基于数据流自监督的雷达信号在线分选方法

普运伟[1,2],杜 林[1],戴子瑜[1],何志强[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 计算中心,昆明 650500)

摘 要:针对电子对抗领域雷达信号截获困难和分选准确率低的问题,提出一种基于数据流自监督的雷达信号在线分选新方法。先通过生成对抗网络的均衡特征融合方法,利用有限样本完成高质量特征融合和样本增强;再构建一种基于多任务元学习的自监督模型,实现无标签信号流的在线分选。实验表明,在4 dB时,采用所提方法在仿真数据集上准确率为95.82%,在实测数据和公开数据集上也具有良好表现,证实了所提方法在数据流在线分选方面的有效性。

关键词:雷达信号;在线分选;无监督学习;数据流

中图分类号:TN974;TH89 **文献标志码**:A **文章编号**:1671-5497(2026)02-0564-11

DOI:10.13229/j.cnki.jdxbgxb.20240827

Online sorting method of radar signal based on self-supervised data stream

PU Yun-wei[1,2],DU Lin[1],DAI Zi-yu[1],HE Zhi-qiang[1]

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

Abstract: To address the challenges of radar signal interception and low sorting accuracy in the electronic warfare domain, this paper proposes a new online sorting method for radar signals based on self-supervised data streams. Firstly, a balanced feature fusion method using generative adversarial networks is employed to achieve high-quality feature fusion and sample enhancement with limited samples. Secondly, a self-supervised model based on multi-task meta-learning is constructed to realize online sorting of unlabeled signal streams. Finally, experimental results show that the proposed method achieves an accuracy of 95.82% on a simulated dataset at 4 dB, and it also performs well on real and public datasets, confirming the effectiveness of the proposed method in online sorting of data streams.

Key words: radar signal; online sorting; unsupervised learning; data stream

0 引 言

雷达信号分选是电子侦察中信号处理的关键环节[1-3]。目前,雷达信号特征提取手段和分选方法日新月异[4],如何在缺乏先验知识和信号样本的条件下,充分利用样本特征实现雷达信号数据流实时、有效分选,成为一项重要的研究任务。

在雷达信号的特征融合中,模糊函数[5]因具有丰富的时频特征而备受关注,相关学者常通过提取模糊函数的不同切面特征进行特征融合,普

收稿日期:2024-07-22.

基金项目:国家自然科学基金项目(61561028).

作者简介:普运伟(1972-),男,教授,博士.研究方向:智能信息处理.E-mail:puyunwei@126.com

运伟等[6]尝试拼接模糊函数主脊的二维投影，但简单的拼接会导致信息的丢失。曹勇等[7]运用主成分分析提取3个主成分，但该方法对特征参数的相关性不敏感，导致信息缺失。针对数据流的分选方法，普运伟等[8]使用聚类算法实现在线分选，但仍需要少量数据标签。Lang等[9]提出SD-ADPC算法实现分选，但该方法不能处理数据流。Jang等[10]提出基于伪标签的自监督学习方法，但该方法严重依赖伪标签质量。

为解决上述方法中存在的问题，本文提出一种基于生成对抗网络的均衡特征融合方法（Balanced feature fusion using GAN，BFFGAN）与自监督对比多任务元学习（Self-supervised contrastive multi-task meta learning，SCMTL）模型相结合的在线分选方法。首先，利用BFFGAN模型将截获的雷达数据流信号逐个进行特征融合和样本增强，并将数据划分为训练集和测试集，该过程能同时处理多个截获信号。其次，利用SCMTL模型对训练集进行在线自监督对比学习，逐个或逐批次完成测试集中的雷达信号分选任务，该过程允许在学习和分选阶段加入新的雷达信号。本文所提方法在仿真雷达数据集、实测雷达数据集和公开数据集上都具有良好表现。

1　特征融合和样本增强

1.1　基于模糊函数的特征提取

窄带雷达信号是一种非平稳信号，可用$s(t)$表示，模糊函数（AF）定义式为：

$$\chi_s(\tau,\xi)=\int_{-\infty}^{+\infty} g\left(t+\frac{\tau}{2}\right)g^*\left(t-\frac{\tau}{2}\right)\mathrm{e}^{-\mathrm{j}2\pi\xi t}\mathrm{d}t \quad (1)$$

式中：$\chi_s(\tau,\xi)$为$s(t)$的模糊函数，且仅由其复包络函数$g(t)$确定；$g^*(t)$为$g(t)$的共轭；τ为时延；ξ为频移；t为时间变量。该式说明，AF实质为信号在时域和频域上的联合二维表示，能较好地反映出信号的内在特性。

信号AF切片能直观凸显信号的时域和频域特性，因此通过这些切片的对比分析可以更好区分不同的信号类型。本文选用AF主脊切片和AF正交切片作为实验所需特征输入，SNR=4 dB时CON、EQFM、2PSK、QPSK、2FSK共5种雷达信号的AF正交切片和AF主脊切片如图1所示。

1.2　小波阈值滤波

雷达信号在实际采集过程中，常受到环境或敌方干扰，导致信号AF产生毛刺和畸变，其波形受到显著影响，大幅度增加了雷达信号分选的难度。为尽可能抑制噪声影响，最大化保留数据原始特征，本文采用小波阈值滤波算法[11]，以实现雷达信号的降噪处理。硬阈值函数如式（2）所示。

$$w_{\mathrm{thr}}=\begin{cases} w & |w|\geqslant \mathrm{thr} \\ 0 & |w|<\mathrm{thr} \end{cases} \quad (2)$$

式中：thr为小波阈值，w为小波系数。本文使用的是Daubechies 4小波基数对输入信号进行3级二维小波分解，阈值选择0.2。

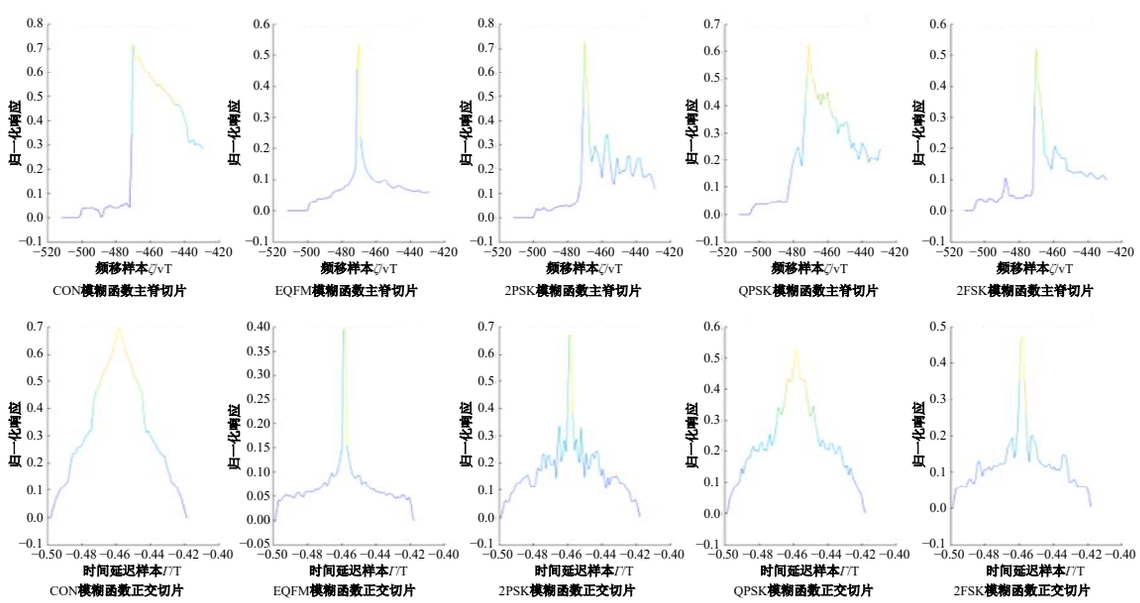

图1　雷达信号的AF主脊切片和正交切片

Fig. 1　AF main ridge slices and orthogonal slices of radar signal

图2(a)~(c)依次为滤波前、滤波后和无噪时LFM的AF波形图。对比图2中滤波前与无噪声的波形图可知,强噪声干扰环境中,信号AF的失真情况较为严重。对比滤波前和滤波后的波形图,发现经过小波滤波后,信号AF波形中的毛刺明显减少且主要特征得到保留。以上结果证明本文采用的滤波方法有助于降低噪声对信号特征的干扰。

1.3 基于生成对抗网络的特征融合和样本增强

为解决截获样本有限的问题,常采用生成对抗网络(Generative adversarial network, GAN)[12]进行样本增强,GAN由生成器和判别器组成,两者通过对抗训练达到纳什均衡,从而实现样本增强。

GAN在图像增强、语音增强、文本增强等领域都取得了显著成效[13],故在本文中将其引入雷达样本增强中,同时探索该模型在特征融合上的潜力,以同步实现雷达信号的特征融合和样本增强。基于此,本文提出了BFFGAN模型。首先,将Transformer引入GAN模型中,通过自注意力机制[14]提升模型强序列建模和条件信息整合能力;其次,加入均衡采样模块,以保证模型学习的每一批次样本中各类特征样本占比相等,降低融合后样本特征发生特征偏移的风险。BFFGAN模型结构如图3所示。

与GAN模型相比,引入Transformer模型有助于改善传统GAN中学习模式单一、特征提取不充分、细节不真实的问题;均衡采样模块的加入进一步完善了模型的整体架构,确保融合后的样本同时具备两种特征,降低了融合后特征偏移的风险。BFFGAN提高了特征融合和样本增强的多样性和细节逼真度,可为复杂电子战环境中的信号处理提供更加精确和可靠的特征融合与样本增强手段。

1.3.1 均衡采样模块

(1)类别索引提取和初始化

提取数据集中不同类别雷达的AF正交切片样本和AF主脊切片索引。假设数据集中有N个样本,每个样本为$x_j\left(j=1,2,\cdots,N\right)$。其中,$N_{i,j}$个为AF正交切片样本,$N_{z,j}$个为AF主脊切片样

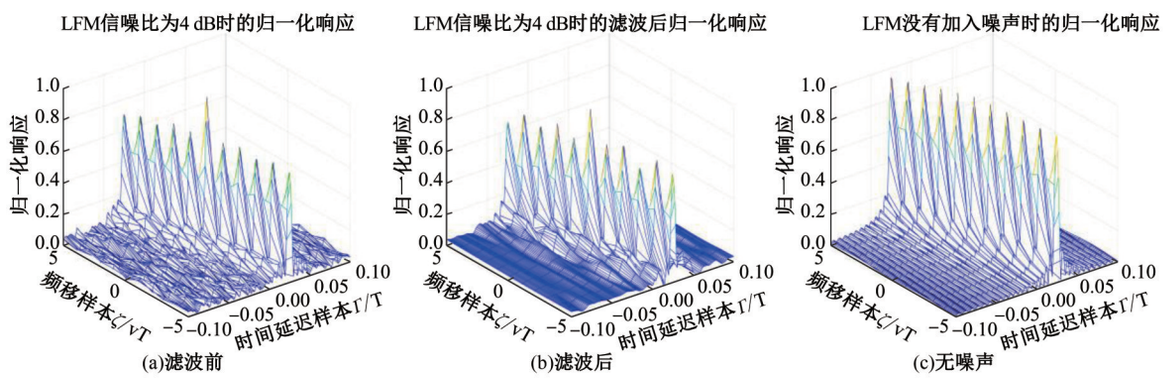

图2 LFM的AF主脊切片滤波前后的对比图

Fig. 2 Comparison of the AF main ridge slice filter of the LFM signal before and after filtering

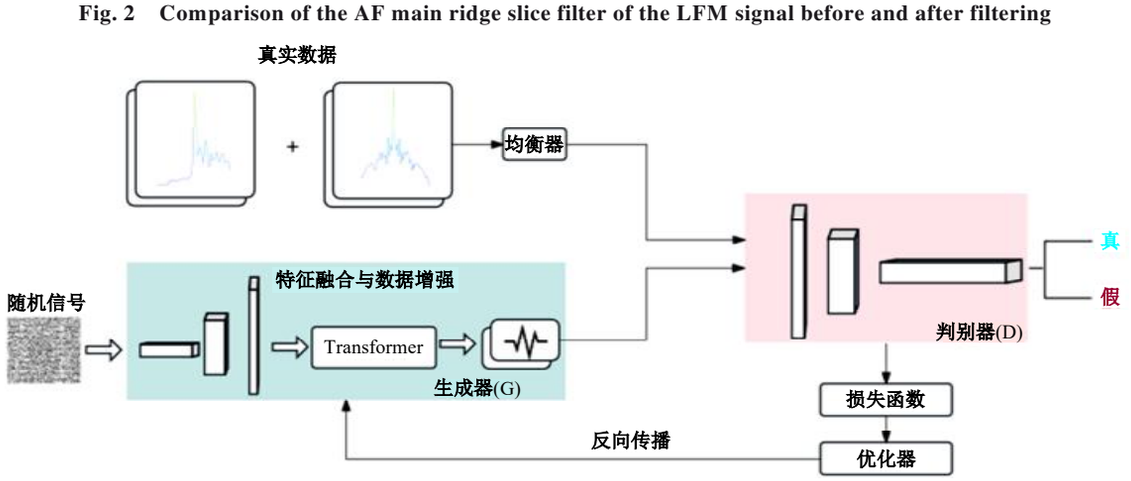

图3 BFFGAN框架图

Fig. 3 BFFGAN framework diagram

本，见式(3)。

$$x_j \rightarrow (N_{i,j}, N_{z,j}) \tag{3}$$

索引集合分别为S_i和S_z，见式(4)。

$$|S_i| = N_{i,j}, \quad |S_z| = N_{z,j} \tag{4}$$

(2)随机打乱和索引合并

为了保证训练过程中样本的随机性，对每个类别的索引进行随机打乱，见式(5)。

$$S_i' = \text{shuffle}(S_i), \quad S_z' = \text{shuffle}(S_z) \tag{5}$$

将打乱后的索引交替合并，以确保每个批次中的样本均衡，见式(6)。合并索引集合为S_{combined}，其中$k = \min(N_i, N_z)$。

$$S_{\text{combined}} = [S_i'[0], S_i'[0], \cdots, S_z'[k-1], S_z'[k-1]] \tag{6}$$

(3)批次生成

将合并后的索引集合按照批次大小分割，假设批次大小为B，则批次数量N_{batches}见式(7)。

$$N_{\text{batches}} = \left\lfloor \frac{2 \times \min(N_{i,j}, N_{z,j})}{B} \right\rfloor \tag{7}$$

每个批次B_{batches}包含B个索引，见式(8)。

$$B_{\text{batches}} = [S_{\text{combined}}[n \cdot B], \cdots, S_{\text{combined}}[(n+1) \cdot B - 1]] \tag{8}$$

(4)迭代器长度

定义生成批次数量的长度，见式(9)。

$$\text{len} = \left\lfloor \frac{2 \cdot \min(N_{i,j}, N_{z,j})}{B} \right\rfloor \tag{9}$$

通过以上步骤，均衡采样模块实现了在每个批次中均衡抽取AF正交切片特征和AF主脊切片特征，从而解决了特征样本量不平衡的问题。

1.3.2　Transformer模块

Transformer的核心是多头自注意力机制和前馈神经网络。多头自注意力机制可以捕捉序列中元素之间的全局依赖关系，而前馈神经网络则用于进一步处理和转换这些特征。

1.3.2.1　将Transformer引入生成器

(1)生成器输入映射

将输入噪声z和条件下向量c通过线性层映射到高维空间，见式(10)。

$$h_{\text{G}} = \boldsymbol{W}_1[z; c] + b_1 \tag{10}$$

式中：$\boldsymbol{W}_1$为权重矩阵；b_1为偏置项。

(2)Transformer 构建

自注意力机制计算输入特征之间的相似性，见式(11)。

$$\text{Attention}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = \text{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\text{T}}}{\sqrt{d_k}}\right)\boldsymbol{V} \tag{11}$$

式中：$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$分别为查询、键和值矩阵；d_k为键的维度。

多头自注意力机制将多个自注意力机制的输出拼接在一起，见式(12)。

$$\text{MultiHead}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = [\text{head}_1; \text{head}_2; \cdots; \text{head}_h]\boldsymbol{W}^{\text{O}} \tag{12}$$

式中：head_i为第i个自注意力头的输出；$\boldsymbol{W}^{\text{O}}$为输出权重矩阵。

(3)前馈神经网络的输出

前馈神经网络的输出，见式(13)。

$$\text{FFN}(x) = \text{ReLU}(\boldsymbol{W}_2 x + b_2)\boldsymbol{W}_3 + b_3 \tag{13}$$

式中：$\boldsymbol{W}_2$、$\boldsymbol{W}_3$为权重矩阵；b_2、b_3为偏置项。

(4)使用Transformer模块对输入进行处理

使用Transformer模块对输入进行处理，见式(14)。

$$h'_{\text{G}} = \text{Transformer}(h_{\text{G}}) \tag{14}$$

(5)输出生成

最终输出通过线性层映射到目标维度，见式(15)。

$$\hat{x} = \text{sigmoid}(\boldsymbol{W}_4 h_{\text{G}}' + b_4) \tag{15}$$

式中：$\hat{x}$为生成器的输出；$\boldsymbol{W}_4$为权重矩阵；b_4为偏置项。

1.3.2.2　将Transformer引入判别器

(1)判别器输入映射

输入样本x线性层映射到高维空间，见式(16)。

$$h_{\text{D}} = \boldsymbol{W}_1 x + b_1 \tag{16}$$

引入式(11)～(13)构建的Transformer，见式(17)。

$$h_{\text{D}}' = \text{Transformer}(h_{\text{D}}) \tag{17}$$

(2)判别输出

最终输出通过线性层映射到判别结果，见式(18)。

$$y = \text{sigmoid}(\boldsymbol{W}_4 h_{\text{D}}' + b_4) \tag{18}$$

式中：y为判别结果；$\boldsymbol{W}_4$为权重矩阵；b_4为偏置项。

综上所述，Transformer模块在生成器和判别器中的应用显著增强了模型的特征提取和处理能力。具体来说，生成器通过捕捉全局依赖关系和复杂特征映射，促进生成器生成更加逼真和多样化的样本，前馈神经网络的非线性变换使生成器的输出更加稳定。判别器中的自注意力机制能够

捕捉输入样本的全局特征,使判别器更容易区分真实样本和生成样本;多头自注意力机制能够从不同的特征子空间中提取信息,提高判别器在面对多样化生成样本时的鲁棒性,此时判别器可以提供更有效的梯度反馈,有助于指导生成器调整生成参数。因此,BFFGAN模型在处理复杂数据分布和生成高质量样本方面具有显著优势。

2 雷达信号在线分选

2.1 雷达信号数据流

现实中,数据流[15]并非以静态形式批量到达,而是按照"流"的形式以时间为序列逐个或逐批次动态到达。实际电子对抗中,截获的雷达信号是随时间到达的密集脉冲流且没有标签信息。目前,绝大多数雷达信号数据流的分选都是静态形式,需收集到足量的信号才能进行雷达信号的离线分选工作。因此,探索一种雷达信号数据流在线分选方法更具有实际工程意义。

2.2 分选模型

自监督对比学习是一种结合自监督学习和对比学习的方法,旨在训练过程中利用自监督任务生成伪标签,并通过对比学习来优化模型。这种训练方法能够从大规模未标记数据中学习有用的表示,从而提升模型的泛化性能,并减少模型过拟合的风险。然而,自监督对比学习过程严重依赖伪标签,传统伪标签生成方法存在伪标签固定和生成方法依赖样本质量的问题。

多任务学习[16]涉及在单个网络架构中学习多个任务。元学习[17]旨在学习过程中重复利用信息以快速适应新任务。然而,元学习要求任务具有相似性质或单一模态。相比之下,多任务学习可以联合学习同类型和不同类型的任务。因此,将多任务学习与元学习相结合有助于解决元学习的局限性,元学习又有助于用更少的样本更快地学习看不见的任务,能够促进多任务学习对新任务的处理。

基于多任务元学习能从多个任务中快速学习然后迅速适应新任务的特点,以及自监督对比学习模型在无监督分选任务的出色表现,再结合雷达信号数据流应用背景,本文提出SCMTL模型用于雷达信号在线分选,并在训练过程中引入对比学习来优化模型,其目标函数见式(19)。

$$\gamma=-\frac{1}{N}\sum_{i=1}^{N}\frac{1}{\sum_{j=1}^{N}\xi_{i,j}}\sum_{j=1}^{N}\xi_{i,j}\log\frac{\exp\left(q_i^{\mathrm{T}}k_j/\tau\right)}{\sum_{z=1}^{N}\exp\left(q_i^{\mathrm{T}}k_z/\tau\right)} \tag{19}$$

式中:$\{q_i\}$为样本的查询集;$\{k_j\}$为样本的支持集示例;$\xi\in\{0,1\}$为样本的正负;$\xi_{i,j}=1$为正样本;$\xi_{i,j}=0$为负样本;τ为温度超参数。

分选架构如图4所示。

通过以下策略优化训练过程:使用动态网络动态地逐步改进伪标签;使用动态队列以在线方式利用先前和当前的小批量数据构建多样化任务,即构建N-way K-shot的任务划分,以解决传统方法中伪标签固定和生成方法依赖样本质量,导致任务单一化的问题。同时,引入多任务学习和元学习机制,以促进标签准确、快速地动态更新。

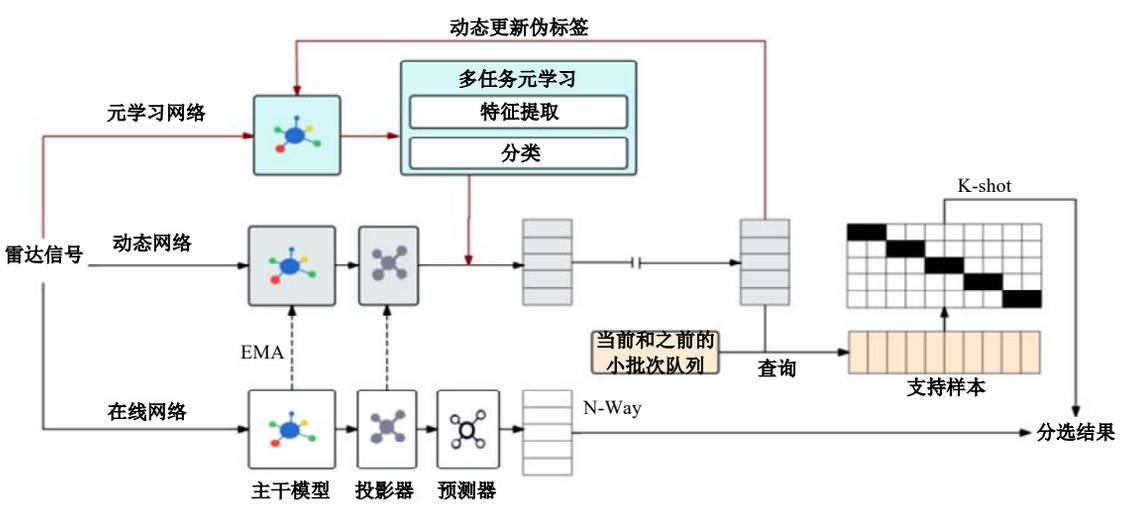

图4 SCMTL框架图

Fig. 4 SCMTL framework diagram

引入的多任务元学习模块不但增强了模型对信号全局特征的提取，而且轻量化的特征提取方法并没有带来大量的运算。同时，构建 N-way K-shot 的任务划分实现元学习提高模型对未知雷达信号的学习能力。本文将对信号的特征提取作为主要任务，将对信号的分选作为辅助任务，并通过共享卷积层将全连接层视为任务相关。通过学习多个任务，加入元学习后的模型将学会如何提取信号的特征并如何更新参数，当新的未知雷达信号出现时，模型就能更好地提取该信号的特征，加速模型对伪标签的更新。

多任务学习和元学习通过影响模型损失函数来快速、准确地指导伪标签更新。具体来说，自监督对比学习的损失函数见式(20)。

$$\mathcal{L}_{\text{self-supervised}}=-\log\left(\frac{\exp(\text{sim}(z_i,z_j)/\tau)}{\sum_{k=1}^{N}\exp(\text{sim}(z_i,z_k)/\tau)}\right) \tag{20}$$

式中：z_i 为当前样本；z_j 为当前样本的增强样本；z_k 为其他样本；τ 为温度。

通过最大化正样本之间的相似性和最小化负样本的相似度，实现自监督对比学习。

多任务学习的损失函数见式(21)～(23)。

$$\mathcal{L}_{\text{multi-task}}=\mathcal{L}_{\text{task1}}+\mathcal{L}_{\text{task2}} \tag{21}$$

$$\mathcal{L}_{\text{task1}}=\frac{1}{N}\sum_{i=1}^{N}\mathcal{L}_{\text{MSE}}(f(x_i),\hat{f}(x_i)) \tag{22}$$

$$\mathcal{L}_{\text{task2}}=\frac{1}{N}\sum_{i=1}^{N}\mathcal{L}_{\text{CE}}(g(f(x_i)),y_i) \tag{23}$$

式中：$f(x_i)$ 为模型提取的信号特征；$\hat{f}(x_i)$ 为伪标签指导下的信号特征；$g(f(x_i))$ 为通过信号特征进行分选的结果；y_i 为分选任务的伪标签。

元学习损失函数见式(24)。

$$\mathcal{L}_{\text{meta}}=\frac{1}{N}\sum_{i=1}^{N}\mathcal{L}_{\text{CE}}(\hat{y}_i^{\text{meta}},y_i^{\text{meta}}) \tag{24}$$

式中：$\hat{y}_i^{\text{meta}}$ 为元学习任务的预测；y_i^{meta} 为伪标签。

整体损失函数见式(25)。

$$\mathcal{L}_{\text{total}}=\alpha\mathcal{L}_{\text{self-supervised}}+\beta\mathcal{L}_{\text{multi-task}}+\gamma\mathcal{L}_{\text{meta}} \tag{25}$$

式中：α、β 和 γ 为权重系数。通过设置权重系数，可以有效提高模型最大化正样本之间的相似性和最小化负样本之间的相似性，并且提高在多个相关任务时快速适应和整体泛化的能力。

与离线训练不同，当前模型的训练允许在模型训练过程中增加新的训练数据，有效避免了模型训练时只能固定训练数据而无法立刻使用新数据训练的问题，从而提高模型的时效性。在线分选阶段同样能够在模型进行分选过程中加入新数据并立即对新数据进行分选，应对传统方法存在当前模型测试完毕才能对新数据进行测试的问题。

整体分选流程图如图 5 所示。当前时刻雷达信号逐个或逐批次到达，首先记录到达信号的先后顺序，再进行模糊函数分析，并提取 AF 切片特征。然后，逐个对信号进行样本增强与特征融合，随后按照数据到达的时间顺序对特征融合和样本增强后的数据进行排序，并将数据划分为训练集和测试集，SCMTL 对数据集进行学习并对测试集分选。SCMTL 模型处理当前批次数据流程为：首先，模型将对当前批次的 N 个无标签数据视为 N 个不同的样本(N-way)。然后，对每个类别，基于动态网络提取特征表示，模型在动态队列中为每个类别找到最相关的 K 个支持样本(K-shot)。在构建 K-shot 任务中，SCMTL 模型首先通过构建多头元学习任务，指导动态队列的更新，以便选用最相关的 k 个支持样本。其次，通过为 N 个类别匹配到最合适的 k 个支持样本来解决模型训练的数据集划分的问题。最后，给同类的无标签数据附上相同的伪标签，不同的伪标签就代表不同的类别，以此实现分选。整个过程均为在

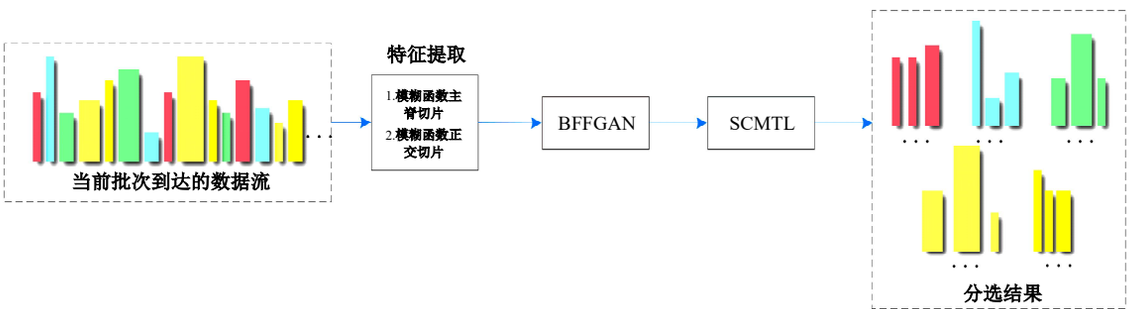

图 5　整体分选流程图

Fig. 5　Overall sorting flow chart

线过程,对新到来的数据,模型能及时进行学习和分选。

3 实验与结果分析

3.1 构建雷达数据流

为验证BFFGAN-SCMTL模型分选的有效性,本文实验中所用的数据流采用了包括CON、2FSK、2PSK、QPSK、EQFM、COSTAS、LFM、P1、T1、8PSK在内的共10类仿真雷达信号。设置信号数据在0~10 s的时间段内不定时到达,并且每批次随机到达1~50个信号来组成随机交替的雷达信号序列,以模拟真实的雷达信号数据流。

3.2 BFFGAN-SCMTL模型分选的有效性

为了验证本文所提方法的有效性和时效性,将BFFGAN-SCMTL模型与现有的PSO-K[18]、ABC-K[19]方法进行对比。为确保实验结果具备科学性和公平性,实验中采用与文献[9]相同的数据集。其中,Iris[20]数据集包含3类,每类共50个实例,每类为1种鸢尾花植物;Wine数据集[21]包含3类,每类分别有59、71、48个实例,每类为1种葡萄酒,每个实例有13个属性。

实验过程中,PSO-K和ABC-K方法采用一次性输入所有数据并完成分选的方式。本文所提方法则通过构建Iris和Wine数据流,模拟信号流到达。取所有批次在线分选结果的平均分选准确率作为本文所提方法的最终性能评估指标。实验结果如表1所示,BFFGAN-SCMTL模型在Iris数据集上的平均准确率(ACC)为93.48%,在Wine数据集上的平均准确率为94.65%,在线分选所需的时间T分别为2.67 s和2.79 s。

相比之下,PSO-K和ABC-K在分选精度和时效性方面均未能达到本文方法的表现。这充分证明了BFFGAN-SCMTL模型在处理信号分选任务时的优势,不仅有较好的在线分选准确率,还在时效性上有显著提升。

3.3 BFFGAN模型特征融合与样本增强效果

样本增强阶段进行两轮样本增强措施。

表1 在Iris和Wine数据集上的实验结果

Table 1 Results of experiments on Iris and Wine dataset

数据集		PSO-K	ABC-K	本文
Iris	Acc/%	88.24	86.32	93.48
	T/s	6.24	4.43	2.67
Wine	Acc/%	72.12	61.89	94.65
	T/s	7.99	4.45	2.79

首先,在截获到信号阶段,对每个截获到的信号x进行$N=8\,192$的重采样,以应对真实环境中截获信号长度不一致的问题。随后,对每个x进行分段操作,为方便计算,将x划分为8个子信号x_i。该过程完整保留了信号不同时段的特征,并在无标签情况下完成初次样本增强。

其次,使用BFFGAN模型进行第二次样本增强。通过计算信号$x_i\in\{x,1\leqslant i\leqslant 8\}$的AF主脊切片和AF正交切片用作BFFGAN模型的输入,实现特征融合和样本增强,生成信号X_N,此过程能同时处理多个截获信号。然后,按照信号到达的先后顺序对X_N进行排序和数据集划分,作为SCMTL模型的输入。

为验证BFFGAN模型的性能,如图6所示,依次将SNR=4 dB时EQFM,CON的特征分布散点图、样本增强和特征融合后特征分布散点图可视化为图6(1)(2)。AF正交切片、AF主脊切片、GAN结果和改进后的GAN结果的特征分布如图6中(a)~(d)所示。

对比图6中任意信号的(d)与(a)(b)特征分布散点图,可以直观地观察特征融合前后的特征分布异同:增强后的数据在保留(a)和(b)的整体特征时,还增强(a)采样点在0~2 000时的局部特征以及(b)采样点在3 000~5 000的局部特征。同时,融合后的数据图(d)较原始数据特征分布图(a)(b)特征明显增多,局部特征得到较好的增强。图6(c)证明GAN生成的样本质量与原始数据有很大差距。这进一步验证了本文提出的特征融合和样本增强方法不仅保持了原始数据的特征,还增强了局部特征,解决了传统GAN中存在生成样本质量低的问题。实验说明,本文提出的BFFGAN模型是一种有效的特征融合和样本增强方法。

3.4 信号特征选取分析与消融实验

为验证本文采用模糊函数主脊切片和正交切片作为特征的合理性,选取Choi-Wiliams特征[22]、Wigner-Rille特征[23]与本文使用特征对比。同时,为验证本文采用BFFGAN模型作为样本增强方法的合理性,选取原始GAN[12]方法作对比。如表2所示,SNR=4 dB时,采用3.1节的方法,使用每类雷达信号各50个以构建数据流,并进行消融实验。表2中特征1表示Choi-Wiliams特征,特征2表示Wigner-Rille特征,特征3表示

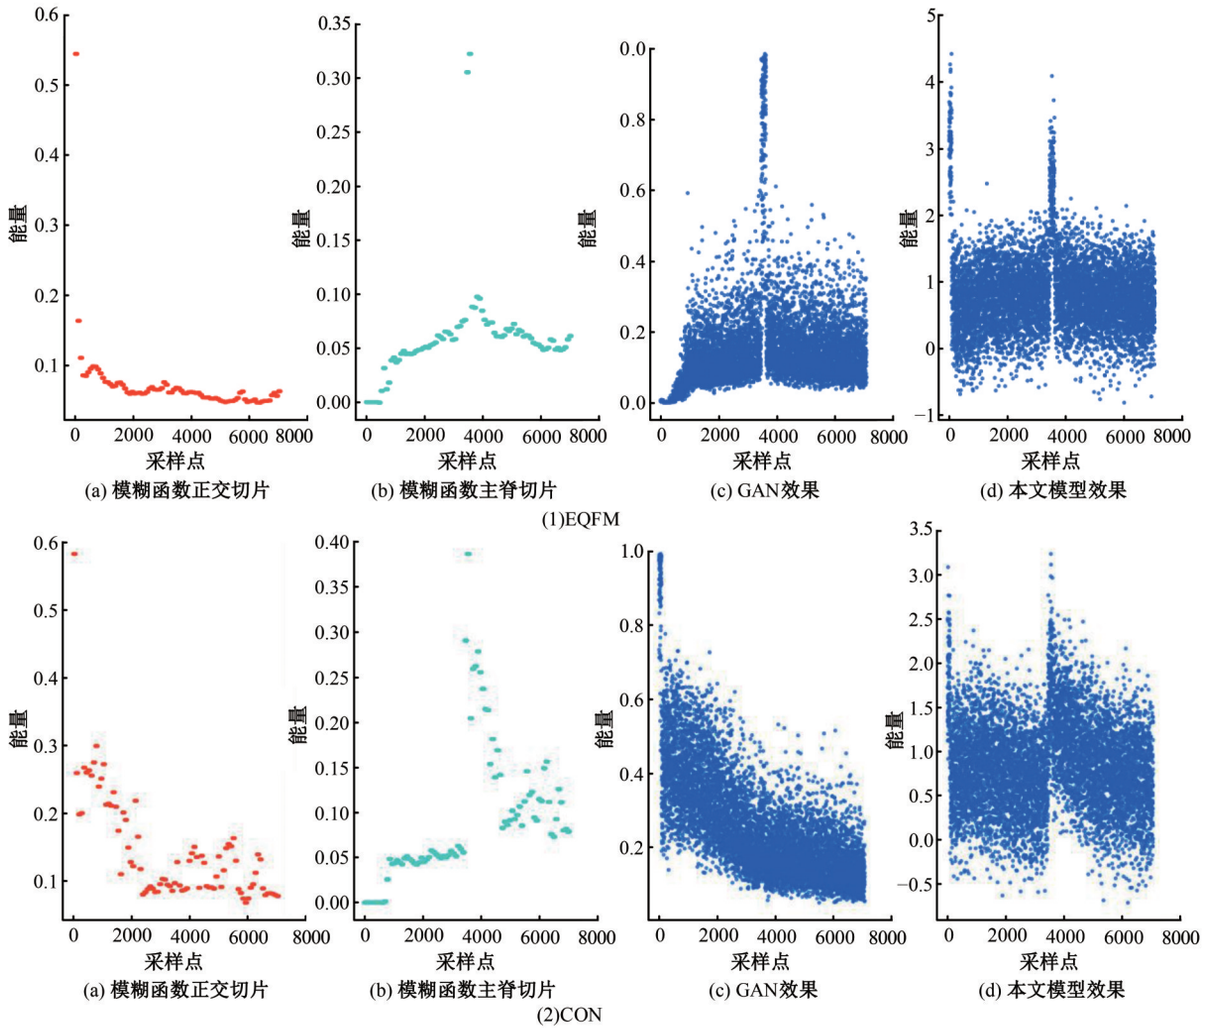

图 6　特征分布散点图

Fig. 6　Scatter plot of feature distribution

模糊函数主脊切片特征，特征 4 表示模糊函数正交切片特征。

表 2 结果表明，使用模糊函数特征时，SCMTL、GAN-SCMTL 和 BFFGAN-SCMTL 模型在线分选准确率较使用其他特征的分选准确率分别高出 5.31%、9.35% 和 17.16%，并且在线分选所用时长分别缩短了 1.42、3.32、2.71 s。这证明了本文采用模糊函数主脊切片和正交切片的有效性。仅使用 SCMTL 模型对原始数据进行在线分选的准确率较低，采用特征融合和样本增强手段明显提高了 SCMTL 模型的分选准确率。同时，采用 BFFGAN 进行特征融合和样本增强，SCMTL 模型的分选准确率为 95.82%，与原始的 GAN 相比，分选准确率提高了 26.04%。这说明本文提出的 BFFGAN-SCMTL 模型有效缓解了雷达信号分选中存在的截获样本少、特征融合效果差和分选准确率低的问题。

表 2　不同特征与消融实验结果

Table 2　Different characteristics and results of ablation experiments

模型	特征 1 和特征 2		特征 3 和特征 4	
	Acc/%	T/s	Acc/%	T/S
SCMTL	29.12	3.78	34.43	2.36
GAN-SCMTL	60.43	7.86	69.78	4.54
BFFGAN-SCMTL	81.66	5.58	95.82	2.87

3.4　SCMTL 模型分选效果分析

为进一步验证本文提出的 SCMTL 模型的有效性和稳定性，实验按照 3.1 节的方法，采用 SNR$\in\{-4,4\}$ dB 时每类 50 个样本构建数据流。通过 BFFGAN 模型将数据进行特征融合和 1∶5 比例的样本增强，并按照雷达信号到达时间的先后顺序排序对数据集进行划分。再进行蒙特卡洛实验，得到在线分选平均结果如图 7 所示。

图 7(a)为小提琴图，其轮廓展示实验结果的

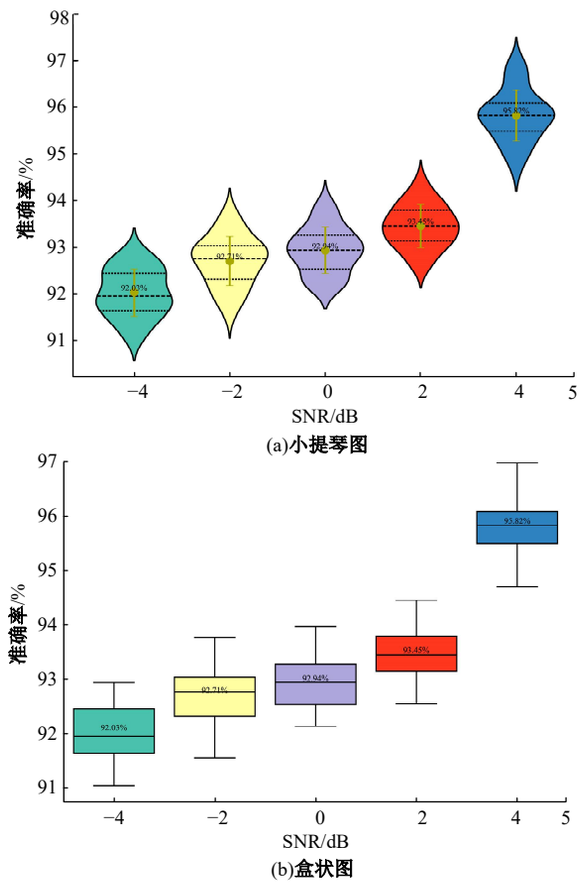

图7 蒙特卡洛实验结果

Fig. 7 Monte Carlo experiment results

密度分布;图7(b)为盒状图。由图7可以看出,BFFGAN-SCMTL模型的在线分选准确率随着SNR的增加而提高,但SNR∈{−4,2} dB时准确率波动不明显。这表明,虽然SNR的提升有助于提高模型性能,但总体而言,SNR的变化对在线分选准确率的影响并不显著,SCMTL模型在不同SNR时均表现出较高的准确率和较好的稳健性。SNR=4 dB时,SCMTL模型在线分选准确率显著提高。小提琴图表明,准确率的分布密度集中在95.82%。准确率分布范围为94%~97%,密度曲线较为尖锐,这表明数据分布集中且波动较小。箱线图进一步验证了这一点,中位数达到95.82%,四分位距相对较窄,显示出模型在高SNR条件下的高稳定性和出色性能。上下须线显示的数据离群点较少,进一步说明在SNR=4 dB时,模型分选准确率在高水平上具有较好的稳健性。

3.6 实测雷达数据集分选效果分析

为进一步验证本文方法的应用价值,采用某雷达外场实测数据构建数据流进行在线分选实验。为保证实验公平性,选取与文献[8]相同的5种雷达信号各700个来构建数据流。其中,信号1和信号2、5分别在5个和6个频点上进行频率组合变换;而信号3表现为单脉冲捷变,信号4则采用固定频率。脉冲宽度从0.9 μs到20 μs不等,这样的频率和脉冲宽度差异性为信号的分选提供了丰富的依据,雷达信号参数如表3所示。

实测雷达信号数据流按照0~20 s不定时到达,每批次随机到达50~100个信号,实验共记录2 min时长内的分选结果。其中,文献[8]模型为基于半监督学习的雷达信号数据流在线分选模型。图8给出了相同实测雷达信号数据集时,本文方法与文献[8]方法的分选结果对比。

从图8可以看出,在相同数据集的条件下,本文提出的BFFGAN-SCMTL模型在分选任务中

表3 实测雷达辐射源信号数据集参数

Table 3 Parameters of measured radar emitter signals data set

雷达信号	参数	
	RF/MHz	PW/μs
1	9 645、9 662、9 682、9 750、9 810共5个频点波位组变,频率分集	20
2	9 762、9 773、9 792、9 807、9 822、9 833共6个频点波位组变	3~5个脉冲为1组,每组PW在7、13任意
3	9 500~9 700单脉冲捷变	3~5个脉冲为1组,每组PW在0.9、1.0、1.1、1.2任意
4	9 850固定	16
5	9 513/9 518/9 523/9 548/9 553/9 563共6个频点波位组变	3~5个脉冲为1组,每组PW在6、12、18任意

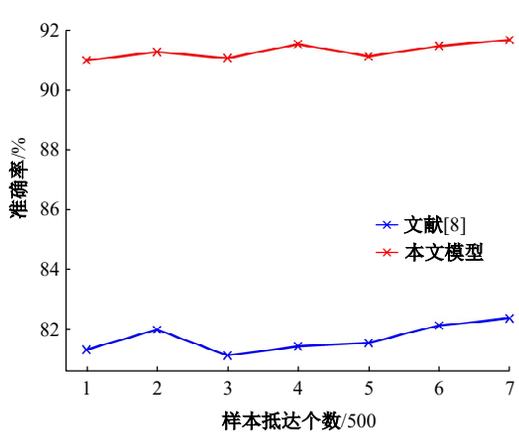

图8 实测雷达信号流在线分选结果

Fig. 8 Results of online sorting of radar signal streams

的表现优于文献[8]方法。具体而言,本文方法的平均准确率达到了91.27%,然而文献[8]模型仅为81.56%,这说明本文模型在信号分选精度上具有明显优势。同时,文献[8]方法在实现过程中仍然依赖于部分先验数据,这种依赖性限制了其在实际应用场景中的适应性和普遍性;而本文提出的BFFGAN-SCMTL模型则完全不依赖任何先验数据,实现了无先验数据条件下的高效分选。本文的方法在准确率、数据依赖性及适应复杂环境的能力方面均展现出显著的优势。

4　结　论

(1)针对常见的雷达信号特征融合存在信息缺失、复杂度增加等问题,以及截获样本有限时传统样本增强手段存在生成样本质量较差的问题,本文提出的BFFGAN模型能够同步实现特征融合和样本增强,有效地将不同模态的数据特征进行融合。同时,保留关键特征,以提高数据多样性和质量。通过生成高质量特征,该方法有望提升机器学习模型的性能和鲁棒性。

(2)针对无监督雷达信号数据流分选数据的无标签性质,以及基于神经网络的无监督模型在训练过程中对数据标签的依赖等问题,本文提出SCMTL模型。该模型通过引入多任务和元学习,不仅能加速伪标签的动态更新,还能提高伪标签的准确性。这有效解决了伪标签更新不及时及伪标签准确率提升缓慢的问题。

(3)仿真实验结果表明,SNR$\in\{-4,4\}$ dB时本文提出的分选方法有较好的表现,在线分选准确率受信噪比影响较小。SNR=4 dB时,在线分选平均准确率为95.82%并具有较好的稳健性。实测数据实验证明,本文方法在真实电磁环境中具有工程意义,基本满足实际战场需要。在公开数据集上与其他分选模型的对比进一步证明了本文提出方法的有效性。

参考文献:

[1] 国强, 李明松, 周凯, 等. 基于势距图与改进云模型的多模雷达分选[J]. 吉林大学学报: 工学版, 2022, 52(8): 1904-1911.
Guo Qiang, Li Ming-song, Zhou Kai, et al. Multi-mode radar sorting based on potential distance map and improved cloud model[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(8): 1904-1911.

[2] Wang S Q, Gao C, Zhang Q, et al. Research progress on key technologies of radar signal sorting[J]. Recent Trends in Intelligent Computing, Communication and Devices, 2019, 1: 773-779.

[3] Wang S Q, Hu G P, Zhang Q L, et al. The background and significance of radar signal sorting research in modern warfare[J]. Procedia Computer Science, 2019, 154: 519-523.

[4] 徐卓君, 杨雯婷, 杨承志, 等. 雷达脉内调制识别的改进残差神经网络算法[J]. 吉林大学学报: 工学版, 2021, 51(4): 1454-1460.
Xu Zhuo-jun, Yang Wen-ting, Yang Cheng-zhi, et al. Improved residual neural network algorithm for radar intra-pulse modulation recognition[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(4): 1454-1460.

[5] 普运伟, 马蓝宇, 侯文太, 等. 模糊函数主脊切面特征提取的局域差分方法[J]. 数据采集与处理, 2019, 34(3): 386-395.
Pu Yun-wei, Ma Lan-yu, Hou Wen-tai, et al. Local differential method for feature extraction of main ridge section of ambiguity function[J]. Journal of Data Acquisition and Processing, 2019, 34(3): 386-395.

[6] 普运伟, 余永鹏, 姜萤, 等. 基于模糊函数多域特征融合与集成学习的雷达辐射源信号识别[J]. 控制与决策, 2024, 39(1):39-48.
Pu Yun-wei, Yu Yong-peng, Jiang Ying, et al. Radar emitter signal sorting based on multi-domain feature fusion of ambiguity function and ensemble learning[J]. Control and Decision, 2024, 39(1):39-48.

[7] 曹勇, 许秀颖, 蔡丹, 等. 玉米籽粒后熟品质性状主成分分析与综合评价[J]. 食品科学, 2024, 45(11): 1-7.
Cao Yong, Xu Xiu-ying, Cai Dan, et al. Principal component analysis and comprehensive evaluation of post-ripening quality traits of corn kernels[J]. Food Science, 2024, 45(11): 1-7.

[8] 普运伟, 陈新杰, 余永鹏, 等. 基于模糊函数多维结构度量特征的雷达辐射源信号流在线分选[J]. 仪器仪表学报, 2023, 44(8):277-288.
Pu Yun-wei, Chen Xin-jie, Yu Yong-peng, et al. Radar emitter signal online sorting based on multidimensional structural metric features of ambiguity function[J]. Chinese Journal of Scientific Instrument,

2023, 44(8): 277-288.

[9] Lang P, Fu X J, Cui Z D, et al. Subspace decomposition based adaptive density peak clustering for radar signals sorting[J]. IEEE Signal Processing Letters, 2022, 29: 424-428.

[10] Jang H, Lee H, Shin J. Unsupervised meta-learning via fewshot pseudo-supervised contrastive learning [J]. Arxiv Preprint, 2023, 3: No. 230300996.

[11] Halidou A, Mohamadou Y, Ari A A A, et al. Review of wavelet denoising algorithms[J]. Multimed Tools Appl, 2023, 82: 41539-41569.

[12] Goodfellow I J, Pouget A J, Mirza M, et al. Generative adversarial networks[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, Montreal, Canada, 2014: 2672-2680.

[13] 王启帆. 基于数据增强的小样本学习方法研究[D]. 北京:北京交通大学计算机学院, 2023.
Wang Qi-fan. Research on few-shot learning method based on data augmentation[D]. Beijing: School of Computer Science, Beijing Jiaotong University, 2023.

[14] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems, New York, USA, 2017:6000-6010.

[15] 隋金坪. 基于数据流聚类的雷达在线分选方法研究[D]. 长沙:国防科技大学电子科学学院, 2020.
Sui Jin-ping. Research on online sorting method of radar emitter based on data stream clustering[D]. Changsha: College of Electronic Science, National University of Defense Technology, 2020.

[16] 吴瑞琪, 周毅. 知识融入多源多任务学习的眼底图像分类方法[J]. 计算机工程与应用, 2025, 61(7): 255-266.
Wu Rui-qi, Zhou Yi. Fundus image classification method with knowledge integration in multi-source multi-task learning[J]. Computer Engineering and Applications, 2025, 61(7): 255-266.

[17] 李红光, 王玉峰, 杨丽春. 基于元学习的小样本遥感图像目标检测[J]. 北京航空航天大学学报, 2024, 50(8):2503-2513.
Li Hong-guang, Wang Yu-feng, Yang Li-chun. Few-shot remote sensing image object detection based on meta-learning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(8): 2503-2513.

[18] Wang X, Fu X, Dong J, et al. Dynamic mo-dified chaotic particle swarm optimization for radar signal sorting[J]. IEEE Access, 2021, 9: 88452-88466.

[19] Zhang D, Luo K. Clustering algorithm based on artificial bee colony optimization [C]//Proceed-ings of the 2015 International Conference on Applied Science and Engineering Innovation, Jinan, China, 2015: 126-131.

[20] 吴婷. 基于EM算法的高斯混合模型在鸢尾花数据集的应用[J]. 网络安全技术与应用, 2022, 2022(4): 47-49.
Wu Ting. Application of gaussian mixture model based on EM algorithm in Iris dataset[J]. Network Security Technology and Application, 2022, 2022(4): 47-49.

[21] Feng S Y, Wang H X. Comparison of PCA and LDA dimensionality reduction algorithms based on wine dataset[C]//33rd Chinese Control and Decision Conference (CCDC), Kunming, China, 2021: 1-6.

[22] Zhang Z Z. Variance-SNR based noise suppression on linear canonical choi-williams distribute-on of LFM signals[J]. Chinese Journal of Electronics, 2022, 31(5): 804-820.

[23] 李思源, 徐天吉. 基于Wigner-Ville分布与Chrip-Z变换的高分辨时频分析方法[J]. 石油地球物理勘探, 2022, 57(1): 168-175.
Li Si-yuan, Xu Tian-ji. High-resolution time-frequency analysis method based on Wigner-Ville distribution and Chrip-Z transform[J]. Geophysical Prospecting for Petroleum, 2022, 57(1): 168-175.