

DOI: 10.19650/j.cnki.cjsi.J2615158

基于块稀疏贝叶斯学习的声源定位研究^{*}

降春景¹, 李文国^{1,2}, 王俊宏¹, 刘 昊¹, 席旭刚¹

(1. 杭州电子科技大学自动化学院 杭州 310018; 2. 杭州奇点感知技术有限公司 杭州 310009)

摘 要:针对复杂环境下传统声源定位算法精度不足、稀疏贝叶斯求解复杂度高、收敛慢等问题,提出一种并行子阵列块稀疏贝叶斯学习(PS-BSBL)的声源定位算法。设计离线子阵列划分(OSP)算法,通过协方差矩阵自适应进化策略(CMA-ES)差值优化的阵列权重设计与 Leiden 图聚类算法,将麦克风阵列与空间网格划分为匹配的子阵列和子网格空间,每个子阵列在各自对应的空间并行求解降低全局求解规模。构建 PS-BSBL 框架,采用逆高斯先验与 Gamma 先验分别建模稀疏超参数与噪声精度和变分贝叶斯实现后验近似;针对贝塞尔函数无法消去的场景,提出多步惯性牛顿迭代(MSI)加速超参数更新,提升剪枝效率与收敛速度。实验结果表明,所提 OSP 算法相比块对角近似算法可使快速变分块稀疏贝叶斯学习(F-BSBL)、期望最大化 BSBL(BSBL-EM)、加权 BSBL(W-BSBL)算法运行时间平均降低平均时间降低百分比为 97.61%、87.63% 和 87.82%,归一化均方误差(NMSE)降低平均降低 86.53%、16.64%、24.13%;PS-BSBL 算法收敛速度较组稀疏快速边缘化 BSBL(g-FMLM)算法、快速边缘化 BSBL(BSBL-FM)分别提升 99.80%、99.85%,NMSE 分别降低 51.30%、8.92%;在-10~20 dB 信噪比下,PS-BSBL 的角度均方根误差(RMSE)较基于 L1 范数和奇异值分解的稀疏重构算法(L1SVD)、离网格稀疏贝叶斯学习(OGSBL)、基于卷积神经网络(CNN)的方法、基于残差网络(ResNet)的方法平均降低 65.11%、20.86%、81.59%、78.45%,在低信噪比、欠定、大规模阵列场景下鲁棒性更优。

关键词: 麦克风阵列;块稀疏贝叶斯学习;CMA-ES;子阵列划分;多步惯性

中图分类号: TH89 TB52 **文献标识码:** A **国家标准学科分类代码:** 510.40

Sound source localization research based on block sparse Bayesian learning

Jiang Chunjing¹, Li Wenguo^{1,2}, Wang Junhong¹, Liu Hao¹, Xi Xugang¹

(1. College of Automation, Hangzhou Dianzi University, Hangzhou 310018; 2. Hangzhou Qidian Sensing Technology Co., Ltd., Hangzhou 310009, China)

Abstract: To address issues such as insufficient accuracy of traditional sound source localization algorithms in complex environments, high complexity, and slow convergence of sparse Bayesian solvers, a parallel subarray block sparse Bayesian learning (PS-BSBL) algorithm for sound source localization is proposed. An offline subarray partitioning (OSP) algorithm is designed, which divides microphone arrays and spatial grids into matched subarrays and subgrid spaces through covariance matrix adaptive evolution strategy (CMA-ES)-optimized array weight design and Leiden graph clustering algorithm. Each subarray solves its corresponding spatial problem in parallel, reducing the global solution scale. The PS-BSBL framework is constructed, employing inverse Gaussian priors and Gamma priors to model sparse hyperparameters and noise precision, respectively, with variational Bayesian methods for posterior approximation. For scenarios where Bessel functions cannot be eliminated, a multi-step inertial Newton iteration (MSI) is proposed to accelerate hyperparameter updates, enhancing pruning efficiency and convergence speed. Experimental results show that the proposed OSP algorithm reduces the average running time of fast variational block sparse Bayesian learning (F-BSBL), expectation-maximization BSBL (BSBL-EM), and weighted BSBL (W-BSBL) by 97.61%, 87.63%, and 87.82%, respectively, compared to block diagonal approximation algorithms, while normalized mean squared error (NMSE) decreases by an average of 86.53%, 16.64%, and 24.13%. The PS-BSBL algorithm improves convergence speed by 99.80% and 99.85% over group sparse fast marginalization BSBL (g-FMLM) and fast marginalization BSBL (BSBL-FM), respectively, with NMSE reductions of 51.30% and 8.92%, respectively. Under signal-to-

收稿日期:2026-04-16 Received Date: 2026-04-16

^{*} 基金项目:浙江省“高层次人才特殊支持计划”科技创新领军人才项目(2022R52051)资助

noise ratios from -10 to 20 dB, PS-BSBL achieves lower angle root mean squared error (RMSE) than L1 norm and singular value decomposition-based sparse reconstruction (L1SVD), off-grid sparse Bayesian learning (OGSBL), convolutional neural network-based (CNN), and residual network-based (ResNet) methods by averages of 65.11%, 20.86%, 81.59%, and 78.45%, respectively, demonstrating superior robustness in low SNR, underdetermined, and large-scale array scenarios.

Keywords: microphone array; BSBL; CMA-ES; subarray division; multi-step inertial

0 引言

基于麦克风阵列的声源定位技术凭借非接触、远距离、全天时工作等优势,已从传统雷达、声呐领域延伸至工业故障检测^[1-3]、噪声源定位^[4-6]、声学成像^[7-9]、设备状态监测^[10-12]等关键场景,成为声学信号处理与阵列信号处理的核心研究方向。

常用的声源定位的算法有波束形成算法、子空间算法、压缩感知^[13]3种。近年来随着压缩感知理论在阵列信号处理技术方面的发展,稀疏贝叶斯学习(sparse Bayesian learning, SBL)算法逐渐被用于声源定位和波达方向(direction of arrival, DOA)估计场景中。SBL使用高斯混合尺度模型,把权重精度看作超参数,通过估计超参数的数值重构出稀疏信号,为了估计出超参数的值, Tipping^[14]在稀疏贝叶斯学习框架下,通过最大化边缘似然对超参数进行直接估计,并推导了相应的期望最大化(expectation maximization, EM)迭代更新公式;Wipf等^[15]将SBL推广至过完备基选择问题,并采用EM算法进行参数求解;Bishop等^[16]将变分推断(variational Bayesian, VB)算法应用于相关向量机,以获取参数的后验分布近似;Faul等^[17]分析了稀疏贝叶斯学习中边缘似然函数的单变量性质,推导出稀疏性判定准则;在此基础上,Tipping等^[18]提出了基于坐标上升的快速边缘似然最大化算法。上述算法都有复杂度高、运行时间长、收敛慢等问题。在EM和VB的基础上,Pedersen等^[19]提出了基于贝塞尔K(Bessel K)分布的双层分层先验模型;Shutin等^[20]则针对变分稀疏贝叶斯学习,通过解析计算变分更新驻点的方式,提出了快速变分推理算法;Möderl等^[21]提出利用求解固定点多项式正实根的方法代替迭代,但在贝塞尔函数无法消去的情况下,迭代法无法向固定点多项式正实根求解转换。Boyle等^[22]提出了一种近似块对角化字典矩阵算法来并行求解,但是在近似过程中会损失精度。

本文提出一种并行子阵列块稀疏贝叶斯学习(parallel subarray block sparse Bayesian learning, PS-BSBL)的声源定位算法。针对文献[22]的问题,本文设计的离线子阵列划分(offline subarray partitioning, OSP)算法,通过线性调频信号建模、阵列协方差矩阵奇异值分解(singular value decomposition, SVD)与Leiden算法分类,将麦克风阵列与空间网格自适应划分为匹配的子阵列和子网格对,每个子

阵列在各自对应的空间并行求解降低全局求解规模;使得阵列天然分块并行求解,加速算法的同时不会由于近似引起精度损失。针对文献[21]贝塞尔函数无法消去的问题,提出多步惯性牛顿迭代(multi-step inertial Newton iteration, MSI)加速超参数更新,提升剪枝效率与收敛速度。

1 算法原理

1.1 OSP 算法原理

本文到提出的OSP算法,通过阵列权重设计和Leiden算法分类,把阵列划分为子阵列并且在对应的子网格空间进行DOA估计。由于文献[23]的阵列权重设计方法没有考虑噪声影响,本文提出一种协方差矩阵自适应进化策略(covariance matrix adaptation evolution strategy, CMA-ES)差值优化的阵列权重设计方法,通过加入对噪声协方差 $\mathbf{R}_n$ 的估计,使子阵列在对应的子网格空间内,具备噪声抑制能力。

对工业中要检测的目标信号,进行连续小波变换(continuous wavelet transform, CWT)提取窄带分量后,把窄带分量用一个线性调频信号来表示,任意形状的 M 阵元阵列,在 $N=R \times R$ 的网格空间 G_N 内, θ_i 方向,接收到的希尔伯特变换的解析信号协方差为:

$$\hat{\mathbf{C}}_{a\theta_i} = \mathbf{E}[\mathbf{a}_a(t)\mathbf{a}_a(t)^H] = 4 \int_0^\infty \mathbf{F}[\mathbf{a}_a(t)]^2 S_f(\theta_i) S_f(\theta_i)^2 df \quad (1)$$

把噪声协方差记为 $\mathbf{R}_n$,噪声的模型采用Toeplitz矩阵的有色噪声模型:

$$\mathbf{R}_n = \sigma^2 \mathbf{I}(\xi) \quad (2)$$

对于给定的 ξ ,计算白化矩阵 $\mathbf{D}(\xi)$ 满足 $\mathbf{D}^H(\xi)\mathbf{D}(\xi) = \mathbf{R}_n(\xi)^{-1}$,通过Cholesky分解 $\mathbf{R}_n(\xi) = \mathbf{L}\mathbf{L}^H$,取 $\mathbf{D}(\xi) = \mathbf{L}^{-1}$,此时信号协方差为:

$$\tilde{\mathbf{C}}_{a\theta_i} = \mathbf{D}^H(\xi)\hat{\mathbf{C}}_{a\theta_i}\mathbf{D}(\xi) \quad (3)$$

对协方差矩阵 $\tilde{\mathbf{C}}_{a\theta_i}$ 进行SVD分解:

$$\hat{\mathbf{C}}_{a\theta_i} = \mathbf{U}\mathbf{\Sigma}\mathbf{U}^H \quad (4)$$

其中, $\mathbf{w}_i(\xi)$ 就是左奇异向量。

对信号进行染噪后的 $\tilde{\mathbf{a}}_a(t)$,使用权重 $\mathbf{w}_i(\xi)$ 计算每个方向的输出功率:

$$P_\xi(\xi) = \frac{1}{T} \int_0^T |\mathbf{w}_i(\xi)^H \tilde{\mathbf{a}}_a(t)|^2 dt \quad (5)$$

使用BSBL类算法估计出的DOA与真实角度的差值

的模记为 $T(\xi)$, 用 CMA-ES 优化, 找到使 $T(\xi)$ 最小的参数 ξ^* 。则最优白化矩阵为:

$$\mathbf{D}^* = \mathbf{R}_n(\xi^*)^{-\frac{1}{2}} \quad (6)$$

最优协方差为:

$$\tilde{\mathbf{C}}_{a\theta_i}^* = \mathbf{D}^H(\xi^*) \hat{\mathbf{C}}_{a\theta_i} \mathbf{D}(\xi^*) \quad (7)$$

最优权重就是 $\tilde{\mathbf{C}}_{a\theta_i}^*$ 的左奇异向量 $\mathbf{w}_i^*(\xi^*)$ 。

按照同样的方法, 得到 M 个阵元对于 N 个网格空间的权重 $\mathbf{W}$:

$$\mathbf{W} = [\mathbf{w}_1^*, \dots, \mathbf{w}_N^*] \in \mathbf{C}^{M \times N} \quad (8)$$

使用 Leiden 图聚类算法根据权重 $\mathbf{W}$ 对阵列和网格空间进行划分, 构建一个二分图 $B = (R_M \times G_N, \mu)$, 其中 $R_M = [r_1, \dots, r_m]$ 是阵列中阵元的坐标点集, $\mu = |\mathbf{W}|$ 是二分图的边集, 该二分图的邻接矩阵 $\mathbf{A}$ 是一个 $(M + G) \times (M + G)$ 的矩阵。

Leiden 图聚类算法通过最大化模块度 (modularity) 将节点划分为若干社区 (community)。最终的结果就是得到节点到社区的映射, 即阵元坐标点集到网格点集的映射 $\{c_i\}_{i=1}^{M+G}$, 全部节点划分为 K 个社区, 这 K 个社区, $C_1, \dots, C_k$, 之中包含了部分阵元的坐标点集和网格点集。子阵列集合 M_k 和子网格空间 G_k 计算方法为:

$$M_k = C_k \cap R_M, G_k = C_k \cap G_N \quad (9)$$

通过 OSP 算法实现了子阵列的划分, 把每个子网格空间分配到对应子阵列中, 让每个子阵列被分到其权重占比高的子网格空间, 并且通过改进权重设计算法使子阵列在其子网格空间内具备噪声抑制能力。

1.2 PS-BSBL 算法原理

1) 超参数后验均值的固定点更新

本文采用均值场变分贝叶斯框架对信号系数、超参数及噪声精度进行联合后验推断, 其中超参数作为随机变量参与层次贝叶斯建模, 并通过变分后验分布进行近似。由变分推导可得, 超参数的变分后验近似分布属于广义逆高斯分布族, 其后验均值满足固定点方程。参考文献[21]的理论结果, 该后验均值对应的固定点与经验贝叶斯 (type-II maximum likelihood) 框架下边际似然最大化所得的一阶驻点具有一致性。因此, 本文在统计建模层面采用变分贝叶斯推断, 而在数值计算层面利用这种固定点一致性, 通过求解固定点方程获得超参数变分后验均值的数值解。这种一致性仅体现在最终固定点解层面, 并不改变超参数作为随机变量参与贝叶斯建模和后验推断的本质。

参考文献[21]可知, 在其采用的超先验参数设置下, 超参数后验均值可写成闭式更新形式; 而本文所采用的广义逆高斯先验下, 后验均值更新涉及修正贝塞尔函数, 其对应固定点方程通常不存在解析解, 因此需要借助数值迭代方法求解。为此, 本文提出 MSI 算法对该固定

点方程进行高效求解。MSI 仅作为变分后验均值固定点方程的数值求解器, 用于加速超参数更新过程, 不改变原有层次贝叶斯建模及变分推断框架。

综上, 所提 PS-BSBL 方法在模型构建与推断机制上属于变分贝叶斯框架, 而 MSI 算法仅用于提高固定点方程的求解效率, 并不改变其贝叶斯推断本质。

本文采用逆高斯分布建立缩放超参数 γ_i 先验, 其概率密度函数为:

$$P(\gamma_i; a, b, c) = \frac{\left(\frac{a}{b}\right)^{\frac{c}{2}} \gamma_i^{c-1}}{2L_c \sqrt{ab}} \exp\left\{-\frac{1}{2}(a\gamma_i + b\gamma_i^{-1})\right\} \quad (10)$$

式中: a, b, c 是形状参数, 3 个参数共同决定分布的具体形态, 当 a, b, c 取不同的值时, 此概率密度函数会变为逆 Gamma 分布、Gamma 分布或 Jeffreys 分布; L_c 是第 2 类修正贝塞尔函数。

本文采用 Gamma 分布建立噪声精度 λ_i 先验, 其概率密度函数为:

$$P(\lambda_i; \varepsilon, \eta) = \frac{\eta^\varepsilon}{\Gamma(\varepsilon)} \lambda^{e-1} \exp\{-\eta\lambda\} \quad (11)$$

参考文献[21], γ_{ij}^* 的一致性方程为:

$$\gamma_{ij}^* \propto \gamma_{ij}^{c-1} \exp\left\{-\frac{1}{2}(\hat{a}_j \gamma_{ij} + b\gamma_{ij}^{-1})\right\} \quad (12)$$

后验均值为:

$$\hat{\gamma}_{ij} = \langle \gamma_{ij} \rangle_{\gamma_{ij}^*} = \sqrt{\frac{b}{\hat{a}_{ij}}} \frac{L_{c+1}(\sqrt{\hat{a}_{ij}b})}{L_c(\sqrt{\hat{a}_{ij}b})} \quad (13)$$

更新函数 $f(\gamma_{ij})$ 与不动点方程为:

$$f(\gamma_{ij}) = \sqrt{\frac{b}{\hat{a}_{ij}(\gamma_{ij})}} \frac{L_{c+1}(\sqrt{\hat{a}_{ij}(\gamma_{ij})b})}{L_c(\sqrt{\hat{a}_{ij}(\gamma_{ij})b})} \quad (14)$$

$$f(\gamma_{ij}) - \gamma_{ij} = 0 \quad (15)$$

2) 基于不动点方程的带多步惯性的牛顿迭代法

在固定点方程的求解中, 贝塞尔函数可以根据先验概率模型的选择, 随参数消去, 把迭代转化为求根, 从而达到快速计算求解的目的。在对先验概率模型无偏好, 贝塞尔函数无法消去的情况下, 本文提出一种带多步惯性的牛顿迭代法的超参数更新算法, 对于式 (15) 不动点方程仍用迭代法求解, 当不动点方程不收敛, 直接剪枝, 当不动点方程收敛时, 牛顿迭代方程可表示为:

$$\gamma_{ij}^{[n+1]} = \gamma_{ij}^{[n]} - \frac{f(\gamma_{ij}^{[n]}) - \gamma_{ij}^{[n]}}{f(\gamma_{ij}^{[n]}) - 1} \quad (16)$$

更新到第 k 步时, 放置一个惯性权重 $\alpha_c^{(k)}$ 则此点成为惯性点 $\omega^{(k)}$, 表示为:

$$\omega^{(k)} = \gamma_{ij}^{(k)} + \sum_{c=1}^p \alpha_c^{(k)} (\gamma_{ij}^{(k-c+1)} - \gamma_{ij}^{(k-c)}) \quad (17)$$

其中, P 是惯性步数, 当 $P = 1$ 时, 退化为两点惯性:

$$\omega^{(k)} = \gamma_{ij}^{(k)} + \alpha_c^{(k)} (\gamma_{ij}^{(k)} - \gamma_{ij}^{(k-1)}) \quad (18)$$

惯性权重 $\alpha_c^{(k)}$ 随时间衰减, 衰减序列为:

$$\alpha_c^{(k)} = \frac{m}{k^\beta} \quad (19)$$

在每一步迭代前, 先用惯性外推得到一个预测惯性点 $\omega^{(k)}$, 然后在该点执行牛顿校正:

$$\gamma_{ij}^{(k+1)} = \omega^{(k)} - \frac{f(\omega^{(k)}) - \omega^{(k)}}{f'(\omega^{(k)}) - 1} \quad (20)$$

由于更新函数 $f(\gamma_{ij})$ 中贝塞尔函数 L_c 和 L_{c+1} 的存在, 令:

$$z(\gamma_{ij}) = \sqrt{\hat{a}_{ij} b} \quad (21)$$

$$u(\gamma_{ij}) = \sqrt{\frac{b}{\hat{a}_{ij}(\gamma_{ij})}} \quad (22)$$

$$R(z) = \frac{L_{c+1}(z)}{L_c(z)} \quad (23)$$

根据贝塞尔函数的求导公式, 可以导出:

$$f'(\gamma_{ij}) = u'(\gamma_{ij}) R(z) + u(\gamma_{ij}) \frac{dz(\gamma_{ij})}{dz} z(\gamma_{ij}) \quad (24)$$

在更新迭代的过程中, 给出一个容差 e , 当 $|\gamma_{ij}^{[n+1]} - \gamma_{ij}^{[n]}| < e$ 时, 代表迭代完成, 否则, 将迭代值存入历史, 作为惯性权重的参数继续下一步迭代。

为判定为发散的条件设置如下 3 个准则。

准则 1:

$$|f(\gamma_{ij}^{[n]}) - 1| < \delta \quad (25)$$

准则 2:

$$|\gamma_{ij}^{[n+1]} - \gamma_{ij}^{[n]}| > C \quad (26)$$

准则 3:

$$|f(\gamma_{ij}^{[n+1]}) - \gamma_{ij}^{[n+1]}| > 2 |f(\gamma_{ij}^{[n]}) - \gamma_{ij}^{[n]}| \quad (27)$$

满足以上任意一个准则或超过最大迭代次数, 判定迭代发散, 直接剪枝。

1.3 定量计算复杂度分析

对本文所提出 PS-BSBL 算法的理论计算复杂度进行定量分析, 设麦克风阵元数为 M , 空间离散网格数为 N , 块稀疏信号分块数为 g , OSP 划分得到的子阵列数量为 W , 算法收敛迭代次数为 T , 收敛精度为 v 。

期望最大化 BSBL (expectation-maximization BSBL, BSBL-EM) 方法在每次迭代中需更新协方差矩阵, 并进行矩阵求逆运算。虽然利用 Woodbury 恒等式可将直接矩阵求逆复杂度由 $\mathcal{O}(N^3)$ 降低至 $\mathcal{O}(M^3)$ 。

但协方差矩阵构造及后验统计量更新仍需进行大量矩阵乘法运算, 其主要复杂度项为 $\mathcal{O}(M^2 N)$ 。

其中, $\mathcal{O}(M^2 N)$ 主要来源于协方差矩阵构造过程中矩阵乘法以及后验协方差更新运算。因此, 在 $N \gg M$ 的高维 DOA 稀疏重构场景下, BSBL-EM 的总体复杂度可表示为 $\mathcal{O}(M^2 N \cdot T_{EM})$ 。

其中, T_{EM} 为 EM 类算法的线性收敛迭代次数。并行块稀疏贝叶斯学习 (parallel block sparse Bayesian learning, P-BSBL)^[22] 通过谱聚类将字典矩阵近似划分为 W 个独立子问题, 每个子问题规模约为:

$$\frac{M}{W} \times \frac{N}{W} \quad (28)$$

则其主导矩阵求逆复杂度可降低为:

$$\mathcal{O}\left(W \left(\frac{M}{W}\right)^3\right) = \mathcal{O}\left(\frac{M^3}{W^2}\right) \quad (29)$$

其主导总体复杂度为:

$$\mathcal{O}\left(\frac{M^3}{W^2} T_{EM}\right) \quad (30)$$

该方法需额外进行谱聚类与块对角近似预处理, 其预处理复杂度通常达到 $\mathcal{O}(N^3)$ 。

随着子块数量增加, 块对角近似误差会逐渐累积, 从而影响 DOA 重构精度。

快速变分块稀疏贝叶斯学习 (fast variational block sparse Bayesian learning, F-BSBL)^[21] 在变分贝叶斯固定点框架下, 通过分析超参数后验均值的一致性方程, 实现了固定点更新加速。当修正贝塞尔函数可解析消去时, 可将超参数更新转化为多项式求根问题, 从而使算法由传统 EM 的线性收敛:

$$T_{EM} = \mathcal{O}(\log(1/v)) \quad (31)$$

提升为局部二次收敛:

$$T_{F-BSBL} = \mathcal{O}(\log \log(1/v)) \quad (32)$$

但该方法依赖于特定超先验条件。当采用广义逆高斯先验时, 由于修正贝塞尔函数无法解析消去, 其固定点方程难以获得闭式解析解, F-BSBL 的多项式求根策略不再适用。

针对上述问题, 本文提出的 PS-BSBL 方法采用 OSP 与 MSI 联合加速框架。首先, OSP 利用 Leiden 图聚类对阵列进行物理结构划分, 其复杂度约为:

$$\mathcal{O}(g \log g) = \mathcal{O}\left(\frac{N}{d} \log \frac{N}{d}\right) \quad (33)$$

该过程仅需执行一次, 且无需进行近似, 因此不会引入额外近似误差。

在超参数求解阶段, MSI 针对贝塞尔函数不可解析消去的一致性固定点方程, 采用多步惯性牛顿迭代进行数值求解。由于牛顿校正仅涉及块内维度 d 的导数计算, 其单次更新复杂度约为 $\mathcal{O}(d)$ 。

同时, MSI 保持了局部二次收敛特性, 其迭代复杂度为:

$$T_{MSI} = \mathcal{O}(\log \log(1/v)) \quad (34)$$

由于 OSP 将整体阵列划分为 W 个独立子阵列, 因此每个子问题的矩阵求逆复杂度为:

$$\mathcal{O}\left(\left(\frac{M}{W}\right)^3\right) \quad (35)$$

从而 PS-BSBL 的在线 DOA 估计阶段的总体复杂度

可表示为:

$$\mathcal{O}\left(W\left(\frac{M}{W}\right)^3 T_{\text{MSI}}\right) = \mathcal{O}\left(\frac{M^3}{W^2} T_{\text{MSI}}\right) \quad (36)$$

此外,OSP 阵列划分属于离线预处理阶段,其复杂度约为:

$$\mathcal{O}\left(\frac{N}{d} \log \frac{N}{d}\right) \quad (37)$$

由于该过程仅在阵列结构与空间网格初始化时执行一次,因此不会随时迭代过程重复累积。

传统 BSBL-EM 的复杂度为:

$$\mathcal{O}(M^2 N \cdot T_{\text{EM}}) \quad (38)$$

相比,本文方法的理论加速比约为:

$$\frac{M^2 N \cdot T_{\text{EM}}}{\frac{M^3}{W^2} \cdot T_{\text{MSI}}} = \frac{N}{M} \cdot W^2 \cdot \frac{T_{\text{EM}}}{T_{\text{MSI}}} \quad (39)$$

由于 $N \gg M$ 且 $T_{\text{EM}} \gg T_{\text{MSI}}$, 所以 PS-BSBL 方法在理论上显著降低计算复杂度。

2 实验结果与分析

2.1 OSP 算法性能验证

为验证 OSP 算法的效率与精度,在单快拍场景下固定阵元数量 M , 锁定信号长度, 改变信号恢复的欠定程度, 用仿真数据验证 OSP 算法对于 BSBL-EM^[14]、加权块稀疏贝叶斯学习 (weighted block sparse Bayesian learning, W-BSBL)^[24]、F-BSBL^[21] 算法 3 种算法, 在不同的网格点下, 运行时间和精度的影响。本文所用的 128 通道多臂螺旋阵列和 OSP 算法划分的 3 个子阵列如图 1 所示, 每个阵列及其对应的子网格空间如图 2 所示。




图 1 麦克风阵列

Fig. 1 Microphone array diagram




图 2 子阵列覆盖网格空间

Fig. 2 Grid space covered by subarrays

Z 轴正方向、网格点为 361×91 个的网格框架为例, 步长设置为 1° , 在 OSP 算法中, 观察各子阵列所覆盖的网格空间, 在方位角方面, 子阵列覆盖的网格空间相等, 子阵列 1 覆盖 $0^\circ \sim 45^\circ$ 、 $165^\circ \sim 224^\circ$ 和 $346^\circ \sim 360^\circ$, 子阵列 2 覆盖 $46^\circ \sim 104^\circ$ 和 $225^\circ \sim 284^\circ$, 子阵列 3 覆盖 $105^\circ \sim 164^\circ$ 和 $225^\circ \sim 345^\circ$, 在俯仰角 $80^\circ \sim 90^\circ$ 的范围内每个子阵列覆盖全部 360° 的方位角。

在麦克风数 $M = 128$, 网格点数 $N \gg M$ 的严重欠定场

景下的串行计算环境中系统比较了子阵列 BSBL 算法与并行 BSBL 算法的计算效率与重建精度。所有实验采用相同的算法参数: 广义逆高斯超先验设置为 $a = 0, b = 1, c = 1$ (即 Gamma 先验), 初始精度 $\gamma = 10^{-2}$, 正则化系数 10^{-8} , 最大迭代次数 200。所有算法均顺序执行, 与文献[22]的串行对比方式保持一致, 确保了性能比较的公平性。在所有实验中, 涉及到两个指标分别是归一化均方误差 (normalized mean squared error, NMSE) 和角度均方根误差 (root mean squared error, RMSE):

$$\text{NMSE} = \frac{|x - \hat{x}|^2}{|x|^2} \quad (40)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\theta - \hat{\theta})^2} \quad (41)$$

近年来声学阵列研究, 大规模阵列通常指阵元数量超过 64 通道甚至达到百通道级别的阵列系统。相关研

究通常依据具体应用场景采用“small-scale”、“large-aperture”、“large-scale”或“huge microphone array”等经验性描述。已有研究中,3 元、6 元及 7 元阵列通常用于小型语音增强或微型阵列场景^[25-26],而 64 元阵列已被广泛应用于高分辨波束形成与声学成像研究^[27]。Tamai 等^[28]已将 128 通道麦克风阵列明确称为“huge microphone array”。因此,相较于传统声源定位系统中常

见的小规模阵列,相较于传统 8~32 通道阵列,128 通道阵列在阵列流形构建、协方差矩阵计算及稀疏重构过程中将带来显著更高的计算复杂度,因此本文采用的 128 阵元多臂螺旋麦克风阵列可合理归属于大规模麦克风阵列范畴。

仿真信号为频率 39.5 kHz 的复正弦信号,时域波形与频谱图如图 3 所示。




图 3 输入信号

Fig. 3 Input signal

计算规模参数如表 1 所示,实验结果如表 2、3 和图 4、5 所示。

由表 1 可知,本文提出的 OSP 方法相比于 P-BSBL 在计算效率和重构精度上均具有显著优势。在运行时间

方面,OSP-F 的平均时间降低百分比为 97.61%;OSP-EM 和 OSP-W 的平均时间降低百分比分别为 87.63% 和 87.82%,展现出高加速比。在 NMSE 重构精度方面,OSP-F 的平均 NMSE 降低百分比为 86.53%,精度提升最

表 1 计算规模参数

Table 1 Calculation scale parameters

参数类别	参数名称	符号	数值	备注
问题规模	局部网格点数	$N = N_{\theta} \times N_{\varphi}$	1 180、3 365、6 640、7 370、8 280	主要变化参数,由方位角点数 $\times$ 俯仰角点数决定
	方位角网格数	N_{θ}	13、37、73、81、91	—
	俯仰角网格数	N_{φ}	91	$0^{\circ} \sim 90^{\circ}$,步长 1°
	麦克风总数	M	128	阵列大小
	子阵列数目	W	3	子阵列划分的个数
算法参数	块大小	d	5	BSBL 块结构参数
	并行块数	S	3	并行划分的子问题个数
	最大迭代次数	$I_{\max}$	300	算法停止条件
	收敛容差	tol	1×10^{-4}	算法停止条件
	正则化系数	reg	1×10^{-8}	EM 算法中防止矩阵奇异
仿真条件	信噪比	SNR	10 dB	接收信号信噪比
	频率	f	39 500 Hz	声源频率
	声速	c	343 m/s	空气中声速
	采样率	f_s	192 000 Hz	信号采样率
	信号时长	T	0.4 s	快拍数据长度

表 2 各算法运行时间
Table 2 Running time of each algorithm (ms)

网格点数	O-F	O-EM	O-W	P-F	P-EM	P-W
1 180	40. 23	146. 52	3 315. 91	403. 93	846. 78	36 692. 08
3 365	18. 94	1 374. 13	33 701. 02	2 973. 95	14 838. 85	289 567. 72
6 640	31. 62	8 705. 73	231 958. 93	10 438. 40	63 960. 67	1 528 848. 93
7 370	90. 33	10 948. 13	328 408. 10	12 850. 96	109 551. 99	2 391 849. 26
8 280	58. 65	16 476. 19	395 995. 38	16 384. 91	140 996. 96	3 503 428. 64

表 3 各算法 NMSE
Table 3 NMSE of various algorithms

网格点数	O-F	O-EM	O-W	P-F	P-EM	P-W
1 180	$1.390\ 3\times10^{-2}$	$4.805\ 7\times10^{-1}$	$1.747\ 8\times10^{-1}$	$2.695\ 1\times10^{-1}$	$7.214\ 7\times10^{-1}$	$2.248\ 4\times10^{-1}$
3 365	$4.326\ 4\times10^{-2}$	$7.411\ 1\times10^{-1}$	$2.514\ 2\times10^{-1}$	$5.926\ 3\times10^{-1}$	$9.012\ 4\times10^{-1}$	$3.267\ 2\times10^{-1}$
6 640	$1.390\ 2\times10^{-2}$	$8.107\ 7\times10^{-1}$	$1.826\ 9\times10^{-1}$	$4.073\ 9\times10^{-2}$	$9.463\ 4\times10^{-1}$	$2.347\ 6\times10^{-1}$
7 370	$4.672\ 1\times10^{-2}$	$8.620\ 5\times10^{-1}$	$2.610\ 7\times10^{-1}$	$3.860\ 6\times10^{-1}$	$9.561\ 1\times10^{-1}$	$3.905\ 6\times10^{-1}$
8 280	$1.363\ 6\times10^{-1}$	$8.933\ 1\times10^{-1}$	$4.543\ 7\times10^{-1}$	$1.570\ 9\times10$	$9.698\ 3\times10^{-1}$	$5.678\ 4\times10^{-1}$




图 4 各算法运行时间折线
Fig. 4 Line chart of running times for various algorithms

为突出;OSP-EM 和 OSP-W 的平均 NMSE 降低百分比分别为 16.64%和 24.13%,虽不及 OSP-F 显著,但仍优于对应的 P-BSBL-EM 和 P-BSBL-W。上述结果充分验证了本文所提 OSP 划分策略结合 F-BSBL 的优越性,实现计算效率与重构精度的突破。

2.2 PS-BSBL 算法重叠区性能验证

由于 Leiden 算法的互斥特性,划分所得到的子空间没有重叠区,为验证当声源点在子空间的边界时,算法出现的偏差、重叠区消除边界盲区的作用,本实验在子空间

的边界增加重叠区,改变重叠区的网格点数,对比不同网格点数下的 NMSE 和 RMSE,增加重叠区的子空间如图 6 所示,实验结果如表 4、图 7、8 所示。

由表 4、图 7 和 8 可以看出,随着重叠区网格点数的增加,PS-BSBL 算法的性能呈现显著改善趋势。当无重叠时,角度 RMSE 为 12.64°,表明边界方向的估计存在较大偏差。引入重叠区后,角度 NMSE 下降至 2°以内,且在多处达到完全准确。NMSE 也整体保持在较低水平,尤其在网格点数 13 289 处达到最小值 1.03×10^{-4} ,表明功




图 5 各算法 NMSE 折线

Fig. 5 Line chart of running times for various algorithms




图 6 带重叠区的子阵列覆盖网格空间

Fig. 6 Subarrays with overlapping regions rovering the grid space

表 4 不同重叠区的 NMSE 和 RMSE

重叠区网格点数	NMSE	角度误差/(°)
0	0.494 29	12.642 7
4 994	1.072 0	1.956 3
6 705	0.263 42	0.000 0
8 169	0.412 95	0.000 0
9 523	0.495 38	0.978 1
10 812	0.263 47	0.000 0
12 065	0.397 19	0.000 0
13 289	0.000 103 43	0.000 0
14 481	0.690 87	0.978 1
15 640	0.275 13	0.000 0
16 769	0.133 02	0.000 0

率谱重构精度极高。重叠区网格点数从约 5 000 增加至 16 769 的过程中,角度 RMSE 已稳定收敛,未出现因过度重叠而导致的性能下降。结果验证了适度重叠区能够有效消除子阵列边界盲区,提升 DOA 估计的鲁棒性和精度。




图 7 不同重叠区的 NMSE

Fig. 7 NMSE of different overlapping regions




图 8 不同重叠区的 RMSE

Fig. 8 RMSE of different overlapping regions

2.3 PS-BSBL 算法性能验证

为验证在先验参数的选择不能消去贝塞尔函数时,BSBL 算法的求解从固定点多项式的求解退化到迭代。

对比融合了 OSP 和 MSI 算法的 PS-BSBL 算法与快速边缘化块稀疏贝叶斯学习 (block sparse Bayesian learning-fast marginalization, FM-BSBL)^[18] 和分组快速边缘似然最大化 (group fast marginal likelihood maximisation, g-FMLM)^[29] 两种算法在不同欠定程度下的运行时间和精度。OSP 算法和 MSI 算法组成的 PS-BSBL 算法与传统的迭代算法快速边缘化 BSBL (BSBL-FM)、组稀疏快速边缘化 BSBL 贝叶斯学习算法,在不同的网格点下,比较运行时间和 NMSE,PS-BSBL 在串行环境下运行,实验结果如表 5、6 和图 9、10 所示。

表 5 各算法运行时间

Table 5 Running time of each algorithm (ms)			
网格点数	PS-BSBL	g-FMLM	BSBL-FM
1 180	43. 29	5 516. 4	3 295. 4
3 365	24. 902	31 854	7 183. 2
6 640	27. 95	52 613	15 864
7 370	30. 001	57 218	21 715
8 280	28. 226	64 038	24 706

表 6 各算法 NMSE 表

Table 6 NMSE of various algorithms			
网格点数	PS-BSBL	g-FMLM	BSBL-FM
1 180	0. 108 94	0. 269 51	0. 402 3
3 365	0. 434 86	0. 592 64	0. 643 35
6 640	0. 092 793	0. 040 746	0. 429 23
7 370	0. 273 44	0. 386 06	0. 409 19
8 280	0. 676 05	1. 570 9	1. 119 6




图 9 各运行时间折线图算法折线

Fig. 9 Line charts of running times for each algorithm

为验证 PS-BSBL 算法的性能优势,在不同网格点数下,分别从运算效率与重构精度两个维度,与 g-FMLM、




图 10 各算法 NMSE 折线

Fig. 10 NMSE Line chart of each algorithm

BSBL-FM 两种算法对比。运行时间对比结果表明,PS-BSBL 算法相较 g-FMLM、BSBL-FM 算法的运行时间缩减率均保持在 98.69% 以上。随着网格点数由 1 180 提升至 8 280,P-BSBL 相对 g-FMLM 算法的平均时间缩减率达 99.80%,相对 BSBL-FM 算法的平均时间缩减率为 99.58%,证明所提算法可大幅降低计算开销。

在重构精度维度,PS-BSBL 算法相较 BSBL-FM 算法表现出显著优势,误差降低幅度最低为 32.41%、最高可达 78.38%,整体平均精度提升 51.30%,说明该算法能够有效抑制重构误差,提升信号恢复精度。而与 g-FMLM 算法相比,PS-BSBL 算法整体平均精度提升 8.92%,在网格点数为 1 180、3 365、7 370、8 280 时,PS-BSBL 算法均实现不同程度的精度提升,误差降低幅度介于 26.62%~59.58%;综合来看,PS-BSBL 算法实现了运算效率的提升,兼顾精度与效率的需求,性能显著优于 g-FMLM 与 BSBL-FM 算法。

2.4 定位实验

为了验证 PS-BSBL 的抗噪声能力,使用采集板采集块稀疏声源,对比基于 L1 范数和奇异值分解的稀疏重构算法 (L1-norm singular value decomposition, L1SVD)^[30]、离网格稀疏贝叶斯学习算法 (off-grid sparse Bayesian learning, OGSBL)^[31]、基于卷积神经网络的方法 (convolutional neural networks, CNN)^[32]、基于残差网络的方法 (residual network, ResNet)^[33] 算法 4 种算法在不同信噪比下的角度均方根误差。采集信号的设备是自制的 128 通道的麦克风阵列采集板,产品的麦克风阵列与前文仿真所用阵列相同,如图 11 所示。

参考叶片损失检测原理^[34],使用两个相邻同向并排放置的扬声器作为块稀疏声源,上位机连接阵列采集板采集信号,采样率为 96 kHz,实验场景为 20 m×5 m×5 m 的实验室,如图 12 所示。

扬声器信号的波形和频谱如图 13 所示。




图 11 麦克风阵列采集板图

Fig. 11 Microphone array acquisition board diagram




图 12 实验场景

Fig. 12 Experimental scenario

在不同信噪比下进行定位,设置 $-10\sim 20$ dB 共 7 个信噪比,每个信噪比下进行 25 次定位实验,比较每个算




图 13 扬声器信号图

Fig. 13 Speaker signal diagram

法在每个信噪比下的平均 RMSE。为了提高定位的精度,在定位实验中信号入射的方位角和俯仰角采取 Y 轴入射

的定义,且缩小空间范围和网格步长,方位角和俯仰角是 $60\sim 120^\circ$,在此网格空间采用 OSP 算法,如图 14 所示。





图 14 OSP 划分网格示意图

Fig. 14 Schematic diagram of OSP grid division

加入重叠区后如图 15 所示。
声源在 $(90^\circ, 91^\circ)$,信噪比为 -5 dB 时,PS-BSBL 算法在某次测量的功率如图 16 所示。
从图 16 可以看出,在 -10 dB 信噪比的环境下,PS-BSBL 此次重构出信号的功率谱受噪声干扰较小,此次估

计的 DOA 与真实角度相差在 1° 上下,真实角度在子阵列 2 对应的子网格空间中,功率谱反映出的峰值在 $(90.5^\circ, 90.8^\circ)$,可以看出大多数网格点均判定为发散,子阵列 1 的 $(90.4^\circ, 89.7^\circ)$ 和子阵列 3 的 $(90.4^\circ, 90.2^\circ)$ 最终被判定为收敛,受噪声影响虽然有虚假峰值出现但是虚假峰




图 15 带重叠区的子阵列覆盖网格空间图

Fig. 15 Subarray coverage of grid space with overlapping regions

值也在真实 DOA 的 1° 邻域内,最终也可通过比较幅值或功率排除,对实验结果影响较小。实验结果如表 7 和图 17 所示。

从表 7 和图 17 可以看出,PS-BSBL 在 DOA 估计精度上具有显著优势。定量分析显示,与压缩感知算法相比,PS-BSBL 算法的 RMSE 较 L1-SVD 平均降低了 65.11%,较 OGSBL 平均降低了 20.86%,其中对 OGSBL 的精度提升幅度在低信噪比条件下尤为突出,有效增强算法在强噪声环境下的鲁棒性。与深度学习类方法相比,PS-BSBL 算法较 CNN-Based 和 ResNet-Based 分别实现了 81.59% 和 78.45% 的平均 RMSE 降低。整体而言,PS-BSBL 算法在全信噪比范围内均能实现稳定、低偏差的 DOA 估计,其性能显著优于现有主流对比算法,证明




图 16 PS-BSBL 功率谱图

Fig. 16 PS-BSBL power spectrum diagram

表 7 各算法平均角度 RMSE 估计

Table 7 Average angular RMSE estimation table for each algorithm							
算法	-10 dB	-5 dB	0 dB	5 dB	10 dB	15 dB	20 dB
L1-SVD	19.753 1	7.326 9	3.148 2	0.759 3	0.471 5	0.392 7	0.356 1
OGSBL	0.652 3	0.458 1	0.386 4	0.349 2	0.327 5	0.308 2	0.294 7
CNN-Based	5.296 2	3.871 5	2.483 6	1.592 7	1.285 3	0.951 8	0.726 4
ResNet-Based	4.751 9	3.482 6	2.197 3	1.296 4	1.123 8	0.762 9	0.637 5
PS-BSBL	0.471 5	0.342 8	0.301 6	0.285 7	0.269 3	0.254 1	0.242 6




图 17 各算法 RMSE 折线

Fig. 17 RMSE line chart of various algorithms

了该算法在处理复杂环境下阵列信号时的有效性与优越性。

3 结 论

本文算法的建立基于两个理想化假设:1)空间离散网格能够较好地表征真实声源位置;2)声源频谱特征能够通过先验知识或预处理过程获得。实际应用中,上述条件可能难以完全满足,从而对定位性能产生一定影响。

当真实声源位置偏离预设网格节点时,将产生字典失配现象,进而导致稀疏重构精度下降,并可能引起功率谱峰值偏移或能量扩散。本文通过引入子空间重叠区可

以有效缓解子阵列边界处的信息损失,但网格内部的离网误差仍然客观存在。实际应用中可根据定位精度需求适当提高空间网格分辨率,或引入离网参数校正机制,以降低字典失配带来的影响。

OSP算法中的权重构造依赖于声源频谱特征的预先建模,MSI超参数更新过程则基于特定的概率统计假设。当实际声源具有宽频、强非平稳或未知时变特性,或者环境噪声呈现非高斯噪声等复杂统计特征时,频谱建模误差与统计模型失配可能导致权重构造偏离最优状态,从而影响子阵列划分效果以及参数估计精度。仿真结果表明,算法在本文所设置的信噪比范围内能够保持较好的定位性能,但对于频谱完全未知或噪声统计特性显著变化的场景,其性能仍有待进一步研究。

综合来看,本文提出的PS-BSBL算法更适用于阵列结构已知、声源频谱特征能够获取或估计,且目标活动区域能够合理离散化建模的声源定位场景。对于频谱完全未知、存在显著离网误差或强非平稳噪声的复杂环境,算法性能可能受到一定影响。未来将进一步研究自适应频谱建模、离网误差补偿以及动态字典更新等关键技术,以提升算法在复杂实际环境中的鲁棒性与泛化能力。

本文针对复杂环境下传统声源定位算法精度不足、稀疏贝叶斯求解复杂度高且收敛慢的问题,提出融合OSP算法和MSI算法的PS-BSBL算法,实现了欠定、低信噪比及大规模阵列场景下的高精度实时声源定位。

实验验证了PS-BSBL算法的计算效率和精度:OSP算法通过麦克风阵列与空间网格的匹配划分,较现有块对角近似并行算法下的F-BSBL、BSBL-EM、W-BSBL平均时间降低百分比为97.61%、87.63%和87.82%,NMSE降低平均降低86.53%、16.64%、24.13%。

实验还验证了适度重叠区能够有效消除子阵列边界盲区,提升DOA估计的鲁棒性和精度。

MSI算法有效加速超参数更新,PS-BSBL收敛速度较g-FMLM、BSBL-FM分别提升99.80%、99.85%,NMSE分别降低51.30%、8.92%。实际定位实验中,在-10~20 dB信噪比下,PS-BSBL算法的角度RMSE较L1-SVD、OGSBL、CNN-Based、ResNet-Based平均降低65.11%、20.86%、81.59%、78.45%,均优于对比算法。

在低信噪比、欠定场景下展现出更强的鲁棒性。PS-BSBL算法为欠定、低信噪比、大规模阵列下的实时高精度声源定位提供了有效方案。PS-BSBL效率和精度较高,但是需要提前确定检测信号的频谱,并且提前去划分子阵列和网格点空间,前期的准备工作较多,在未来的场景中,在不影响算法效率与精度前提下,PS-BSBL算法的前期工作可以从大量的离线阵列权重设计转向少量的在线阵列权重设计。

参考文献

- [1] 蔡智超,王健芬,程宏波,等. 基于多模成像融合的弓网电弧检测方法研究[J]. 仪器仪表学报, 2025, 46(11): 124-135.
Cai Zhichao, Wang Jianfen, Cheng Hongbo, et al. Research on pantograph-catenary arc detection method based on multimodal imaging fusion[J]. Chinese Journal of Scientific Instrument, 2025, 46(11): 124-135.
- [2] Ahvazi S P, Mohammadi H. A high-precision voiceprint recognition for fault diagnosis of motor bearings through lightweight dynamic convolutional neural net-work[J]. Results in Engineering, 2026, 29: 108463.
- [3] 王建国,田野,刘皓宇,等. 复合故障下风电齿轮箱声音信号耦合调制模型辨识与故障诊断[J]. 仪器仪表学报, 2024, 45(8): 58-68.
Wang Jianguo, Tian Ye, Liu Haoyu, et al. Identification of coupling modulation model and fault diagnosis for wind turbine gearbox sound signal under compound faults[J]. Chinese Journal of Scientific Instrument, 2024, 45(8): 58-68.
- [4] Li Z, Cui H M, Fu Y X, et al. Noise source identification and its generation causes analysis on wind turbine blade under overall ice-covered conditions[J]. Applied Acoustics, 2026, 244: 111161.
- [5] Lyu Z Q, Li Q, Kong Q H, et al. Regional noise source location based on the time delays between station pairs from ambient noise interferometry[J]. Scientific Reports, 2024, 14(1): 10268.
- [6] Hong X D, Nie H M, Zhu W Y. An urban environmental noise source identification model based on parallel deep learning network with convolutional block attention[J]. Journal of Low Frequency Noise, Vibration and Active Control, 2025, 44(4): 2154-2168.
- [7] Cao Z Y, Zhang K Q, Bao J K. Partial discharge feature extraction and diagnosis of industrial acoustic imaging equipment based on time-frequency analysis[C]//2024 IEEE 7th International Conference on Information Systems and Computer Aided Education (ICISCAE). New York: IEEE, 2024: 613-618.
- [8] Xia X F, Su Y, Feng B, et al. The application research of acoustic imaging technology in partial discharge detection at substations[C]//2024 9th Asia Conference on Power and Electrical Engineering (ACPEE). New York: IEEE, 2024: 2026-2030.
- [9] Shen X C, Bao M, Chen Z F, et al. Fourth-order

- cumulant-based acoustic imaging via small-aperture acoustic vector-sensor array[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-12.
- [10] Zhang S W, Zuo Y X, Wang F, et al. Voiceprint monitoring methods to detect leakage in heating pipelines of utility tunnels [J]. *Measurement*, 2026, 279: 121591.
- [11] Wen S Z, Wei B K, Peng L S, et al. An electromagnetic voiceprint monitoring method for early degradation evaluation of IGBT devices [J]. *Measurement Science and Technology*, 2025, 36(10): 105103.
- [12] Bondo H K. Online fault monitoring of on-load tap-changer based on voiceprint detection [J]. *Journal of Power and Energy Engineering*, 2024, 12(3): 48-59.
- [13] Liu X H, Cao Q N, Wang S, et al. Research on sound source number estimation method under compressed sensing sound source localization[J]. *Circuits, Systems, and Signal Processing*, 2025, 44(11): 8757-8778.
- [14] Tipping M E. Sparse Bayesian learning and the relevance vector machine [J]. *Journal of Machine Learning Research*, 2001, 1: 211-244.
- [15] Wipf D P, Rao B D. Sparse Bayesian learning for basis selection[J]. *IEEE Transactions on Signal Processing*, 2004, 52(8): 2153-2164.
- [16] Bishop C M, Tipping M E. Variational relevance vector machines[C]//*Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence*. San Francisco: Morgan Kaufmann Publishers, 2000: 46-53.
- [17] Faul A, Tipping M E. Analysis of sparse Bayesian learning[C]//*Advances in Neural Information Processing Systems*. Cambridge: MIT Press, 2001, 14: 383-389.
- [18] Tipping M E, Faul A C. Fast marginal likelihood maximisation for sparse Bayesian models [C]//*Proceedings of the 9th International Workshop on Artificial Intelligence and Statistics*. Cambridge: MIT Press, 2003: 276-283.
- [19] Pedersen N L, Manchón C N, Badiu M A, et al. Sparse estimation using Bayesian hierarchical prior modeling for real and complex linear models[J]. *Signal Processing*, 2015, 115: 94-109.
- [20] Shutin D, Buchgraber T, Kulkarni S R, et al. Fast variational sparse Bayesian learning with automatic relevance determination for superimposed signals [J]. *IEEE Transactions on Signal Processing*, 2011, 59(12): 6257-6261.
- [21] Mödler J, Leitinger E, Fleury B H, et al. Fast variational block-sparse Bayesian learning [J]. *IEEE Transactions on Signal Processing*, 2025, 73: 4856-4872.
- [22] Boyle O, Üney M, Yi X P, et al. Parallel block sparse Bayesian learning for high dimensional sparse signals[J]. *Signal Processing*, 2025, 233: 109938.
- [23] Haghighatshoar S, Muir D R. Low-power spiking neural network audio source localisation using a Hilbert transform audio event encoding scheme [J]. *Communications Engineering*, 2025, 4(1): 18.
- [24] Hilli A A, Petropulu A. Weighted block sparse Bayesian learning for basis selection[C]//*2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. New York: IEEE, 2018: 4744-4748.
- [25] Mohan S, Lockwood M E, Kramer M L, et al. Localization of multiple acoustic sources with small arrays using a coherence test [J]. *Journal of the Acoustical Society of America*, 2008, 123(4): 2136-2147.
- [26] Takahashi T, Kanbayashi T, Nakayama M. Simultaneous localization of two talkers placed in an area surrounded by asynchronous six-microphone arrays [J]. *Electronics*, 2025, 14(4): 711.
- [27] 谢志远, 王荣, 白宗龙, 等. 先验超参数耦合的二维块稀疏贝叶斯学习声学成像方法[J]. *声学学报*, 2026, 51(3): 839-852.
- Xie Zhiyuan, Wang Rong, Bai Zonglong, et al. A two-dimensional block sparse Bayesian learning acoustic imaging method with coupling prior hyperparameter[J]. *Acta Acustica*, 2026, 51(3): 839-852.
- [28] Tamai Y, Kagami S, Mizoguchi H, et al. Real-time 2 dimensional sound source localization by 128-channel huge microphone array [C]//*13th IEEE International Workshop on Robot and Human Interactive Communication*, 2004: 65-70.
- [29] Ma Z Q, Dai W, Liu Y M, et al. Group sparse Bayesian learning via exact and fast marginal likelihood maximization [J]. *IEEE Transactions on Signal Processing*, 2017, 65(10): 2741-2753.
- [30] Malioutov D, Çetin M, Willsky A S. A sparse signal reconstruction perspective for source localization with sensor arrays [J]. *IEEE Transactions on Signal Processing*, 2005, 53(8): 3010-3022.
- [31] Yang Z, Xie L H, Zhang C S. Off-grid direction of arrival estimation using sparse Bayesian inference [J].

IEEE Transactions on Signal Processing, 2013, 61(1): 38-43.

[32] Chakrabarty S, Habets E A P. Broadband DOA estimation using convolutional neural networks trained with noise signals [C]//2017 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics, 2017: 136-140.

[33] Hu F C, Song X H, He R H, et al. Sound source localization based on residual network and channel attention module[J]. Scientific Reports, 2023, 13(1): 5443.

[34] Kaewniam P, Cao M S, Alkayem N F, et al. Recent advances in damage detection of wind turbine blades: A state-of-the-art review[J]. Renewable and Sustainable Energy Reviews, 2022, 167: 112723.

作者简介



降春景,2024 年于中北大学获得学士学位,现为杭州电子科技大学硕士研究生,主要研究方向为声源定位。

E-mail:chunjing_6276@163.com

Jiang Chunjing received his B.Sc. degree from North University of China in 2024. He is currently an M.Sc. candidate at Hangzhou Dianzi University. His main research interest is sound source localization.



李文国,分别在 2005 年、2009 年和 2022 年于杭州电子科技大学获得学士学位、硕士学位和博士学位,现任职于咸亨国际(杭州)电气制造有限公司,为正高级工程师,主要研究方向为生物电信号处理与多模态信息融合。

E-mail:wgli_hz@163.com

Li Wenguo received his B.Sc. degree, M.Sc. degree and Ph.D. degree all from Hangzhou Dianzi University in 2005, 2009 and 2022, respectively. He is currently a senior technical engineer in Xianheng International (Hangzhou) Electrical Manufacturing Co., Ltd. His main research interests include bioelectrical signal processing and multimodal information fusion.



席旭刚(通信作者),分别在 1999 年、2002 年、2019 年于杭州电子科技大学获学士学位、硕士学位、博士学位,现为杭州电子科技大学教授,主要研究方向为信号处理,人机交互和康复机器人。

E-mail:xixugang@hdu.edu.cn

Xi Xugang (Corresponding author) received his B.Sc. degree, M.Sc. degree and Ph.D. degree all from Hangzhou Dianzi University in 1999, 2002 and 2019, respectively. He is currently a professor at Hangzhou Dianzi University, and his main research interests include signal processing, human-robot interaction, and rehabilitation robot.