



# 一种利用两阶段学习模型的水下阵列定位方法

张 宇<sup>1</sup> 江 鹏<sup>1</sup> 郭文飞<sup>1</sup> 张 丹<sup>2</sup> 韩 震<sup>1</sup>

1 武汉大学卫星导航定位技术研究中心, 湖北 武汉, 430079

2 武汉大学计算机学院, 湖北 武汉, 430079

**摘 要:**水下声学(underwater acoustic, UWA)阵列信号处理是常见的水下定位方式之一。针对噪声影响定位精度的问题,提出一种利用两阶段学习模型的定位方法。首先,分别对接收信号的实部和虚部特征进行训练,建立一个基于多层卷积神经网络的学习模型进行降噪处理;然后,构建一个改进的加权延时求和的波束形成器组模型,利用梯度下降准则对各个通道的权重进行调整,得到最优相对时延和最佳角度估计,再通过几何解算得到较为精确的定位信息。仿真实验结果表明,在-25~10 dB的信噪比环境中,所提方法与传统水下声阵列处理相比,应对信噪比变化的鲁棒性更强,且定位精度更高,湖上实验进一步验证了该方法的有效性。

**关键词:**两阶段学习模型;水下声阵列定位;降噪处理;加权延时求和;深度学习

**中图分类号:**P229.5

**文献标志码:**A

近年来,随着海洋资源的开发和海洋科学技术的发展,水声定位在海洋科学领域的应用越来越广<sup>[1]</sup>。基于水下声阵列信号处理的定位方法在水下空间的不同位置布放多个传感器组成阵列,利用阵列接收信号再对其进行处理,目的是估计判断主径上的发射信号方向,抑制无用的干扰和噪声。在解算出发射信号到各个阵元间的时间差后,利用方向角度和时延推算出发射单元的位置,从而达到定位的目的。

目前广泛应用于水下声阵列定位的方法有水下目标波达角(direction of arrival, DOA)估计<sup>[2]</sup>、水下波束形成技术<sup>[3]</sup>,均借鉴了无线电和声学的阵列处理方式解算水下位置。常用的DOA估计方法包括多信号分类(multiple signal classification, MUSIC)算法<sup>[4-6]</sup>、旋转不变技术估计信号参数(estimating signal parameters via rotational invariance techniques, ESPRIT)算法<sup>[7]</sup>、最大似然估计法<sup>[8-9]</sup>等。上述算法的核心是将噪声假设为高斯过程,通过分离噪声子空间来估计发射信号角度。水下波束形成对多路接收阵信号进行合并处理,抑制非目标方向的干扰并增强目标方向的信号,常见的波束形成算法包括最小均方误差(minimum mean square error, MMSE)波束形成器<sup>[10-11]</sup>、

线性约束最小方差(linearly constrained minimum variance, LCMV)波束形成器<sup>[12]</sup>。在时延估计中,常采用广义互相关-相位变换(generalized cross correlation phase transformation, GCC-PHAT)算法<sup>[13]</sup>,其核心是通过对水下阵列间信号进行互相关处理,得到使互相关函数最大的值即信号的时间差。但在实际阵列信号接收中,信道变化是一个复杂的过程,会受到噪声的干扰<sup>[14]</sup>。上述算法在噪声环境下均存在难以克服的问题,例如水下信道的噪声变化并不都是高斯过程,DOA估计算法并不能完整地分离出噪声子空间来估计波达方向角<sup>[15-17]</sup>;波束形成算法大多聚焦于对主径角度的估算,算法的性能过度依赖目标信号的DOA信息<sup>[18]</sup>,而强噪声环境对其处理精度影响十分明显。综上所述,噪声是制约定位精度的主要原因,为了最大程度降低噪声对接收信号的干扰,可应用自适应滤波进行降噪处理,其依靠线性滤波器滤掉噪声频率成分<sup>[19]</sup>,但收敛速率较慢且计算量大,为了克服以上问题,本文将深度学习引入降噪的处理中。

近年来,深度神经网络(deep neural network, DNN)被广泛应用于图像降噪和语音识别领域,并取得了突破性进展。依据研究侧重的不

收稿日期: 2021-08-25

项目资助:国家重点研发计划(2016YFB0501800)。

第一作者:张宇,博士生,主要从事水下数据处理和水下通信研究。zhangziju125@whu.edu.cn

通讯作者:江鹏,博士,研究员,博士生导师。jiangp@whu.edu.cn

同可分为聚焦于数据特征方面<sup>[20-22]</sup>和网络模型方面<sup>[23-26]</sup>两种。前者将重点放在对接收信号数据特征的训练处理中,根据训练特征不同可大致分为基于掩码估计<sup>[27]</sup>和基于谱映射估计<sup>[28]</sup>两类。后者则通过不同结构的神经网络提取噪声特征进行训练,例如文献[29]将信号的理想二值掩蔽(ideal binary mask, IBM)作为降噪神经网络的输入特征,对比信号时频单元的信噪比,学习并估计噪声;文献[30]提出一种基于卷积神经网络的声学通信降噪方法,利用时-频关系对接收信号进行二维化表述,达到降噪的目的。深度学习模型的本质是通过学习大量纯净信号和含噪信号样本数据构造复杂非线性函数,生成新的降噪处理估计。但上述两种模型均未针对水下声学信号进行适应性设计,大多数降噪方式都是直接将语音信号处理中常见的特征作为输入,忽略了水声信号的短时平稳性特点<sup>[31]</sup>,或者直接套用图像降噪的方式,随着噪声的筛除,水声信号中的关键传输信息也会伴随性丢失<sup>[32]</sup>。

针对以上问题,本文在DOA定位的基础上,提出一种基于降噪学习模型的定位方法,通过构建一个两阶段学习模型来处理水下声阵列接收数据,进而完成定位。在第一阶段模型中,为了克服水下噪声对定位结果的影响,使用神经网络模型对接收信号完成降噪处理,为了最大限度地挖掘水声信号的特征,在特征预处理阶段对其进行分帧处理,将信号的实部和虚部作为训练特征,充分利用了水声信号的短时平稳特性,为了尽可能降低对信号信息正交性的破坏,采用压缩合并和还原策略处理数据。在第二阶段模型中,使用第一阶段输出的降噪还原信号作为第二阶段的输入,通过改进的基于加权延时求和的波束形成方法来完成多空域滤波权值更新,达到对期望波达方向的信号增强,结合角度估计结果和时延估计结果解算发射端位置。该方法显著提升了定位系统对信噪比变化的鲁棒性,改善了系统定位精度。

## 1 水下声阵列定位的数据模型

图1为水下声阵列的发射-接收结构示意图,发射端信号经过水下噪声和反射产生多径效应的影响,到达接收阵列, $L$ 为阵元间距, $\theta$ 为入射信号与阵元夹角, $c$ 为信号传播速度。

图2展示了两个参考阵元间的结构关系。假设水下声阵列由 $M$ 个接收阵元组成,有 $K$ 个信号




图1 水下声阵列的发射-接收结构示意图

Fig.1 Transmit-Receive Structure of the Underwater Acoustic Arrays




图2 参考阵元间的结构关系

Fig.2 Structural Relationship of Reference Array Elements

$s_1(t), s_2(t) \cdots s_K(t)$ 到达该阵列,则第 $m$ 个阵元的接收信号可以表示为:

$$x_m(t) = \sum_{k=1}^K s_k(t - \tau_{m,k}) + n_m(t) \quad (1)$$

式中, $m=1, 2, \dots, M$ ;  $t$ 为传播时间; $\tau_{m,k}$ 为第 $k$ 个信号到达第 $m$ 个阵元相对于参考阵元的时延; $s_k(t - \tau_{m,k})$ 表示第 $m$ 个阵元上接收到的第 $k$ 个发射信号到达波; $n_m(t)$ 表示第 $m$ 个阵元上的加性噪声。阵列接收数据按照向量形式可表示为:

$$x(t) = \begin{bmatrix} e^{-j\omega\tau_{1,1}} & e^{-j\omega\tau_{1,2}} & \cdots & e^{-j\omega\tau_{1,K}} \\ e^{-j\omega\tau_{2,1}} & e^{-j\omega\tau_{2,2}} & \cdots & e^{-j\omega\tau_{2,K}} \\ \vdots & \vdots & \ddots & \vdots \\ e^{-j\omega\tau_{M,1}} & e^{-j\omega\tau_{M,2}} & \cdots & e^{-j\omega\tau_{M,K}} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_K(t) \end{bmatrix} + \begin{bmatrix} n_1(t) & n_2(t) & \cdots & n_M(t) \end{bmatrix}^T \quad (2)$$

式中, $\omega$ 为数字域频率。式(2)可简化为:

$$x(t) = As(t) + n(t) \quad (3)$$

其中,

$$x(t) = [x_1(t) \ x_2(t) \ \cdots \ x_M(t)]^T \quad (4)$$

$$A = [a(\theta_1) \ a(\theta_2) \ \cdots \ a(\theta_K)] \quad (5)$$

$$a(\theta_k) = [e^{j\omega\tau_{1,k}} \ e^{j\omega\tau_{2,k}} \ \cdots \ e^{j\omega\tau_{M,k}}]^T \quad (6)$$

式中, $\theta_k$ 为第 $k$ 个发射信号的方位角。

根据式(3)得到参考接收信号 $x_1(t)$ 和 $x_2(t)$ 为:

$$x_1(t) = As(t) + n_1(t) \quad (7)$$

$$x_2(t) = As(t) + n_2(t) \quad (8)$$

时延 $\tau$ 可通过广义互相关(generalized cross

correlation, GCC)算法<sup>[33]</sup>对两个参考阵元间的接收信号峰值检测得到,计算如下:

$$R_{x_1 x_2}(\tau) = \int x_1(\omega) x_2^*(\omega) e^{-j\omega\tau} d\omega \quad (9)$$

$$\hat{\tau} = \arg \max_{\tau} R_{x_1 x_2}(\tau) \quad (10)$$

式中,“\*”表示矩阵共轭; $\hat{\tau}$ 表示估计时延,一般为相关运算峰值最大的时刻。

由图 2 可知,估算时延  $\hat{\tau}$  和发射信号的波达方向估计值  $\hat{\theta}$  的关系可表示为:

$$\sin \hat{\theta} = \frac{c\hat{\tau}}{L} \quad (11)$$

在式(1)中,以第一个阵元为参考阵元,若第  $m$  个阵元的位置坐标为  $(x_m, y_m)$ ,根据式(10)和式(11)可得到<sup>[34]</sup>:

$$\tau_{m,k} = \frac{1}{c} [x_m \sin \theta_k + y_m \cos \theta_k] \quad (12)$$

通过几何解算可完成发射端的定位,但是在实际环境中,噪声的存在会导致式(9)中相关运算  $R_{x_1 x_2}(\tau)$  的峰值不明显,降低了时延估计的精度,影响定位精度。因此如何准确地估计出  $\hat{\theta}$  和  $\hat{\tau}$  成为水下声阵列定位系统的关键。

## 2 本文方法

为了在噪声影响严重的条件下准确地估计角度信息  $\hat{\theta}$  和时延信息  $\hat{\tau}$ ,本文提出一种基于两阶段学习模型的水下声学定位方法。在第一阶段模型中,构建一个基于深度卷积神经网络(deep convolution neural network, DCNN)的降噪模型<sup>[35]</sup>,将接收端信号进行基于时-频关系的二维矩阵化<sup>[36]</sup>,对其进行提取特征输入,通过该模型在纯净不含噪的发射信号和带噪的接收信号之间建立神经网络函数映射,进而得到具有降噪效果的接收信号;在第二阶段模型中,为了提升角度估计的准确性,设计一种改进的基于加权延时求和的波束形成模型,该模型利用梯度下降准则确定各个通道的最优相对延时,根据实际环境对各个通道的权重进行迭代更新<sup>[37]</sup>,得到最优权值,最终输出估计出的角度信息  $\hat{\theta}$  和时延  $\hat{\tau}$ ,得到位置估计。图 3 为本文两阶段学习模型的结构示意图。

### 2.1 第一阶段模型

第一阶段模型的核心是一个降噪学习网络模型。由于降噪的过程不是简单的线性过程,对实部和虚部进行分离再合并的过程会破坏二者的正交性,为了使这种影响最小化,本文对数据

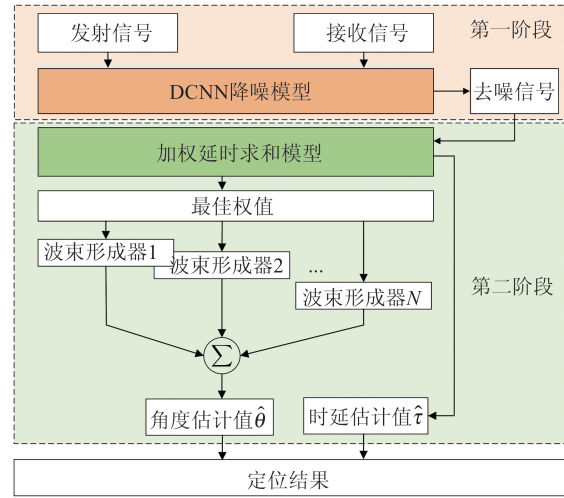


图 3 两阶段学习模型结构

Fig.3 Structure of Two-Stage Learning Model

预处理进行了策略优化:(1)在预处理阶段对接收信号数据进行重新组合分帧,在短时平稳区间内,截取数据长度间存在帧重叠,尽量保持正交的关联性;(2)在得到分帧数据后进行实部和虚部分离,将分离后的实部和虚部数据进行函数压缩,保证数据特性的统一;(3)利用归一化函数将降噪后的实部和虚部数据合并。对式(1)接收信号数据进行分帧和加窗处理,窗函数  $window(n)$  采用海明窗,  $\alpha_0$  取值 0.538 36,则取窗函数为:

$$window(n) = \alpha_0 - \underbrace{(1 - \alpha_0)}_{\alpha_1} \cos\left(\frac{2\pi n}{N-1}\right) \quad (13)$$

式中,  $0 \leq n \leq N-1$ ,  $N$  表示海明窗取值长度。

对加窗处理后的帧数据进行重新组合分帧,由于接收的信号具有短时平稳的特点,在 20~30 ms 表现为较为平稳的幅度特征,分帧时每一帧长度为 20 ms,帧间设置重叠长度为 10 ms,分帧组合策略如图 4 所示。




图 4 数据预处理的分帧策略

Fig.4 Framing Strategy of Data Preprocessing

首先将每帧信号表示为时间-频率的二维化矩阵,进行短时傅里叶变换(short time Fourier transform, STFT),计算如下:



$$x_{\text{revSTFT}}(t, f) = \sum_{n=0}^{N-1} x(t, f) \text{window}(t, f) e^{\frac{-j2\pi kn}{N}} \quad (14)$$

式中,  $f$  为信号频率。

然后进行实部和虚部分离:  $x_{\text{revSTFT}}(t, f) \rightarrow (R_x, I_x)$ , 得到接收信号输入特征。同理, 对发射信号  $s(t)$  也进行同样的操作, 得到  $s_{\text{STFT}}(t, f) \rightarrow (R_s, I_s)$ 。其中,  $R_x$ 、 $R_s$  分别是  $x_{\text{revSTFT}}(t, f)$ 、 $s_{\text{STFT}}(t, f)$  对应的实部数据;  $I_x$ 、 $I_s$  分别是  $x_{\text{revSTFT}}(t, f)$ 、 $s_{\text{STFT}}(t, f)$  对应的虚部数据。

最后采用双曲正切函数分别对实部和虚部进行压缩, 得到对应的实部双曲正切压缩 (hyperbolic tangent compressed real component, TR) 和虚部双曲正切压缩 (hyperbolic tangent compressed imaginary component, TI) 作为网络的输入输出特征, 计算如下:

$$\text{TR}(t, f) = \frac{\beta(1 - e^{-\alpha Z_R(t, f)})}{1 + e^{-\alpha Z_R(t, f)}} \quad (15)$$

$$\text{TI}(t, f) = \frac{\beta(1 - e^{-\alpha Z_I(t, f)})}{1 + e^{-\alpha Z_I(t, f)}} \quad (16)$$

式中,  $\alpha$  和  $\beta$  为限制因子, 取值分别为 0.5 和 10;  $Z_R(t, f)$  表示  $R_x$  和  $R_s$  经压缩后的结果;  $Z_I(t, f)$  表示  $I_x$  和  $I_s$  经压缩后的结果。图 5 为降噪网络模型的神经网络结构,  $\hat{R}$ 、 $\hat{I}$  分别代表经降噪网络输出后的实部、虚部。




图 5 降噪网络模型的神经网络结构

Fig.5 Neural Network Structure of the Noise-Reduction Network Model

降噪网络是基于 DCNN 的结构进行适应性调整得到的, 常见的 DCNN 已包含完整的训练结构, 为使其在实部虚部特征训练过程中具有去噪作用, 本文引入通道关注机制<sup>[38]</sup>进行特征运算, 同时将金字塔去噪结构分配到每个分支, 只聚焦在同一个尺度内的特征提取<sup>[39]</sup>, 提取全局信息并保留局部细节, 为全面去噪进行初始化准备, 使用 U-Net 来分割池化层降采样的特征<sup>[40]</sup>, 激活函数选用 Sigmoid 采用的交叉熵损失函数, 计算如下:

$$\text{Loss} = -\frac{1}{B} \sum_{b=1}^B [n \ln \hat{n} + (1 - n) \ln (1 - \hat{n})] \quad (17)$$

式中,  $B$  为接收阵元个数;  $n$  为预期输出;  $\hat{n}$  为神经网络输出, 即降噪后的  $\hat{R}_z$  和  $\hat{I}_z$ 。

将降噪输出的实部和虚部进行归一化还原, 得到:

$$\hat{R}(n) = -\frac{1}{\alpha} \log \frac{\beta - \hat{R}_z(n)}{\beta + \hat{R}_z(n)} \quad (18)$$

$$\hat{I}(n) = -\frac{1}{\alpha} \log \frac{\beta - \hat{I}_z(n)}{\beta + \hat{I}_z(n)} \quad (19)$$

降噪还原信号为:

$$y(t) = \hat{R}(t) + \hat{I}(t) \times j \quad (20)$$

表 1 为该阶段模型的具体参数设置。

表 1 降噪神经网络的参数设置

Tab.1 Parameter Setting of the Noise-Reduction DNN

设置项	参数值
卷积层	4
全连接层	2
卷积层滤波器	5×5, 3×3, 2×2
步长	2×2
激活函数	Sigmoid 函数
池化层	3
输出层	6×161

## 2.2 第二阶段模型

第二阶段模型的核心是一个改进的基于加权延时求和的波束形成组, 将第一阶段降噪处理的接收信号作为第二阶段的输入, 进行角度  $\hat{\theta}$  估计和时延  $\hat{\tau}$  估计。

为了更准确地完成期望波达方向上的角度  $\hat{\theta}$  估计, 需要抑制降低其他方向的干扰, 本文提出一种使用多个波束形成器对期望信号估计策略, 如图 6 所示, 水下声阵列接收信号分别与  $P$  个波束形成器相连, 对感兴趣用户的第  $p$  条路径信号进行波束形成, 即将阵列波束主瓣对准其到达方向, 并在其他路径信号和多址干扰信号到达方向上形成期望方向零陷或较低的增益<sup>[41]</sup>。

波束形成器组输出向量  $\eta_1, \eta_2 \cdots \eta_M$ , 各个接收支路降噪接收后波束形成器的输出信号可表示为:

$$\tilde{y}(k) = \sum_{p=1}^L \eta_p y_p(k - \tau_p) = \sum_{p=1}^L \eta_p V_p^H x(k - \tau_p) \quad (21)$$

式中,  $\eta_p$  表示每个分支波束形成器中期望方向的加权系数;  $\tau_p$  为相对时延;  $V_p$  表示阵列加权向量,






图 6 多个波束形成器组成的角度估计结构

Fig.6 Angle Estimation Structure Consisting of Multiple Beamformers

可采用 MMSE 准则<sup>[42]</sup>迭代计算得到:

$$V_p = \left[ \frac{\alpha_1}{M} e^{2\pi i f \Delta \tau_1} \quad \frac{\alpha_2}{M} e^{2\pi i f \Delta \tau_2} \quad \dots \quad \frac{\alpha_M}{M} e^{2\pi i f \Delta \tau_M} \right]^T \quad (22)$$

$$R_{x_{m-1}x_m}(\tau) = A_{m-1}A_mE(s(t-\tau_{m-1})s(t-\tau_m-\tau)) + A_{m-1}E(s(t-\tau_{m-1})n_m(t-\tau) + A_mE(s(t-\tau_m-\tau)n_m(t)) + E(n_{m-1}(t)n_m(t-\tau)) \quad (26)$$

当限制条件  $\tau = \tau_{m-1} - \tau_m$  成立时,  $R_{x_{m-1}x_m}(\tau)$  取最大值, 则两个参考阵元间的时延可表示为:

$$\Delta\tau_{m-1,m} = \arg \max \Psi_{x_{m-1}x_m}(\tau) \quad (27)$$

式中,  $\Psi_{x_{m-1}x_m}(\tau)$  为互相关系数<sup>[26]</sup>, 由快速傅里叶逆变换 (inverse fast Fourier transforms, IFFT) 展开得到, 对于估计时延  $\hat{\tau}$ , 计算如下:

$$\Psi_{x_{m-1}x_m}(\hat{\tau}) = \text{IFFT} \left( \frac{x_{m-1}(f)x_m^*(f)}{|x_{m-1}(f)x_m^*(f)|} \right) \quad (28)$$

将时延  $\hat{\tau}$  求解转换为对  $\Psi_{x_{m-1}x_m}(\hat{\tau})$  的最佳加权估计<sup>[43]</sup>是一个基于梯度下降准则的白化滤波过程, 可逐次迭代权值直至得到最优估计, 定义梯度为  $W_t$ , 前后两次权值的加权平均和为  $H_t$ ,  $\delta$  为学习率,  $\odot$  表示矩阵逐元素相乘, 则有:

$$W_{t+1} = W_t - \delta \nabla_{W_t} \quad (29)$$

$$H_t = \delta H_{t-1} + (1 - \delta) \nabla_{W_t} \odot \nabla_{W_t} \quad (30)$$

$$W_{t+1} = W_t - \frac{\delta}{\sqrt{H_t}} \odot \nabla_{W_t} \quad (31)$$

$$H_t = \delta^{t-0} \hat{H} + (1 - \delta) \sum_{i=1}^t \delta^{t-i} \hat{H} \quad (32)$$

式中,  $\hat{H} = \nabla_{W_0} \odot \nabla_{W_0}$ .

将  $\Psi_{x_{m-1}x_m}(\tau)$  设置为初始权值, 按照以下条件更新:

$$\left\| \frac{\delta}{\sqrt{H_t}} \right\| \leq \left\| \frac{\delta}{\sqrt{\nabla_{W_t} \odot \nabla_{W_t}}} \right\| \quad (33)$$

最后通过式(28)完成对  $\hat{\tau}$  的有效估计。

式中,  $\alpha_m$  为第  $m$  个接收阵元上的接收信号经频域变化后的相位调节参数, 由迭代计算产生。

将  $V_p$  代入波束形成器组, 为了使期望角度上的输出功率为最大, 从而抑制干扰和噪音完成输出  $\hat{\theta}$  估计,  $\hat{\theta}$  的判断依据为:

$$\hat{\theta} = \arg \max [E|d(t)|^2 \|V_p^H a(\theta)\|^2 + \sigma^2 \|V_p\|^2] \quad (23)$$

计算时延  $\hat{\tau}$  需对式(2)和式(4)进行转换, 则第  $m$  个接收阵元上接收信号可表示为:

$$x_m(t) = As(t - \tau_m) + n_m(t) \quad (24)$$

式中,  $m = 1, 2, \dots, M$ ;  $\tau_m$  为两个参考阵元间的相对时延, 可采用互相关求解得到:

$$R_{x_{m-1}x_m}(\tau) = E(x_{m-1}(t)x_{m-1}(t-\tau)) \quad (25)$$

式(25)可进一步表示为:

### 3 仿真实验和湖上实验

#### 3.1 仿真实验

仿真实验采用 Bellhop 仿真工具<sup>[44]</sup>模拟水下阵列的发射-接收场景, 如图 7 所示。发射端为 1 个声源, 接收端为四元均匀线性阵列 (uniform linear array, ULA), 声场限定在  $300 \text{ m} \times 300 \text{ m} \times 160 \text{ m}$  的水域内, 阵元间距为半波长  $d$ , 与阵元中心  $O$  的距离  $R = 100 \text{ m}$ , 其中发射端  $T_1$ 、 $T_2$ 、 $T_3$  的入射角发生了角度变化, 对应角度分别为  $\theta_1 = 60^\circ$ ,  $\theta_2 = 100^\circ$ ,  $\theta_3 = 130^\circ$ , 发射信号由线性调频波 (linear frequency modulation, LFM) 和正交相移键控 (quadrature phase shift keying, QPSK) 组成, 噪声采用高斯白噪声, 为全频带噪声, 信噪比设置为  $-25 \sim 10 \text{ dB}$ , 多径数设置为 5。




图 7 发射-接收的仿真示意图

Fig.7 Transmit-Receive Simulation Schematic

第一阶段模型的输出为降噪后的实部和虚部, 通过短时傅里叶逆变换 (inverse STFT, ISTFT) 得到去噪接收信号。当信噪比为  $5 \text{ dB}$  时, 分别取 3 个角度的某一帧抽样显示去噪接收信号的时域-频域二维重构结果, 如图 8 所

示。由图8可以看出,对于接收信号而言,第一阶段降噪学习网络模型具有良好的降噪效果。

图9为去噪前后第二阶段模型角度估计结果。图9(a)为未经过降噪网络处理直接采用波

束形成进行角度估计的结果,图9(b)为经过第一阶段降噪网络后再使用波束形成估计的角度。由图9可以看出,角度估计的准确率有了较大幅度的提升。

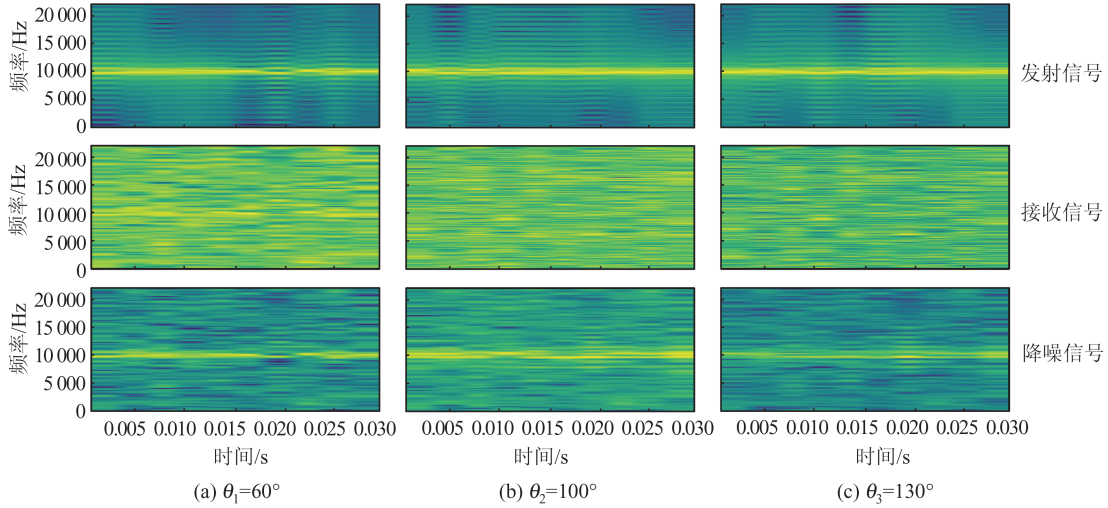


图8 信号降噪后的时域-频域二维重构

Fig.8 Time-Frequency Domain 2-Dimensional Reconstruction of the Received Signal After Noise Reduction




图9 去噪前后第二阶段模型角度估计对比

Fig.9 Angle Estimation of the Second-Stage Model Before and After Noise Reduction

广义互相关-相位变换方法根据两个参考阵元的互相关函数峰值来估计时延值,在本文仿真模型中,四阵元接收阵列两两可组成一对参考阵元。

根据式(7)、(8)得到参考阵元接收信号 $x_1$ 和 $x_2$ ,将其转换至频域 $X_1$ 和 $X_2$ ,则互相关(generalized cross correlation, GCC)过程的互相关函数和

互功率谱关系为:

$$R_{X_1 X_2}(\tau) = \int_0^{\pi} X_1(\omega) X_2^*(\omega) e^{-j\omega\tau} d\omega \quad (34)$$

由于噪声的影响, $R_{X_1 X_2}(\tau)$ 的相关峰值会受影响,这降低了时延的估计精度。为了锐化峰值,在频域内对互功率谱进行加权,从而抑制干扰。则式(34)可变为:

$$R_{X_1 X_2}(\tau) = \int_0^\pi \varphi_{12}(\omega) X_1(\omega) X_2^*(\omega) e^{-j\omega\tau} d\omega \quad (35)$$

式中,  $\varphi_{12}(\omega)$  表示频域加权函数。

加权函数  $\varphi_{12}(\omega)$  利用 PHAT(phase transformation) 加权, 其对噪声的约束效果较好, 但当信号能量较小时, 处理误差增大。  $\varphi_{12}(\omega)$  可展开为:

$$\varphi_{\text{PHAT}}(\omega) = 1/\|G_{x_1 x_2}\| = 1/\|X_1(\omega) X_2^*(\omega)\| \quad (36)$$

经过 PHAT 加权的 GCC 互功率谱近似于单位冲击响应, 可突出时延的峰值, 进而解算出时延。在对多径的处理中, 采用判断策略确定主径, 将接收阵列首次到达的信号方向(时间最短)设为主径的入射方向, 在 GCC-PHAT 中, 两个参考阵元间, 互相关运算后时间最短的即为相对时延。

克拉美-罗下界(Cramer-Rao lower bound, CRLB)<sup>[45]</sup> 常用于描述计算理论能达到的最佳估计精度。对于真实值  $\theta$  和  $\tau$ , 其 CRLB 根据定义可表示为:

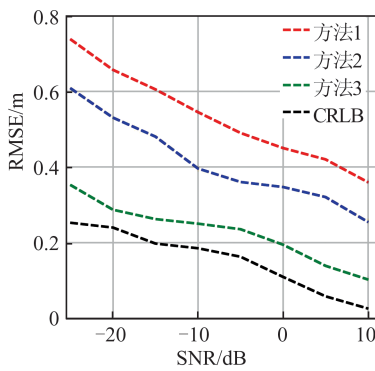
$$P_\theta = (J_\theta^T R_\theta^{-1} J_\theta)^{-1} \quad (37)$$

$$P_\tau = (J_\tau^T R_\tau^{-1} J_\tau)^{-1} \quad (38)$$


式中,  $J_\theta$  和  $J_\tau$  分别表示  $\theta$  和  $\tau$  的观测函数关于发射端位置的雅可比(Jacobi)矩阵;  $R$  为协方差矩阵。式(12)中第  $m$  个阵元位置为  $(x_m, y_m)$ , 则  $J_\theta$  中各行元素为:

$$J_\theta^m = \begin{bmatrix} -\frac{y_m}{r_m^2} & \frac{x_m}{r_m^2} \end{bmatrix} \quad (39)$$


$J_\tau$  中各行元素为:



(a)  $\theta_1=60^\circ$



(b)  $\theta_2=100^\circ$



(c)  $\theta_3=130^\circ$

图 10 定位结果的 RMSE 对比

Fig.10 RMSE Comparison of Positioning Results

### 3.2 湖上实验

湖上实验采用 2021 年 7 月在安徽省安庆市花亭湖采集的数据, 发射信号由 LFM 和 QPSK 组成, 多帧连续的波形组合生成 WAV 格式文件,

$$J_\tau^m = \begin{bmatrix} -\frac{y_m}{r_m^2} + \frac{y_1}{r_1^2} & \frac{x_m}{r_m^2} - \frac{x_1}{r_1^2} \end{bmatrix} \quad (40)$$

则联合定位误差的 CRLB 为:

$$P = (J^T R^{-1} J)^{-1} \quad (41)$$

将式(37)和式(38)代入式(41)可得:

$$P = (J_\theta^T R_\theta^{-1} J_\theta + J_\tau^T R_\tau^{-1} J_\tau)^{-1} = (P_\theta^{-1} + P_\tau^{-1})^{-1} \quad (42)$$

$$P_\theta^{-1} = \frac{1}{\sigma_\theta^2} \begin{bmatrix} \sum_{m=1}^M \frac{y_m^2}{r_m^4} & -\sum_{m=1}^M \frac{x_m y_m}{r_m^4} \\ -\sum_{m=1}^M \frac{x_m y_m}{r_m^4} & \sum_{m=1}^M \frac{x_m^2}{r_m^4} \end{bmatrix} \quad (43)$$

$$P_\tau^{-1} = (\sigma_\theta^2 / \sigma_\tau^2) P_\theta^{-1} - (1/\sigma_\tau^2) a a^T \quad (44)$$

$$a = \begin{bmatrix} -\sum_{m=1}^M \frac{y_m}{r_m^2} & \sum_{m=1}^M \frac{x_m}{r_m^2} \end{bmatrix} \quad (45)$$

式中,  $\sigma_\theta^2$  和  $\sigma_\tau^2$  分别为  $\theta$  和  $\tau$  的噪声方差。

应用本文方法和其他两种方法进行仿真实验, 设置信噪比为  $-25 \sim 10$  dB, 多径数设置为 5 时, 分别验证了  $\theta_1 = 60^\circ$ 、 $\theta_2 = 100^\circ$ 、 $\theta_3 = 130^\circ$  3 个角度下定位结果的均方根误差(root mean square error, RMSE)和 CRLB 对比, 结果如图 10 所示。其中方法 1 表示直接利用传统算法 GCC-PHAT 进行定位, 方法 2 表示在第一阶段降噪模型处理后联合 GCC-PHAT 算法进行处理, 方法 3 为本文方法。由图 10 可知, 本文方法模型在应对信噪比变化的鲁棒性更高。

同时, 本文在仿真实验中还进行了收发拉距测试, 以验证方法的适用边界, 发现在收发距离超过 1 km 后, 本文方法对于噪声的鲁棒性逐渐降低。

通过功放由发射换能器发出, 接收端为四元 ULA, 实验水域丰水期平均水深为 90 m, 发射端变换两次位置, 角度分别为  $30^\circ$  和  $60^\circ$ 。实验具体参数设置如下: LFM 带宽为  $7 \sim 13$  kHz, QPSK 载



波频率为 10 kHz,采样率为 200 kHz,发射端水深为 50 m、86 m,收发距离为 100 m。

实验中使用 LFM 宽带信号对水下信道的信噪比进行测量估算,平均信噪比为 10 dB。图 11 为 4 个接收阵元接收到的水声信号。




图 11 4 个阵元的接收信号  
Fig. 11 Received Signals of the 4 Array Elements

对角度估计值和位置估计值的计算结果进行 100 次统计,图 12、13 分别为角度估计、定位结果的对比,其中方法 1、方法 2、方法 3 与 §3.1 相同。

由图 12 可知,在角度估计中,方法 1 未经过第一阶段降噪模型处理,角度的估计结果与真实值差距较大;方法 2 经过第一阶段降噪模型处理,明显改善了噪声对估计结果的影响;方法 3 即本文方法改善了噪声的影响,准确地估算出期望方向的角度,验证了方法的稳定性。由图 13 可知,在定位结果中,方法 1 定位结果的解算收敛性不佳,误差较大;方法 2 定位结果有所改善;方法 3 的定位解算结果具有十分良好的收敛性,定位精度更高,更稳定。




图 12 角度估计结果对比  
Fig.12 Comparison of Angle Estimate Results




图 13 位置估计统计  
Fig.13 Statistics of Positioning Estimates

表 2 为湖上实验的结果对比,包括 30°和 60°角度估计的平均值和均方根误差,以及真实值分别为 (20, 50) m、(56, 86) m 中定位估计的平均值和均方根误差。由表 2 可知,本文提出的两阶段方法在实测数据中也保持了较好的优势。

表 2 湖上实验结果对比统计						
Tab.2 Result Comparison on the Lake Test						
方法	角度/(°)			定位结果/m		
	真实值	估计平均值	均方根误差	真实值	估计平均值	均方根误差
方法 1	30	22.3	0.52	(20, 50)	(15.32, 51.67)	0.36
方法 2		27.4	0.31		(21.02, 53.43)	0.25
方法 3		30.8	0.12		(20.87, 50.24)	0.10
方法 1	60	53.6	0.49	(56, 86)	(52.30, 84.28)	0.34
方法 2		56.3	0.33		(54.24, 87.51)	0.29
方法 3		60.5	0.14		(56.38, 86.55)	0.15

## 4 结 语

水下声阵列信号处理是水下定位研究的重要手段之一。引入降噪处理、加权时延估计和基于梯度下降准则的权值迭代等方法,可提升定位系统对于噪音变化影响的鲁棒性和准确率,本文利用以上策略建立了两阶段模型方法,有效地应

对了仿真环境中信噪比为 -25~10 dB、多径数为 5 的干扰场景,并在湖上实验也得到了有效的验证。对接收信号分段处理的两阶段模型结构适用于多数阵列信号处理的定位场景,包括室内声学定位和无线电雷达阵列等领域<sup>[46]</sup>。在未来的工作中,可持续性发掘深度学习模型中数据特征提取的优势<sup>[47]</sup>,在多个场景下的水声传播数据场

景中,构建覆盖范围更广的训练模型库,使得预训练结构具有更佳的范围价值<sup>[48]</sup>,从而达到最佳的定位效果。

### 参 考 文 献

- [1] Liu Jingnan, Chen Guanxu, Zhao Jianhu, et al. Development and Trends of Marine Space-Time Frame Network[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(1): 17-37 (刘经南, 陈冠旭, 赵建虎, 等. 海洋时空基准网的进展与趋势[J]. 武汉大学学报·信息科学版, 2019, 44(1): 17-37)
- [2] Tao J W, Chang W X, Cui W. Vector Field Smoothing for DOA Estimation of Coherent Underwater Acoustic Signals in Presence of a Reflecting Boundary[J]. *IEEE Sensors Journal*, 2007, 7(8): 1 152-1 158
- [3] Yang T C. Deconvolved Conventional Beamforming for a Horizontal Line Array[J]. *IEEE Journal of Oceanic Engineering*, 2018, 43(1): 160-172
- [4] Friedlander B. A Sensitivity Analysis of the MUSIC Algorithm[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1990, 38(10): 1 740-1 751
- [5] Rahamim D, Tabrikian J, Shavit R. Source Localization Using Vector Sensor Array in a Multipath Environment[J]. *IEEE Transactions on Signal Processing*, 2004, 52(11): 3 096-3 103
- [6] Paulraj A, Reddy V U, Shan T J, et al. Performance Analysis of the Music Algorithm with Spatial Smoothing in the Presence of Coherent Sources[C]// IEEE Military Communications Conference, Monterey, California, USA, 1986
- [7] Roy R, Kailath T. ESPRIT-Estimation of Signal Parameters via Rotational Invariance Techniques[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1989, 37(7): 984-995
- [8] Li M H, Lu Y L. Maximum Likelihood DOA Estimation in Unknown Colored Noise Fields[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(3): 1 079-1 090
- [9] Stoica P, Gershman A B. Maximum-Likelihood DOA Estimation by Data-Supported Grid Search[J]. *IEEE Signal Processing Letters*, 1999, 6(10): 273-275
- [10] Iltis R A, Kim S J, Hoang D A. Noncooperative Iterative MMSE Beamforming Algorithms for Ad Hoc Networks[J]. *IEEE Transactions on Communications*, 2006, 54(4): 748-759
- [11] Choi S, Choi J, Im H J, et al. A Novel Adaptive Beamforming Algorithm for Antenna Array CDMA Systems with Strong Interferers[J]. *IEEE Transactions on Vehicular Technology*, 2002, 51(5): 808-816
- [12] Koutrouvelis A I, Hendriks R C, Heusdens R, et al. Relaxed Binaural LCMV Beamforming[J]. *ACM Transactions on Audio, Speech, and Language Processing*, 2017, 25(1): 137-152
- [13] Blandin C, Ozerov A, Vincent E. Multi-source TDOA Estimation in Reverberant Audio Using Angular Spectra and Clustering[J]. *Signal Processing*, 2012, 92(8): 1 950-1 960
- [14] Kilfoyle D B, Baggeroer A B. The State of the Art in Underwater Acoustic Telemetry[J]. *IEEE Journal of Oceanic Engineering*, 2000, 25(1): 4-27
- [15] Odendaal J W, Barnard E, Pistorius C W I. Two-Dimensional Superresolution Radar Imaging Using the MUSIC Algorithm[J]. *IEEE Transactions on Antennas and Propagation*, 1994, 42(10): 1 386-1 391
- [16] Zhao Jianhu, Yan Jun, Zhang Hongmei, et al. Using Backscatter Characteristic of Seabed Sediment to Remove Angular Response Effect in Multibeam Images[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(8): 1 228-1 233 (赵建虎, 严俊, 张红梅, 等. 基于海底底质回波特征的多波束声呐图像角度响应影响消除[J]. 武汉大学学报·信息科学版, 2018, 43(8): 1 228-1 233)
- [17] Li J F, Ma P H, Zhang X F, et al. Improved DFT Algorithm for 2D DOA Estimation Based on 1D Nested Array Motion[J]. *IEEE Communications Letters*, 2020, 24(9): 1 953-1 956
- [18] Van Veen B D, Buckley K M. Beamforming: A Versatile Approach to Spatial Filtering[J]. *IEEE ASSP Magazine*, 1988, 5(2): 4-24
- [19] Pillai S U, Bar-Ness Y, Haber F. A New Approach to Array Geometry for Improved Spatial Spectrum Estimation[J]. *Proceedings of the IEEE*, 1985, 73(10): 1 522-1 524
- [20] Ren A, Li Z, Ding C W, et al. SC-DCNN: Highly-Scalable Deep Convolutional Neural Network Using Stochastic Computing[C]// The 22nd International Conference on Architectural Support for Programming Languages and Operating Systems, Xi'an, China, 2017
- [21] Huang H J, Yang J, Huang H, et al. Deep Learning for Super-Resolution Channel Estimation and DOA Estimation Based Massive MIMO System[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(9): 8 549-8 560

- [22] Zheng W Q, Zou Y X, Ritz C. Spectral Mask Estimation Using Deep Neural Networks for Inter-Sensor Data Ratio Model Based Robust DOA Estimation [C]// IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), South Brisbane, QLD, Australia, 2015
- [23] Wang D S, Zou Y X, Wang W W. Learning Soft Mask with DNN and DNN-SVM for Multi-Speaker DOA Estimation Using an Acoustic Vector Sensor [J]. *Journal of the Franklin Institute*, 2018, 355(4): 1 692-1 709
- [24] Lee H Y, Cho J W, Kim M, et al. DNN-Based Feature Enhancement Using DOA-Constrained ICA for Robust Speech Recognition [J]. *IEEE Signal Processing Letters*, 2016, 23(8): 1 091-1 095
- [25] Xiang H H, Chen B X, Yang M L, et al. A Novel Phase Enhancement Method for Low-Angle Estimation Based on Supervised DNN Learning [J]. *IEEE Access*, 2019, 7: 82 329-82 336
- [26] Cong J Y, Wang X P, Huang M X, et al. Robust DOA Estimation Method for MIMO Radar via Deep Neural Networks [J]. *IEEE Sensors Journal*, 2021, 21(6): 7 498-7 507
- [27] Rizwan T, Cai Y Z, Ahsan M, et al. Neural Network Approach for 2-Dimension Person Pose Estimation with Encoded Mask and Keypoint Detection [J]. *IEEE Access*, 2020, 8: 107 760-107 771
- [28] Selva J. Computation of Spectral and Root MUSIC Through Real Polynomial Rooting [J]. *IEEE Transactions on Signal Processing*, 2005, 53(5): 1 923-1 927
- [29] Abdullah S, Zamani M, Demosthenous A. Towards more Efficient DNN-Based Speech Enhancement Using Quantized Correlation Mask [J]. *IEEE Access*, 2021, 9: 24 350-24 362
- [30] Dong Y D, Wang H X, Yao Y D. Channel Estimation for One-Bit Multiuser Massive MIMO Using Conditional GAN [J]. *IEEE Communications Letters*, 2021, 25(3): 854-858
- [31] Larsson E G, Edfors O, Tufvesson F, et al. Massive MIMO for Next Generation Wireless Systems [J]. *IEEE Communications Magazine*, 2014, 52(2): 186-195
- [32] Xia H J, Yang K D, Ma Y L, et al. Noise Reduction Method for Acoustic Sensor Arrays in Underwater Noise [J]. *IEEE Sensors Journal*, 2016, 16(24): 8 972-8 981
- [33] Lee R, Kang M S, Kim B H, et al. Sound Source Localization Based on GCC-PHAT with Diffuseness Mask in Noisy and Reverberant Environments [J]. *IEEE Access*, 2020, 8: 7 373-7 382
- [34] Khabbazi Basmenj A, Vorobyov S A, Hassanien A. Robust Adaptive Beamforming Based on Steering Vector Estimation with as Little as Possible Prior Information [J]. *IEEE Transactions on Signal Processing*, 2012, 60(6): 2 974-2 987
- [35] Wei Z, Chen X D. Deep-Learning Schemes for Full-Wave Nonlinear Inverse Scattering Problems [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(4): 1 849-1 860
- [36] Wang Z Q, Zhang X L, Wang D L. Robust Speaker Localization Guided by Deep Learning-Based Time-Frequency Masking [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2019, 27(1): 178-188
- [37] Liu Jingnan, Zeng Wenxian, Xu Peiliang. Overview of Total Least Squares Methods [J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(5): 505-512 (刘经南, 曾文宪, 徐培亮. 整体最小二乘估计的研究进展 [J]. 武汉大学学报·信息科学版, 2013, 38(5): 505-512)
- [38] Chadwell D, Bürgmann R, Zhang Bo, et al. The Nonsub Sampled Contourlet Transform [J]. *Transactions on Image Processing*, 2006, 15(10): 3089-3101
- [39] Morozs N, Gorma W, Henson B T, et al. Channel Modeling for Underwater Acoustic Network Simulation [J]. *IEEE Access*, 2020, 8: 136 151-136 175
- [40] Hinton G, Deng L, Yu D, et al. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups [J]. *IEEE Signal Processing Magazine*, 2012, 29(6): 82-97
- [41] Zhang Y, Yan D Q. Path Generation Method for Aero-Engine Free-Form Surface Blade in Laser Solid Forming [J]. *IEEE Access*, 2019, 7: 140 588-140 595
- [42] Protter M, Yavneh I, Elad M. Closed-Form MMSE Estimation for Signal Denoising Under Sparse Representation Modeling over a Unitary Dictionary [J]. *IEEE Transactions on Signal Processing*, 2010, 58(7): 3 471-3 484
- [43] Sundar H, Sreenivas T V, Seelamantula C S. TDOA-Based Multiple Acoustic Source Localization Without Association Ambiguity [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2018, 26(11): 1 976-1 990
- [44] Stamatiou K, Casari P, Zorzi M. The Throughput of Underwater Networks: Analysis and Validation Using a Ray Tracing Simulator [J]. *IEEE Transac-*



- tions on *Wireless Communications*, 2013, 12(3): 1 108-1 117
- [45] Balkan G O, Gezici S. CRLB Based Optimal Noise Enhanced Parameter Estimation Using Quantized Observations [J]. *IEEE Signal Processing Letters*, 2010, 17(5): 477-480
- [46] Liu Jingnan, Gao Kefu. Challenges and Opportunities for M-apping and Surveying and Location Based Service in the Age of Intelligence [J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(11): 1 506-1 517 (刘经南, 高柯夫. 智能时代测绘与位置服务领域的挑战与机遇[J]. 武汉大学学报·信息科学版, 2017, 42(11): 1 506-1 517)
- [47] Zhu Jianjun, Song Yingchun, Hu Jun, et al. Challenges and Development of Data Processing Theory in the Era of Surveying and Mapping Big Data [J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(7): 1 025-1 031 (朱建军, 宋迎春, 胡俊, 等. 测绘大数据时代数据处理理论面临的挑战与发展[J]. 武汉大学学报·信息科学版, 2021, 46(7): 1 025-1 031)
- [48] Liu Jingnan, Fang Yuan, Guo Chi, et al. Research Progress in Location Big Data Analysis and Processing [J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(4): 379-385 (刘经南, 方媛, 郭迟, 等. 位置大数据的分析处理研究进展[J]. 武汉大学学报·信息科学版, 2014, 39(4): 379-385)

## An Underwater Array Localization Method Using Two-Stage Learning Model

ZHANG Yu<sup>1</sup> JIANG Peng<sup>1</sup> GUO Wenfei<sup>1</sup> ZHANG Dan<sup>2</sup> HAN Zhen<sup>1</sup>

<sup>1</sup> GNSS Research Center, Wuhan University, Wuhan 430079, China

<sup>2</sup> School of Computer Science, Wuhan University, Wuhan 430079, China

**Abstract: Objectives:** In the localization method based on underwater acoustic arrays, noise affects the localization accuracy mainly. A localization method using a two-stage learning model is proposed to minimize noise's influence on the localization results. **Methods:** Firstly, a learning model based on a multilayer convolutional neural network is built for noise reduction by training the real and imaginary features of the received signal separately. Secondly, an improved weighted delay summation beamformer group model is constructed, and the gradient descent criterion adjusts the weights of each channel to obtain the optimal relative time delay and the best angle estimation. Finally, more accurate localization information is received by geometric solving. **Results:** Simulation experimental results show that the two-stage noise reduction model has awe-inspiring noise reduction performance compared to conventional underwater acoustic array processing for angular comparisons of 30°, 100°, and 130° in a SNR (signal-to-noise ratio) environment in the range of -25 dB to 10 dB. Lake tests show the same advantage of the proposed method in terms of RMSE (root mean square error) of positioning results. **Conclusions:** The two-stage learning model has excellent robustness in coping with SNR variations, and the received signal after processing by noise reduction has higher localization accuracy after processing based on an improved time-delay and angle estimation model, which can also be applied in practical applications such as indoor acoustic localization and radio radar arrays.

**Key words:** two-stage learning model; underwater acoustic array localization; noise reduction processing; weighted time-delay summation; deep learning

**First author:** ZHANG Yu, PhD candidate, specializes in underwater data processing and communication. E-mail: zhangziju125@whu.edu.cn

**Corresponding author:** JIANG Peng, PhD, professor. E-mail: jiangp@whu.edu.cn

**Foundation support:** The National Key Research and Development Program of China(2016YFB0501800).

**引文格式:** ZHANG Yu, JIANG Peng, GUO Wenfei, et al. An Underwater Array Localization Method Using Two-Stage Learning Model[J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(12): 1889-1899. DOI: 10.13203/j.whugis20210466 (张宇, 江鹏, 郭文飞, 等. 一种利用两阶段学习模型的水下阵列定位方法[J]. 武汉大学学报·信息科学版, 2021, 46(12): 1889-1899. DOI: 10.13203/j.whugis20210466)