

文章编号: 1671-0576(2024)03-0008-07

基于双谱三维向量的雷达辐射源个体识别

张佛生^{1,2}, 张文旭^{1,2}, 富云霄^{1,2}

(1. 哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001; 2. 哈尔滨工程大学工业和信息化部先进船舶通信与信息技术重点实验室, 黑龙江 哈尔滨 150001)

摘要: 基于相位噪声造成的辐射源个体差异, 提出了一种新的雷达辐射源个体识别算法。该算法以由双谱熵、双谱能量熵以及双谱主成分均值所组成的三维向量为特征向量, 以K-均值(K-means)算法为分类器, 完成了雷达辐射源个体识别。相比于现在比较主流的使用深度学习模型作为分类器的辐射源个体识别算法, 该算法无需繁琐的模型训练步骤也能取得较好的识别效果。仿真结果表明, 在信噪比为 0 dB 时, 该算法依然能确保 80% 的识别正确率, 算法性能优越。

关键词: 雷达辐射源个体识别; 相位噪声; 双谱; K-均值

中图分类号: TN957.3

文献标志码: A

DOI: 10.3969/j.issn.1671-0576.2024.03.002

Radar Specific Emitter Identification Based on Bispectrum Three-dimensional Vector

ZHANG Fosheng^{1,2}, ZHANG Wenxu^{1,2}, FU Yunxiao^{1,2}

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, Heilongjiang, China; 2. Key Laboratory of Advanced Marine Communication and Information Technology, Ministry of Industry and Information Technology, Harbin Engineering University, Harbin 150001, Heilongjiang, China)

Abstract: On the basis of the differences of emitters caused by phase noise, a new radar specific emitter identification algorithm was proposed. The algorithm used a three-dimensional vector composed of bispectrum entropy, bispectrum energy entropy and bispectrum principal component mean as feature vector, and completed radar specific emitter identification with K-means algorithm as classifier. Compared to the popular emitter individual identification algorithms that use deep learning models as classifiers, the proposed algorithm can achieve good identification results without the cumbersome model training steps. Simulation results show that when the signal-to-noise ratio is 0 dB, the algorithm can

收稿日期: 2023-12-10

基金项目: 黑龙江省自然科学基金(LH2020F020)

作者简介: 张佛生(1996—), 男, 硕士研究生, 主要从事雷达辐射源个体识别技术研究。

still ensure 80% identification accuracy, demonstrating superior performance.

Key words: radar specific emitter identification; phase noise; bispectrum; K-means

0 引言

在现代战争中,雷达发挥着越来越重要的作用。在战场上,敌我双方都会部署多部雷达,因此准确区分敌我雷达并获取敌方雷达的身份信息非常重要^[1-3]。然而,随着现代雷达制造技术的迅速发展,同一类型雷达之间的个体差异越来越小,这意味着通过传统方法很难区分同一类型的不同雷达个体^[4-5]。在此背景下,雷达辐射源个体识别技术应运而生。雷达辐射源个体识别是通过比较雷达信号脉内特征来区分不同雷达辐射源个体的过程^[6-7]。在所有脉内特征中,脉冲无意调制(unintentional modulation on pulse, UMOP)特征是在复杂的电磁环境中可表征雷达个体差异的理想参数,因此该特征得到了广泛的运用和研究^[8-9]。

目前,已有大量文献研究了利用 UMOP 特征来实现雷达辐射源个体识别的方法。文献[10]提出了一种自动多特征提取与融合方法,该方法利用卷积神经网络来提取和融合信号的典型特征(如幅度、相位和频谱对称性等),并利用融合后的特征完成了雷达辐射源个体识别。文献[11]利用分形理论提取了由相位噪声产生的雷达辐射源个体差异特征,并使用支持向量机完成了识别。文献[12]提出了一种基于训练序列的射频前端非线性估计器,用于完成雷达辐射源个体识别任务。

作为一种典型的脉冲无意调制特征,相位噪声几乎存在于所有雷达发射信号中。由于相位噪声的存在,即使是相同型号的不同雷达的发射信号间也必定存在微小差异^[13-14],而这些差异可用于区分不同的雷达辐射源个体。文献[15]分析了相位噪声产生的原因,并给出了相位噪声的数学模型及其测量方法。文献[16-17]对包含相位噪声的雷达辐射源信号进行了建模,并通过提取的积分双谱完成了识别。

基于以上研究,本文提出一种新的雷达辐射源个体识别算法。该算法以从雷达信号双谱中提

取的双谱熵、双谱能量熵以及双谱主成分均值为分类特征,采用 K-均值(K-means)机器学习算法作为分类器,进行雷达辐射源个体的识别。

1 相位噪声分析

理想正弦振荡器的输出电压可以表示为

$$V(t) = A_0 \sin(\omega_0 t + \varphi_0) \quad (1)$$

式中: A_0 为振幅; ω_0 为中心角频率; φ_0 为初始相位。然而,不同信号发生器的输出信号中都存在各种不同的噪声,且同一信号发生器输出的不同噪声分量之间也存在着显著差异。存在噪声的正弦振荡器的输出电压可以表示为

$$V(t) = (A_0 + \epsilon(t)) \sin(\omega_0 t + \varphi(t)) \quad (2)$$

式中: $\epsilon(t)$ 为随时间变化的调幅噪声; $\varphi(t)$ 为随时间变化的相位噪声。在实际雷达发射机中,调幅噪声可以被显著衰减甚至抑制,这意味着 $|\epsilon(t)/A_0| \ll 1$ 。所以,可忽略 $\epsilon(t)$, 而只关注相位噪声 $\varphi(t)$ 。由此,式(2)可以简化为

$$V(t) = A_0 \sin(\omega_0 t + \varphi(t)) \quad (3)$$

相位噪声一般由放大器的噪声和非线性克尔(Kerr)效应导致,通常在频域中进行测量。信号 $V(t)$ 中的相位噪声 $\varphi(t)$ 可以表示为 1 Hz 带宽内的功率与载波总功率之比,其对数表达式为

$$L_{\text{tot}}(\Delta\omega) = 10 \log_2 (P_{\text{sb}}(\omega_0 + \Delta\omega, 1 \text{ Hz}) / P_{\text{car}}) \quad (4)$$

式中: $L_{\text{tot}}(\cdot)$ 为相位噪声的对数函数; $P_{\text{sb}}(\omega_0 + \Delta\omega, 1 \text{ Hz})$ 表示偏离中心角频率 $\Delta\omega$ 处、1 Hz 带宽内的信号单边带(SSB)功率; P_{car} 为 ω_0 处的载波总功率。

为直观展示相位噪声在时域和频域上对信号的影响,现构造一个理想线性调频(LFM)信号和一个含相位噪声的 LFM 信号,其时域和频域波形分别如图 1 和图 2 所示。由图 1 可知,相位噪声会使 LFM 信号在时域上产生不规则的波动和失真。图 2 展示了两个信号在频谱上的差异,含相位噪声的 LFM 信号频谱存在较大抖动,这些

抖动使其频谱纯度低于理想 LFM 信号的。

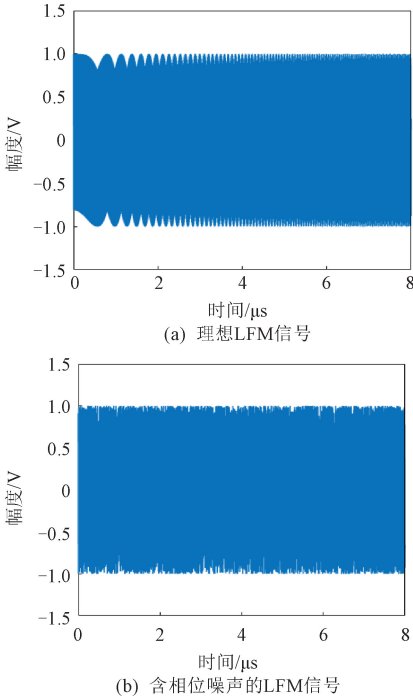


图 1 LFM 信号的时域波形对比

2 信号建模

现以 LFM 雷达信号为例,推导含相位噪声的雷达信号模型。理想的 LFM 信号的表达式为

$$s(t) = A(t) \sin(2\pi f_c t + K\pi t^2 + \varphi_0), \quad 0 \leq t \leq T \quad (5)$$


式中: $A(t)$ 为幅度函数; f_c 为信号载频; K 为线性调频斜率; T 为信号持续时间。设 $A(t) = A$,

$$\begin{cases} \cos(M \sin(2\pi f_m t)) = J_0(M) + 2 \sum_{\alpha=1}^{\infty} J_{2\alpha}(M) \cos(4\alpha\pi f_m t) \\ \sin(M \sin(2\pi f_m t)) = 2 \sum_{\alpha=1}^{\infty} J_{2\alpha-1}(M) \sin((4\alpha-2)\pi f_m t) \end{cases} \quad (9)$$


式中: $J_0(\cdot)$ 为 0 阶第一类贝塞尔函数; $J_{2\alpha}(\cdot)$, $J_{2\alpha-1}(\cdot)$ 分别为偶数阶和奇数阶第一类贝塞尔函数。

根据第一类贝塞尔函数性质可得,当 $M \rightarrow 1$ 时,有

$$\begin{cases} J_0(M) = 1 \\ J_1(M) = M/2 \\ J_\alpha(M) \approx 0, \quad \alpha \geq 2 \end{cases} \quad (10)$$



(a) 理想 LFM 信号



(b) 含相位噪声的 LFM 信号

图 2 LFM 信号的频域波形对比

$\varphi_0 = 0$, 则含有相位噪声的 LFM 信号表达式为

$$s(t) = A \sin(2\pi f_c t + K\pi t^2 + \varphi(t)), \quad 0 \leq t \leq T \quad (6)$$

现普遍认可的相位噪声的数学模型^[17]为

$$\varphi(t) = M \sin(2\pi f_m t) \quad (7)$$

式中: M 为调相系数; f_m 为补偿频率。将式(7)代入式(6),展开后可得

$$s(t) = A [\sin(2\pi f_c t + K\pi t^2) \cos(M \sin(2\pi f_m t)) + \cos(2\pi f_c t + K\pi t^2) \sin(M \sin(2\pi f_m t))] \quad (8)$$

根据雅可比-安格展开式可得

根据式(9)和式(10),式(8)可以改写为

$$s(t) = A [\sin(2\pi f_c t + K\pi t^2) + (M \sin 2\pi(f_c + Kt/2 + f_m)t)/2 - (M \sin 2\pi(f_c + Kt/2 - f_m)t)/2] \quad (11)$$

在实际情况下,LFM 信号的相位噪声可以看作是由多个具有不同调相系数 M 以及不同补偿频率 f_m 的信号组成的,则含相位噪声的 LFM 信号的数学模型可表示为

$$s(t) = A \sin(2\pi f_c t + K\pi t^2) + A \left[\sum_{i=1}^{\infty} \frac{M_i}{2} \sin(2\pi(f_c + Kt/2 + f_{m,i})t) - \sum_{i=1}^{\infty} \frac{M_i}{2} \sin(2\pi(f_c + Kt/2 - f_{m,i})t) \right] \quad (12)$$

式中: M_i 为第 i 个补偿频率 $f_{m,i}$ 对应的调相系数。

其他调制方式的含相位噪声的雷达信号模型的推导过程与上述推导过程类似。

3 特征提取方法

本章主要探讨含相位噪声信号的特征分析和提取方法。

3.1 信号的双谱分析

本文选择双谱作为处理原始雷达信号的工具。与频谱相比,高阶谱包含更多的幅度和相位信息,并且双谱可充分体现信号的非线性与非高斯性特征^[18]。此外,双谱在高阶谱中的阶数最低,这使得其成为处理雷达信号的理想工具。

对于离散时间信号 $x(n)$, 其双谱可定义为

$$B_x(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{\infty} \sum_{\tau_2=-\infty}^{\infty} C_{3x}(\tau_1, \tau_2) \times \exp(-j(\omega_1 \tau_1 + \omega_2 \tau_2)) \quad (13)$$

其中

$$C_{3x}(\tau_1, \tau_2) = E(x(n)x(n+\tau_1)x(n+\tau_2)) \quad (14)$$

式中: ω_1, ω_2 为双谱的两个不同的频率分量; $C_{3x}(\tau_1, \tau_2)$ 为 $x(n)$ 的三阶累积量, 其中 τ_1 和 τ_2 表示不同的时延; $E(\cdot)$ 为数学期望函数。从式(13)可知, $B_x(\omega_1, \omega_2)$ 为 $C_{3x}(\tau_1, \tau_2)$ 的二维傅里叶变换。

根据式(13)和式(14)计算离散信号 $x(n)$ 的双谱, 并将其双谱离散成二维复矩阵 \mathbf{B}_x 。二维复矩阵 \mathbf{B}_x 中含有许多对信号分类识别无用的信息, 并且二维复矩阵 \mathbf{B}_x 的匹配计算复杂度高, 这限制了信号双谱在雷达辐射源个体分类识别中的应用。为解决上述问题, 需要在保留双谱有用信息的前提下, 对二维复矩阵进行降维。

3.2 信号双谱的特征提取

现从双谱中提取双谱熵、双谱能量熵、双谱主

成分均值三个参数, 实现对双谱二维复矩阵的降维。

(1) 双谱熵

双谱熵(bispectrum entropy)是从信号的双谱中提取出的一个标量, 可以用于描述信号的复杂度和不规则度, 在信号处理和模式识别领域被广泛应用。信号 $x(n)$ 的双谱熵定义为

$$E_b(\mathbf{B}_x) = - \sum_{i=1}^N \sum_{j=1}^N p_{b,ij} \log_2 p_{b,ij} \quad (15)$$

其中

$$\begin{cases} p_{b,ij} = |B_x(i, j)| / W_b \\ W_b = \sum_{i=1}^N \sum_{j=1}^N |B_x(i, j)| \end{cases} \quad (16)$$

式中: N 为离散二维傅里叶变换点数; $p_{b,ij}$ 为矩阵 \mathbf{B}_x 的第 i 行第 j 列元素 $B_x(i, j)$ 的模与累加和 W_b 的比值; $|\cdot|$ 为取模运算符; W_b 为二维复矩阵 \mathbf{B}_x 中所有元素取模后的累加和。

(2) 双谱能量熵

能量熵(energy entropy)一般用来描述信号的复杂度和信息量。双谱能量熵也是起同样的作用; 描述双谱二维复矩阵的复杂度以及信息量。对于信号 $x(n)$ 的双谱二维复矩阵 \mathbf{B}_x , $x(n)$ 的双谱能量熵可定义为

$$E_e(\mathbf{B}_x) = \sum_{i=1}^N \sum_{j=1}^N p_{e,ij} \log_2 p_{e,ij} \quad (17)$$

其中

$$\begin{cases} p_{e,ij} = |B_x(i, j)|^2 / W_e \\ W_e = \sum_{i=1}^N \sum_{j=1}^N |B_x(i, j)|^2 \end{cases} \quad (18)$$

式中: $p_{e,ij}$ 为 $B_x(i, j)$ 的模的平方与 W_e 的比值; W_e 为矩阵 \mathbf{B}_x 中所有元素取模并平方之后的累加和。

(3) 双谱主成分均值

主成分分析(principal component analysis, PCA)^[19]可以将数据集集中的高维特征压缩到少数几个主成分中, 是一种常用的数据降维和特征提取技术。其主要思想是将高维数据集映射到低维空间中, 同时尽可能地保留原有数据的信息。对于信号 $x(n)$ 的双谱二维复矩阵 \mathbf{B}_x , 利用 PCA 将其降维成一维复矩阵的具体步骤如下。

步骤1, 将矩阵 \mathbf{B}_x 展开成一个长度为 N^2 的列向量 \mathbf{x} , 其第 i 行第 j 列的元素对应 \mathbf{x} 的

第 $[(i-1)N+j]$ 个元素。

步骤 2, 对列向量 \mathbf{x} 的每个元素 $x_i (i = 1, 2, \dots, N^2)$ 进行中心化, 即将每个元素减去列向量元素平均值, 使其均值为 0, 表达式为

$$x_i \leftarrow x_i - \frac{1}{N^2} \sum_{i=1}^{N^2} x_i \quad (19)$$

步骤 3, 计算 \mathbf{x} 的协方差矩阵 \mathbf{C} , 其表达式为

$$\mathbf{C} = \mathbf{x}\mathbf{x}^T / (N^2 - 1) \quad (20)$$

式中: T 为矩阵转置运算符。

步骤 4, 计算协方差矩阵 \mathbf{C} 的特征值 λ 和特征向量 \mathbf{V} , 其表达式为

$$\mathbf{C}\mathbf{V} = \lambda\mathbf{V} \quad (21)$$

步骤 5, 选择最大的特征值对应的特征向量作为主成分方向。

步骤 6, 将中心化的列向量 \mathbf{x} 投影到主成分方向上, 得到一维矩阵

$$\mathbf{y} = \mathbf{V}^T \mathbf{x} \quad (22)$$

通过以上步骤, 原始的双谱二维复矩阵 \mathbf{B}_x 被降维成了一个一维矩阵 \mathbf{y} 。一维矩阵 \mathbf{y} 保留了原始矩阵的大部分信息, 同时能够实现有效的数据压缩和特征提取。则双谱主成分均值

$$\mu_b = \text{mean}(\mathbf{y}) \quad (23)$$

式中: $\text{mean}(\cdot)$ 表示对矩阵中的元素取平均值。

从信号的双谱中提取的三种参数组成的三维向量 (E_b, E_e, μ_b) 即为分类特征向量。


4 仿真验证

本章将按照式 (12) 的雷达信号模型 (复数形式) 仿真四个雷达辐射源信号, 雷达辐射源信号的载频 $f_c = 100$ MHz, 采样频率 $f_s = 500$ MHz, 信号采样点数 $N = 1\ 500$ 。设四个辐射源为个体 1~个体 4, 各个辐射源在不同补偿频率上的相位噪声如表 1 所示。


在信噪比为 0~15 dB 的情况下, 四个雷达辐射源个体分别产生 100, 300, 500, 900 个信号样本, 对每个雷达辐射源个体产生的信号样本提取双谱熵、双谱能量熵和双谱主成分均值, 并组成三维向量。当样本数为 100 且信噪比分别为 0, 5, 10, 15 dB 时, 四个雷达辐射源的三维特征在特征空间中的分布情况如图 3 所示。

表 1 辐射源在不同补偿频率上的相位噪声


辐射源	补偿频率/MHz	相位噪声/(dBc · Hz ⁻¹)
个体 1	5	-70.283 7
	15	-76.324 6
	25	-78.349 2
	60	-85.102 6
个体 2	5	-73.082 3
	15	-78.032 6
	25	-82.046 4
	60	-88.435 8
个体 3	5	-74.657 9
	15	-79.076 4
	25	-85.743 2
	60	-92.084 6
个体 4	5	-76.103 3
	15	-83.081 1
	25	-88.076 5
	60	-100.021 1



(a) 信噪比为 0 dB




(b) 信噪比为 5 dB



(c) 信噪比为 10 dB

图 3 四个雷达辐射源个体的三维特征分布



(d) 信噪比为 15 dB

图3 四个雷达辐射源个体的三维特征分布(续)

从图3可以看出,四个雷达辐射源个体的三维特征都能在特征空间中聚成一簇,并且各个簇的簇中心有明显的差异。

当信噪比为 10 dB 且样本数为 100 时,采用 K -means 算法^[20]对所有三维特征进行聚类,四个雷达辐射源个体的三维特征的聚类结果如图4所示。可以看出,四个辐射源个体的三维特征向量都集中在各自的聚类中心附近,并且簇1~簇4的聚类中心的差异非常明显。




图4 四个雷达辐射源个体的三维特征的聚类结果

当信噪比为 0~15 dB 且样本数为 100, 300, 500, 900 时,四个雷达辐射源个体的聚类识别正确率如表2所示。

从表2可知:当信噪比不小于 5 dB 时,即使样本数量较多,聚类识别正确率也能达到 100%;当信噪比较小时,聚类识别正确率仍能达到 80%。仿真结果证明本文所提算法能在信噪比较低的情况下取得较高的识别正确率。

5 结束语

针对相位噪声可造成同一型号不同雷达个体的发射信号之间存在细微差异的现象,本文提出

表2 聚类识别正确率

信噪比/ dB	聚类识别正确率/%				
	样本数为 100	样本数为 300	样本数为 500	样本数为 700	样本数为 900
0	81.1	80.9	80.6	80.5	80.0
1	85.7	85.5	85.0	84.5	84.7
2	93.1	93.0	92.9	92.7	92.7
3	97.5	97.3	97.2	97.0	97.0
4	100.0	100.0	99.8	99.8	99.8
5	100.0	100.0	100.0	100.0	100.0
6	100.0	100.0	100.0	100.0	100.0
7	100.0	100.0	100.0	100.0	100.0
8	100.0	100.0	100.0	100.0	100.0
9	100.0	100.0	100.0	100.0	100.0
10	100.0	100.0	100.0	100.0	100.0
11	100.0	100.0	100.0	100.0	100.0
12	100.0	100.0	100.0	100.0	100.0
13	100.0	100.0	100.0	100.0	100.0
14	100.0	100.0	100.0	100.0	100.0
15	100.0	100.0	100.0	100.0	100.0

了一种新的雷达辐射源个体识别算法。该算法首先求得信号的双谱,然后从双谱中提取出三个参数——双谱熵、双谱能量熵以及双谱主成分均值,并将由这三个参数组成的三维向量作为特征向量,最后利用 K -means 机器学习算法完成了雷达辐射源个体聚类识别。相比于现在主流的使用深度学习模型作为分类器的雷达辐射源个体识别算法,本文算法采用简单的无监督机器学习算法完成了识别,规避了繁琐的模型训练过程。由于提取的特征能够精准表征雷达辐射源个体差异,即使在信噪比为 0 dB 的情况下,基于 K -means 的聚类算法的识别正确率也不低于 80%。仿真结果证明,本文所提算法性能优越,具有一定的应用价值。

参考文献

- [1] 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: 3335-3346.
- [2] ZHA X, CHEN H, LI T Y, et al. Specific

- emitter identification based on complex Fourier neural network [J]. *IEEE Communications Letters*, 2022, 26(3): 592-596.
- [3] MERCHANT K, REVAY S, STANTCHEV G, et al. Deep learning for RF device fingerprinting in cognitive communication networks [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 160-167.
- [4] DING L D, WANG S L, WANG F G, et al. Specific emitter identification via convolutional neural networks [J]. *IEEE Communications Letters*, 2018, 22(12): 2591-2594.
- [5] GONG J L, XU X D, LEI Y K. Unsupervised specific emitter identification method using radio-frequency fingerprint embedded InfoGAN [J]. *IEEE Transactions on Information Forensics and Security*, 2020, 15: 2898-2913.
- [6] MCGINTHY J M, WONG L J, MICHAELS A J. Groundwork for neural network-based specific emitter identification authentication for IoT[J]. *IEEE Internet of Things Journal*, 2019, 6(4): 6429-6440.
- [7] SATIJA U, TRIVEDI N, BISWAL G, et al. Specific emitter identification based on variational mode decomposition and spectral features in single hop and relaying scenarios[J]. *IEEE Transactions on Information Forensics and Security*, 2019, 14(3): 581-591.
- [8] HE B X, WANG F G. Cooperative specific emitter identification via multiple distorted receivers[J]. *IEEE Transactions on Information Forensics and Security*, 2020, 15: 3791-3806.
- [9] WANG Y, GUI G, GACANIN H, et al. An efficient specific emitter identification method based on complex-valued neural networks and network compression [J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(8): 2305-2317.
- [10] LIU Z M. Multi-feature fusion for specific emitter identification via deep ensemble learning [J]. *Digital Signal Processing*, 2021, 110(1): 102939.
- [11] WU L W, ZHAO Y Q, WANG Z, et al. Specific emitter identification using fractal features based on box-counting dimension and variance dimension [C]// 2017 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). Piscataway, NJ: IEEE Press, 2017: 226-231.
- [12] LIU M W, DOHERTY J F. Nonlinearity estimation for specific emitter identification in multipath channels [J]. *IEEE Transactions on Information Forensics and Security*, 2011, 6(3): 1076-1085.
- [13] LEE T H, HAJIMIRI A. Oscillator phase noise: a tutorial[J]. *IEEE Journal of Solid-state Circuits*, 2000, 35(3): 326-336.
- [14] RAZAVI B. A study of phase noise in CMOS oscillators [J]. *IEEE Journal of Solid-state Circuits*, 1996, 31(3): 331-343.
- [15] HAJIMIRI A, LEE T H. A general theory of phase noise in electrical oscillators [J]. *IEEE Journal of Solid-state Circuits*, 1998, 33(2): 179-194.
- [16] CHEN T W, JIN W D, LI J. Feature extraction using surrounding-line integral bispectrum for radar emitter signal[C]// 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). Piscataway, NJ: IEEE Press, 2008: 294-298.
- [17] WAN T, JI H, XIONG W, et al. Deep learning-based specific emitter identification using integral bispectrum and the slice of ambiguity function[J]. *Signal, Image and Video Processing*, 2022, 16(7): 2009-2017.
- [18] 张贤达. 现代信号处理[M]. 2版. 北京: 清华大学出版社, 2002.
- [19] WOLD S, ESBENSEN K, GELADI P. Principal component analysis [J]. *Chemometrics and Intelligent Laboratory Systems*, 1987, 2(1/2/3): 37-52.
- [20] HARITIGAN J A, WONG M A. Algorithm AS 136: a K-means clustering algorithm[J]. *Journal of the Royal Statistical Society: Series C Applied Statistics*, 1979, 28(1): 100-108.