

拖曳阵列流致噪声的混合高斯建模与抑制*

王 冉¹ 汪光哲¹ 张晨宇² 郭奇欣³ 张永立¹
余 亮^{4†} 高 源^{5,6} 陈 诺^{5,6}

(1 上海海事大学 物流工程学院 上海 201306)
(2 哈尔滨工程大学 动力与能源工程学院 哈尔滨 150006)
(3 同济大学 电子与信息工程学院 上海 201804)
(4 西北工业大学 民航学院 西安 710072)
(5 上海船舶电子设备研究所 上海 201108)
(6 水声对抗技术重点实验室 上海 201108)

2023 年 3 月 1 日收到
2023 年 5 月 26 日定稿

摘要 湍流边界层压力起伏导致拖曳阵列流噪声难以精确建模与抑制, 为此分析了拖曳阵列流噪声的产生机理与统计特性。针对非高斯分布的拖曳阵列流噪声, 发展了混合高斯模型建模方法, 同时建立了多通道的拖曳阵列中声源信号的低秩模型, 并对流噪声和声源信号模型中的参数通过期望最大算法进行求解, 最终实现了水听器接收信号中的流噪声与声源信号成分分离。对实际湖试数据进行流噪声抑制与目标方位估计, 结果表明, 在不影响定位结果的前提下, 最大旁瓣级抑制达到 8~10 dB。

关键词 拖曳阵列, 流噪声, 混合高斯模型, 期望最大算法, 声呐探测

PACS 数 43.60, 43.30, 43.50

DOI: [10.12395/0371-0025.2023033](https://doi.org/10.12395/0371-0025.2023033)

Gaussian mixture model fitting and suppression of towed array flow noise

WANG Ran¹ WANG Guangzhe¹ ZHANG Chenyu² GUO Qixin³ ZHANG Yongli¹
YU Liang^{4†} GAO Yuan^{5,6} CHEN Nuo^{5,6}

(1 School of Logistics Engineering, Shanghai Maritime University Shanghai 201306)
(2 College of Power and Energy Engineering, Harbin Engineering University Harbin 150006)
(3 College of Electronic and Information Engineering, Tongji University Shanghai 201804)
(4 School of Civil Aviation, Northwestern Polytechnical University Xi'an 710072)
(5 Shanghai Marine Electronic Equipment Research Institute Shanghai 201108)
(6 Science and Technology on Underwater Acoustics Antagonizing Laboratory Shanghai 201108)

Received Mar. 1, 2023
Revised May 26, 2023

Abstract Aiming at the problem that it is difficult to accurately model and suppress the towed array flow noise caused by the pressure fluctuation in the turbulent boundary layer, this paper analyzes the generation mechanism of the towed array flow noise and the statistical properties of the noise. A hybrid Gaussian model modelling method is developed for the non-Gaussian distributed towed array flow noise, and a low-rank model of the acoustic source signal in the multi-channel towed array is established. The parameters in the model of the flow noise and the acoustic source signal are solved by the expectation-maximization algorithm, which ultimately realizes the separation of the flow noise and acoustic source signal in the received signal of the hydrophone. The results of the flow noise suppression and target orientation estimation of the actual lake test data show that the maximum side-valve level suppression reaches 8–10 dB without affecting the localization results.

* 国家自然科学基金项目 (12074254, 51505277)、上海市自然科学基金项目 (21ZR1434100)、上海交通大学深蓝计划项目 (SL2021MS009) 和上海交通大学机械系统与振动国家重点实验室开放基金课题 (MSV202305) 资助

† 通讯作者: 余亮, liang.yu@nwpu.edu.cn

Keywords Towed array, Flow noise, Gaussian mixture model, Expectation maximum algorithm, Sonar detection

引言

流致噪声是水听器接收信号的主要噪声成分, 对流致噪声进行有效抑制可以显著提升拖曳阵列声呐的探测性能。目前抑制拖曳阵列流致噪声主要通过物理途径, 如增大水听器与护套之间的距离或增加护套厚度等。然而拖曳阵小直径化的发展趋势限制了护套表面到水听器的距离, 上述方法不再适用。因此, 通过信号处理来抑制水听器接收数据中的流噪声成为提升拖曳阵列声呐探测性能的重要方法。

流噪声的物理模型与噪声特性分析是实现拖曳阵列流噪声抑制的前提。Corcos 等^[1]研究了平板表面上的湍流流动, 建立了湍流边界层 (TBL) 压力脉动的二维波数-频率谱模型。Carpenter 等^[2]提出更加拟合拖曳阵列护套管的细长圆柱 TBL 压力起伏模型, 计算了拖曳阵列流噪声并进行试验测量。Linderman 等^[3]推导了在护套外表面有 TBL 压力起伏时护套层对其响应的传递函数。汤渭霖等^[4]详细分析了流噪声的产生机理, 并讨论了不同水听器参数与护套参数对流噪声的影响。王斌等^[5]详细比较了不同的 TBL 压力起伏模型, 并给出了流噪声功率谱的解析表达式。王晓林等^[6]通过分析大量实验数据对 Carpenter 压力起伏模型的参数进行修正, 更为准确地计算了拖曳阵列护套管内的流致噪声响应。杨秀庭等^[7-8]利用护套管内流致噪声的空间相关性, 计算了不同形状矢量水听器和水听器阵列接收的流噪声。

近年来, 通过阵列信号处理技术抑制拖曳阵列流噪声并提高阵处理性能受到关注。孟彧仟等^[9]分析了流噪声在声压、轴向振速和径向振速三个分量之间的相关性, 提出了基于声强流的拖曳阵列流噪声抑制方法。李磊等^[10-11]通过设计信号模拟器仿真拖曳阵列声呐工作时的不同噪声, 并提出了噪声抑制的相关算法, 但该算法主要针对本舰噪声与其他海洋环境噪声。张宾等^[12]采用经验模式分解的方法分解水听器的接收信号, 并分离出拖船噪声分量, 从而达到消除噪声的目的。针对水下目标特征提取与噪声源的识别, 如瞬时频率变化率算法^[13]、波束域时频分析方法^[14]等声源信号分析技术被提出并广泛应用。此外, 如正交匹配追踪波达方向估计法^[15]、利用期望最大算法的多频带声信号时延估计法^[16]等提升阵列定位性能的方法也被尝试用于拖曳阵列声呐探

测中。韩东等^[17]将匹配场定位和平面波目标方位估计相结合, 设计了具有强噪声抑制功能的空域矩阵滤波器, 减小了处理后探测盲区的范围并提升了盲区外的探测能力。

上述基于阵列信号处理的流噪声抑制方法, 无论是利用信号的相关性或是从目标方位估计出发减少流噪声的影响, 均未实现拖曳阵列流噪声的有效抑制, 所带来的目标方位估计结果增益也十分有限。且上述流噪声模型研究中, 传统的 TBL 模型基于稳态的建模方法, 即仅为统计量上的建模, 没有考虑复杂噪声的概率密度分布, 而流噪声的准确建模以及信号成分的正确提取可实现噪声的有效抑制。Meng 等^[18]提出通过高斯混合模型与低秩矩阵分解的方法模拟复杂噪声, 并通过最大似然法估计混合高斯模型中的参数。Yong 等^[19]在此基础上引入分帧的概念, 让模型通过学习先前帧完成逐帧在线更新以更加鲁棒并适应现实场景的噪声变化情况。Yu 等^[20-21]将混合高斯噪声模型引入传声器阵列测量与声成像中, 并通过分帧处理进行噪声的混合高斯模型构建与低秩矩阵分解, 实现了复杂噪声情况下的谐波信号去噪。

针对上述问题, 本文从拖曳阵列流致噪声的产生机理与噪声统计特性出发, 根据拖曳阵列流噪声表现出的非高斯的复杂统计特性, 建立了流噪声的高斯混合模型 (Gaussian Mixture Model, GMM)。同时对低秩信号时频矩阵建模, 发展了混合高斯模型与期望最大 (Gaussian Mixture Model-Expectation Maximum, GMM-EM) 算法, 并对模型中的参数进行更新, 将水听器接收声压数据中的噪声与信号分离, 并完成信号的重建。仿真和实验结果表明, 所提方法可实现拖曳阵列流噪声的有效抑制, 提升拖曳阵列探测定位性能。

1 问题描述

拖曳阵列流致噪声的主要来源可看作是 TBL 压力起伏激发线列阵振动产生的噪声信号, 其结果直接作用在水听器上, 成为拖曳阵列声呐主要的自噪声源。在拖曳阵列声呐探测工作过程中, 假设用于收集信号的水听器有 M 个, 水听器的接收信号是由远场平面波信号和背景噪声两部分组成, 在 t 时刻所有传声器接收信号 $\mathbf{y}(t) \in \mathbb{R}^{M \times 1}$ 可表示为

$$\mathbf{y}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{n}(t), \quad (1)$$

其中, $\mathbf{A} \in \mathbb{R}^{M \times I}$ 为阵列流形矩阵, I 为信号源的等效源数量, $\mathbf{x}(t) \in \mathbb{R}^{I \times 1}$ 为 t 时刻水听器接收的远场平面波信号, $\mathbf{n}(t) \in \mathbb{R}^{M \times 1}$ 表示 t 时刻的背景噪声, 即 TBL 压力起伏产生的流噪声。在实际工作环境中强烈的背景噪声 $\mathbf{n}(t)$ 会严重影响目标探测的结果。由于 TBL 压力起伏的复杂性, 拖曳阵列流噪声表现出非高斯的复杂统计特性, 对背景噪声进行建模与抑制十分困难。本文基于拖曳阵列流致噪声的非高斯特性, 建立精确的噪声拟合模型并对信号进行重建。通过将噪声成分从接收信号中分离以对实现拖曳阵列流噪声的抑制, 使用降噪后的信号进行波束形成能够显著提升拖曳阵列探测性能。

2 拖曳阵列流噪声的混合高斯建模与抑制方法

2.1 拖曳阵列流噪声的混合高斯建模

实际工作环境中背景噪声非常强, 严重影响目标探测结果, 并且由于 TBL 压力起伏的复杂性, 拖曳阵列流噪声表现出非高斯的复杂统计特性。拖曳阵列流噪声抑制的基本思想是通过分别对测量声压数据中的噪声与信号两部分建模, 实现信号与噪声的分离。

如图 1 所示, 对于流噪声部分的建模是针对拖曳阵列流噪声表现出的非高斯的复杂统计特性, 将噪声成分建模为几个不同参数不同权重的高斯模型叠加而成。而对于信号部分, 谐波信号在时频矩阵上会表现出低秩特性, 时频矩阵的秩取决于正弦曲线的数量^[22-23], 因此可对信号进行低秩矩阵分解, 从而与混合高斯建模的噪声相分离。

式 (1) 中, 需将水听器接收信号分离成远场平面波信号 $\mathbf{x}(t)$ 与噪声 $\mathbf{n}(t)$, 即对信号部分完成低秩建模, 对噪声成分进行混合高斯建模。整个过程需要在时频域完成, 将 M 个水听器通道中的第 m 个通道

采集到的声压数据通过短时傅里叶变换 (STFT) 转换到时频域:

$$Y_m(\tau, f) = \int y_m(t) w(t - \tau) e^{-2j\pi f(t - \tau)} dt + N_m(\tau, f), \quad (2)$$

其中, τ 和 f 分别表示 STFT 过程中的时间参数与频率参数, $w(t)$ 是 STFT 的窗口函数, $e^{-2j\pi f(t - \tau)}$ 是基函数。 Y_m 是测量信号 y_m 的时频表示, 其组成的矩阵 $\mathbf{Y} \in \mathbb{C}^{N_1 \times N_2}$, N_m 是噪声 n_m 的时频表示, 其组成的矩阵 $\mathbf{N} \in \mathbb{C}^{N_1 \times N_2}$, N_1, N_2 分别为时频矩阵的时间与频率维度大小, y_m 为 t 时刻水听器接收信号 $\mathbf{y}$ 的第 m 个分量, n_m 为背景噪声 $\mathbf{n}$ 的第 m 个分量。

通过 STFT 得到的时频矩阵在完成模型构建与抑制算法求解后通过逆短时傅里叶变换 (ISTFT) 转换回时域, 转换过程如图 2 所示。通过 STFT 将每个通道的声压时域数据转换得到时频矩阵, 其中时频矩阵的大小由 STFT 过程中的时间参数 τ 与频率参数 f 决定。将 M 个通道的时频矩阵拼接在一起, 数据维度为 $M \times N_1 \times N_2$ 。然后, 通过矩阵维度的转换将 M 个通道的时频矩阵转换为 N_2 个矩阵 $\mathbf{P} \in \mathbb{C}^{M \times N_1}$ 作为后续建模与噪声抑制处理的数据矩阵, 即 $\{\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_{N_2}\}$ 。矩阵转换的目的在于可对时频矩阵中的每个频率点做后续建模与噪声抑制处理, 相当于在频域上对于宽带信号其整个频段都能够实现噪声建模与抑制, 使得算法能够处理宽带信号而不需要发射信号频率这一先验信息。由此得到的处理矩阵数据可以看成是信号低秩矩阵与噪声矩阵的叠加, 之后则对矩阵 $\mathbf{P}$ 分别进行低秩矩阵分解与混合高斯建模, 以实现信号的重构。

采用 $\mathbf{U}$ 和 $\mathbf{V}$ 矩阵分解的形式来表示信号部分, 其中 $\mathbf{U}$ 矩阵为子空间矩阵, $\mathbf{V}$ 矩阵为系数矩阵, $\mathbf{U}$ 矩阵的维度为 $r \times N_1$, $\mathbf{V}$ 矩阵的维度为 $r \times N_2$, r 为 STFT 得到时频矩阵的秩。可以将上述时频变换后得到的处理矩阵 $\mathbf{P}$ 的每个元素表示为

$$p_{ij} = (\mathbf{u}^i)^T \mathbf{v}^j + \varepsilon_{ij}, \quad (3)$$

其中, $\mathbf{u}^i$ 代表 $\mathbf{U}$ 矩阵的第 i 行, $\mathbf{v}^j$ 代表 $\mathbf{V}$ 矩阵的第




图 1 拖曳阵列流噪声混合高斯建模示意图




图2 接收数据时频转换示意图

j 行, $1 \leq i \leq N_1, 1 \leq j \leq N_2$, ε_{ij} 代表单元内的噪声信号, 每一个 ε_{ij} 都假设满足混合高斯模型, 而总体噪声信号则表述为

$$[\varepsilon] = \sum_{k=1}^K \pi_k N_c(\varepsilon | 0, \sigma_k^2), \quad (4)$$

其中, $[\cdot]$ 表示随机变量的概率密度函数, $N_c(\varepsilon | 0, \sigma_k^2)$ 表示均值为 0, 方差为 σ_k^2 的高斯分布。 π_k 是混合系数, 表示每一个高斯模型在总体模型中所占的权重, $0 \leq \pi_k \leq 1, \sum_{k=1}^K \pi_k = 1$ 。每一个单元的概率 p_{ij} 表示为

$$[p_{ij} | \mathbf{u}^i, \mathbf{v}^j, \mathbf{\Pi}, \mathbf{\Sigma}] = \sum_{k=1}^K \pi_k [p_{ij} | k], \quad (5)$$

其中, $[p_{ij} | k] = N_c(p_{ij} | (\mathbf{u}^i)^T \mathbf{v}^j, \sigma_k^2)$, $\mathbf{\Pi} = \{\pi_1, \pi_2, \dots, \pi_K\}$, $\mathbf{\Sigma} = \{\sigma_1, \sigma_2, \dots, \sigma_K\}$ 。因此, $\mathbf{P}$ 的似然函数为

$$[\mathbf{P} | \mathbf{U}, \mathbf{V}, \mathbf{\Pi}, \mathbf{\Sigma}] = \prod_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} [p_{ij} | \mathbf{u}^i, \mathbf{v}^j, \mathbf{\Pi}, \mathbf{\Sigma}] = \prod_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} \sum_{k=1}^K \pi_k N_c(p_{ij} | (\mathbf{u}^i)^T \mathbf{v}^j, \sigma_k^2). \quad (6)$$

在混合高斯模型的构建过程中, 主要包含三类未知参数: 第一类是每个高斯分布函数的均值和方差; 第二类是每个高斯分布函数占整个分布的权重; 第三类是用来逼近任意概率密度函数分布的高斯函数的个数。为达到信号与噪声分离的目的, 需要将混合高斯模型中的各参数以及信号模型中的 $\mathbf{U}$ 和 $\mathbf{V}$ 矩阵进行求解计算。

2.2 拖曳阵列流噪声的抑制算法

可采用 EM 算法迭代求解上述模型参数, 模型的整体构建与求解过程主要包括: 构建复杂噪声的

概率密度函数, 对任意概率分布的复杂噪声进行自适应建模, 提出高斯分量参数的先验假设。初始化 $\mathbf{\Pi}, \mathbf{\Sigma}$ 和 $\mathbf{U}, \mathbf{V}$ 等参数, 确定混合高斯模型个数, 对混合高斯模型中各个高斯分量选取分配权重, 之后迭代求解混合高斯模型参数与 $\mathbf{U}, \mathbf{V}$ 矩阵。

首先引入一个隐变量 γ_{ijk} , 引入隐变量的目的在于补齐样本来源于哪类高斯模型, 其表达式为

$$\gamma_{ijk} = \begin{cases} 1, & p_{ij} \text{ 来自于第 } k \text{ 个高斯模型,} \\ 0, & \text{其他.} \end{cases} \quad (7)$$

加入隐变量后可获得完全数据 $(\mathbf{P}, \gamma)$, 其似然函数为

$$[\mathbf{P}, \gamma | \mathbf{U}, \mathbf{V}, \mathbf{\Pi}, \mathbf{\Sigma}] = \prod_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} \prod_{k=1}^K \left\{ \pi_k N_c(p_{ij} | (\mathbf{u}^i)^T \mathbf{v}^j, \sigma_k^2) \right\}^{\gamma_{ijk}} = \prod_{k=1}^K \pi_k^{N_k} \prod_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} \left\{ \frac{1}{\sigma_k^2 \pi} \exp \left(-\frac{|p_{ij} - (\mathbf{u}^i)^T \mathbf{v}^j|^2}{\sigma_k^2} \right) \right\}^{\gamma_{ijk}}, \quad (8)$$

其中, $N_k = \sum_{ij} \gamma_{ijk}$, $N = \sum_{k=1}^K N_k$ 。

算法需更新的参数包括混合高斯模型中每个单一高斯分布的方差集合 $\mathbf{\Sigma} = \{\sigma_1, \sigma_2, \dots, \sigma_K\}$ 、总体模型中的混合系数 $\mathbf{\Pi} = \{\pi_1, \pi_2, \dots, \pi_K\}$ 以及 $\mathbf{U}, \mathbf{V}$ 矩阵, 因此需要假设更新参数的先验信息。

混合高斯模型中的方差与混合系数的先验可分别假设为逆伽马分布与迪利克雷分布, 而 $\mathbf{U}$ 和 $\mathbf{V}$ 矩阵中的行向量 $\mathbf{u}^i, \mathbf{v}^j$ 则可设置为高斯分布, 参数的先验分布如下:

$$\mathbf{\Sigma} \sim \text{Inv-Gamma}(c, d), \quad (9)$$

$$\mathbf{\Pi} \sim \text{Dir}(\alpha), \quad (10)$$

$$\mathbf{u}_i \sim N_c(\mathbf{0}, \gamma_n^{-1} \mathbf{I}_N), \quad \mathbf{v}_j \sim N_c(\mathbf{0}, \gamma_n^{-1} \mathbf{I}_N),$$

$$\gamma_n \sim \text{Gamma}(\gamma_n | a, b), \quad (11)$$

其中, $\text{Inv-Gamma}(\cdot)$ 为逆伽马分布, $\text{Dir}(\cdot)$ 为迪利克雷分布, $\text{Gamma}(\cdot)$ 为伽马分布。 c, d, α 为逆伽马分布与迪利克雷分布中的参数, $\mathbf{I}_N$ 是维度为 $N_1 \times N_2$ 的单位矩阵, 超参数 γ_n 满足参数为 a, b 的伽马分布。似然函数可从假设的参数先验信息中计算得到每一步的参数后验函数, 并作为下一次更新的参数先验信息, 以此实现参数的迭代更新。

获得完全数据的似然函数之后, 分 E 步与 M 步两步进行计算与迭代求解。算法的 E 步即计算确定数据来源于哪一类高斯模型。计算给定一组数据下对各类高斯模型的响应度, 即对隐变量 γ_{ijk} 进行估计, 首先需定义 Q 函数^[24-25]:

$$Q(\theta, \theta^{(i)}) = E_{\gamma} \left(\ln[\mathbf{P}, \gamma | \theta] | \mathbf{P}, \theta^{(i)} \right) = \sum_{k=1}^K \left\{ \sum_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} E(\gamma_{ijk}) \ln \pi_k + \sum_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} E(\gamma_{ijk}) \cdot \left(\ln \frac{1}{\pi} - 2 \ln \sigma_k - \frac{|p_{ij} - (\mathbf{u}^i)^T \mathbf{v}^j|^2}{\sigma_k^2} \right) \right\}, \quad (12)$$

其中, θ 表示估计参数 Π, Σ 和 $\mathbf{U}, \mathbf{V}$ 的集合, $\theta^{(i)}$ 表示迭代前的参数, $E(\gamma_{ijk})$ 是指在混合高斯模型中, 观测数据 p_{ij} 来自于第 k 个高斯分布模型, 称为对第 k 个模型的响应度, 算法的 E 步求解具体为估计隐变量的期望值。Q 函数被用于计算当前迭代的似然值, 也称为完全数据的对数似然, 通过最大化 Q 函数可以逐步优化模型中需要求解的参数, 直到收敛。

估计隐变量之后, 剩余部分参数只与样本有关, 此时算法进入 M 步的计算, 即通过最大似然进行估计, 在最大化模型参数 Π, Σ 和 $\mathbf{U}, \mathbf{V}$ 之间进行迭代。将上述 Q 函数最大化:

$$\theta^{(i+1)} = \arg \max_{\theta} Q(\theta, \theta^{(i)}), \quad (13)$$

其中, $\theta^{(i+1)}$ 代表迭代后的参数, Π, Σ 的迭代需对 Q 函数进行最大化, 以得到参数的求解公式, 即得到混合高斯模型中每一个高斯模型的方差与模型的混合系数。参数的迭代求解公式为

$$\pi_k = \frac{N_k}{\sum N_k}, \quad (14)$$

$$\sigma_k^2 = \frac{1}{N_k} \sum_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} E(\gamma_{ijk}) \left(p_{ij} - (\mathbf{u}^i)^T \mathbf{v}^j \right)^2, \quad (15)$$

其中, $N_k = \sum_{i,j \in \Omega} E(\gamma_{ijk})$ 。对于 Π, Σ 的迭代即求解得到 π_k, σ_k^2 , 将其代入重新计算来进行 $\mathbf{U}, \mathbf{V}$ 的迭代, 通过最大化下述方程来实现 $\mathbf{U}, \mathbf{V}$ 的迭代求解:

$$\begin{aligned} \sum_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} \sum_{k=1}^K E(\gamma_{ijk}) \left(-\frac{|p_{ij} - (\mathbf{u}^i)^T \mathbf{v}^j|^2}{\sigma_k^2} \right) = \\ - \sum_{\substack{1 \leq i \leq N_1 \\ 1 \leq j \leq N_2}} \left(\sum_{k=1}^K \frac{E(\gamma_{ijk})}{\sigma_k^2} \right) |p_{ij} - (\mathbf{u}^i)^T \mathbf{v}^j|^2 = \\ - \|\mathbf{W} \odot (\mathbf{P} - \mathbf{UV}^T)\|_2, \end{aligned} \quad (16)$$

其中

$$w_{ij} = \begin{cases} \sqrt{\sum_{k=1}^K \frac{E(\gamma_{ijk})}{\sigma_k^2}}, & i, j \in \Omega, \\ 0, & i, j \notin \Omega, \end{cases}$$

符号 $\odot$ 表示矩阵的 Hadamard 乘积, $\|\cdot\|_2$ 表示矩阵的 L_2 范数。式 (16) 的求解可以通过交替最小二乘法

(ALS)^[26] 实现。在完成参数的闭式迭代求解之后, 再重建得到去除噪声之后的信号。

综上所述, 基于混合高斯模型的拖曳阵列流噪声抑制算法的整体流程步骤如图 3 所示。首先通过 STFT 将测得的声压时域数据转换到时频域, 并得到处理矩阵 $\mathbf{P}$, 之后初始化 Π, Σ 和 $\mathbf{U}, \mathbf{V}$ 等参数, 确定混合高斯模型个数与阈值, 对混合高斯模型中各个高斯分量选取分配权重。通过迭代 Π, Σ 计算 π_k, σ_k^2 从而进一步实现 $\mathbf{U}, \mathbf{V}$ 矩阵的迭代, 直至满足迭代终止准则, 此时输出矩阵 $\mathbf{U}, \mathbf{V}$, 最终得到重建信号 $\mathbf{L} = \mathbf{U}^T \mathbf{V}$ 。




图 3 GMM-EM 算法流程图

3 仿真分析

3.1 流噪声机理分析与信号仿真

对含流噪声的谐波以及宽带信号进行仿真, 验证方法的有效性。采用拖曳阵列流噪声的自功率谱模型^[4]仿真流噪声信号。基于图 4 所示湍流边界层压力起伏激励圆柱壳内噪声场结构, 将模型简化为无限长弹性圆柱管, 即仅与纵向 z 及径向 r 相关的二维问题。

根据 TBL 压力起伏模型、护套传递函数模型以及由水听器形状得到的水听器函数等, 计算得到流噪声声压的自功率谱:

$$\Phi_p(r_0, \omega) = \int_{-\infty}^{\infty} \Phi_s(k_z, \omega) |h_p(k_z, r_0, \omega)|^2 |a_p(k_z)|^2 dk_z, \quad (17)$$




图4 湍流边界层压力起伏激励圆柱壳内噪声场

式中

$$h_p(k_z, r_0, w) = T(k, w) \frac{J_0(k_1 r_0)}{J_0(k_1 b)}$$

是系统的波数-频率谱传递函数, $\Phi_s(k_z, \omega)$ 是 TBL 压力起伏的波数-频率谱, 其中 k 为波数, ω 为频率, k_z 为 z 轴方向的波数, k_1 是对应管内流体介质中的波数, $T(k, w)$ 为护套传递函数, 以圆柱形水听器为例, r_0 为水听器半径, b 为护套内径, $J_0(\cdot)$ 为 0 阶 Bessel 函数, $a_p(k_z) = \sin(k_z l/2)/(k_z l/2)$ 为单个水听器的波数响应函数, l 为水听器长度。基于此模型, 已知拖曳阵护套表面 TBL 压力起伏的波数-频率谱和护套的传递函数, 即可得到压力起伏激励下的拖曳阵流噪声自功率谱。

采用基于细长圆柱体外表面 TBL 压力起伏理论模型^[2], 其中涉及的参数是由大量实验所得测量结果拟合而得。Carpenter 压力起伏模型的波数-频率谱为

$$\Phi(k_z, \omega) = \frac{c^2 \rho_2^2 v_*^3 R^2 [(k_z R)^2 + 1/12]}{[(\omega R - U_c k_z R)^2 / (h v_*)^2 + (k_z R)^2 + 1/b^2]^{2.5}}, \quad (18)$$

其中, R 是圆柱护套的外径, ρ_2 为外部流体的密度, U_c 为迁移波数, 根据测量结果拟合得 $U_c \approx 0.75U$, U 是自由流速, V_* 为 TBL 剪切速度, $V_* = 0.04U$ 。 c , h , b 可由实验数据测得, 王晓林等^[7-8] 使用掌握的实验

数据修正 Carpenter 压力起伏模型的参数, 本文采用修正后的参数, 具体见表 1。

表1 基本参数表

参数	数值	参数	数值
拖曳速度 U (m/s)	8	护套内径 b_0 (mm)	30
管外声速 c_2 (m/s)	1500	护套厚度 t (mm)	3
管内密度 ρ_1 (kg/m ³)	761	c	10
管外密度 ρ_2 (kg/m ³)	1000	h	3.7
水听器半径 r_0 (mm)	10.4	b	0.2
水听器长度 l (mm)	40		

护套传递函数采用内部充液护套传递函数模型^[3], 近似传递函数公式为

$$|T(k_z, \omega)|^2 = \left| \frac{k_b^2}{k_b^2 - k_z^2} \right|, \quad (19)$$

其中, k_b 为呼吸波波数, 由此可得到拖曳阵列流噪声的自功率谱。图 5(a) 为此模型下得到的不同拖曳速度下 (2 m/s, 4 m/s, 6 m/s, 8 m/s) 拖曳阵列流噪声的自功率谱。选取拖曳速度为 8 m/s 的拖曳阵列流噪声自功率谱, 计算信号幅值并输入随机相位得到时域信号, 如图 5(b) 所示。由图 5(a) 可见, 随着频率的增加, 声压的自功率谱逐渐降低, 且在较低频段处下降速度较快。比较不同拖曳速度下的声压自功率谱也可以看出, 拖曳速度提高 1 倍, 声压的自谱值增加约 20~40 dB。

3.2 谐波信号情况下的流噪声抑制

在上节所得拖曳阵列流噪声信号中添加不同频率的谐波信号, 用 GMM-EM 方法对含噪信号进行抑制处理, 再通过时域波束形成的目标方位估计方法验证噪声抑制效果。仿真中, 采样频率 $f_s = 4000$ Hz, 添加谐波信号信噪比 $R_{SN} = -5.85$ dB, 谐波信号频率分别设置为 300 Hz, 500 Hz, 700 Hz, 900 Hz, 时域波束方向估计采用阵元数为 8 的均匀直线阵, 入射角




图5 仿真拖曳阵列流噪声信号 (a) 不同拖速流噪声自功率谱; (b) 流噪声时域波形

度设置为 30° 的单入射角度和 $-40^\circ, 30^\circ$ 的双入射角度两种情况。图 6(a) 为入射角度 30° 情况下含流噪声信号与经 GMM-EM 方法降噪后的信号分别做时域 DOA 的结果, 谐波信号频率为 700 Hz; 并与 Hankel 矩阵降噪方法^[27] 相比较, Hankel 矩阵降噪方法通过 SVD 分解从谐波信号的 Hankel 矩阵提取特征向量以实现目标信号的重建。该方法被广泛应用于谐波信号的去噪。图 6(b) 为双入射角度 $-40^\circ, 30^\circ$ 的仿真结果。

如图 6 所示, 在信号频率为 700 Hz 情况下, 经 GMM-EM 方法进行噪声抑制后的信号, 在单入射角度和双入射角度两种仿真条件下都能准确定位到目标, 且全角度背景级都能有效降低。对于单入射角度, 在不影响定位精度的情况下, 空间谱的背景级与含噪信号相比能够降低 10~13 dB, 最大旁瓣级能够降低 5 dB, 对于双入射角度, 背景级的降低也可达 5~8 dB, 最大旁瓣级能够降低 4 dB。而 Hankel 矩阵去噪信号的定位结果在多数角度虽也表现出更低的背景级, 但某些角度会出现错误的伪峰。其他谐波信号频率下的结果与图 6 类似。

采用信号噪声功率谱密度比来反映水听器接收信号中噪声的抑制情况:

$$\text{PSDR} = 10 \lg \left(\frac{\text{PSD}_x}{\text{PSD}_N} \right), \quad (20)$$

其中, PSDR 表示信号噪声功率谱密度比, PSD_x 表示发射信号频率处信号的功率谱密度, PSD_N 表示流噪声所在低频频段内信号的功率谱密度。图 7 为不同目标信号频率以及不同信噪比下经各方法抑制前后的 PSDR 折线图。

图 7(a) 为仿真不同频率目标信号情况下的 PSDR, 各频率下 GMM-EM 降噪处理后的信号噪声功率谱密度比均高于未经降噪处理的信号, 这表示接收信号中的噪声成分得到有效抑制, 且在高频段提升效果明显, 而 GMM-EM 方法与 GMM-VB 方法结果较为相近, GMM-EM 在旁瓣抑制上效果稍好于 GMM-VB。Hankel 方法则会在高频段带来更好的提升, 而目标信号频率较低时噪声抑制效果较差。图 7(b) 为不同信噪比下的 PSDR 结果, 各抑制方法相较未降噪的信号均有一定提升, 并且随着添加目标信号信噪比的提高, 信号噪声功率谱密度比显著增大。

3.3 宽带信号情况下的流噪声抑制

实际场景中多为宽带信号, 且信号频率可能存在于流噪声频段, 设置不同带宽和带宽频率的仿真




图 6 信号频率为 700 Hz 时 DOA 结果对比 (a) 入射角度 30° ; (b) 入射角度 $40^\circ, 30^\circ$




图 7 噪声抑制前后信号噪声功率谱密度比 (a) 不同目标信号频率; (b) 不同信噪比




图8 信号频率 600~800 Hz 时 DOA 结果对比 (a) 入射角度 30°; (b) 入射角度 -40°, 30°

信号, 以验证 GMM-EM 方法的有效性和实用性。仿真中, 采样频率 $f_s=4000$ Hz, 宽带信号频率分别设置为 300~500 Hz, 600~800 Hz, 200~600 Hz, 500~900 Hz, 时域 DOA 采用阵元数为 16 的均匀直线阵, 入射角度设置为 30° 的单入射角度和 -40°, 30° 的双入射角度两种情况。图 8(a) 为入射角度 30° 情况下含流噪声信号与经 GMM-EM 方法降噪后的信号分别做时域 DOA 的结果, 并与 Hankel 矩阵去噪后的结果进行对比, 宽带信号频率为 600~800 Hz。图 8(b) 为双入射角度 -40°, 30° 的仿真结果。

如图 8 所示, 在信号频率为 600~800 Hz (其他频率结果类似) 情况下, 经 GMM-EM 方法抑制噪声后的信号, 在单入射角度和双入射角度两种仿真条件下都能准确定位到目标, 且全角度其背景级都能有效降低。对于单入射角度, 在不影响定位精度的情况下, 空间谱的背景级与含噪信号相比能够降低 10~15 dB, 最大旁瓣级能够降低 10 dB; 对于双入射角度, 背景级的降低也能够达到 5~10 dB, 最大旁瓣级能够降低 8 dB。而 Hankel 矩阵去噪信号的定位结果在多数角度虽也表现出更低的背景级, 但在某些角度会出现更强的错误角度估计伪峰。由此可见, 本文方法可有效抑制拖曳阵列流噪声, 且显著提升拖曳阵列声呐定位目标的性能。

4 实验验证

4.1 湖试实验工况与流噪声信号分析

为验证所提方法在实际应用场景下的噪声抑制效果, 采用莫干山试验站湖试实验所得数据进行处理与分析, 包括不同拖速下的流噪声数据以及不同发射信号下的水听器接收数据。湖试实验的设置与工况如下: 载有拖曳阵列的船只静止于湖中, 通过船上电机设备设定收绳速度对连接的水下阵列进行拖

曳, 载有换能器的船只距离拖曳船 200 m 时发射信号, 实验阵列共 16 个阵元。实验发射信号分别设置为单一谐波信号和带宽 500 Hz 的宽带信号, 拖曳速度分别设定为 10 kn, 12 kn, 14 kn, 16 kn 以模拟不同船速下的流噪声测定, 下述实验说明以及图片中涉及的具体频率信息均根据实验采样频率进行了归一化处理。图 9 为拖曳阵列探测湖试实验示意图。




图9 拖曳阵列声呐探测湖试示意图

未发射信号时所测拖曳阵列噪声数据如图 10 所示。图 10(a) 是拖速为 14 kn 时实验测得的流噪声信号时域波形, 图 10(b) 是噪声信号的时频谱, 流噪声基本集中在低频范围附近。

分析流噪声数据的非高斯性。对单通道噪声数据快拍矩阵的实部 (虚部结果类似) 进行概率密度函数 (PDF) 拟合, 结果如图 11(a) 所示, 实测流噪声数据的概率密度函数峰度高于高斯分布, 且较高斯分布更加陡峭。实验所有 16 通道噪声数据快拍矩阵的实部 (虚部结果类似) 概率密度分布函数的拟合结果如图 11(b) 所示, 不同通道的分布差异很大, 且存在数据分布偏离中心位置等复杂情况。通过计算实测信号的峰度与偏度来分析其是否满足高斯分布, 高斯分布峰度值应为 3, 偏度值应等于 0。分别计算 16 通道信号的峰度值与偏度值, 与高斯分布差异最大的通道信号峰度值低至 1.82, 而不对称性最高的信号偏度值为 0.97, 体现出明显的非高斯性。因此,




图 10 实验所得拖曳阵列流噪声信号 (a) 流噪声时域波形; (b) 流噪声时频图




图 11 流噪声概率密度分布 (PDF) (a) 单通道信号概率密度分布; (b) 所有通道信号概率密度分布

采用混合高斯模型拟合流噪声能够更加准确地考虑到流噪声的非高斯特性, 以及实际测量过程中通道之间噪声概率密度分布差异大的问题。

4.2 发射谐波信号情况下的流噪声抑制

选取拖曳速度为 14 kn, 发射信号为谐波信号的数据进行分析。处理的信号数据有 65536 个样本, 选取长度为 1024 个数据样本的汉明窗对每个通道的数据做 STFT, 窗口重叠率为 3/4, 得到的时频矩阵大小为 513×253 。将 16 个通道的时频矩阵拼接并转换矩阵的维度, 得到各频点的处理矩阵大小为 16×253 , 对每个频点的处理矩阵使用 GMM-EM 方法进行噪声抑制处理, 再改回通道数乘时频矩阵的形式, 最后对每个通道做 ISTFT, 得到降噪处理后的时域信号。

对测量信号做时频分析观察信号的时频特征。图 12(a) 为测量信号的时频谱, 其中谐波信号的信噪比较高。将处理前后的数据分别使用时域波束形成进行 DOA 估计, 通过定位结果验证本文方法对流噪声的抑制效果。湖试实验中, 声源静止而拖曳阵列不断移动, 声源相对于阵列的位置和角度随时间变化, 而本研究仅截取很短时间内的数据进行目标方位估计, 不考虑阵列的动态过程, 即本文的 DOA 估

计不考虑多普勒效应的影响。图 12(b) 为测量信号经降噪处理前后的波束形成结果, 经 GMM-EM 降噪处理的信号, 在 DOA 结果没有发生偏移的情况下, 其最大旁瓣级能够有效抑制 8~10 dB 左右。GMM-EM 方法与 GMM-VB 方法的结果较为相近, 但在某些方位角上的旁瓣级抑制表现更好; 而与 Hankel 矩阵降噪方法相比, 其在主瓣宽度减小的同时, 最大旁瓣级抑制效果能够提升 2~5 dB 左右。

表 2 为发射谐波信号时各方法抑制噪声后的信号噪声功率谱密度比。经 GMM-EM 方法抑制噪声后, 接收信号中信号噪声功率谱密度比从 0.07 dB 提升至 3.04 dB, 与 GMM-VB 方法近似, 较 Hankel 方法提升更多。

表 2 发射谐波信号时各方法抑制噪声后的信号噪声功率谱密度比

	原始信号	GMM-EM 去噪信号	Hankel 去噪信号	GMM-VB 去噪信号
PSDR (dB)	0.07	3.04	0.24	2.58

4.3 发射宽带信号情况下的流噪声抑制

选取拖曳速度为 14 kn, 发射信号为宽带信号的数据进行分析, 数据的时频转换和处理过程与发射谐波信号情况相同。图 13(a) 为测量信号的时频谱,




图 12 发射谐波信号下噪声抑制结果 (a) 测量信号时频图; (b) DOA 结果对比




图 13 发射宽带信号下噪声抑制结果 (a) 测量信号时频图; (b) DOA 结果对比图

与发射信号为谐波信号的情况相比,信噪比较低,已无法准确分辨发射信号的频带范围。使用 GMM-EM 方法对测量信号进行噪声抑制处理,再将处理前后的数据分别使用时域波束形成进行 DOA 估计。图 13(b) 为测量信号经降噪处理前后的波束形成结果。经 GMM-EM 方法降噪处理的信号,在 DOA 结果没有发生偏移的情况下,其最大旁瓣级能够有效抑制 8~10 dB 左右。并且在宽带信号情况下,相较于 GMM-VB 方法最大旁瓣级抑制效果能够提升 2~5 dB 左右,经 Hankel 矩阵降噪方法处理的信号已无法准确定位。

表 3 为发射宽带信号时各方法抑制噪声后的信号噪声功率谱密度比。经 GMM-EM 与 GMM-VB 方法抑制后,接收信号中信号噪声功率谱密度比提升较大,且 PSDR 值相近,而 Hankel 方法在宽带信号的情况下未能有效抑制噪声成分。

综上可知,在发射信号为谐波和宽带情况下,所提方法均可有效抑制流噪声;在低信噪比情况下,经降噪处理后的信号定位效果显著提升。即所提方法能够实现实际拖曳阵列流噪声的有效抑制,提升拖曳阵列声呐的定位性能。

表 3 发射宽带信号时各方法抑制后的信号噪声功率谱密度比

	原始信号	GMM-EM 去噪信号	Hankel 去噪信号	GMM-VB 去噪信号
PSDR (dB)	-1.76	1.50	-4.59	1.37

5 结论

利用阵列信号处理抑制拖曳阵列流噪声时,由于 TBL 噪声特性与传播过程复杂,难以准确建模与抑制。本文采用 GMM 的建模方法对拖曳阵列流噪声进行抑制处理,利用流噪声的非高斯特性,使用混合高斯模型对流噪声进行拟合。通过 EM 算法求解出混合高斯模型参数,将流噪声部分从测量信号中分离。该方法解决了现有流噪声模型拟合不准确的问题,发射信号为谐波信号和宽带信号时,该方法均能有效抑制流噪声,重建后的信号可实现目标的准确定位,且最大旁瓣级可抑制 8~10 dB。湖试实验进一步验证了所提方法的有效性,该方法与 GMM-VB 方法的噪声抑制结果相近,某些条件下抑制效果稍好,但 GMM-VB 方法的求解速度更快;与 Hankel 矩阵去噪方法相比,该方法在发射谐波信号和发射

宽带信号时均可实现流噪声的有效抑制。

参 考 文 献

- Corcos G M. The structure of the turbulent pressure field in boundary layer flows. *J. Fluid Mech.*, 1964; **18**: 353–378
- Carpenter A L, Kewley D J. Investigation of low wavenumber turbulent boundary layer pressure fluctuations on long flexible cylinders. The Eighth Australasian Fluid Mechanics Conference, NSW, Australia, 1983
- Lindemann O A. Influence of material properties on low wavenumber turbulent boundary layer noise in towed arrays. *U. S. Nav. Underwater Acoust.*, 1981; **31**(2): 265–271
- 汤渭霖, 吴一. TBL 压力起伏激励下粘性圆柱壳内的噪声场: I. 噪声产生机理. *声学学报*, 1997; **22**(1): 60–69
- 王斌, 汤渭霖, 范军. 水听器非轴线布放时的拖曳阵流噪声响应. *声学学报*, 2008; **33**(5): 402–408
- 王晓林, 王茂法. 基于 C&K 修正模型的拖曳阵流噪声特性仿真研究. *声学与电子工程*, 2010; (1): 9–13
- 杨秀庭, 孙贵青, 李敏. 矢量拖曳式线列阵声呐流噪声影响初探. *声学技术*, 2007; **26**(5): 775–780
- 杨秀庭, 孙贵青, 李敏. 矢量拖曳式线列阵声呐流噪声的空间相关性研究. *声学学报*, 2007; **32**(6): 547–552
- 孟戡仟. 矢量拖曳阵流致噪声抑制方法研究. *声学与电子工程*, 2010; (1): 20–24
- 李磊, 高洁, 吴克桐, 等. 一种基于矢量拖曳阵的拖船干扰抵消算法. *声学技术*, 2009; **28**(5): 582–585
- 李磊, 吴培荣, 邓红超, 等. 矢量水听器拖曳阵的信号模拟器设计. *应用声学*, 2010; **29**(1): 28–35
- 张宾, 孙长瑜. 拖船干扰抵消的一种新方法研究. *仪器仪表学报*, 2006; **27**(S2): 1355–1357
- 杨龙, 杨益新, 徐灵基. 水下航行器噪声源分布位置估计的瞬时频率变化率算法研究. *声学学报*, 2015; **40**(4): 500–510
- 徐灵基, 杨益新, 杨龙. 水下线谱噪声源识别的波束域时频分析方法研究. *物理学报*, 2015; **64**(17): 189–199
- 蔡盛盛, 张佳维, 冯大航, 等. 改进正则化正交匹配追踪波达方向估计方法. *声学学报*, 2014; **39**(1): 35–41
- 朱文龙, 印明, 佟建飞, 等. 多频带期望值最大声信号时延估计. *声学学报*, 2022; **47**(6): 856–866
- 韩东, 李建, 康春玉, 等. 拖曳线列阵声呐平台噪声的空域矩阵滤波抑制技术. *声学学报*, 2014; **39**(1): 27–34
- Meng D Y, Torre D L. Robust matrix factorization with unknown noise. IEEE International Conference on Computer Vision, Sydney, NSW, Australia, 2013: 1337–1344
- Yong H W, Meng D W, Zuo W M, *et al.* Robust online matrix factorization for dynamic background subtraction. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2018; **40**(7): 1726–1740
- Yu L, Antoni J, Deng J Y, *et al.* Low-rank gaussian mixture modeling of space-snapshot representation of microphone array measurements for acoustic imaging in a complex noisy environment. *Mech. Syst. Signal Process.*, 2022; **165**: 108294
- Yu L, Chen Y Q, Zhang Y L, *et al.* On-line harmonic signal denoising from the measurement with non-stationary and non-Gaussian noise. *Signal Process.*, 2022; **201**: 108723
- Emiya V, Hamon R, Chaux C. Being low-rank in the time-frequency plane. IEEE International Conference on Acoustics, Speech and Signal Processing, Calgary, AB, Canada, 2018: 4659–4663
- Usevich K, Emiya V, Brie D, *et al.* Characterization of finite signals with low-rank STFT. IEEE Statistical Signal Processing Workshop, Germany, 2018: 393–397
- Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm. *J. R. Stat. Soc. B*, 1977; **39**: 1–22
- Bishop C M. Pattern recognition and machine learning. New York: Springer, 2006
- Torre D L, Black M J. A framework for robust subspace learning. *Int. J. Comput. Vision*, 2003; **54**: 117–142
- Yang Y, Rao J. Robust and efficient harmonics denoising in large dataset based on random SVD and soft thresholding. *IEEE Access*, 2019; **7**: 77607–77617