

DOI: 10.19650/j.cnki.cjsi.J2311559

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*

普运伟^{1,2}, 陈新杰¹, 余永鹏¹, 戴子瑜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:针对现有雷达辐射源信号(RES)特征信息易受噪声影响、分选时效性低等问题,提出一种基于模糊函数多维结构度量特征的信号数据流在线分选方法。首先,应用图像全局相似性思想,以积分加速后的非局部均值平滑方法对信号模糊函数进行去噪处理。其次,从处理后模糊函数的主、侧两个角度提取多维度结构分布特征,形成特征向量。最后,优化了一种半监督学习分选模型并在线作用于不断输入的信号特征向量流,得到实时分选结果。实验结果表明,在先验数据量较少的情况下,所提方法在8~18 dB的信噪比环境中均可保持99%及以上的分选成功率,即使处于2 dB环境下,准确率仍可达91.8%。同时,提取单个信号特征平均耗时仅需0.29 s。结果验证了所提方法的有效性和实时性,具有一定工程价值。

关键词: 雷达辐射源;信号在线分选;模糊函数;非局部均值平滑;半监督学习;数据流

中图分类号: TN974 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

Online sorting of radar emitter signal stream based on multidimensional structural measurement features of ambiguity function

Pu Yunwei^{1,2}, Chen Xinjie¹, Yu Yongpeng¹, Dai Ziyu¹

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

Abstract: The radar emitter signal is susceptible to noise interference of feature information and low real-time performance of sorting, etc. To address these issues, this article proposes a method for online signal data stream classification based on ambiguity function multidimensional structural metrics. Firstly, the concept of global image similarity is leveraged, and the signal's ambiguity function is denoised by using an integral-accelerated non-local means smoothing method. Then, multidimensional structural distribution features are extracted from both the main and side perspectives of the processed ambiguity function, and a comprehensive feature vector is formulated. Finally, a semi-supervised learning classification model is optimized and applied in real-time to the continuous input stream of signal feature vectors, and instantaneous classification outcomes are achieved. Experimental results show that with less prior data, the proposed method maintains a classification success rate of 99% or higher in signal-to-noise ratios ranging from 8 to 18 dB, and the accuracy can also reach 91.8% even at 2 dB. Moreover, the average time required for extracting features from a single signal is a mere 0.29 second. These results evaluate the effectiveness and real-time capability of the proposed method, and show significant engineering value.

Keywords: radar emitter; online sorting of signals; ambiguity function; non-local means smoothing; semi-supervised learning; data stream

0 引言

雷达辐射源信号(radar emitter signal, RES)分选是指将截获的混合雷达信号流分离成不同类别的信号集,

在电子对抗、雷达情报分析等领域具有广泛的应用。研究雷达辐射源信号的深层特征分布以及构建高效的分选模型已成为当下亟待解决的关键问题。

针对RES特征的提取,目前已提出双谱分析^[1],时频分析^[2],经验模态分解^[3]等多种方法。但这些方法主要针

对特定信号形式而设计,泛化性较差,使得信号的分选效果不佳。模糊函数(ambiguity function, AF)描述了信号在时延域和多普勒域的变化规律,反映出信号内在的结构信息,不同信号的模糊函数具有不同的形态特征,可从中提取有效的分选特征信息。文献[4]抽取模糊函数主脊(ambiguity function main ridge, AMFR)切面作为特征,取得了较好的效果。文献[5]将 AFMR 切面变换到极坐标域并提取了均面积、致密度等较好的特征参数。文献[6]则对 AFMR 进行了导数约束平滑处理,加强了 AFMR 特征信息的抗噪性能。虽然以 AFMR 作为特征的分选方法效果较好,但由于利用分数自相关等运算,搜索 AFMR 时计算复杂度较高,实际应用上时效性不足。尽管可通过自适应灰狼算法(adaptive grey wolf optimizer, AGWO)^[7],改进的粒子群优化算法(particle swarm optimization, PSO)^[8]等方法加快 AFMR 的搜索效率,但耗时仍处于秒量级。

性能稳定的特征是有效分选的前提,而分选方法的实际可行性也是信号分选中不容忽视的部分。近年来,机器学习领域中的监督学习与非监督学习被广泛应用于 RES 的分选中,文献[9]应用卷积神经网络(convolutional neural networks, CNN)、长短期记忆网络(long short-term memory, LSTM)、深度神经网络(deep neural network, DNN)识别处于时频域及自相关域的信号;文献[10]抽取信号多维度特征并分析时频图像,使用残差思想与注意力机制(attention mechanism, AM)的深度网络进行信号分类;文献[11]在模糊聚类的基础上结合 K 近邻搜索,提出了连通 K 近邻(k nearest neighbors, KNN)聚类算法对信号进行聚类分选;文献[12]则通过具有噪声的基于密度的空间聚类(density-based spatial clustering of applications with noise, DBSCAN)算法进行预分类,再通过脉冲重复间隔(pulse repetition interval, PRI)变换获得估计结果。虽然上述方法都取得了可观的实验结果,但都需先收集完整数据并进行大量学习或是多次迭代得出分类结果,难以满足电子对抗中的实时需求。

为解决现有信号易于受到噪声影响且分选实时响应普遍较差的问题,本文提出一种基于模糊函数结构特征分布的雷达辐射源信号流在线分选方法。首先,计算信号的 AF 后采用积分加速的非局部均值平滑(non-local means, NLM)方法进行去噪处理;然后对获取到的 AF 从主、侧两视角进行观测并提取多维度结构度量特征;最后,利用改进后的半监督学习模型在线作用于陆续输入的信号特征向量,得到信号实时分选结果。

1 信号的模糊函数

1.1 理论基础

将任意的窄带雷达辐射源信号定义为 $s(t)$, 则模糊

函数为:

$$\chi_s(\tau, \xi) = \int_{-\infty}^{+\infty} g\left(t + \frac{\tau}{2}\right) g^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\xi t} dt \quad (1)$$

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。模糊函数是信号自相关函数中 t 经傅里叶变换后得到的,体现了信号在不同的时延和频移下匹配滤波的结果,能有效的反映出信号的结构特性。

1.2 模糊函数平滑处理

信号在实际采集的过程中,难免会受到敌方干扰或环境影响而伴有噪声,信号的 AF 同样也会产生异常的畸变。AF 是自相关函数在时域和频域的联合二维分布,因此,对于 AF 的去噪处理可采用与图像平滑相似的思路。

1) 全局相似性平滑

相较于传统平滑算法, NLM 会在整个图像中寻找与目标像素具有相似纹理特征的像素点集合,而不仅是使用待平滑点周围局部的邻域进行加权平均进行去噪处理。通过比较全局图像块邻域间的相似性以提取所需的结构信息,从而保证了奇异点和边缘的结构不被损坏^[13],可有效避免加权平均造成的过平滑现象,能较好的保留边缘细节等信息。

NLM 的基本思想是利用搜索窗口像素值的加权平均来估计目标像素值,以图像上某像素点 y 为中心构成的图像块 N_y , 作为相似窗口 T 处于搜索窗口 F 的内部进行滑动,并计算其与待平滑像素点 x 作为中心构成的图像块 N_x 间的相似性。为使 AF 的毛刺与畸变得有效的抑制,搜索窗口 F 则会在全局图像上移动,寻找与 N_x 相似的图像块,从而每个像素点都将获得全局邻域图像块的权值以矫正噪声的影响。

2) 积分图加速 NLM

对图像块直接进行相似性匹配运算会导致算法复杂度急剧增大,处理信号过程中难以做到实时响应。引入积分图像思想^[14]可减少算法重复运算,可解决原算法时间复杂度过高的问题,并且本文以欧氏距离替代高斯加权的欧氏距离,从而大幅降低了图像块邻域间的相似性计算量。

计算图像块间相似性时,构造像素点 m 偏移差值的积分图像 $s(m)$, 其表达式如下:

$$s_a(m) = \|N_m - N_{m+a}\|_2^2 \quad (2)$$

式中: a 代表图像块 N_m 与 N_{m+a} 间的偏移量, $a \in [-L, L_s]^2$, L_s 为搜索框 F 边长 L 的 $1/2$ 。定义任意像素积分图像函数为 $S_a(i)$ 。

$$S_a(i) = \sum s_a(m), i \in \Omega \quad (3)$$

由积分的性质可知,以 a 为当前偏移量下任意两图像块间的欧氏距离 $Z(x, y)$ 可表示为:

$$Z(x, y) = \frac{1}{l^2} (S_a(x_1 + l_s, x_2 + l_s) + S_a(x_1 - l_s, x_2 - l_s) - S_a(x_1 + l_s, x_2 - l_s) - S_a(x_1 - l_s, x_2 + l_s)) \quad (4)$$

式中: l 为相似框 T 的边长; l_s 取 l 的 $1/2$ 。对于 AF 的平滑处理是一个加权平均的过程,如下所示:

$$\overline{AF}(i, j) = \sum \frac{\omega(x, y) \times AF(i, j)}{\sum \omega(x, y)} \quad (5)$$

式中: (i, j) 为 AF 中任意网格点, $\overline{AF}(i, j)$ 表示平滑后的估计值, $\omega(x, y)$ 代表赋予平滑处理前 $AF(i, j)$ 的权重因子。

$$\omega(x, y) = \exp\left(-\frac{Z(x, y)}{h^2}\right) \quad (6)$$

式中: h 为平滑系数。

3) 参数选取

平滑过程中,平滑系数 h 、搜索窗口 F 以及相似窗口 T 的大小对处理的结果起着至关重要的作用,需根据信号噪声的强度合理调控 h 、 F 、 T 的大小以便获取较好的平滑效果,下面对相应参数值的选取进行讨论。

积分加速后算法的加权核函数性能主要由欧氏距离 $Z(x, y)$ 与平滑系数 h 的比值决定, h 控制了权值函数的衰减进而影响了权值的大小,其决定了图像的平滑程度,而 F 和 T 尺寸的选取影响了平滑过程的计算复杂度。基于本文的研究背景,在减小算法复杂度的同时还应对信号的 AF 进行充分的平滑处理以抵抗复杂电磁环境带来的干扰,便于后续有效提取信号蕴含的特征信息。

F 和 T 的大小通常是不同的,分别代表了 2 个不同的尺度。在搜索窗口中寻找与待平滑像素点相似的图像块,可以理解为一种宏观的搜索策略;而在相似窗口中计算相似度则更侧重于局部细节的处理,可以看作是一种微观的计算方式。这 2 个尺度的结合使得平滑算法在去除噪声和保留细节方面具有更好的性能。应用于本文 AF 平滑处理中, F 和 T 的尺寸同取 3×3 时计算复杂度降到最低。对于 T 的搜索过程而言,不必再对 F 进行逐个像素的遍历,可直接计算其中像素的权值,并由于 F 的大小完全限制了 T 的滑动,从而更准确地找到与待平滑点相似的像素,更好避免了计算过程中的噪声干扰。经综合考量,取平滑系数 $h = 0.2$ 。

采用参数 $h = 0.2$ 、 $F = 3 \times 3$ 、 $T = 3 \times 3$ 的加速后 NLM 方法对 M 伪随机序列 (M pseudo random sequence, MSEQ) 的 AF 分别在信噪比 (signal to noise ratio, SNR) 为 6 和 2 dB 的环境下进行平滑处理,平滑结果如图 1 所示。由图 1(a)、(c) 可以看出,在受到强噪声的干扰下, MSEQ 的 AF 出现了严重的失真;由图 1(b)、(d) 可见,经全局相似性平滑处理后, AF 中部分毛刺被去除且保持了主要形状结构, MSEQ 的 AF 内部信息得以凸显。

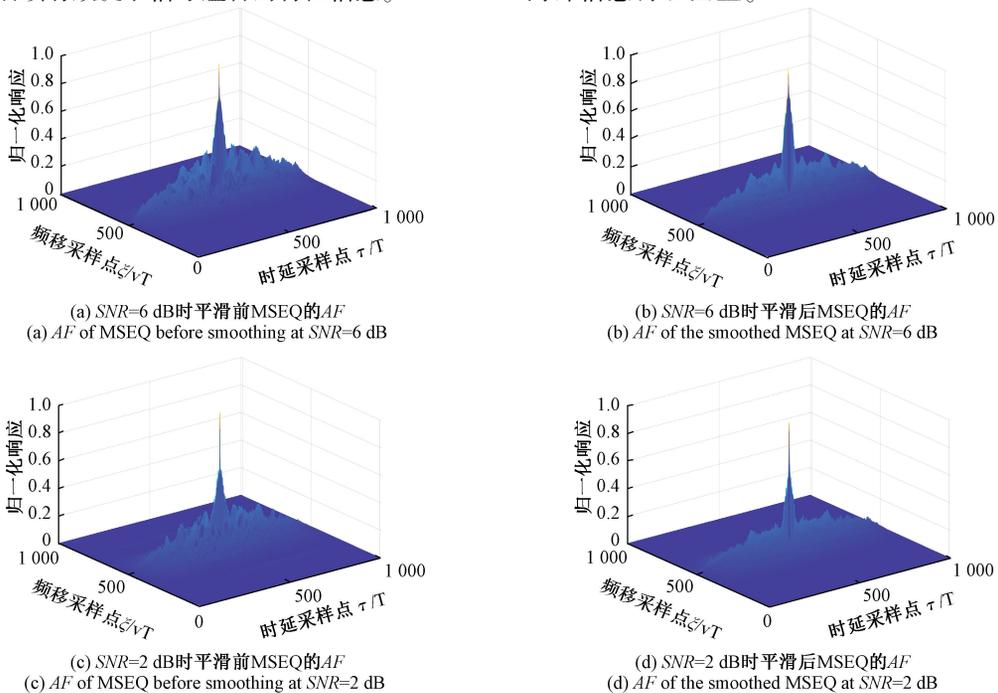


图 1 MSEQ 的 AF 在 6 和 2 dB 下的平滑效果

Fig. 1 Smoothing effect of AF of MSEQ at 6 and 2 dB

2 多维结构度量特征

信号的 AF 图呈三维分布,若直接从中提取三维特

征,复杂度太高。特征提取时应兼顾提取速度与 AF 特征信息的完整性。观察 AF 的全局结构,能够发现其形状具有类似山脉一样的分布特点。

2.1 主特征提取

1) 分布离散度

不同信号的 AF 有各自的分布结构,其能量的分布也有很大区别。从时延方向观测 AF 主视图,其最高处投影所得结构如同山岭一般连绵,层峦叠嶂,此起彼伏,9类信号投影如图2所示。由于“岭”包含了大部分 AFMR 切面,其能量远高于同时延条件下其他构成 AF 的成员,因此其同样具有较好的抗噪声性能以及独特的分布特性,可作为特征选取的基础。

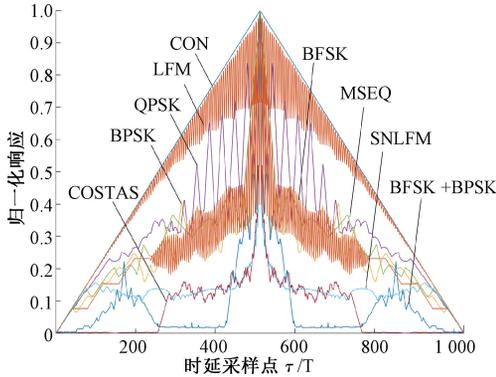


图2 9类信号的 AF 主视图岭的投影

Fig. 2 Projection of AF main view ridges for class 9 signals

设 AF 岭的采样域为 α , 其归一化响应用 $H(\alpha)$ 表示, 由于 AF 的对称性, 取一半区域 μ 即可。文献[15]引入矩特征相关思想, 使用一阶原点矩作为重心描述岭的能量集中度, 但由于岭的分布偏斜不均, 并不能很好的反映信号的特性分布; 而能量的波动性与稳定性则可以提供更加全面的特征信息, 能更有效的描述岭的构成。为表示该特性, 定义岭的标准差 Dis_α , 即分布离散度, 首先计算能量的均值 C 。

$$C = \frac{\int_0^\mu \alpha |H(\alpha)|^2 d\alpha}{\int_0^\mu |H(\alpha)|^2 d\alpha} \quad (7)$$

式中: $|H(\alpha)|^2$ 为采样域对应的能量。则分布离散度 Dis_α 为:

$$Dis_\alpha = \sqrt{\frac{\int_0^\mu (H(\alpha) - C)^2 |H(\alpha)|^2 d\alpha}{\mu}} \quad (8)$$

2) 峰值差分

与主视图相比, 从频移方向观测 AF 的侧视图则反映了山峰向斜成山, 背斜成谷的地势, 9类信号投影如图3所示, 其“峰”对应的模糊能量同样较高, 且不同信号 AF 的峰各有特色和差异, 可提取相应特征。由于主峰高耸孤立, 具有较好的辨识度, 文献[15]采用了阈值法寻找主峰的分布, 这种方法计算复杂度较低, 但缺点是应对不

同种类信号都采用同一阈值判定主峰位置。在噪声干扰下, 若阈值选择不恰当会造成主峰分布的误检。

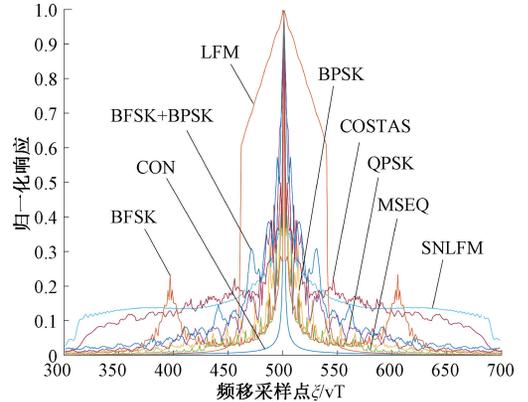


图3 9类信号的 AF 侧视图峰的投影

Fig. 3 Projection of AF side view peaks for class 9 signals

除较为显著的主峰位置信息可作为特征以外, 各副峰所含信息同样不可忽视。 AF 侧视图反映了信号的频移特性, 相邻峰值的差分则可表示频移的变化幅度, 以此捕捉到频移的变化趋势, 而部分由噪声引起的波形突变成分会在差分计算中相互抵消, 以降低噪声干扰。因此, 可将各相邻峰值间差分作为分选的有效特征之一, 考虑到差分数据较多, 将所有差分值求和, 压缩为单一值可大幅缩减数据的维度, 从而构成整体的频移信息特征值。

设 AF 峰的采样域为 β , 对应的归一化响应为 $P(\beta)$, 因 AF 的对称性, 取其一侧对应的有效采样域为 λ , 在此区间内按顺序搜寻各峰值 p_i 。

$$p_i = [p_1, p_2, p_3, \dots, p_n], \quad n \in \lambda \quad (9)$$

计算相邻峰值间差分的总和 Spd_β :

$$Spd_\beta = \sum_{i=1}^{n-1} (p_{i+1} - p_i) \quad (10)$$

2.2 副特征提取

为尽可能分离不同的信号, 除以上所述 AF 能量较大的特征之外, 还可通过其他细微结构信息来辅助信号的分选。由 AF 的体积不变性定理可知, AF 仅与信号的能量强度相关, 不同信号以不同方式分配模糊体积, 导致投影所得岭和峰的形态各异, 其波形结构与陡峭程度有明显差异, 可从中提取不易受到环境干扰、表现较为稳定的无量纲指标。

定义波形因子 W , 为归一化响应的峰值与有效值之比, 以表示 AF 波形的尖锐程度, 又 AF 关于原点对称, 岭的波形因子 W_α 为:

$$W_\alpha = \frac{\sqrt{\frac{1}{\mu} \sum_{i=1}^{\mu} |H(\alpha)|^2}}{\frac{1}{\mu} \sum_{i=1}^{\mu} |H(\alpha)|} \quad (11)$$

则峰的波形因子 W_β 为:

$$W_\beta = \frac{\sqrt{\frac{1}{\lambda} \sum_{i=1}^{\lambda} |P(\beta)|^2}}{\frac{1}{\lambda} \sum_{i=1}^{\lambda} |P(\beta)|} \quad (12)$$

定义峭度因子 K_α , 是峭度与方差的比值, 用于描述 AF 峰值的陡峭程度, 数值越大表示峰值越陡峭, 岭的峭度因子 K_α 为:

$$K_\alpha = \frac{\frac{1}{\mu} \sum_{n=1}^{\mu} |H(\alpha)|^4}{\left[\sqrt{\frac{1}{\mu} \sum_{n=1}^{\mu} |H(\alpha)|^2} \right]^4} \quad (13)$$

则峰的峭度因子 K_β 为:

$$K_\beta = \frac{\frac{1}{\lambda} \sum_{n=1}^{\lambda} |P(\beta)|^4}{\left[\sqrt{\frac{1}{\lambda} \sum_{n=1}^{\lambda} |P(\beta)|^2} \right]^4} \quad (14)$$

由此, 可构建由 2 个主特征, 4 个副特征组成的 6 维特征向量 \mathbf{V} , 即:

$$\mathbf{V} = [Dis_\alpha, W_\alpha, K_\alpha, Spd_\beta, W_\beta, K_\beta] \quad (15)$$

3 辐射源信号在线分选

3.1 信号数据流

大量连续传输且潜在无限的有序数据序列称为数据流, 其中蕴含着重要的时间动态信息。实际电子对抗中, 雷达侦察接收机所截获的信号是持续到达、密集交叠的, 即交错脉冲流。对雷达辐射源信号的在线分选可抽象转化为数据流的实时分选去交错问题。

目前, 信号分选绝大多数都采用事先收集数据再处理的方法, 即静态处理^[16]。对于脉冲流中时间变化信息的挖掘能力较低, 无法满足电子对抗中快速有效的实时响应需求。

3.2 半监督在线分选模型

针对数据流的动态特性, Din 等^[17]提出了一种在线的半监督学习算法, 该算法可有效处理实时演化的数据流。其基本思想是通过动态维护系统中的聚类概要, 以应对不断演化的数据流, 主要包含初始化学习模型、分类模型和在线数据维护模型 3 个模块。

为进一步提高计算和搜索效率, 本文采用高斯加权方法对 KNN 分类模型进行优化, 构建了基于高斯加权 KNN 分类的半监督学习信号在线分选模型, 该模型分选流程如下。

1) 初始学习, 往初始模型中传入少量带标签的先验信号样本, 使用 K-means 算法对该部分数据进行聚类, 从

而获得聚类概要以创建初始学习模型。

2) 实时分选, 以聚类概要为标准, 使用高斯加权的 KNN 分类器预测每个传入系统的待分选无标签信号。分类器工作时, 若传入信号被预测为现有类, 则增加对应类簇的中信号的数量, 否则将判定该信号为新一类, 并以此创建新类微簇并添加到聚类概要中。

3) 在线维护, 分选期间内被打上标签的信号将增加其对应类簇的能量, 可靠性增加。反之, 随着时间的推移, 某些未能增添信号数量的微簇, 其能量会陆续衰减, 可靠性降低, 直到被模型消除。通过这种方式, 算法可快速适应局部概念漂移, 而不影响整个数据空间。

3.3 高斯加权的 KNN 分类器

对于实测信号数据, 每一个新进入系统的信号特征向量都将与 KNN 分类模型中现存的所有数据进行对比, 在如今脉冲密度激增, 调制参数复杂的战场上, 这无疑会使得信号的实时分析速度大幅降低。

为应对上述问题, 本文将原算法中 KNN 分类模型计算新旧数据间相似度调整为使用高斯加权的相似性比较。利用高斯加权的思想虽会额外增加计算样本权重、加权距离等运算量, 但使用了相似性加权的距离来衡量样本间的相似度, 在算法选取 k 个最近的样本时, 考虑了相似性信息, 进而加快了搜索效率。

首先, 计算样本间的距离 D 如下:

$$D = \sqrt{\sum_{i=1}^m (x_i - y_i)^2} \quad (16)$$

式中: x_i 与 y_i 分别是 2 个向量 \mathbf{x} 和 \mathbf{y} 在第 i 维的数值。然后计算高斯权重 f_j 。

$$f_j = \exp\left(-\frac{D_j^2}{2\sigma^2}\right) \quad (17)$$

式中: D_j 是第 j 个样本与待预测样本间的距离; σ 为高斯核函数中的标准差。

综上所述, 本文信号在线分选算法完整流程如算法 1 所示。

算法 1 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算法

- 1 初始化变量
- 2 输入:
- 3 Types: 待分选信号类别
- 4 Num: 每类信号产生的个数
- 5 SNR: 信噪比
- 6 n: 信号长度
- 7 N: 信号重采样长度
- 8 输出:
- 9 V: 特征向量
- 10 Acc: 分选准确率
- 11 for all Types do
- 12 for all SNR do

```

13 for all Num do
14     生成离散信号  $Signal(n)$ ;
15     据有理式  $N/n$ , 将  $Signal(n)$  重采样为  $Signal(N)$ ;
16     根据计算式(1)计算信号  $AF$ ;
17     取  $h = 0.2, F = 3 \times 3, T = 3 \times 3$ , 使用积分加速后的
NLM 方法对  $AF$  进行平滑处理;
18     根据式(7)~(14)分别计算  $Dis_\alpha, W_\alpha, K_\alpha, Spd_\beta, W_\beta, K_\beta$ ;
19     构建特征向量

$$V = [Dis_\alpha, W_\alpha, K_\alpha, Spd_\beta, W_\beta, K_\beta];$$

20     对  $V$  应用 3.2 与 3.3 节算法进行信号分选;
21     结束
22 结束
23 结束
24 统计分选结果  $Acc$ 

```

4 实验方案与分析

4.1 构建信号数据流

为验证本文方案可行性和特征有效性,选取 CON、LFM、SNFLM、MSEQ、BPSK、BFSK、QPSK、COSTAS 以及 BFSK+BPSK 混合调制共 9 类信号进行在线分选实验。

其中,LFM 与 SNLFM 带宽均取 10 MHz, MSEQ 使用 [1 0 1 1 1 0 0] 的伪随机序列, BPSK 和 BFSK 均采用 13 位 Barker 码, COSTAS 频率编码取 [1 2 4 8 5 10 9 7 3 6], QPSK 采用 16 位 Frank 码, BFSK+BPSK 使用频率编码 [3 2 6 4 5 1] 和 5 位 Barker 码混合调制。所有信号脉宽均取 10 μ s, 除 BFSK 信号的 2 个频点分别取 10 和 2 MHz 以外,其余信号的载频均为 10 MHz,所有信号重采样长度为 1 024 点。

依据上述信号类别及参数,仿真生成信号数据流。9 类信号每类各生成 1 200 个共计 10 800 个纯净信号样本并随机交替排列,形成连续采样且具有一定顺序的密集叠脉冲数据流序列。为便于更好地进行测试,忽略信号真实情况下传递的时间信息,仅以先后顺序排列模拟实时接收到的信号,并使用各时段的成功分选平均值作为在线分选整体准确率。实验所用计算机为惠普 OMEN 16, CPU 为 2.30 GHz, 内存为 16.0 GB, 仿真平台为 MATLAB 2021a。

4.2 参数寻优

信号分选准确率受限于平滑算法以及高斯加权 KNN 分类器的性能,需寻取最优的参数,以构建适合信号数据流的在线分选模型。

实际上,信号本身具有较高的复杂性和多样性,可用的信号先验数据极其有限。分选实验中认定信号数据集前 200 个样本为先验数据,优先进入学习模型形成聚类概要,剩余 10 600 个数据作为测试集随后依次传入分类模型。实验最终选取平滑系数 $h = 0.2$, 超参数 $k = 4$, 对所选值进行如下分析。

1) 平滑系数的选取

为测试 h 取值对于系统的影响,固定 k 值为 4, σ 作为高斯分布的标准差,通常情况下选取为 1。信号流数据集处于 $SNR = 2$ dB 的环境下, h 取 0.1 ~ 1 且步长为 0.1 时,不同 h 取值对分选正确率的影响如图 4 所示。

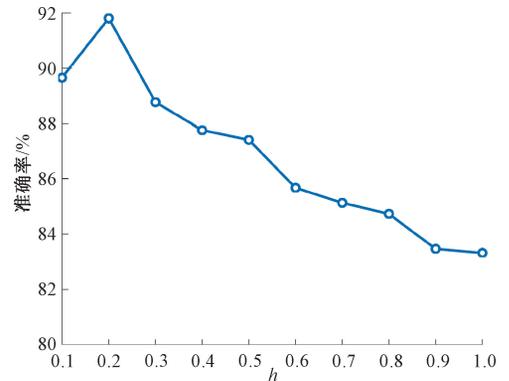


图 4 不同平滑系数下正确分选率变化

Fig. 4 Comparison of correct sorting rate for different smoothing factors

由图 4 可见,起初增加 h 的取值加强了平滑效果,对于噪声有着较好的抑制作用,在 $h = 0.2$ 时,分选准确率达到最高。但随 h 取值不断增加,信号的 AF 上出现了过平滑现象,局部细节信息丢失严重,所提取的特征信息难以区分,加大了分选的误差,因此设置平滑系数为 0.2。

2) k 值的选取

信号分选速度以及准确度很大程度依赖于分类器中 k 值的选取,它控制着算法选择多少个最近邻样本对待分选数据进行预测。设置所有信号的 SNR 为 2 dB, 固定 $h = 0.2, \sigma = 1$, 调整 k 值进行分选实验。首先,测试 KNN 算法调整前后不同 k 值对模型耗时的影响,结果如图 5 所示。

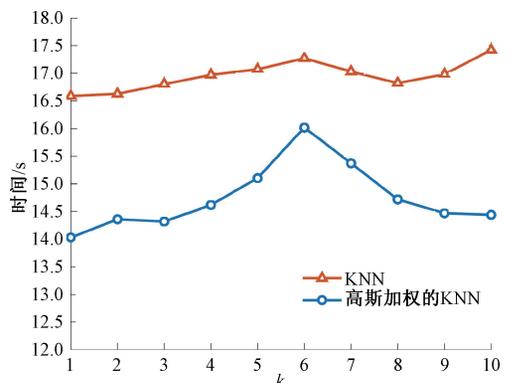


图 5 不同 k 值下系统耗时变化

Fig. 5 Comparison of system time consumption for different values of k

从图 5 可以看出,使用原始算法进行的分选实验中,由于每个新数据都会与最近 k 个现存样本进行比对,而 k 值越大,需要比较的样本就会越多,从而导致算法耗时增加。当 k 取 7 和 8 时,由于样本中彼此相似的数目相对较多,使算法更容易分类,耗时反而有所下降。在引入高斯加权的相似性比较后, k 取 1~10 的平均耗时缩短了 13%,且 $k=6$ 的耗时到达了顶峰。后续虽增大 k 值,但时间消耗却陆续减少,因 k 值较大时,离待分类数据较远的样本对于相似度计算的贡献极小,其权重几乎可以忽略不计,从而降低了算法的计算复杂度。而改进后系统分选正确率随参数调整的变化则如图 6 所示。

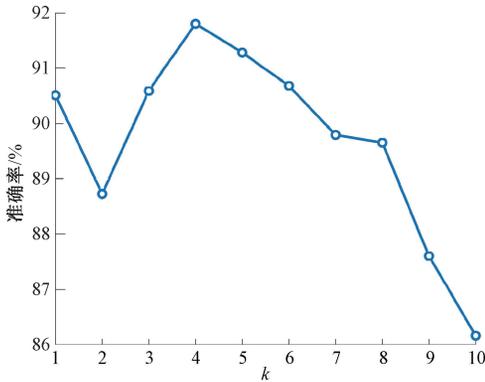


图 6 不同 k 值下正确分选率变化

Fig. 6 Comparison of correct sorting rate for different values of k

由图 6 可知, k 值小于 4 时,所选取的近邻样本较少,对异常值和局部情况过于敏感,模型泛化能力不足,引起分选错误率增加;而 k 的取值超过 4 时,正确率逐步降低,因 k 的取值过大,过多引入不必要的比对样本,导致模型欠拟合从而使性能下降。

综合运行耗时与分选准确度,设置 $k=4$,即对于任意待分选数据,使用 4 个最近已知样本进行预测投票。

4.3 实验性能比较

实验通过对不同平滑算法、不同特征提取方法、不同分选方案共 3 个部分进行综合性能的对比探讨,以验证本文在不同实验阶段采用的方法和整体分选模型的有效性和泛化能力。实验信号 SNR 处于 2~18 dB 环境下,每隔 2 dB 生成一组随机连续交叠的信号数据流样本。

1) 不同平滑算法的比较

为研究不同平滑方法对信号 AF 的去噪效果影响,采取高斯平滑法^[18]、滑动平均法^[19]进行对比实验,不同 SNR 分选正确率如表 1 所示。

由表 1 可见,高斯平滑法在 SNR=2 dB 的信噪比下识别准确率仅有 74.86%,这是因为该方法易导致 AF 出现过平滑现象,使信号的细节信息在低信噪比下模糊化严重,而高信噪比下,信号保留了更多自身信息,噪声影响相对较小,因此准确率有明显提升。相比之下,滑动平均法在低信噪比时平滑性能有着大幅提升,且在 SNR=2 dB 时,此方法相较本文方法更具优势,由于其仅

表 1 不同平滑算法的正确分选率

Table 1 The correct sorting rates for different smoothing algorithms

	%								
平滑算法	2 dB	4 dB	6 dB	8 dB	10 dB	12 dB	14 dB	16 dB	18 dB
高斯平滑	74.86	82.57	93.36	97.61	98.10	98.50	99.62	99.85	100
滑动平均	93.82	94.96	95.58	96.88	98.14	98.42	99.92	100	100
本文算法	91.80	95.70	96.64	99.57	99.79	99.96	100	100	100

采用了局部信息进行平滑,而本文算法考虑了 AF 图像的全局情况,进而受到了更多噪声的干扰。然而,随信噪比增高,噪声对信号的影响减小,本文算法则更好的利用了全局信息进行平滑,从而提高了分选准确率。SNR=4 dB 以上时,性能均优于其余两种方法,且在 SNR=8 dB 时,正确分选率就已达到 99% 以上,具有更快的收敛性。

2) 不同特征性能的比较

选取有效且分辨力强的特征是信号分选的基础,为验证本文提取特征的性能,选取 AF 三维特征^[15]、动态时间规整(dynamic time warping, DTW) 距离特征^[20]以及双谱特征^[21] 3 种提取特征方法进行对比实验,结果如图 7 所示。

由图 7 可知,文献[21]采取双谱估计法提取特征,其特征是对信号相位噪声特性进行提取,在受到噪声

影响下该特征鲁棒性较差,导致整体正确分选率不佳。文献[15]使用了模糊函数的主岭重心、主峰分布半径构成的三维特征进行分选,但该特征对噪声较为敏感,强噪声影响下,信号的 AF 产生形变,主岭重心偏移严重,且以同一阈值也易误判不同信号的主峰分布,SNR=2 dB 时,分选成功率仅有 82.46%。文献[20]以 DTW 计算信号间的相似度从而构建距离特征,不同 SNR 的性能相对较好,SNR=2 dB 时,正确分选率达到了 88.67%,但此方法时间复杂度较高且分选准确率整体低于本文特征。而本文所取的多维特征兼顾了 AF 的时频域信息,全面描述了 AF 的特性,且具有较好的抗噪声性能,在 SNR 为 2~10 dB 环境下,分选成功率均优于其余 3 种特征。

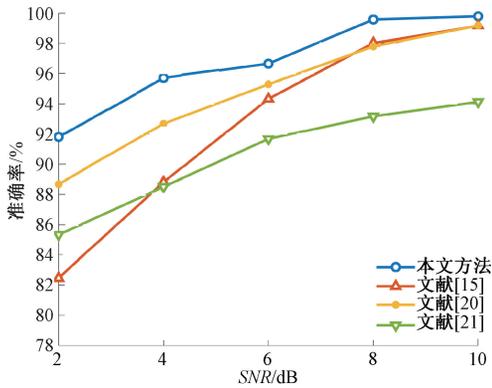


图7 不同特征性能的比较

Fig. 7 Comparison of the performance of different features

3) 不同分选方案的比较

为验证本文整体方案的有效性,通过实验与文献[4,22-23]的方法进行对比分析,观察动态 SNR 时信号的平均分选成功率,实验结果如图 8 所示。

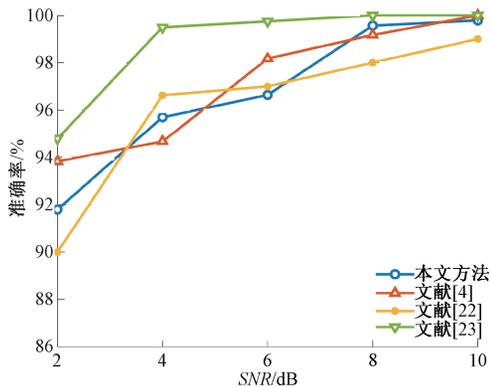


图8 不同分选方案的对比

Fig. 8 Comparison of different sorting options

由图 8 可见,当 SNR=2 dB 时,4 种方法的分选准确率均能达到 90% 及以上。其中,文献[23]采用深度卷积去噪自编码器识别信号,在不同 SNR 下的分选结果表现最优,SNR=4 dB 就已达到 99.5% 的正确率,但该实验以 1 200 个信号为一组并需 CR 分类器进行 50 次迭代,平均所需 223.7 s 得出分选结果,时效性不足。文献[4]使用 AFMR 作为分选特征,具有较强抗干扰能力,但使用 KFCM 聚类方法进行分选,需要人为指定聚类数目,同时也需一定时间迭代计算,在 SNR=2 dB 环境下准确率仅比本文方法高出 2%。文献[22]基于分数傅里叶变换,提取 4 组改进的相似系数构成特征向量并使用 KNN 分类器进行分选,其同样利用了不同信号间的波形差异作为分选基础,在 SNR=4 dB 时,成功分选率达到了 96.3%,略优于本文方法,但在 SNR=2 dB 时,识别率略低,且高信噪比下的收敛性较差。

SNR=2 dB 时,本文方法正确分选率优于文献[22]方法,略低于文献[4]方法;SNR=4 dB 环境下与文献[22]方法几乎持平;SNR=8 dB 及以上时,准确率收敛迅速,与文献[23]方法相差无几。相较其他 3 种方法,本文方法虽未在 SNR 为 2~8 dB 环境下,分选成功率均达到最优,但优势在于信号的分选全程在线运行,且并不需要训练大量样本或是多次迭代计算。通过在线维护模块的实时响应,并结合分类模型进行新旧数据间的比对直接得出结果,实现了脉冲流的实时分选。

4.4 系统性能分析

1) 稳定性分析

整个系统的运行需要一定的先验样本优先静态聚类预处理,而实测数据的分选是实时进行的,同时分选的标准也在实时更新,为保证信号的分选准确性,需要系统尽快趋于平稳并保持稳定。使脉冲流分别处于 2、4、6 dB 的 SNR 环境下,保持先验数据量为 200,按接收顺序计算每到达 1 000 个样本的正确分选率,结果如图 9 所示。

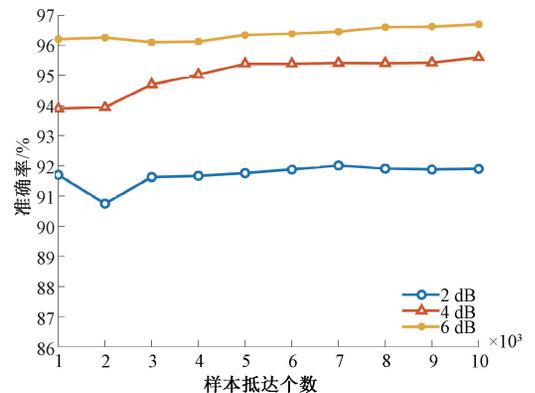


图9 样本在线抵达量与正确分选率变化

Fig. 9 Comparison of correct sorting rate of sample online arrivals

由图 9 可见,在 SNR=2 dB 的环境下,随接收数据量增加,分选准确率稍有降低,但当第 3 000 个样本抵达时,正确率迅速回升近 92% 并保持稳定,波动范围不超过 0.2%。而 SNR=4 dB 时,分选成功率起初仅有 93.9%,但随时间推进,系统逐渐矫正聚类概要中的信号类别,使得准确率逐步提升,直到接收第 5 000 个数据时保持稳定,准确率达到 95.38%。当 SNR 增加至 6 dB,整体分选准确率保持较高水平,虽在接收到第 3 000 个样本使准确率有略有波动,但从第 4 000 个数据开始,准确率保持小幅度上升。综上所述,应对不同信噪比下噪声的影响,本文系统处于在线分选信号的过程中仍能保持较好的稳定性。

2) 先验数据依赖性分析

先验数据量对模型的整体正确分选率具有一定影响,可通过不同的数量先验样本验证系统的鲁棒性。将先验数据量从 200 逐步增加至 800,步长为 100,在信号数据流的 SNR 分别处于 2、4、6 dB 的环境下进行实验,且测试样本数量均为 10 000,平均准确率如图 10 所示。

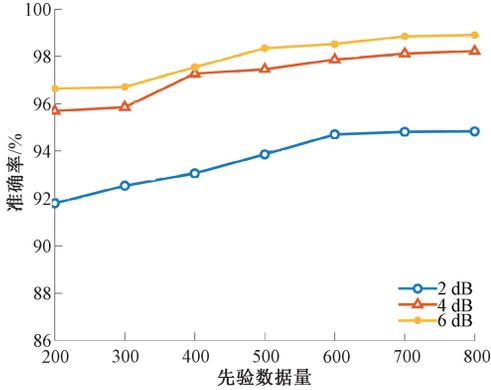


图 10 不同先验数据量下的正确分选率

Fig. 10 Comparison of correct sorting rate for different amounts of a priori data

实验结果表明,信号数据流的在线分选平均准确率随先验数据量的增加而提高,且 SNR 越高上升幅度越平缓。当先验数据量大于 500 时,3 种 SNR 情形下,正确分选率上升幅度细微,系统整体性能趋于平稳。SNR=2 dB 的环境下,先验数据量从 200 增加至 800 时,分选成功率变化幅度达到了 3.03%,因 SNR 较低,所以先验样本的增加对准确率影响相对较大;而 SNR 为 4 和 6 dB 的环境下,随先验数据量增加至 800,变化幅度分别仅有 2.52% 及 2.26%,均处于 3% 以下。验证了在较低 SNR 及先验数据较少的情况下,本文整体系统仍具有良好的类内聚敛性和鲁棒性。

表 2 实测雷达辐射源信号数据参数

Table 2 Measured radar radiation source signal data parameters

辐射源	调制类型	RF/MHz	PW/ μ s
1	线性调频	9 645,9 662,9 682,9 750,9 810 5 个频点波位组变,频率分集	20
2	非线性调制	9 762,9 773,9 792,9 807,9 822,9 833 6 个频点波位组变	3~5 个脉冲一组,每组 PW 在 7、3 任意
3	常规脉冲	9 500~9 700 单脉冲捷变	3~5 个脉冲一组,每组 PW 在 0.9、1.0、1.1、1.2 任意
4	非线性调制	9 850 固定	16
5	线性调频	9 513,9 518,9 523,9 548,9 553,9 563 6 个频点波位组变	3~5 个脉冲一组,每组 PW 在 6、12、18 任意

4.6 复杂度分析

信号数据流的在线分选需要在信号采集的过程中及时地对信号进行处理和判别,以实现快速响应,因此实时性是衡量雷达信号在线分选方法优良的一个重要指标。实验选取文献[4,18,21,24]的特征提取方法与本文方案进行对比,复杂度及特征提取耗时如表 3 所示。

4.5 实测雷达数据实验

为进一步验证本文方法在实际战场中的应用价值,采用某雷达外场部分实测数据进行实验。选取 5 种雷达辐射源产生的各 700 个信号,总计 3 500 个样本,并混合形成数据流,辐射源信号集参数如表 2 所示。实验以数据集前 100 个信号作为先验数据,剩余样本作为实测数据,按次序输入分选系统,分选准确率变化如图 11 所示。

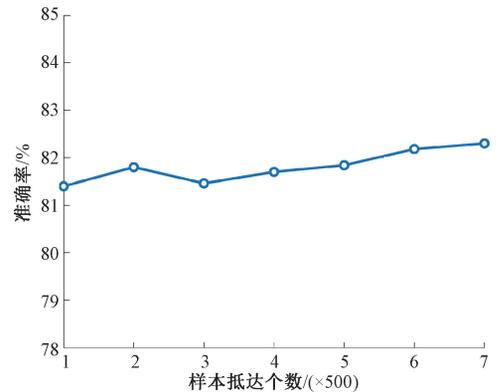


图 11 实测样本抵达数与分选准确率变化

Fig. 11 Comparison of correct sorting rate of measured sample arrivals

由表 2 可知,辐射源信号的调制类型与参数均有不同程度的交叠,基本符合实际战场复杂电磁环境需求。从图 11 可见,随实测数据陆续被分选,由于信号的存在明显的跳变,分选效果受限,准确率整体上升幅度较为细微,但平均分选准确率仍能达到 81.85%。由此可见,作为仿真实验的补充,本文方法在真实复杂的电磁环境下具有一定实际应用价值。

文献[4]提取 AFMR 特征使用了分数自相关计算任意角度的 AF 值,单次运算需要进行一次傅里叶反变换和一次 $(1 + P)$ 阶的快速傅里叶变换(fast Fourier transform, FFT),复杂度分别为 $O(M\log N)$ 和 $O(9M\log N)$,此外,当搜索精度为 0.1° 时,在 $[-\pi/2, \pi/2]$ 区间内搜索 AFMR 的搜索次数为 1 800 次,因此该方法复杂度为 $O(18\ 000M\log N)$ 。

表3 不同方法的算法复杂度对比

Table 3 Comparison of algorithm complexity of different methods

分选特征	算法复杂度	特征提取耗时/s
文献[4]	$O(18\ 000N\log N)$	4.52
文献[18]	$O(N\log N + (2M + 3)N^2)$	0.24
文献[21]	$O(KN\log N + 2N)$	0.16
文献[24]	$O(N^3 + 2N\log N + 2N)$	3.67
本文方法	$O(N\log N + L^2N^2)$	0.29

文献[18]的等高线特征提取是面向网格采样的离散 AF 值,使用 FFT 计算信号的 AF 值,复杂度为 $O(N\log N)$ 。其次,使用掩膜尺寸为 M 的高斯平滑对 AF 进行逐行平滑,再对中间结果逐列平滑,复杂度为 $O(2MN^2)$ 。等高线求解过程考虑相邻 AF 间均有等值点存在,复杂度为 $O(3N^2)$,此方法总复杂度为 $O(N\log N + (2M + 3)N^2)$ 。

文献[21]首先计算了双谱的幅度谱,使用了 K 次 FFT,单次 FFT 的计算复杂度为 $O(N\log N)$,则该步骤复杂度为 $O(KN\log N)$ 。随后需计算幅度谱截面分选维数中的合维数和信息维数,其复杂度为 $O(2N)$,因此算法总复杂度为 $O(KN\log N + 2N)$ 。

文献[24]实现过程是对文献[21]进行了改进,通过 Choi-Williams 分布取代双谱提取分选维数,其次使用频谱的奇异熵作为分选特征。其中奇异值的分解涉及到时频矩阵的乘法计算,复杂度为 $O(N^3)$,Choi-Williams 变换及频谱通过 FFT 实现,此方法总复杂度为 $O(N^3 + 2N\log N + 2N)$ 。

本文方法提取了 AF 主侧视图的特征,计算 AF 与文献[18]相同,此过程的复杂度为 $O(N\log N)$,随后使用 NLM 方法进行去噪处理,其复杂度为 $O(L^2l^2N^2)$, L 和 l 分别是搜索窗口 F 与相似窗口 T 的边长。进一步使用积分图加速平滑,将偏移量 a 作为主循环变量,复杂度降至 $O(L^2N^2)$,而对于特征向量成员的计算可忽略不计,因此本文方法的算法总复杂度为 $O(N\log N + L^2N^2)$ 。

综上所述,从方法阶数分析,文献[24]所用方法复杂度阶数最高,其次是文献[18]与本文方法,文献[4,21]的复杂度阶数最低,但常系数各自不同,复杂度主要取决于信号采样长度 N ,而 N 通常取值在 128~1 024,可对算法总计算量 I 进行估算,总计算量对比结果为:

$$I_{\text{文献}[21]} < I_{\text{文献}[18]} \approx I_{\text{本文方法}} < I_{\text{文献}[24]} < I_{\text{文献}[4]}$$

可见,本文所提算法有着较好的实时性,能够满足实际需求。

5 结 论

为应对雷达辐射源信号特征信息易受噪声影响及分选实时性差的问题,本文提出一种信号数据流在线分选思路。首先,从与图像处理相似的角度出发,利用 AF 的全局信息进行快速相似性平滑处理以降低噪声的影响,进而最大程度上保留 AF 的结构信息,并且从 AF 主、侧投影图结构上提取多维分选特征,同时兼顾了 AF 的时、频分布信息,有效的降低直接从 AF 三维结构上抽取特征的计算量,缓解了实际应用的时间压力。其次,针对现有方法分选时效性不足的情况,将信号脉冲流抽象为数据流,利用改进后的半监督在线分选模型,使用高斯加权的分类器进一步减少了信号分选耗时,脱离传统静态处理数据的约束,实现了信号数据流的在线分选。

实验结果与算法分析表明,本文所采取的方法在不同信噪比下具有良好的分选准确率与反馈时效性能,具有一定的工程应用价值。

参考文献

- [1] DONG Z, LV F, WAN T, et al. Radar signal modulation recognition based on bispectrum features and deep learning[C]. 2021 International Conference on Computer Engineering and Application (ICCEA), IEEE, 2021: 63-67.
- [2] SEDDIGHI Z, AHMADZADEH M R, TABAN M R. Radar signals classification using energy-time-frequency distribution features[J]. IET Radar, Sonar & Navigation, 2020, 14(5): 707-715.
- [3] TIAN C, HONG M, LI D, et al. Deep recurrent neural network for ground-penetrating radar signal denoising[C]. 2022 4th International Conference on Intelligent Information Processing (IIP), IEEE, 2022: 85-88.
- [4] 普运伟,金炜东,朱明,等. 雷达辐射源信号模糊函数主脊切面特征提取方法[J]. 红外与毫米波学报, 2008(2): 133-137.
PU Y W, JIN W D, ZHU M, et al. Extracting the main ridge slice characteristics of ambiguity function for radar emitter signals[J]. Journal of Infrared and Millimeter Waves, 2008(2): 133-137.
- [5] 普运伟,郭媛蒲,侯文太,等. 模糊函数主脊切面极坐标域形态特征提取方法[J]. 仪器仪表学报, 2018, 39(10): 1-9.

- PU Y W, GUO Y P, HOU W T, et al. Morphological feature extraction based on the polar transformation of the slice of ambiguity function main ridge [J]. *Chinese Journal of Scientific Instrument*, 2018,39(10):1-9.
- [6] 许程成,周青松,张剑云,等. 导数约束平滑条件下基于模糊函数特征的雷达辐射源信号识别方法[J]. *电子学报*,2018,46(7):1663-1668.
- XU CH CH, ZHOU Q S, ZHANG J Y, et al. Radar emitter recognition based on ambiguity function features with derivative constraint on smoothing [J]. *Acta Electronica Sinica*, 2018,46(7):1663-1668.
- [7] 郑陵潇,吴海潇,陈磊,等. 一种快速搜索模糊函数主脊切面的自适应灰狼算法[J]. *数据采集与处理*, 2020,35(5):892-902.
- ZHENG L X, WU H X, CHENG L, et al. A self adaptive GWO for quickly searching the main ridge slice of ambiguity function [J]. *Journal of Data Acquisition and Processing*, 2020,35(5):892-902.
- [8] PU Y W, ZHANG T F, SHI Y. An improved PSO algorithm and its application in fast feature extraction of radar emitter signals[C]. *2012 8th International Conference on Natural Computation*, IEEE, 2012: 1115-1118.
- [9] WEI S, QU Q, SU H, et al. Intra-pulse modulation radar signal recognition based on CLDN network[J]. *IET Radar, Sonar & Navigation*, 2020, 14(6): 803-810.
- [10] LIAO Y, JIANG F, WANG J. Intra-pulse modulation recognition of radar signals based on multi-feature random matching fusion network [J]. *The Journal of Supercomputing*, 2023, 79(6): 6422-6451.
- [11] 司伟建,张悦,邓志安. 用于雷达信号分选的连通 k 近邻聚类算法[J]. *系统工程与电子技术*,2023,45(8):2463-2470.
- SI W J, ZHANG Y, DENG ZH AN. Connected k-nearest neighbor clustering algorithm for radar signal sorting[J]. *Systems Engineering and Electronics*, 2023, 45(8): 2463-2470.
- [12] KANG K, ZHANG Y, GUO W, et al. Key radar signal sorting and recognition method based on clustering combined with PRI transform algorithm [J]. *Journal of Artificial Intelligence and Technology*, 2022, 2(2): 62-68.
- [13] 陈建宏,赵拥军,赖涛,等. 单视全极化 SAR 图像快速非局部均值滤波[J]. *武汉大学学报(信息科学版)*, 2016,41(5):629-634.
- CHEN J H, ZHAO Y J, LAI T, et al. Fast non-local means filtering of SLC fully PolSAR image [J]. *Geomatics and Information Science of Wuhan University*, 2016,41(5):629-634.
- [14] FACCIOLO G, LIMARE N, MEINHARDT-LLOPIS E. Integral images for block matching [J]. *Image Processing on Line*, 2014, 4: 344-369.
- [15] 普运伟,侯文太,郭媛蒲,等. 基于模糊函数三维特征的雷达辐射源信号分选方法[J]. *控制与决策*,2019, 34(10):2178-2184.
- PU Y W, HOU W T, GUO Y P, et al. A sorting method of radar emitter signal based on three dimensional feature of ambiguity function [J]. *Control and Decision*, 2019, 34(10):2178-2184.
- [16] 隋金坪,刘振,刘丽,等. 雷达辐射源信号分选研究进展[J]. *雷达学报*,2022,11(3):418-433.
- SUI J P, LIU ZH, LIU L, et al. Progress in radar emitter signal deinterleaving [J]. *Journal of Radars*, 2022,11(3):418-433.
- [17] DIN S U, SHAO J, KUMAR J, et al. Online reliable semi-supervised learning on evolving data streams [J]. *Information Sciences*, 2020, 525: 153-171.
- [18] 侯文太,普运伟,郭媛蒲,等. 基于高斯平滑与模糊函数等高线的雷达辐射源信号分选[J]. *自动化学报*, 2021,47(10):2484-2493.
- HOU W T, PU Y W, GUO Y P, et al. A sorting method for radar emitter signals based on the gaussian smoothing and contour lines of ambiguity function [J]. *Acta Automatica Sinica*, 2021,47(10):2484-2493.
- [19] 普运伟,刘涛涛,吴海潇,等. 基于卷积双向长短时记忆网络的雷达辐射源信号识别[J]. *激光与光电子学进展*,2022,59(22):361-368.
- PU Y W, LIU T T, WU H X, et al. Radar emitter signal recognition based on convolutional bidirectional long-and short-term memory network [J]. *Laser & Optoelectronics Progress*, 2022,59(22):361-368.

- [20] 黄颖坤,金炜东,颜康,等. 基于距离特征的雷达辐射源信号识别方法[J]. 系统仿真学报, 2021, 33(12): 2959-2966.
- HUANG Y K, JIN W D, YAN K, et al. Radar emitter signal identification via distance features[J]. Journal of System Simulation, 2021, 33(12): 2959-2966.
- [21] CHEN C, HE M, XU J, et al. A new method for sorting unknown radar emitter signal[J]. Chinese Journal of Electronics, 2014, 23(3): 499-502.
- [22] CHEN S W, WANG G M, XING X P, et al. A method of radar signal feature extraction based on fractional fourier transform [C]. 2019 IEEE 4th International Conference on Signal and Image Processing (ICSIP), IEEE, 2019: 583-587.
- [23] ZHOU Z, HUANG G, CHEN H, et al. Automatic radar waveform recognition based on deep convolutional denoising auto-encoders [J]. Circuits, Systems, and Signal Processing, 2018, 37: 4034-4048.
- [24] 曲志昱,毛校洁,侯长波. 基于奇异值熵和分形维数的雷达信号识别[J]. 系统工程与电子技术, 2018, 40(2): 303-307.
- QU ZH Y, MAO X J, HOU CH B. Radar signal recognition based on singular value entropy and fractal

dimension [J]. Systems Engineering and Electronics, 2018, 40(2): 303-307.

作者简介



普运伟(通信作者), 分别在 1995 年和 1998 年于西南师范大学获得学士学位和硕士学位, 2007 年于西南交通大学获得博士学位, 现为昆明理工大学教授、博士生导师, 主要研究方向为智能信号处理、模式识别等。

E-mail: puyunwei@126.com

Pu Yunwei (Corresponding author) received his B.Sc. degree and M.Sc. degree both from Southwestern Normal University in 1995 and 1998, and Ph.D. degree from Southwestern Jiaotong University in 2007, respectively. He is currently a professor and a Ph.D. supervisor at Kunming University of Science and Technology. His main research interests include intelligent signal processing, pattern recognition, etc.



陈新杰, 2021 年于攀枝花学院获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为智能信号处理、模式识别等。

E-mail: 1401545585@qq.com

Chen Xinjie received his B.Sc. degree from Panzhihua University in 2021. He is currently a M.Sc. candidate at Kunming University of Science and Technology. His main research interests include intelligent signal processing, pattern recognition, etc.