机制计算。对比 $O(B\cdot(n_z+r)\cdot h_1\cdot h_2\cdot h_d)$ 和 $O(B\cdot(n_z+n_c)\cdot H+L\cdot B\cdot H^2)$ 可知,引入 Transformer 模块后,模型的计算复杂度较原结构增加了 $O(L\cdot B\cdot H^2)$。

#### 3.7.2 判别器的复杂度

判别器的计算复杂度主要由输入维度、隐藏层结构以及输出类别数量共同决定,可表示为 $O(B\cdot r\cdot h_1\cdot h_2\cdot h_d)$。当判别器采用条件输入或多分类判别结构时,计算量将与类别数 $V$ 成正比,即复杂度可扩展为 $O(B\cdot V\cdot r\cdot h_1\cdot h_2\cdot h_d)$,由此可知,判别器的计算代价主要受网络层数和隐藏层规模的影响,而输入样本维度与类别数量的增加会导致复杂度呈线性增长。

#### 3.7.3 自适应模块的复杂度

在模型训练阶段,fast_adapt 函数作为核心自适应模块,主要涉及生成器与判别器的联合优化,其复杂度为 $O(K\cdot T\cdot B\cdot(n_z+r)\cdot(r+w))$,其中 $K$ 为任务数,$T$ 为迭代步数,$w$ 为分类器权重维度。

引入自注意力生成器虽会导致计算复杂度增加,但能够显著提升伪数据的生成质量。考虑实际应用中采样点数通常位于 128 ~ 1 024 之间,可据此对模型的总计算量进行估算。设 MetaDAGAN 的计算量为 $C_1$,MetaGAN 的计算量为 $C_2$,则二者的关系可表示为 $C_1>C_2$,$C_1/C_2\in[k_1,k_2]$,其中 $[k_1,k_2]$ 表示模型复杂度的相对增长范围,用于表征不同结构引入后的计算负载变化,反映出引入 Transformer 模块后 MetaDAGAN 的计算复杂度相较基准模型有所增加,但增长幅度受限于 $[k_1,k_2]$ 内,呈受控上升趋势。

从理论上看,复杂度的增加主要来源于 Transformer 层的线性映射与自注意力计算。结合硬件算力与模型优化策略,其增长幅度仍处于可接受范围内,未显著影响训练效率。适度的复杂度提升在生成样本的全局依赖建模与特征表达上带来了性能收益,实现了计算代价与生成质量的平衡。

### 3.8 与常见模型比较

为深入验证小样本条件下本文提出的基于 MetaDAGAN 的特定 MFR 及其工作模式识别方法的有效性,选取 SVM[5]、WACGAN[6]、SMOTE + CNN[7]、KNN[8]、MetaGAN[18]、feature hallucination[19]、CPAAN[20] 和 imaginary[21] 进行对比实验,结果如图 9 所示。

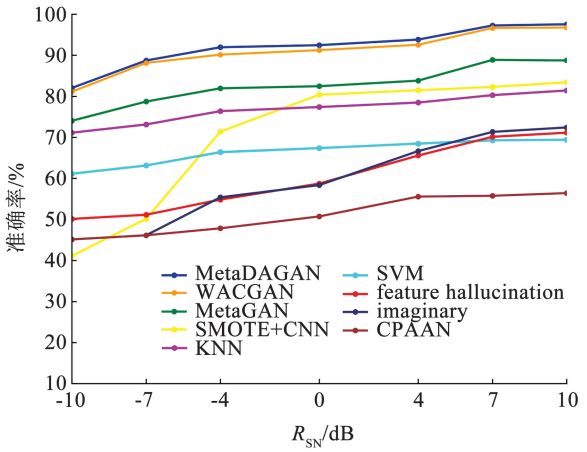



**图 9 不同 $R_{SN}$ 条件下各模型的准确率对比**

Fig. 9 Accuracy of different models under various $R_{SN}$ conditions

由图 9 可以看出:MetaDAGAN 在整个信噪比区间内均保持较高且稳定的识别性能,识别曲线整体位于所有对比模型的上方;WACGAN 在中高信噪比条件下表现相对稳定,但整体准确率略低于 MetaDAGAN;MetaGAN 在信噪比较低时准确率较低,随信噪比的提高,性能逐步改善,但仍存在一定波动;传统模型如 SVM 与 KNN 在全区间内识别准确率偏低,对噪声较为敏感;基于过采样与卷积结构的 SMOTE + CNN 在中高信噪比下略有提升,但稳定性不及 MetaDAGAN;相比之下,feature hallucination、imaginary 和 CPAAN 3 种生成类模型在整体识别性能上均不及 MetaDAGAN,且曲线位于较低区间。

## 4　结　论

本文针对复杂电磁环境下多功能雷达及其工作模式识别问题，提出一种基于 MetaDAGAN 的多功能雷达及工作模式识别方法，主要结论如下：

1）MetaDAGAN 可有效提升原始小样本信号的代表性与分布多样性，为下游判别器提供更具判别力的训练样本。在多个常规雷达信号场景下，特定 MFR 识别的准确率达 98.50%，MFR 工作模式识别的准确率达 97.24%，实验结果均高于其他常见模型。

2）设计了结构共享的元学习判别器，具备任务间迁移能力，能充分利用不同雷达信号间的共享特征实现跨任务的快速适应与准确判别，尤其在样本较小的测试条件下仍能维持较高的识别精度。

3）构建了基于 MetaDAGAN 的雷达辐射源及其工作模式识别流程，有效融合生成增强与特征判别，形成从“增强—训练—测试”一体化的识别路径，提升了实际复杂环境下的应用适应性。

## 参考文献


[1]何重航，刘佳琪，高路，等. 基于脉冲序列语义的雷达工作模式分析[J]. 导弹与航天运载技术(中英文)，2023(6)：144
He Zhonghang，Liu Jiaqi，Gao Lu，et al. Radar operation mode analysis based on the semantics of pulse sequences[J]. Missile and Space Vehicles，2023(6)：144. DOI：10.7654/j.issn.2097－1974.20230623

[2]沈家煌，黄建冲，朱永成. 特征参数匹配法在雷达信号识别中的应用[J]. 航天电子对抗，2017，33(2)：9
Shen Jiahuang，Huang Jianchong，Zhu Yongcheng. The application of feature parameter matching method in radar signal recognition[J]. Aerospace Electronic Warfare，2017，33(2)：9. DOI：10.16328/j.htdz8511.2017.02.003

[3]付银娟，李勇，卢光跃，等. 脉间复合调频脉内相位编码雷达信号设计与分析[J]. 哈尔滨工程大学学报，2019，40(7)：1347
Fu Yinjuan，Li Yong，Lu Guangyue，et al. Design and analysis of interpulse composite frequency modulated and intrapulse phase-coded radar signal[J]. Journal of Harbin Engineering University，2019，40(7)：1347. DOI：10.11990/jheu.201805108

[4]刘勇，瞿建，余渝生，等. 基于时频分析的雷达目标识别算法[J]. 制导与引信，2022，43(2)：43
Liu Yong，Qu Jian，Yu Yusheng，et al. Radar target recognition algorithm based on time-frequency analysis[J]. Guidance & Fuze，2022，43(2)：43. DOI：10.3969/j.issn.1671－0576.2022.02.006

[5]陈志仁，顾红，苏卫民，等. 改进的支持向量机低分辨雷达目标分类算法[J]. 系统工程与电子技术，2017，39(11)：2456
Chen Zhiren，Gu Hong，Su Weimin，et al. Improved support vector machine target classification algorithm for low-resolution radar[J]. Systems Engineering and Electronics，2017，39(11)：2456. DOI：10.3969/j.issn.1001－576X.2017.11.10

[6]朱克凡，王杰贵，刘有军. 小样本条件下基于数据增强和 WACGAN 的雷达目标识别算法[J]. 电子学报，2020，48(6)：1124
Zhu Kefan，Wang Jiegui，Liu Youjun. Radar target recognition algorithm based on data augmentation and WACGAN with a limite training data[J]. Acta Electronica Sinica，2020，48(6)：1124. DOI：10.3969/j.issn.0372－2112.2020.06.012

[7]Joloudari J H，Marefat A，Nematollahi M A，et al. Effective class-imbalance learning based on SMOTE and convolutional neural networks[J]. Applied Sciences，2023，13(6)：4006. DOI：10.3390/app13064006

[8]韩磊，周帅. 基于 FLAKNN 的雷达一维距离像目标识别[J]. 北京理工大学学报，2021，41(6)：611
Han Lei，Zhou Shuai. Radar range profile target recognition based on FLAKNN[J]. Transactions of Beijing Institute of Technology，2021，41(6)：611. DOI：10.15918/j.tbit1001－0645.2020.181

[9]周志文，黄高明，王雪宝，等. 基于联合协作表示的特定辐射源识别[J]. 系统工程与电子技术，2019，41(4)：724
Zhou Zhiwen，Huang Gaoming，Wang Xuebao，et al. Specific emitter identification based on joint collaborative representation[J]. Systems Engineering and Electronics，2019，41(4)：724. DOI：10.3969/j.issn.1001－506X.2019.04.04

[10]Gok G，Alp Y K，Arikan O. A new method for specific emitter identification with results on real radar measurements[J]. IEEE Transactions on Information Forensics and Security，2020，15：3335. DOI：10.1109/TIFS.2020.2988558

[11]Ding Lida，Wang Shilian，Wang Fanggang，et al. Specific emitter identification via convolutional neural networks[J]. IEEE Communications Letters，2018，22(12)：2591. DOI：10.1109/LCOMM.2018.2871465

[12]Goodfellow I J，Pougetabadie J，Mirza M，et al. Generative adversarial nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal：NIPS，2014：2672

[13]Zhang Ruixiang，Che Tong，Bengio Y，et al. MetaGAN：an adversarial approach to few-shot learning[C]//Proceedings of the 32nd Conference on Neural Information Processing Systems. Montreal：NIPS，2018：2371

[14]Vaswani A，Shazeer N，Parmar N，et al. Attention is all you need[C]//31st Annual Conference on Neural Information Processing Systems. Long Beach：NIPS，2017：5998

[15]普运伟，杜林，戴子瑜，等. 基于数据流自监督的雷达信号在线分选方法[J/OL]. 吉林大学学报(工学版)，2024-09-23. https://doi.org/10.13229/j.cnki.jdxbgxb.20240827
Pu Yunwei，Du Lin，Dai Ziyu，et al. Online sorting method of radar signal based on self-supervised data stream[J/OL]. Journal of Jilin University(Engineering and Technology Edition)，2024-09-23. https://doi.org/10.13229/j.cnki.jdxbgxb.20240827

[16]Finn C，Abbeel P，Levine S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney：IMLS，2017：1856

[17]Duan Min，Zhang Kun，Yu Juan，et al. Anti-jamming performance analysis of STAP based on MATLAB radar toolbox[C]//2nd Conference on High Performance Computing and Communication Engineering. Harbin：SPIE，2023：12605. DOI：10.1117/12.2673243

[18]Ni R，Goldblum M，Sharaf A，et al. Data augmentation for meta-learning[C]//Proceedings of the 38th International Conference on Machine Learning. Vienna：MLR，2021：8152

[19]Luo Qinxuan，Wang Lingfeng，Lü Jingguo，et al. Few-shot learning via feature hallucination with variational inference[C]//2021 IEEE Winter Conference on Applications of Computer Vision. Waikoloa：IEEE，2021：3963. DOI：10.1109/WACV48630.2021.00401

[20]Gao Hang，Shou Zheng，Zareian A，et al. Low-shot learning via covariance-preserving adversarial augmentation networks[C]//Proceedings of the 32nd Conference on Neural Information Processing Systems. Montreal：NIPS，2018：983

[21]Niel O. A novel algorithm can generate data to train machine learning models in conditions of extreme scarcity of real world data[PP/OL]. V1. arXiv (2023-05-01)[2024-12-01]. https://doi.org/10.48550/arXiv.2305.00987