

一种冲击噪声下相干分布源多峰DOA估计方法

高洪元¹, 刘亚鹏¹, 杜亚男¹, 程建华², 孙贺麟¹

(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. 哈尔滨工程大学智能科学与工程学院, 黑龙江哈尔滨 150001)

摘要: 针对现有相干分布源波达方向(Direction Of Arrival, DOA)估计方法计算量大、抗冲击噪声能力弱和不能有效去相干等难题, 本文提出了一种冲击噪声下相干分布源多峰DOA估计方法, 并推导了冲击噪声下相干分布源DOA估计的克拉美罗界. 为了实现冲击噪声下相干分布源DOA估计, 采用加权范数协方差抑制冲击噪声, 进而首次推导出多峰加权信号子空间拟合方程, 并设计了一种多峰量子秃鹰算法快速无量化误差求解. 仿真结果表明, 所提方法在冲击噪声下能够以较小的快拍数实现相干分布源DOA估计, 且无需额外的解相干操作即可有效去相干. 与一些已有的高精度DOA估计方法相比, 所提方法仿真时间明显缩短, 且具有更高的估计精度和估计成功概率, 突破了已有相干分布源DOA估计方法的应用局限, 可推广应用于其他复杂的DOA估计问题中.

关键词: 相干分布源; DOA估计; 冲击噪声; 多峰加权信号子空间拟合; 多峰量子秃鹰算法; 克拉美罗界

基金项目: 国家自然科学基金(No.62073093); 黑龙江省自然科学基金(No.LH2020F017); 黑龙江省博士后科研启动金(No.LBH-Q19098)

中图分类号: TN911.7

文献标识码: A

文章编号: 0372-2112(2023)09-2330-11

电子学报URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211655

A Multimodal DOA Estimation Method of Coherently Distributed Sources in Impulse Noise

GAO Hong-yuan¹, LIU Ya-peng¹, DU Ya-nan¹, CHENG Jian-hua², SUN He-lin¹

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China;

2. College of Intelligent Systems Science and Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China)

Abstract: To address the problems of the existing direction of arrival (DOA) estimation methods of coherently distributed sources, such as huge computational complexity, inferior performance in impulse noise and ineffective decoherence ability, a multimodal DOA estimation method of coherently distributed sources in impulse noise is proposed and the Cramér-Rao bound is derived for DOA estimation of coherently distributed sources in the impulse noise. A multimodal weighted signal subspace fitting equation, employing the weighted norm covariance, is derived firstly to achieve the DOA estimation of coherently distributed sources in the impulse noise, meanwhile, a multimodal quantum bald eagle algorithm is designed to quickly solve the derived equation without quantization error. Simulation results show that the proposed method can achieve the DOA estimation of coherently distributed sources with a small number of snapshots in the impulse noise, and can locate coherent sources without additional decoherence operations. Compared with the existing high precision DOA estimation methods, the proposed method has shorter simulation time and higher estimation accuracy and successful rate, which breaks through the application limitations of the existing coherently distributed source DOA estimation methods and can be popularized and applied in other complex DOA estimation problems.

Key words: coherently distributed source; DOA estimation; impulse noise; multimodal weighted signal subspace fitting; multimodal quantum bald eagle algorithm; Cramér-Rao bound

Foundation Item(s): National Natural Science Foundation of China (No.62073093); Natural Science Foundation of Heilongjiang Province (No.LH2020F017); Initiation Fund for Postdoctoral Research in Heilongjiang Province (No.LBH-Q19098)

1 引言

波达方向(Direction Of Arrival, DOA)估计,又称为测向,是阵列信号处理领域的重要研究内容之一,在过去的几十年里,许多专家学者对这一技术进行了广泛而深入的研究. 到目前为止,众多的高分辨 DOA 估计算法已经被提出并在雷达、无线通信、声纳等众多领域取得了长足的发展^[1-3],其中,以多重信号分类(Multiple Signal Classification, MUSIC)算法为代表的谱峰搜索类算法^[4,5]在引入量化误差的同时计算量会随着精度要求而急剧增加,而且不损失阵列孔径不能解相干信源. 基于旋转不变性的信号参数估计(Estimating Signal Parameter via Rotational Invariance Technique, ESPRIT)算法^[6]计算量小,但其测向性能相对很差,不损失阵列孔径也不能直接解相干. 极大似然算法^[7]和加权子空间拟合算法^[8]在理论上估计误差更低,可以直接解相干,但都涉及多维联合优化问题的求解,计算量大,限制了该类算法的工程应用. 因此若能降低最接近克拉美罗界的加权子空间拟合算法的计算量,必能极大地促进其工程应用进程.

经典的 DOA 估计算法通常假设目标为点目标,而在复杂环境下实际目标往往具有比点目标更复杂的空间分布特征,此时需要用参数化的分布源模型进行处理. 与点源 DOA 估计相比,分布源 DOA 估计一直是难于求解的工程问题. 根据信道的观测周期和相干时间的关系,文献[9]提出了两种分布源模型:基于确定的角信号密度函数的相干分布(Coherently Distributed, CD)源和基于确定的角功率密度函数的非相干分布(Incoherently Distributed, ID)源,并将 MUSIC 算法推广为分布源模型下的分布源参数估计(Distributed Signal Parameter Estimator, DSPE)算法,该算法需要通过二维谱峰搜索进行求解,计算量巨大,同时会产生无法避免的量化误差,且不损失阵列孔径不能解相干. 文献[10]基于分布源模型提出了广义 ESPRIT 算法,虽然计算量小,但具有估计精度不高和不能直接估计相干源的缺点. 文献[11]分析了存在模型误差时 DSPE 算法在相干分布源 DOA 估计上的性能,但求解结果依旧无法避免谱峰搜索产生的量化误差. 文献[12]提出了一种适用于大规模多输入多输出系统的相干分布源 DOA 估计方法,该方法通过线性收缩操作改进样本协方差矩阵的估计,实现了相干分布源 DOA 的有效估计,但不能解相干. 文献[13]提出了均匀圆阵下相干分布源的二维 DOA 估计方法,但其不能求解角度扩展,也不能解相干. 文献[14]提出了基于空间平滑的二维相干分布源 DOA 估计方法,可以求解相干信源,但会损失阵列孔径. 上述算法多为点目标 DOA 估计算法在相干分布源模型的推广,存在估计精度差,不损失阵列孔径不能解

相干的难题,且背景噪声均假设为高斯噪声,在冲击噪声下 DOA 估计性能将显著下降甚至失效.

实际中低频大气噪声、闪电和开关瞬间切换等都属于比较常见的冲击噪声,它们都具有显著的峰值特性,这些噪声的模型可表示为对称 Alpha 稳定分布(Symmetric α -Stable, S α S)随机过程,它能够很好的描述冲击噪声的冲击特性,也可以作为高斯噪声的一种推广^[15]. 因为冲击噪声不存在二阶及以上矩,因此传统的以高斯噪声为背景噪声的 DOA 估计方法在冲击噪声下性能将会恶化甚至完全失效,一些研究人员对 Alpha 稳定分布深入研究后,提出分数低阶统计量理论来抑制冲击噪声,其中最常用的有分数低阶矩^[16](Fractional Lower Order Moment, FLOM),分数低阶协方差矩^[17](Fractional Lower Order Covariance, FLOC)和共变矩阵^[18](Robust Covariation, ROC). 文献[19]提出了无穷范数归一化预处理方法来抑制冲击噪声,并通过理论推导和统计分析验证了该方法的有效性. 文献[20]基于对冲击噪声分布特性和统计特征的研究与分析,引入中值滤波方法对阵列接收数据进行幅值滤波来滤除冲击噪声. 为了解决冲击噪声环境下的相干分布源 DOA 估计难题,文献[21,22]提出了冲击噪声下相干分布源 DOA 估计方法,实现了冲击噪声环境下相干分布源参数的联合估计,上述方法虽然能够抑制冲击噪声,但是在强冲击噪声下性能将会恶化甚至失效,且算法涉及二维谱峰搜索,势必会产生较大的计算量,不能满足实时性的要求,而且会产生量化误差,同时不损失阵列孔径也不能直接求解相干信源.

因此,为了突破现有冲击噪声下相干分布源 DOA 估计方法的应用局限和性能局限,提出一种基于多峰量子秃鹰算法的多峰加权信号子空间拟合算法. 所提快速高性能 DOA 估计方法大幅度减少了加权信号子空间类算法的计算量,解决了已有相干分布源 DOA 估计方法不损失阵列孔径不能直接求解相干信源的难题. 具体贡献如下:

(1)通过将加权信号子空间拟合算法涉及的多维联合优化问题转化为多峰优化问题,推导得到多峰加权信号子空间拟合(Multimodal Weighted Signal Subspace Fitting, MWSSF)算法的空间谱函数,推导出冲击噪声下相干分布源的克拉美罗界(Cramér-Rao Bound, CRB),并采用双参数柯西高斯混合(Bi-parameter Cauchy-Gaussian Mixture, BCGM)模型来逼近 S α S 分布的概率密度函数(Probability Density Function, PDF)以获得 CRB.

(2)针对多峰加权信号子空间拟合算法的快速求解难题,提出一种多峰量子秃鹰算法(Multimodal Quantum Bald Eagle Algorithm, MQBEA)对所提 MWSSF 算法

进行快速求解,从而避免了进行二维谱峰搜索时所产生的量化误差,而且能满足实时性的要求.

(3)本文所提方法在小快拍数、低信噪比情况下的 DOA 估计性能和仿真时间与已有算法相比有着明显的优势,而且无需空间平滑等额外的解相干操作即可处理相干信源,不损失阵列孔径,突破了已有相干分布源 DOA 估计方法的应用局限.

2 冲击噪声下相干分布源 DOA 估计模型

假设 P 个窄带相干分布源入射到包含 M 个阵元的均匀线性阵列,相邻阵元之间的距离为 d , λ 是载波的波长. 阵列接收到的信号矢量可以表示为

$$\mathbf{x}(t) = \sum_{i=1}^P \int_{\theta \in \Theta} \mathbf{a}(\theta) s_i(\theta, \boldsymbol{\psi}_i, t) d\theta + \mathbf{n}(t) \quad (1)$$

其中, $\mathbf{a}(\theta)$ 为阵列导向矢量, θ 表示分布源信号的来波方向, $s_i(\theta, \boldsymbol{\psi}_i, t)$ 为第 i 个相干分布源的角信号密度函数, $\boldsymbol{\psi}_i = (\theta_i, \Delta_i)$, θ_i 和 Δ_i 分别表示第 i 个相干分布源的中心方位角和角度扩展, $\mathbf{n}(t)$ 为冲击噪声矢量.

相干分布源的角信号密度函数可以表示为随机信号幅度与分布源的空间分布函数乘积的形式,即

$$s_i(\theta, \boldsymbol{\psi}_i, t) = s_i(t) g_i(\theta, \boldsymbol{\psi}_i) \quad (2)$$

其中, $s_i(t)$ 为随机信号幅度, $g_i(\theta, \boldsymbol{\psi}_i)$ 为相干分布源的确定性角信号密度函数.

因此,式(1)可以重写为

$$\mathbf{x}(t) = \sum_{i=1}^P \mathbf{c}(\boldsymbol{\psi}_i) s_i(t) + \mathbf{n}(t) \quad (3)$$

其中, $\mathbf{c}(\boldsymbol{\psi}_i)$ 为第 i 个相干分布源的广义导向矢量

$$\mathbf{c}(\boldsymbol{\psi}_i) = \int_{\theta \in \Theta} \mathbf{a}(\theta) g_i(\theta, \boldsymbol{\psi}_i) d\theta \quad (4)$$

确定性角信号密度函数通常被建模为高斯分布,即

$$g_i(\theta, \boldsymbol{\psi}_i) = \frac{1}{\sqrt{2\pi\Delta_i^2}} \exp\left(-\frac{(\theta - \theta_i)^2}{2\Delta_i^2}\right) \quad (5)$$

当相干分布源的角度扩展较小时,广义导向矢量可以表示为^[9]

$$[\mathbf{c}(\boldsymbol{\psi}_i)]_m = \exp\left(-j \frac{2\pi d(m-1)}{\lambda} \sin \theta_i\right) \times \exp\left(-0.5 \left(\frac{2\pi d(m-1)\Delta_i}{\lambda} \cos \theta_i\right)^2\right) \quad (6)$$

其中, $m = 1, 2, \dots, M$.

因此,式(3)可以重写为

$$\mathbf{x}(t) = \mathbf{C}(\boldsymbol{\psi}) s(t) + \mathbf{n}(t) \quad (7)$$

其中, $\mathbf{C}(\boldsymbol{\psi}) = [\mathbf{c}(\boldsymbol{\psi}_1) \ \mathbf{c}(\boldsymbol{\psi}_2) \ \dots \ \mathbf{c}(\boldsymbol{\psi}_P)]$ 为 $M \times P$ 维广义阵列流型, $\mathbf{n}(t)$ 为 $M \times 1$ 维服从 S α S 分布的复冲击噪声矢量.

S α S 分布的特征函数可以表示为

$$\varphi(w) = \exp(j\eta w - \gamma |w|^\alpha) \quad (8)$$

其中, $0 < \alpha \leq 2$ 为特征指数, $\gamma > 0$ 为离差, $-\infty < \eta < +\infty$ 为位置参数,当 $\alpha = 2$ 时满足高斯分布, $\alpha = 1$ 时满足柯西分布,特别地,当 $\eta = 0, \gamma = 1$ 时, S α S 分布为标准 S α S 分布.

由于 S α S 分布不存在二阶及以上矩,因此,重新定义新的广义信噪比 (Generalized Signal to Noise Ratio, GSNR)

$$\text{GSNR} = 10 \lg \left\{ \frac{\mathbb{E}[\|\mathbf{s}(t)\|^2]}{\gamma^\alpha} \right\} \quad (9)$$

其中, $\mathbb{E}[\cdot]$ 表示期望, $\mathbb{E}[\|\mathbf{s}(t)\|^2]$ 为信号的平均功率.

在冲击噪声下,传统的基于二阶矩的相干分布源 DOA 估计方法性能将会恶化甚至失效,因此使用一种加权范数协方差^[19]来抑制冲击噪声,针对第 k 次快拍采样数据,通过加权范数归一化操作将冲击噪声转化为功率有限的噪声,即

$$\begin{aligned} \bar{\mathbf{x}}(k) &= (\bar{x}_1(k), \bar{x}_2(k), \dots, \bar{x}_M(k))^T \\ &= \mathbf{x}(k) / \max_{1 \leq m \leq M} \{|x_m(k)|^\beta\} \end{aligned} \quad (10)$$

其中, β 为加权常数, $\beta \in [0.8, 1]$, $k = 1, 2, \dots, K$, 之后,对归一化数据取协方差即可得到加权范数协方差 (Weighted Norm Covariance, WNC)

$$\hat{\mathbf{R}}_{\text{WNC}} = \frac{1}{K} \sum_{k=1}^K \bar{\mathbf{x}}(k) \bar{\mathbf{x}}^H(k) \quad (11)$$

对其进行特征分解可以获得信号子空间 \mathbf{U}_S 和噪声子空间 \mathbf{U}_N , 即

$$\hat{\mathbf{R}}_{\text{WNC}} = \mathbf{U}_S \boldsymbol{\Sigma}_S \mathbf{U}_S^H + \mathbf{U}_N \boldsymbol{\Sigma}_N \mathbf{U}_N^H \quad (12)$$

其中, \mathbf{U}_S 是由 P 个大特征值对应的特征向量张成的信号子空间, $\boldsymbol{\Sigma}_S$ 是由 P 个大特征值构成的对角阵, \mathbf{U}_N 是由 $M - P$ 个小特征值对应的特征向量张成的噪声子空间, $\boldsymbol{\Sigma}_N$ 是由 $M - P$ 个小特征值构成的对角阵.

加权信号子空间拟合算法通过找到一个矩阵 \mathbf{T} , 将 $\mathbf{C}(\boldsymbol{\psi})$ 与 $\mathbf{U}_S \mathbf{W}^{1/2}$ 进行最小二乘意义上的拟合, 即

$$\hat{\boldsymbol{\psi}}, \hat{\mathbf{T}} = \arg \min_{\boldsymbol{\psi}, \mathbf{T}} \left\| \mathbf{U}_S \mathbf{W}^{1/2} - \mathbf{C}(\boldsymbol{\psi}) \hat{\mathbf{T}} \right\|_F^2 \quad (13)$$

其中, $\|\cdot\|_F$ 为 Frobenius 范数, 固定 $\mathbf{C}(\boldsymbol{\psi})$ 就可以求出 $\hat{\mathbf{T}}$ 的最小二乘解

$$\hat{\mathbf{T}} = (\mathbf{C}^H(\boldsymbol{\psi}) \mathbf{C}(\boldsymbol{\psi}))^{-1} \mathbf{C}^H(\boldsymbol{\psi}) \mathbf{U}_S \mathbf{W}^{1/2} \quad (14)$$

将式(14)代入式(13)中即得

$$\begin{aligned} \hat{\boldsymbol{\psi}} &= \arg \min_{\boldsymbol{\psi}} \left\| \mathbf{U}_S \mathbf{W}^{1/2} - \mathbf{C}(\boldsymbol{\psi}) \hat{\mathbf{T}} \right\|_F^2 \\ &= \arg \min_{\boldsymbol{\psi}} \text{trace}[\mathbf{P}_{\mathbf{C}(\boldsymbol{\psi})}^\perp \mathbf{U}_S \mathbf{W} \mathbf{U}_S^H] \\ &= \arg \max_{\boldsymbol{\psi}} \text{trace}[\mathbf{P}_{\mathbf{C}(\boldsymbol{\psi})} \mathbf{U}_S \mathbf{W} \mathbf{U}_S^H] \end{aligned} \quad (15)$$

其中, $\mathbf{P}_{\mathbf{C}(\boldsymbol{\psi})}$ 为 $\mathbf{C}(\boldsymbol{\psi})$ 的投影矩阵, 最优权矩阵为 $\mathbf{W} = (\boldsymbol{\Sigma}_S -$

$\sigma \mathbf{I} \Sigma_S^{-1}$, σ 为 $M-P$ 个小特征值的平均, \mathbf{I} 为单位矩阵.

由于式(15)涉及多维联合优化问题,这势必会产生巨大的计算量,为了减小式(15)的计算量,将 $\mathbf{C}(\boldsymbol{\psi})$ 简化为 $\mathbf{c}(\theta, \Delta)$, $[\mathbf{c}(\theta, \Delta)]_m = \exp\left(-j \frac{2\pi d(m-1)}{\lambda} \sin \theta\right) \times \exp\left(-0.5 \left(\frac{2\pi d(m-1)\Delta}{\lambda} \cos \theta\right)^2\right)$, $m=1, 2, \dots, M$. 可以推导出得到多峰加权信号子空间拟合方程的空间谱函数

$$P(\theta, \Delta) = \text{trace}[\mathbf{P}_{\mathbf{c}(\theta, \Delta)} \mathbf{U}_S \mathbf{W} \mathbf{U}_S^H] \quad (16)$$

其中, $\mathbf{P}_{\mathbf{c}(\theta, \Delta)}$ 为 $\mathbf{c}(\theta, \Delta)$ 的投影矩阵. 对于多峰优化方程,虽然可以使用传统二维谱峰搜索方法^[21]进行求解,但所涉及的计算量仍较大,且无法避免量化误差,因此需要设计一个有效的优化方案来求解该多峰优化问题.

3 基于多峰量子秃鹰算法的相干分布源 DOA 估计

所提 MWSSF 算法是一个多峰优化问题,多峰优化问题需要对多峰函数的多个最优解同时进行求解. 近年来,灰狼优化算法^[23]、风驱动优化算法^[24]和秃鹰搜索算法^[25]等智能优化算法是新提出的智能优化算法,已经在不同领域获得了一些成功应用,但这些算法只能求解多维极大似然和多维加权子空间拟合等多维联合优化问题,不能有效求解多峰优化问题多个最优解. 解决多维优化问题的量子鲸鱼算法已经在多输入多输出 (Multi-Input Multi-Output, MIMO) 雷达极大似然 DOA 估计中获得成功应用^[26]. 而已有的多峰优化算法^[27,28]针对相干分布源 DOA 估计这个复杂工程问题也不能直接获得高质量的解,且在每次演化后需要判决每一维变量是否超界,需要耗费大量计算时间. 为了能够高效求解 MWSSF 算法涉及的多峰优化问题,设计一种多峰量子秃鹰算法对 MWSSF 算法进行快速无量化误差求解,不仅能避免二维谱峰搜索计算量大和有量化误差的不足,而且突破现有秃鹰搜索算法无法求解多峰优化问题的局限.

3.1 多峰量子秃鹰算法

在量子秃鹰群体中,有 N 只量子秃鹰,第 φ ($\varphi=1, 2, \dots, N$) 只量子秃鹰在第 t 次迭代时的量子位置可表示为

$$\mathbf{y}_\varphi^t = (y_{\varphi,1}^t, y_{\varphi,2}^t, \dots, y_{\varphi,B}^t) \quad (17)$$

其中, $0 \leq y_{\varphi,b}^t \leq 1$ ($b=1, 2, \dots, B$), 第 φ 只量子秃鹰的位置 $\bar{\mathbf{y}}_\varphi^t = (\bar{y}_{\varphi,1}^t, \bar{y}_{\varphi,2}^t, \dots, \bar{y}_{\varphi,B}^t)$ 由量子位置映射得到,第 φ 只量子秃鹰第 b 维位置的映射规则为

$$\bar{y}_{\varphi,b}^t = y_{\varphi,b}^t (\bar{y}_b^{\text{high}} - \bar{y}_b^{\text{low}}) + \bar{y}_b^{\text{low}} \quad (18)$$

其中, \bar{y}_b^{high} 和 \bar{y}_b^{low} 分别为待优化问题第 b 维优化变量的上下界. 所提的多峰量子秃鹰算法包括 6 种演化策略:

空间选择策略、猎物搜索策略、俯冲捕食策略、记忆策略、记忆池选择策略和净化策略.

(1) 空间选择策略:对于量子秃鹰种群中第 φ 只量子秃鹰,其空间选择策略的量子旋转角矢量 $\mathbf{v}_\varphi^{t+1} = (v_{\varphi,1}^{t+1}, v_{\varphi,2}^{t+1}, \dots, v_{\varphi,B}^{t+1})$ 可以表示为

$$\mathbf{v}_\varphi^{t+1} = \bar{\lambda} \bar{r} (\mathbf{y}_{\text{mean}}^t - \mathbf{y}_\varphi^t) \quad (19)$$

其中, $\bar{\lambda} = \lambda_{\text{max}} - (\lambda_{\text{max}} - \lambda_{\text{min}})t/T$ 为控制位置变化参数, T 为最大迭代次数, λ_{max} 和 λ_{min} 分别为参数 $\bar{\lambda}$ 的最大值和最小值, \bar{r} 为 $[0, 1]$ 内均匀分布的随机数, $\mathbf{y}_{\text{mean}}^t$ 为第 t 代量子秃鹰种群的所有量子位置的平均值.

(2) 猎物搜索策略:对于量子秃鹰种群中第 φ 只量子秃鹰,其猎物搜索策略的量子旋转角矢量 $\mathbf{v}_\varphi^{t+1} = (v_{\varphi,1}^{t+1}, v_{\varphi,2}^{t+1}, \dots, v_{\varphi,B}^{t+1})$ 可以表示为

$$\mathbf{v}_\varphi^{t+1} = \delta_\varphi (\mathbf{y}_\varphi^t - \mathbf{y}_{\text{mean}}^t) + \mu_\varphi (\mathbf{y}_\varphi^t - \mathbf{y}_{\varphi+1}^t) \quad (20)$$

其中, $\delta_\varphi = \delta_{r,\varphi} / \max_{1 \leq \varphi \leq N} \{\delta_{r,\varphi}\}$, $\mu_\varphi = \mu_{r,\varphi} / \max_{1 \leq \varphi \leq N} \{\mu_{r,\varphi}\}$, $\delta_{r,\varphi} = u_\varphi \sin(g_\varphi)$, $\mu_{r,\varphi} = u_\varphi \cos(g_\varphi)$, $u_\varphi = g_\varphi + \lambda_2 r_2$, $g_\varphi = \pi \lambda_1 r_1$, g_φ 和 u_φ 分别表示螺旋方程的极角和极径, $\lambda_1 \in [5, 10]$ 和 $\lambda_2 \in [0.5, 2]$ 是控制螺旋轨迹的参数, r_1 和 r_2 为 $[0, 1]$ 内均匀分布的随机数.

(3) 俯冲捕食策略:对于量子秃鹰种群中第 φ 只量子秃鹰,其俯冲捕食策略的量子旋转角矢量可以表示为

$$\mathbf{v}_\varphi^{t+1} = \omega_\varphi (\mathbf{y}_\varphi^t - z_1 \mathbf{y}_{\text{mean}}^t) + \zeta_\varphi (\mathbf{y}_\varphi^t - z_2 \mathbf{y}_{\text{best}}^t) \quad (21)$$

其中, $\omega_\varphi = \omega_{r,\varphi} / \max_{1 \leq \varphi \leq N} \{\omega_{r,\varphi}\}$, $\zeta_\varphi = \zeta_{r,\varphi} / \max_{1 \leq \varphi \leq N} \{\zeta_{r,\varphi}\}$, $\omega_{r,\varphi} = \vartheta_\varphi \sinh(\kappa_\varphi)$, $\zeta_{r,\varphi} = \vartheta_\varphi \cosh(\kappa_\varphi)$, $\vartheta_\varphi = \kappa_\varphi$, $\kappa_\varphi = \pi \lambda_3 r_3$, κ_φ 和 ϑ_φ 分别表示螺旋方程的极角和极径, $\lambda_3 \in [5, 10]$, r_3 为 $[0, 1]$ 内均匀分布的随机数, $z_1, z_2 \in [1, 2]$ 表示量子秃鹰向最佳与中心位置的运动强度, $\mathbf{y}_{\text{best}}^t$ 为到第 t 代为止量子秃鹰种群的最优量子位置.

使用空间选择策略、猎物搜索策略和俯冲捕食策略更新量子旋转角后,第 φ 只量子秃鹰的第 b 维量子位置使用模拟量子旋转门进行演化,演化规则为

$$y_{\varphi,b}^{t+1} = \left| y_{\varphi,b}^t \cos(v_{\varphi,b}^{t+1}) + \sqrt{1 - (v_{\varphi,b}^{t+1})^2} \sin(v_{\varphi,b}^{t+1}) \right| \quad (22)$$

其中, $v_{\varphi,b}^{t+1}$ 为第 φ 只量子秃鹰的第 b 维量子旋转角, $b=1, 2, \dots, B$.

(4) 记忆策略:该策略分为初始化和更新两个阶段,首先定义记忆池 $M_{\text{MP}} = \{\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_L\}$, 其中, L 为当前记忆池中量子位置数目.

初始化操作:找出初始量子秃鹰种群中的最优量子位置,将其作为记忆池的第一个元素.

更新操作:通过优适应度准则和劣适应度准则来

进行判断.

在优适应度准则中,对于量子秃鹰种群中第 φ 只量子秃鹰, \mathbf{y}_φ^{t+1} 和记忆池中所有元素的欧几里得距离可以表述如下

$$\chi_{\varphi,l}^{t+1} = \sqrt{(y_{\varphi,1}^{t+1} - m_{l,1})^2 + \dots + (y_{\varphi,B}^{t+1} - m_{l,B})^2} \quad (23)$$

其中, $\mathbf{m}_l = (m_{l,1}, m_{l,2}, \dots, m_{l,B})$, $l \in \{1, 2, \dots, L\}$, 定义接受概率为

$$P_\varphi^{t+1}(\chi_{\varphi,l}, h) = (\chi_{\varphi,l}^{t+1})^h \quad (24)$$

其中, $\chi_{\varphi,l}^{t+1}$ 为 \mathbf{y}_φ^{t+1} 与记忆池中所有元素欧几里得距离的最小值, h 代表演化阶段, $h = 1, 2, \dots, \bar{h}$, \bar{h} 为最大演化阶段.

对于第 φ 只量子秃鹰,产生 $[0, 1]$ 间均匀分布的随机数 r_φ^{t+1} ,如果 $r_\varphi^{t+1} < P_\varphi^{t+1}$,则 \mathbf{y}_φ^{t+1} 可以加入到记忆池中;否则,认为 \mathbf{y}_φ^{t+1} 与记忆池中元素 $\mathbf{m}_{l'}$ ($l' = \arg \min_{l \in \{1, 2, \dots, L\}} \chi_{\varphi,l}^{t+1}$)相似,进而,如果与 $\bar{\mathbf{m}}_{l'}$ 相比, $\bar{\mathbf{y}}_\varphi^{t+1}$ 的适应度函数值更优,则将 $\mathbf{m}_{l'}$ 替换为 \mathbf{y}_φ^{t+1} ,具体公式可表示为

$$M_{MP} \leftarrow \begin{cases} \mathbf{m}_{L'+1} = \mathbf{y}_\varphi^{t+1}, & r_\varphi^{t+1} < P_\varphi^{t+1} \\ \mathbf{m}_{l'} = \mathbf{y}_\varphi^{t+1}, & r_\varphi^{t+1} \geq P_\varphi^{t+1} \text{ 且 } F(\bar{\mathbf{y}}_\varphi^{t+1}) > F(\bar{\mathbf{m}}_{l'}) \end{cases} \quad (25)$$

其中, $L' \geq L$, $F(\bar{\mathbf{y}}_\varphi^{t+1})$ 和 $F(\bar{\mathbf{m}}_{l'})$ 分别为 $\bar{\mathbf{y}}_\varphi^{t+1}$ 和 $\bar{\mathbf{m}}_{l'}$ 的适应度函数. \leftarrow 表示将 $\mathbf{m}_{L'+1}$ 加入记忆池中或更新后的 $\mathbf{m}_{l'}$ 替换记忆池中相应元素.

劣适应度准则是 $F(\bar{\mathbf{y}}_\varphi^{t+1}) < F(\bar{\mathbf{m}}^{\text{worst}})$ 时进行的操作,首先定义概率

$$\bar{P}_\varphi^{t+1} = \begin{cases} \tilde{P}_\varphi^{t+1}, & 0.5 \leq \tilde{P}_\varphi^{t+1} \leq 1 \\ 0, & 0 \leq \tilde{P}_\varphi^{t+1} < 0.5 \end{cases} \quad (26)$$

其中, $\tilde{P}_\varphi^{t+1} = (F(\bar{\mathbf{y}}_\varphi^{t+1}) - F(\bar{\mathbf{y}}_{\text{worst}}^{t+1})) / (F(\bar{\mathbf{y}}_{\text{best}}^{t+1}) - F(\bar{\mathbf{y}}_{\text{worst}}^{t+1}))$, $\bar{\mathbf{y}}_{\text{best}}^{t+1}$ 和 $\bar{\mathbf{y}}_{\text{worst}}^{t+1}$ 分别为到第 $t+1$ 代为止量子秃鹰种群中最优位置和最差位置.

对于第 φ 只量子秃鹰,产生 $[0, 1]$ 间均匀分布的随机数 \bar{r}_φ^{t+1} ,如果 $\bar{r}_\varphi^{t+1} < \bar{P}_\varphi^{t+1}$,则 \mathbf{y}_φ^{t+1} 可以看作新的局部最优量子位置;否则,不做任何操作.

为了决定 \mathbf{y}_φ^{t+1} 是否可以加入至记忆池中,产生一个 $[0, 1]$ 间均匀分布的随机数 \tilde{r}_φ^{t+1} ,相应过程类似于优适应度准则,如果 $\tilde{r}_\varphi^{t+1} < P_\varphi^{t+1}$,则 \mathbf{y}_φ^{t+1} 可以加入到记忆池中;否则,不进行任何操作,具体公式可表示为

$$M_{MP} \leftarrow \begin{cases} \mathbf{m}_{L'+1} = \mathbf{y}_\varphi^{t+1}, & \tilde{r}_\varphi^{t+1} < P_\varphi^{t+1} \\ M_{MP}, & \tilde{r}_\varphi^{t+1} \geq P_\varphi^{t+1} \end{cases} \quad (27)$$

(5)记忆池选择策略:如果记忆池中元素个数多于量子秃鹰数目 N ,则选择记忆池中前 N 个较优元素作为更新后的量子秃鹰种群;否则,不足的部分由更新后较优的量子位置进行补充.

(6)净化策略:首先获取记忆池中最优量子位置

\mathbf{m}^{best} ,分别计算记忆池中其他元素 \mathbf{m}_l ($l = 1, 2, \dots, L'$)与 \mathbf{m}^{best} 的欧几里得距离,按其从小到大的顺序逐一比对,如果 $\bar{\mathbf{m}}^{\text{best}}$ 与 $\bar{\mathbf{m}}_l$ 两者中值的适应度函数值 $F[(\bar{\mathbf{m}}^{\text{best}} + \bar{\mathbf{m}}_l)/2]$ 介于两者之间,则认为 \mathbf{m}^{best} 与 \mathbf{m}_l 相似,如果两者适应度函数值均优于 $F[(\bar{\mathbf{m}}^{\text{best}} + \bar{\mathbf{m}}_l)/2]$,则认为 \mathbf{m}_l 属于另一个全局或局部最优区域,因此净化率可以定义为

$$\eta_r = \lambda_4 \|\mathbf{m}^{\text{best}} - \mathbf{m}_l\| \quad (28)$$

其中, λ_4 表示伸缩因子,避免错误删除,之后便通过净化率将净化范围内的元素删除.

3.2 多峰量子秃鹰算法的计算复杂度分析

对于提出的多峰量子秃鹰算法,量子秃鹰种群中有 N 只量子秃鹰,优化问题维数为 B .空间选择策略中,每只量子秃鹰需要更新每一维的量子旋转角和量子位置,则每次迭代更新量子旋转角和量子位置的计算复杂度为 $O(2NB)$;猎物搜索策略中,每只量子秃鹰螺旋飞行相应的计算复杂度为 $O(6N)$,每只量子秃鹰需要更新每一维的量子旋转角和量子位置,则每次迭代更新量子旋转角和量子位置的计算复杂度为 $O(2NB)$;俯冲捕食策略中,每只量子秃鹰螺旋飞行后需要更新每一维的量子旋转角和量子位置,则相应的计算复杂度为 $O(2NB+6N)$;每只量子秃鹰每次迭代均需要通过记忆策略和记忆池选择策略,则相应的计算复杂度为 $O(6N)$;净化策略只在每个演化阶段结束时进行,则相应的计算复杂度为 $O(3N)$;每次迭代中,所有量子秃鹰的量子位置需要映射到位置并计算适应度,此部分计算复杂度为 $O(3NB+3N)$.因此,当最大迭代次数为 T 时,多峰量子秃鹰算法的计算复杂度为 $O(T(9NB+21N)+3N)$.

3.3 基于多峰量子秃鹰算法的相干分布源 DOA 估计

为了保证量子秃鹰种群的多样性,每只量子秃鹰的初始量子位置均在量子区间内随机产生.如果第 φ 只量子秃鹰在第 t 次迭代时的位置为 $\bar{\mathbf{y}}_\varphi^t$,针对所提出的相干分布源 DOA 估计方法,定义其适应度函数为 $F(\bar{\mathbf{y}}_\varphi^t) = \text{trace}(\mathbf{P}_{\alpha(\bar{\mathbf{y}}_\varphi^t)} \mathbf{U}_s \mathbf{W} \mathbf{U}_s^H)$,量子秃鹰算法的每个位置对应于相干分布源的角度参数的估计值.冲击噪声下基于多峰量子秃鹰算法的相干分布源 DOA 估计方法具体步骤如下:

步骤 1 获取相干分布源快拍采样数据,确定待优化变量,构造多峰加权子空间拟合的优化目标函数.

步骤 2 初始化多峰量子秃鹰算法的相关参数,如种群规模,最大迭代次数,螺旋轨迹控制参数,伸缩因子等.初始化量子秃鹰种群的量子位置,其中,量子位

置每一维均为 $[0, 1]$ 间的均匀随机数,将初始量子位置映射为位置,计算所有量子秃鹰的适应度函数,初始化记忆池。

步骤 3 依次利用空间选择策略、猎物搜索策略和俯冲捕食策略更新量子秃鹰种群中每只量子秃鹰的量子旋转角和量子位置,将量子位置映射为位置并进行适应度函数的计算,同时在每次更新量子位置后利用记忆策略更新记忆池并利用记忆池选择策略对量子位置进行选择。

步骤 4 判断是否达到当前演化阶段的最大迭代次数,如果达到,则利用净化策略删除记忆池中的相似元素,令 $h=h+1$ 进入下一演化阶段,执行下一步;否则,直接执行下一步。

步骤 5 判断是否达到最大迭代次数,如果没有,令迭代次数加 1,返回步骤 3;否则,终止算法,输出记忆池中所有元素,经映射后即为中心方位角和角度扩展的估计值。

4 冲击噪声下克拉美罗界推导

克拉美罗界是评估相干分布源 DOA 估计方法性能的重要指标,这一节将推导冲击噪声下相干分布源 DOA 估计的克拉美罗界,首先,考虑第 k 次快拍时相干分布源的阵列接收信号模型为

$$\begin{aligned} \mathbf{x}(k) &= \mathbf{C}(\boldsymbol{\psi})\mathbf{s}(k) + \mathbf{n}(k) \\ &= \mathbf{g}(\boldsymbol{\Gamma}, k) + \mathbf{n}(k) \end{aligned} \quad (29)$$

其中, $\mathbf{g}(\boldsymbol{\Gamma}, k)$ 和 $\mathbf{n}(k)$ 分别表示信号成分和噪声成分, $\mathbf{s}(k)$ 可以表示为 $\mathbf{s}(k) = \bar{\mathbf{s}}(k) + j\tilde{\mathbf{s}}(k)$, $\bar{\mathbf{s}}(k)$ 和 $\tilde{\mathbf{s}}(k)$ 分别表示其实部和虚部,则 $\boldsymbol{\Gamma} = (\bar{\mathbf{s}}^T(1), \dots, \bar{\mathbf{s}}^T(K), \tilde{\mathbf{s}}^T(1), \dots, \tilde{\mathbf{s}}^T(K), \boldsymbol{\psi}^T)^T$, $\mathbf{n}(k) = (n_1(k), n_2(k), \dots, n_M(k))^T$, $n_i(k) = \bar{n}_i(k) + j\tilde{n}_i(k)$,冲击噪声满足参数为 Ω 的圆对称分布,其概率密度函数为 $f_n(\bar{\mathbf{n}}, \tilde{\mathbf{n}})$,克拉美罗界可以表示为

$$\text{CRB}(\hat{\Gamma}_i) \geq [\mathbf{J}_F^{-1}]_{ii} \quad (30)$$

其中, $\hat{\Gamma}_i$ 是对 $\boldsymbol{\Gamma}$ 中元素 Γ_i 的估计, \mathbf{J}_F 是 Fisher 信息矩阵,其第 i 行第 j 列的元素可表示为

$$J_{ij} = \mathbb{E} \left[\frac{\partial \ln f_X(\mathbf{X})}{\partial \Gamma_i} \frac{\partial \ln f_X(\mathbf{X})}{\partial \Gamma_j} \right] \quad (31)$$

其中, $\mathbf{X} = [\mathbf{x}(1) \ \mathbf{x}(2) \ \dots \ \mathbf{x}(K)]$,其概率密度函数可以表示为

$$f_X(\mathbf{X}) = \prod_{k=1}^K \prod_{i=1}^M f_n(\bar{x}_i(k) - \bar{g}_i(\boldsymbol{\Gamma}, k), \tilde{x}_i(k) - \tilde{g}_i(\boldsymbol{\Gamma}, k)) \quad (32)$$

令 $\bar{n}_i(k) = \bar{x}_i(k) - \bar{g}_i(\boldsymbol{\Gamma}, k)$, $\tilde{n}_i(k) = \tilde{x}_i(k) - \tilde{g}_i(\boldsymbol{\Gamma}, k)$,则可以得到

$$\begin{aligned} J_{ij} &= I_r(\Omega) \sum_{k=1}^K \sum_{l=1}^M \frac{\partial \bar{g}_l(\boldsymbol{\Gamma}, k)}{\partial \Gamma_i} \frac{\partial \bar{g}_l(\boldsymbol{\Gamma}, k)}{\partial \Gamma_j} \\ &+ I_i(\Omega) \sum_{k=1}^K \sum_{l=1}^M \frac{\partial \tilde{g}_l(\boldsymbol{\Gamma}, k)}{\partial \Gamma_i} \frac{\partial \tilde{g}_l(\boldsymbol{\Gamma}, k)}{\partial \Gamma_j} \end{aligned} \quad (33)$$

$$I_r(\Omega) = \mathbb{E} \left\{ \left[\frac{\frac{\partial}{\partial \bar{\mathbf{n}}} f_n(\bar{\mathbf{n}}, \tilde{\mathbf{n}})}{f_n(\bar{\mathbf{n}}, \tilde{\mathbf{n}})} \right]^2 \right\}, \quad (34)$$

$$I_i(\Omega) = \mathbb{E} \left\{ \left[\frac{\frac{\partial}{\partial \tilde{\mathbf{n}}} f_n(\bar{\mathbf{n}}, \tilde{\mathbf{n}})}{f_n(\bar{\mathbf{n}}, \tilde{\mathbf{n}})} \right]^2 \right\}$$

由于 $f_n(\bar{\mathbf{n}}, \tilde{\mathbf{n}})$ 具有圆对称特性,则 $I_r(\Omega)$ 和 $I_i(\Omega)$ 可以表示为

$$I_c(\Omega) = \pi \int_0^\infty \frac{[f'(\zeta)]^2}{f(\zeta)} \zeta d\zeta \quad (35)$$

因此, Fisher 信息矩阵可表示为

$$\mathbf{J}_F = I_c(\Omega) \sum_{k=1}^K \text{Re} \left[\left(\frac{\partial \mathbf{g}(\boldsymbol{\Gamma}, k)}{\partial \boldsymbol{\Gamma}} \right)^H \left(\frac{\partial \mathbf{g}(\boldsymbol{\Gamma}, k)}{\partial \boldsymbol{\Gamma}} \right) \right] \quad (36)$$

对 Fisher 信息矩阵求逆可以得到 $\boldsymbol{\psi}$ 的克拉美罗界为

$$\text{CRB}(\boldsymbol{\psi}) = \frac{\left\{ \sum_{k=1}^K \text{Re} \left[\mathbf{S}^H(k) \mathbf{D}^H \mathbf{P}_{C(\boldsymbol{\psi})}^\perp \mathbf{D} \mathbf{S}(k) \right] \right\}^{-1}}{I_c(\Omega)} \quad (37)$$

其中, $\boldsymbol{\psi} = (\theta_1, A_1, \theta_2, A_2, \dots, \theta_p, A_p)^T$, $\mathbf{S}(k) = \text{diag}(\mathbf{s}(k) \otimes \mathbf{1}_{2 \times 1})$, $\mathbf{D} = [\mathbf{d}(\theta_1) \ \mathbf{d}(A_1) \ \dots \ \mathbf{d}(\theta_p) \ \mathbf{d}(A_p)]$, $\mathbf{d}(\theta_i) = \partial \mathbf{c}(\theta_i, A_i) / \partial \theta_i$, $\mathbf{d}(A_i) = \partial \mathbf{c}(\theta_i, A_i) / \partial A_i$, $\mathbf{P}_{C(\boldsymbol{\psi})}^\perp = \mathbf{I} - \mathbf{C}(\boldsymbol{\psi})(\mathbf{C}^H(\boldsymbol{\psi})\mathbf{C}(\boldsymbol{\psi}))^{-1}\mathbf{C}^H(\boldsymbol{\psi})$, $\mathbf{1}_{2 \times 1} = [1, 1]^T$. $I_c(\Omega)$ 和 S α S 分布的概率密度函数 $f(\zeta)$ 有关,可采用双参数高斯柯西混合模型^[29]来近似获得 S α S 分布的概率密度函数,其可以表示为

$$\begin{aligned} f(\zeta) &= (1 - \varepsilon) f_G(\zeta) + \varepsilon f_C(\zeta) \\ &= (1 - \varepsilon) \frac{1}{2\sqrt{\pi\gamma}} \exp\left(-\frac{\zeta^2}{4\gamma^2}\right) + \frac{\varepsilon\gamma}{\pi(\zeta^2 + \gamma^2)} \end{aligned} \quad (38)$$

其中, ε 为混合率, γ 为 S α S 分布的离差。

5 仿真实验及结果分析

为了评估所提相干分布源 DOA 估计方法的性能,定义信号角度的估计值和真实值的绝对偏差小于等于 2° 时为估计成功一次,定义均方根误差(Root Mean Square Error, RMSE)为

$$\text{RMSE} = \sqrt{\sum_{i=1}^p \sum_{n=1}^{N_c} \frac{(\theta_i - \hat{\theta}_{in})^2}{PN_c}} \quad (39)$$

其中, N_c 表示 Monte-Carlo 实验次数, θ_i 表示第 i 个相干

分布源中心方位角的真实值, $\hat{\theta}_n$ 表示 θ_i 第 n 次实验的估计值.

将本文所提方法记为 MQBEA-WNC-MWSSF, 分别将 FLOM^[16]、FLOC^[17]、ROC^[18] 和 DSPE^[22] 算法结合记为 FLOM-DSPE^[22]、FLOC-DSPE、ROC-DSPE, 将 FLOM 和 ESPRIT 算法结合记为 FLOM-ESPRIT^[10].

假设两个窄带相干分布源信号入射到 $M = 8$ 个阵元的均匀线阵, 相邻阵元间距为半波长, 加权常数 $\beta = 1$. 多峰量子秃鹰算法参数设置如下: 种群规模 $N = 10$, $B = 2$, $\lambda_{\max} = 2$, $\lambda_{\min} = 1.5$, $\lambda_1 = 10$, $\lambda_2 = 1.5$, $\lambda_3 = 10$, $z_1 = z_2 = 1$, $\lambda_4 = 0.85$, $\bar{h} = 3$, 最大迭代次数 $T = 100$, 演化过程分为 $h = 1, 2, 3$ 三个阶段, 最大迭代次数的前 50% 为第一阶段, 50% 到 75% 第二阶段, 75% 到 100% 为第三阶段.

本文将所提方法与 FLOM-DSPE、FLOC-DSPE、ROC-DSPE、FLOM-ESPRIT 以及 CRB 进行了对比, FLOM、FLOC 和 ROC 的阶数分别设置为 1.2, 0.7, 1.2, 谱峰搜索的扫描间隔为 0.1° , 仿真实验中, 设定两个相干分布源的中心方位角分别为 -30.13° 和 28.74° , 角度扩展均为 2° , Monte-Carlo 仿真实验次数为 300.

实验 1 快拍数对中心方位角的影响. 假设两个相干分布源是相互独立的, 广义信噪比 $\text{GSNR} = 15 \text{ dB}$, 特征指数 $\alpha = 1.6$, $\varepsilon = 0.4$, $\gamma = 1$, 图 1 仿真了不同快拍数下算法的均方根误差曲线并和克拉美罗界进行了比较, 从图 1 可以看出, 随着快拍数的增大, 各算法的均方根误差不断减小, 本文所提方法均方根误差最小, 相比其他算法估计精度更高, 更接近克拉美罗界.

图 2 仿真了不同快拍数下的估计成功概率曲线, 从图 2 可以看出, 随着快拍数的增大, 各算法的估计成功概率不断提高, 本文所提方法的估计成功概率在快拍数大于 15 时, 估计成功概率均接近 1, 相比其他算法具有更高的估计成功概率. 从实验 1 可以得出所提 MQBEA-WNC-MWSSF 方法充分发挥了 MWSSF 在小快拍时的优势并通过 MQBEA 进行快速无量化误差求解, 具有更好的鲁棒性和有效性.

实验 2 广义信噪比和特征指数对中心方位角的影响. 假设两个相干分布源是相互独立的, 快拍数为 30, 图 3 仿真了特征指数 $\alpha = 1.6$ 时不同广义信噪比下算法的均方根误差曲线并和克拉美罗界进行了比较, 从图 3 可以看出, 在小快拍情况下, 随着广义信噪比的增大, 各算法的均方根误差不断减小, 所提方法相比其他算法更接近克拉美罗界, 具有更高的估计精度.

图 4 仿真了广义信噪比为 15 dB 时不同特征指数下算法的估计成功概率曲线, 从图 4 可以看出, 随着特征指数的增大, 各算法的估计成功概率不断提高, 本文所提方法的估计成功概率在特征指数大于 1 时, 估计成功




图 1 不同快拍数下算法的均方根误差曲线

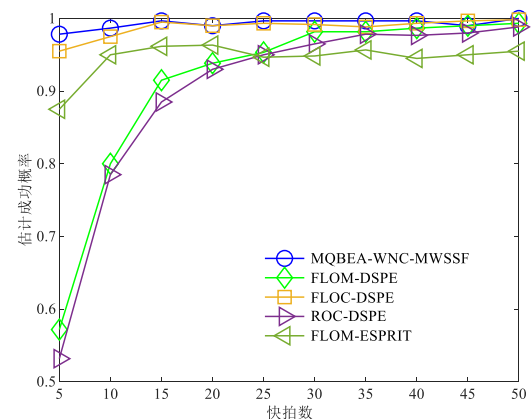


图 2 不同快拍数下算法的估计成功概率曲线

概率逐渐接近于 1, 相比其他算法具有更高的估计成功概率. 从实验 2 可以得出本文所提 MQBEA-WNC-MWSSF 方法具有更好的去冲击效果, 且在低信噪比、小快拍时鲁棒性更好, 性能更优.

实验 3 广义信噪比和特征指数对角度扩展的影响. 假设两个相干分布源是相互独立的, 快拍数为 30,




图 3 不同广义信噪比下算法的均方根误差曲线




图4 不同特征指数下算法的估计成功概率曲线

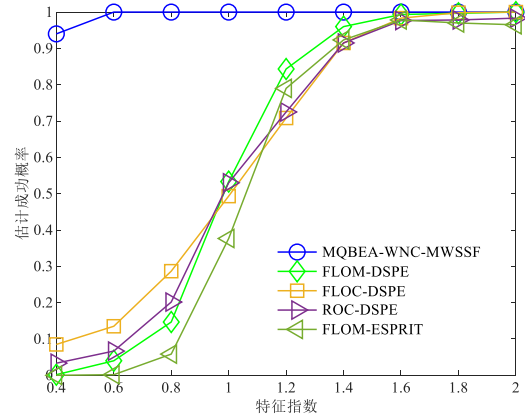


图6 不同特征指数下算法的估计成功概率曲线

图5仿真了特征指数 $\alpha = 1.6$ 时不同广义信噪比下算法估计相干分布源角度扩展的均方根误差曲线并和克拉美罗界进行了比较,从图5可以看出,随着广义信噪比的增大,各算法的均方根误差不断减小,和其他算法相比,所提方法估计相干分布源角度扩展的均方根误差最小,更接近克拉美罗界,在估计精度方面优于其他算法.

图6仿真了广义信噪比为 15 dB 时不同特征指数下算法对相干分布源角度扩展的估计成功概率曲线,从图6可以看出,随着特征指数的增大,各算法的估计成功概率不断提高,本文所提方法的估计成功概率在特征指数大于 0.6 时,估计成功概率达到 1,相比其他算法具有明显的性能优势. 从实验3可以得出本文所提MQBEA-WNC-MWSSF方法不仅可以有效求解中心方位角,在求解角度扩展时也较其他方法有明显的优势.

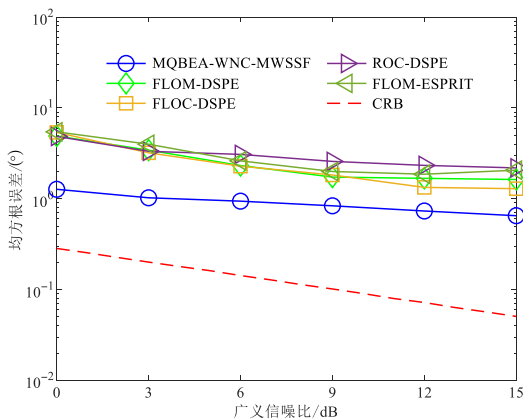


图5 不同广义信噪比下算法的均方根误差曲线

实验4 信源相干时不同参数对中心方位角的影响. 假设两个相干分布源是相干的,快拍数为 30,因为DSPE算法和ESPRIT算法无法定位相干源,因此引入空间平滑方法^[30]用于解相干,将结合后的算法记为

SSDSPE算法和SSESPRIT算法,图7仿真了特征指数 $\alpha = 1.6$ 时不同广义信噪比下算法估计相干分布源中心方位角的均方根误差曲线并和克拉美罗界进行了比较,从图7可以看出,随着广义信噪比的增大,各个算法估计相干信源中心方位角的均方根误差不断减小,和其他算法相比,本文所提方法估计相干信源中心方位角的估计均方根误差最低,估计精度最高,更加接近克拉美罗界.

图8仿真了广义信噪比为 15 dB 时不同特征指数下算法估计相干信源中心方位角的估计成功概率曲线,从图8可以看出,随着特征指数的增大,各个算法的估计成功概率不断提高,本文所提方法的估计成功概率在特征指数大于 1 时,估计成功概率达到 1,相比其他算法具有更高的估计成功概率. 从实验4可以得出本文所提MQBEA-WNC-MWSSF方法在求解相干源上有明显的优势,无需额外的解相干操作即可求解相干源,且不损失阵列孔径.

实验5 仿真时间对比. 假设两个相干分布源是相互独立的,快拍数为 30,广义信噪比为 15 dB,特征指数




图7 不同广义信噪比下算法的均方根误差曲线




图8 不同特征指数下算法的估计成功概率曲线

为 1.6, 仿真使用 MATLAB R2018a 进行, 整个仿真在 PC (Intel (R) Core (TM) i5-7300HQ CPU @ 2.50 GHz, 8 GB, Windows 10-64 bits) 上执行, 本文所提方法与其他算法的平均仿真时间对比如表 1 所示. 结果表明, FLOM-ESPRIT 算法的仿真时间最短, 但综合实验 1 到实验 4, 该算法性能相对很差, 与基于二维谱峰搜索的 DSPE 算法相比, 本文所提算法的仿真时间缩短了 30 倍以上, 且估计性能最优.

表 1 仿真时间对比

算法	平均仿真时间/s
MQBEA-WNC-MWSSF	0.127
FLOM-DSPE	3.958
FLOC-DSPE	4.034
ROC-DSPE	4.201
FLOM-ESPRIT	0.006

通过 5 个仿真实验说明, 与已有的相干分布源 DOA 估计方法相比, 所提的 MQBEA-WNC-MWSSF 方法是性能最优的相干分布源 DOA 估计算法, 其均方根误差最接近克拉美罗界, 且不损失阵列孔径即可解相干信源. 在扫描间隔为 0.1° 时, FLOM-DSPE、FLOC-DSPE 和 ROC-DSPE 等算法的计算时间超过所设计的 MQBEA-WNC-MWSSF 算法 30 倍且量化误差不可避免, 若为了减少量化误差把 DSPE 类算法的扫描间隔设为 0.01° , 其计算量将扩大 100 倍, 量化误差还是不可避免. 因此本文所提的 MQBEA-WNC-MWSSF 方法不仅有优异的性能, 而且通过将加权信号子空间拟合算法涉及的多维联合优化问题转化为多峰优化问题, 同时设计单链编码的多峰量子秃鹰算法快速无量化误差求解, 终于突破了加权信号子空间拟合类算法计算量远大于 DSPE 类算法的不足, 计算时间上取得显著优势, 有利于工程应用和推广.

6 结束语

本文提出了一种冲击噪声下相干分布源多峰 DOA 估计方法, 用于估计冲击噪声环境下相干分布源的中心方位角和角度扩展, 并且推导了冲击噪声下相干分布源 DOA 估计的克拉美罗界. 与已有相干分布源 DOA 估计方法相比, 本文所提方法在小快拍数、低信噪比和强冲击噪声环境下具有更好的鲁棒性和有效性且无需额外解相干操作即可处理相干信源, 不损失阵列孔径, 突破了已有相干分布源 DOA 估计方法的应用局限, 扩大了相干分布源 DOA 估计方法的应用范围.

所提的多峰量子秃鹰算法结合量子计算、秃鹰搜索算法和多峰优化的特点, 设计了新的演化策略, 加快了收敛速度, 其可以替代二维谱峰搜索有效求解 MWSSF 算法, 大大降低了算法的计算量, 避免了量化误差, 是具有良好性能的多峰优化算法, 具有较好的收敛性能. 所设计的多峰量子秃鹰算法和多峰加权信号子空间拟合算法都可以移植应用到其他复杂的 DOA 估计问题, 如极化敏感阵列和 MIMO 雷达的参数估计问题, 促进 DOA 估计技术的进一步发展和应用.

参考文献

- [1] SHI J P, WEN F Q, LIU T P. Nested MIMO radar: Coarrays, tensor modeling, and angle estimation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(1): 573-585.
- [2] DAS A. Real-valued sparse Bayesian learning for off-grid direction-of-arrival (DOA) estimation in ocean acoustics [J]. IEEE Journal of Oceanic Engineering, 2021, 46(1): 172-182.
- [3] WANG F Y, TIAN Z, LEUS G, et al. Direction of arrival estimation of wideband sources using sparse linear arrays [J]. IEEE Transactions on Signal Processing, 2021, 69: 4444-4457.
- [4] FENG M Y, CUI Z M, YANG Y X, et al. A reduced-dimension MUSIC algorithm for monostatic FDA-MIMO radar[J]. IEEE Communications Letters, 2021, 25(4): 1279-1282.
- [5] AHMED T, ZHANG X F, HASSAN W U. A higher-order propagator method for 2D-DOA estimation in massive MIMO systems[J]. IEEE Communications Letters, 2020, 24 (3): 543-547.
- [6] FENG M Y, YANG Y X, SHU Q, et al. An improved ESPRIT-based algorithm for monostatic FDA-MIMO radar with linear or nonlinear frequency increments[J]. IEEE Communications Letters, 2021, 25(7): 2375-2379.
- [7] SONG S S, MA X F, SHENG W X, et al. Maximum likeli-

- hood sensor array calibration using non-approximate hessian matrix[J]. *IEEE Signal Processing Letters*, 2021, 28: 688-692.
- [8] MENG D D, WANG X P, HUANG M X, et al. Robust weighted subspace fitting for DOA estimation via block sparse recovery[J]. *IEEE Communications Letters*, 2020, 24(3): 563-567.
- [9] VALAEE S, CHAMPAGNE B, KABAL P. Parametric localization of distributed sources[J]. *IEEE Transactions on Signal Processing*, 1995, 43(9): 2144-2153.
- [10] SHAHBAZPANAHI S, VALAEE S, BASTANI M H. Distributed source localization using ESPRIT algorithm [J]. *IEEE Transactions on Signal Processing*, 2001, 49(10): 2169-2178.
- [11] XIONG W M, JOSÉ P, SYLVIE M. Performance analysis of distributed source parameter estimator (DSPE) in the presence of modeling errors due to the spatial distributions of sources[J]. *Signal Processing*, 2018, 143: 146-151.
- [12] XU H, TIAN Y, LIU S. Linear-shrinkage-based DOA estimation for coherently distributed sources considering mutual coupling in massive MIMO systems[J]. *AEU - International Journal of Electronics and Communications*, 2020, 126: 153398.
- [13] NAM J G, LEE S H, LEE K K. 2-D nominal angle estimation of multiple coherently distributed sources in a uniform circular array[J]. *IEEE Antennas and Wireless Propagation Letters*, 2014, 13: 415-418.
- [14] WU T, LI Y W, ZHANG X F, et al. DOA estimation of two-dimensional coherently distributed sources based on spatial smoothing of uniform rectangular arrays[J]. *International Journal of Antennas and Propagation*, 2019: 1-12.
- [15] MAHMOOD A, CHITRE M, ARMAND M A. On single-carrier communication in additive white symmetric alpha-stable noise[J]. *IEEE Transactions on Communications*, 2014, 62(10): 3584-3599.
- [16] TZAGKARAKIS G, NOLAN J P, TSAKALIDES P. Compressive sensing using symmetric alpha-stable distributions for robust sparse signal reconstruction[J]. *IEEE Transactions on Signal Processing*, 2019, 67(3): 808-820.
- [17] MA X Y, NIKIAS C L. Joint estimation of time delay and frequency delay in impulsive noise using fractional lower order statistics[J]. *IEEE Transactions on Signal Processing*, 1996, 44(11): 2669-2687.
- [18] TSAKALIDES P, NIKIAS C L. The robust covariation-based MUSIC (ROC-MUSIC) algorithm for bearing estimation in impulsive noise environments[J]. *IEEE Transactions on Signal Processing*, 1996, 44(7): 1623-1633.
- [19] HE J, LIU Z, WONG K T. Snapshot-instantaneous ll. llinfin normalization against heavy-tail noise[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(3): 1221-1227.
- [20] 安春莲, 杨古月, 杨延菊. 基于中值滤波预处理的强冲击噪声背景测向方法[J]. *电子学报*, 2021, 49(6): 1159-1166.
- AN C L, YANG G Y, YANG Y J. DOA estimation under strong impulsive noise based on median value filtering[J]. *Acta Electronica Sinica*, 2021, 49(6): 1159-1166. (in Chinese)
- [21] TIAN Q, QIU T S, LI J C, et al. Robust adaptive DOA estimation method in an impulsive noise environment considering coherently distributed sources[J]. *Signal Processing*, 2019, 165: 343-356.
- [22] TIAN Q, QIU T S, CAI R Y. DOA estimation for CD sources by complex cyclic correntropy in an impulsive noise environment[J]. *IEEE Communications Letters*, 2020, 24(5): 1015-1019.
- [23] 孟荣华, 孙艾文, 吴正佳, 等. 改进灰狼算法求解复杂混合流水调度问题研究[J]. *电子学报*, 2021, 49(8): 1515-1523.
- MENG R H, SUN A W, WU Z J, et al. Research on complex hybrid flow-shop scheduling problem solved by improved grey wolf optimizer[J]. *Acta Electronica Sinica*, 2021, 49(8): 1515-1523. (in Chinese)
- [24] IBRAHIM I A, HOSSAIN M J, DUCK B C, et al. An adaptive wind-driven optimization algorithm for extracting the parameters of a single-diode PV cell model[J]. *IEEE Transactions on Sustainable Energy*, 2020, 11(2): 1054-1066.
- [25] ALSATTAR H A, ZAIDAN A A, ZAIDAN B B. Novel meta-heuristic bald eagle search optimisation algorithm [J]. *Artificial Intelligence Review*, 2020, 53(3): 2237-2264.
- [26] GAO H Y, CHEN M H, DU Y N, et al. Monostatic MIMO radar direction finding in impulse noise[J]. *Digital Signal Processing*, 2021, 117: 103198.
- [27] RIM C, PIAO S H, LI G, et al. A niching chaos optimization algorithm for multimodal optimization[J]. *Soft Computing*, 2018, 22(2): 621-633.
- [28] DOWLATSHAHI M B, DERHAMI V, NEZAMABADIPOUR H. Fuzzy particle swarm optimization with near-

est-better neighborhood for multimodal optimization[J].
Iranian Journal of Fuzzy Systems, 2020,17(4): 7-24.

- [29] LI X T, SUN J, JIN L W, et al. Bi-parameter CGM model for approximation of-stable PDF[J]. Electronics Letters, 2008, 44(18): 1096-1098.
- [30] PAN J J, SUN M, WANG Y D, et al. An enhanced spatial smoothing technique with ESPRIT algorithm for direction of arrival estimation in coherent scenarios[J]. IEEE Transactions on Signal Processing, 2020, 68: 3635-3643.

作者简介



高洪元 男,1977年出生,黑龙江木兰人。现为哈尔滨工程大学副教授、博士生导师。主要研究方向为无线通信系统、阵列信号处理、智能计算理论及应用。中国电子学会会员编号: E190014628M。
E-mail: gaohongyuan@hrbeu.edu.cn



刘亚鹏 男,1999年出生,河北邯郸人。现为哈尔滨工程大学博士研究生。主要研究方向为阵列信号处理、智能计算理论及应用。
E-mail: liuyapeng@hrbeu.edu.cn



杜亚男 女,1992年出生,黑龙江讷河人。现为哈尔滨工程大学博士研究生。主要研究方向为量子优化算法、群智能计算、认知无线电和阵列信号处理。
E-mail: wenhuamo@126.com



程建华 男,1977年出生,黑龙江哈尔滨人。现为哈尔滨工程大学教授、博士生导师。主要研究方向为惯性导航与定位技术、组合导航技术。中国电子学会会员编号: E190017540S。
E-mail: chengjianhua@hrbeu.edu.cn



孙贺麟 男,1999年出生,吉林吉林人。现为哈尔滨工程大学博士研究生。主要研究方向为统计信号分析和阵列信号处理。
E-mail: sunhelin1999@gmail.com