

基于遗传算法的声场重构测量优化方法



许 锋¹ 孙 洁^{2,3} 刘世杰^{2,3}

1 中国刑事警察学院公安信息技术与情报学院 沈阳 110035

2 中国科学院沈阳自动化研究所机器人学国家重点实验室 沈阳 110016

3 中国科学院机器人与智能制造创新研究院 沈阳 110169

摘 要 海洋声信道参数空间场能够刻画水声信号在海洋中传播的空间分布规律,对水声通信位置选取、水下目标探测及隐身等具有重要指导意义。针对应用压缩感知重构声场时水下机器人测量路径的优化问题,在结合声场特点、压缩感知和水下机器人的运动特点的基础上,提出了一种基于遗传算法的测量优化方法,以提高压缩感知方法的重构精度。首先分析了声场重构中压缩感知测量矩阵的结构,然后结合水下机器人的运动能力限制,定义了遗传算法中适用于水下机器人测量的基因表达、生成方式以及适应度函数。仿真实验中以高斯随机点的旅行商问题和梳状测量路径为对照,结果表明所提方法能够明显提高声场重构的精度,且对不同采样率及不同分布声场的重构都能够保持更高的精度。

关键词: 压缩感知; 遗传算法; 测量优化; 水下机器人; 声场重构

中图法分类号 TP249

Sampling Optimization Method for Acoustic Field Reconstruction Based on Genetic Algorithm

XU Feng¹, SUN Jie^{2,3} and LIU Shi-jie^{2,3}

1 College of Public Security Information Technology and Information, Criminal Investigation Police University of China, Shenyang 110035, China

2 State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China

3 Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, China

Abstract The spatial field of ocean acoustic channel parameters can describe the spatial distribution law of underwater acoustic signal propagation in the ocean, which has important guiding significance for underwater acoustic communication location selection, underwater target detection and stealth. For the problem of sampling trajectory optimization in the application of compressive sensing (CS) methods on the acoustic field reconstruction, a sampling optimization method based on a genetic algorithm (GA) is proposed to improve the CS reconstruction accuracy in this paper combining the characteristics of sound field, compressed sensing and the motion characteristics of underwater robot. Firstly, the structure of the CS sampling matrix is analyzed. Then, combining with the kinematic constraint of underwater vehicles, the gene expression and generation method as well as the GA fitness function are defined to support the sampling of underwater vehicles. In simulations, the traveling salesman problem (TSP)-based path from Gaussian random sampling points and the lawnmower sampling path are used for comparison. The results demonstrate that the proposed GA-based sampling method can significantly improve the reconstruction accuracy of acoustic fields. The influences of different sampling rates and different acoustic field distributions are discussed, which further illustrates the superior performance of the proposed method.

Keywords Compressive sensing, Genetic algorithm (GA), Sampling optimization, Underwater vehicle, Acoustic field reconstruction

1 引言

海洋声信道参数空间场能够刻画水声信号在海洋中传播的空间分布规律,对水声通信位置选取、水下目标探测及隐身等具有重要指导意义^[1]。

常用的场重构方法包括克里金、最优线性无偏估计等需要大量的测量数据,随着重构精度要求的提升,测量数据的需求量激增给软件和硬件都带来了很大的挑战。造成这一问题的根本原因在于传统测量方法都采用均匀采样的方式,采样率与信号带宽相关,数据量随着带宽的增加而激增^[2]。压缩

到稿日期:2020-06-28 返修日期:2020-08-25 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家科技重大专项(2017YFC0821004);公安部技术研究计划(2016JSYJC59)

This work was supported by the National Science and Technology Major Project of the Ministry of Science and Technology of China (2017YFC0821004) and Technical Research Plan of the Ministry of Public Security (2016JSYJC59).

通信作者:许锋(xufeng_ccpc@hotmail.com)

感知(Compressive Sensing, CS)理论^[3]突破了采样频率对奈奎斯特采样定律的依赖,当信号能够稀疏表示时,可以通过低于奈奎斯特采样频率的采样数据来实现精确的原始信号重构。压缩感知方法已经在高光谱图像重建^[4]、量子态估计^[5]、水声数据压缩与重构^[6]和水下目标测距^[7]等领域获得了广泛的应用。

Wang 等^[8]研究了基于压缩感知的无线传感网络中的数据采集问题,Zhang 等^[9]研究了基于概率稀疏随机矩阵的数据收集方法海洋观测型水下机器人(如无特殊说明,以下简称水下机器人),如自主水下机器人(Autonomous Underwater Vehicle, AUV)、水下滑翔机等,具有自主移动能力,能够搭载水听器对海洋环境声场进行测量^[10]。

Yan 等^[11]研究了存在热点区域的海洋环境温、盐特征场中 AUV 自适应采样方法。Liu 等^[12]研究了多水下机器人区域覆盖观测问题,通过降低区域内温,实现盐特征场不确定性重构,对水下机器人的采样路径进行优化。

在基于压缩感知的水下机器人测量方面,Chen 等^[13]以水下机器人测量能耗为代价函数,优化水下机器人的测量路径,实现了基于压缩感知方法的环境特征场重构。Hummel 等^[14]考虑了水下机器人运动学约束下的静态环境特征场压缩感知重建问题。Hover 等^[15]进一步将文献^[14]中水下机器人动力约束下的 CS 场重建问题称为运动压缩感知(Kinematic Comprehensive Sensing, KCS)问题,提出了一种贪婪算法,以感知矩阵列向量尽量正交为目的,选择空间中下一步待测量点的集合。

从上述分析可以看出,针对海洋环境温、盐场重构的水下机器人优化测量和基于压缩感知的海洋声场重构虽已有很多工作,但其未能很好地结合声场特点、压缩感知和水下机器人的运动特点。本文基于刻画水声信号能量的海洋声强场空间分布存在干涉条纹的特点,选择压缩感知作为重构方法,以提高声场的重构精度为目的进行水下机器人观测路径的优化,设计优化模型并通过遗传算法(Genetic Algorithm, GA)来求解最优测量路径。

2 问题描述

2.1 基于压缩感知的信号重建

利用压缩感知理论进行信号采样和重建可以分为 3 个步骤^[4]。

1) 目标信号的稀疏表示。 $m \times l$ 维目标信号 \mathbf{F} 写成列向量为 $\mathbf{f} \in \mathbb{R}^N$ ($N = m \times l$)。如果 \mathbf{F} 本身不稀疏但可压缩,则需要找到一个变换矩阵 $\Psi \in \mathbb{R}^{N \times N}$,使得经过 $\mathbf{x} = \Psi^{-1} \mathbf{f}$ 变换后所得到的系数 $\mathbf{x} \in \mathbb{R}^N$ 是一个 K 阶稀疏信号 ($K \ll N$),即 \mathbf{x} 中只有 K 个非零项。对于同一个目标信号 \mathbf{F} ,利用不同 Ψ 得到的 \mathbf{x} 对应的 K 越小表示重建 \mathbf{F} 需要的测量越少。对于不同的信号,其最优的变换矩阵也不相同。常用的稀疏变换有傅里叶变换(Fourier Transform, FT)、小波变换(Wavelet Transform, WT)和 Contourlet 变换(CT)等。

2) 构建测量矩阵。压缩感知通过目标原始信号与测量矩阵 $\Phi \in \mathbb{R}^{M \times N}$ 之间的内积来对目标信号进行测量,得到测量信号 $\mathbf{y} \in \mathbb{R}^M$,信号的测量过程在数学上可表示为 $\mathbf{y} = \Phi \mathbf{f} =$

$\Phi \Psi \mathbf{x}$ 。定义感知矩阵 $\mathbf{A} = \Phi \Psi$ ($\mathbf{A} \in \mathbb{R}^{M \times N}$),并且允许有测量误差 $\boldsymbol{\varepsilon} \in \mathbb{R}^M$,此时测量函数可写为 $\mathbf{y} = \mathbf{A} \mathbf{x} + \boldsymbol{\varepsilon}$ 。

3) 根据测量数据进行信号重建。建立优化问题,由测量信号得到目标信号最优解。在测量矩阵满足一定条件时,通过求解 ℓ_0 范数最优化问题来进行目标信号的精确重建^[16],即通过求解式(1)得到最优解 $\hat{\mathbf{x}}$,再由 $\hat{\mathbf{f}} = \Psi \hat{\mathbf{x}}$ 得到目标信号估计。

$$\min \|\mathbf{x}\|_0 \quad \text{s. t. } \partial \mathbf{y} = \mathbf{A} \mathbf{x} \quad (1)$$

2.2 感知矩阵设计准则

由压缩感知理论对信号的测量和重建可以看出,测量和压缩是同时进行的。当 $M \ll N$ 时,测量过程可视为一个信息压缩的过程,将 N 维的原始信号压缩为 M 维的测量信号。性能良好的测量矩阵应在不丢失目标信号有效信息的情况下,使得 M 尽可能小。要达到这样的目标,感知矩阵需要满足一定的条件,被广泛接受和应用的有 Candès 等提出的有限等距性质^[16](Restricted Isometry Property, RIP)和非相干性准则^[17]。当感知矩阵满足上述条件时,目标信号可以被精确地重建出来^[16-18]。

对于 K 阶稀疏信号 \mathbf{x} ,定义有限等距常数(Restricted Isometry Constant, RIC) $\delta \in (0, 1)$,使得对于任意 $n \leq K$ 有:

$$(1 - \delta) \|\mathbf{x}_n\|_2^2 \leq \|\mathbf{A}_n \mathbf{x}_n\|_2^2 \leq (1 + \delta) \|\mathbf{x}_n\|_2^2 \quad (2)$$

其中, $\|\cdot\|_2$ 表示 ℓ_2 范数, $\mathbf{A}_n \in \mathbb{R}^{M \times n}$ 是从矩阵 \mathbf{A} 中任意抽取 n 个列向量组成的矩阵, \mathbf{x}_n 是与 \mathbf{A}_n 对应的 \mathbf{x} 中的 n 个数。从矩阵分析的角度来理解,式(2)依据 Gramian 矩阵 $\mathbf{G} = \tilde{\mathbf{A}}_n^T \tilde{\mathbf{A}}_n$,其特征值范围为 $[1 - \delta, 1 + \delta]$,其中 $\tilde{\mathbf{A}}_n$ 是 \mathbf{A}_n 的列向量归一化之后的矩阵。换句话说, RIP 性质保证了感知矩阵 \mathbf{A} 的任意子列矩阵都是正交矩阵。

2.3 基于水下机器人测量的声场重建问题

针对海洋中某二维区域内存在的某个标量场 \mathbf{F} ,将区域离散成 $m \times l$ 个网格,则 \mathbf{F} 可表示成一个 $m \times l$ 维的矩阵,区域内空间上的点记为 \mathbf{r}_i ($i = 1, \dots, N$)。在基于水下机器人的采样场景中,采样在空间中网格点上进行,我们的目的是从稀疏的采样数据中尽可能恢复 \mathbf{F} 的分布情况。由于影响海洋声场分布的温度和盐度场在短时间内变化不大,因此我们假设在水下机器人运动时间内声场的结构不发生变化,可以利用水下机器人时间上连续的测量来对声场进行重建。

要想从稀疏观测中恢复目标信号,需要设计满足 RIP 性质的感知矩阵 \mathbf{A} 。直接构造满足式(2)的矩阵 \mathbf{A} 非常困难,因此,一般先固定变换矩阵 Ψ ,通过设计测量矩阵 Φ 使得矩阵 \mathbf{A} 满足 RIP 性质。水下机器人对声信号的测量发生在空间中的点上,测量可以通过冲击函数来表征,即有测量的地方测量矩阵中的值为 1,无测量的值为 0。假设在 M 个点上有测量,则对应的测量矩阵 Φ 的维度为 $M \times N$,对点 \mathbf{r}_j ($j = 1, \dots, N$) 的测量对应 Φ 中的一组行向量 $\boldsymbol{\phi}_i$ ($i = 1, \dots, M$),其中 $\phi_{i,j} = 1$,其余是 0。由于 $M \ll N$,因此从 Φ 的列向量 $\boldsymbol{\phi}_i$ ($i = 1, \dots, N$) 来看,共有 $N - M$ 组列向量为全 0 向量。

3 水下机器人的测量优化

对水下机器人采样路径的优化体现在对测量矩阵 Φ 的

优化上,根据水下机器人上一步的运动方向定义联合概率质量函数(Joint Probability Mass Function, JPMF) $P(\Delta\theta, L)$,其中 $\Delta\theta$ 是下一个运动周期运动方向的变化量, L 为下一运动周期内的运动距离,通过粒子群优化算法找到满足代价函数的最优参量组合。满足 RIP 性质的感知矩阵 \mathbf{A} 的列向量之间相互正交,文献[15]从这一特性入手,定义了代价函数,设计了一种贪婪算法用于找到空间内 a 个采样点,使得更新后的矩阵 \mathbf{A} 的列向量之间最接近两两正交。记第 i 时刻感知矩阵为 \mathbf{A}_i ,水下机器人所在位置为 \mathbf{r}_i ,存在下一时刻(Δt 间隔后)空间内最优采样点 \mathbf{r}_{i+1} 距离当前位置 \mathbf{r}_i 远超过水下机器人的运动能力 v_g 的情况,即 $\|\mathbf{r}_{i+1} - \mathbf{r}_i\| \gg \Delta t \cdot v_g$ 。因此,上述基于贪婪算法的测量优化方法无法给出全局最优采样点,每一步给出的结果都是当前约束下的局部最优解。

3.1 遗传算法的参数设计

遗传算法^[19]模拟了自然界中生物进化过程的全局优化搜索算法,在水下机器人领域有着广泛的应用^[20]。

3.1.1 染色体序列的定义

本文充分考虑了水下机器人运动的连续性,在基于压缩感知的全局优化问题中,定义染色体的主体包含水下机器人每个运动周期的运动方向角,在一个运动周期内水下机器人运动的方向角不变。

初始状态可以分为单台或多台水下机器人、指定或不指定水下机器人的初始位置。对于单台水下机器人指定有初始位置的情况,染色体定义为:

$$[\alpha_1, \alpha_2, \dots, \alpha_n] \quad (3)$$

其中, α_i 为第 i 个运动周期的方向角, n 为水下机器人的运动周期数。结合水下机器人观测时间需求 T_{obs} ,记水下机器人每周期的运动时间为 T_{pf} ,每周期内采样数为 N_{pf} ,则水下机器人满足测量时间需求的最小周期数为:

$$n_1 = \lceil T_{obs} / T_{pf} \rceil$$

最小采样数应满足^[18]:

$$m \geq C\mu^2(\Phi, \Psi) S \log(N) \quad (4)$$

其中, C 为正常数, $\mu(\Phi, \Psi)$ 为测量矩阵 Φ 与变换矩阵 Ψ 的相干系数^[21]。引入 λ 来获得多于最小采样量的测量,允许一定的冗余,则对应的测量周期数为:

$$n_2 = \lceil \lambda m / N_{pf} \rceil$$

最终运动周期数为:

$$n = \max\{n_1, n_2\} \quad (5)$$

对于单台水下机器人不指定初始位置的情况,在式(3)前加上初始位置 \mathbf{r}_0 ,即染色体可以定义为:

$$[\mathbf{r}_0, \alpha_1, \alpha_2, \dots, \alpha_n] \quad (6)$$

生成染色体序列时限定序列值的取值范围,方向角在笛卡尔坐标系内取值,对应地理正东方向为 0° ,正北方向为 90° 。水下机器人的初始位置应位于待测量区域内保证水下机器人安全作业的区域。对所有要进行适应度评估的染色体,都进行染色体生成质量控制,剔除不符合条件的染色体,并重新生成,重复这一过程直到所有染色体都满足条件且种群中染色体的数量满足要求。

3.1.2 适应度函数

固定变换矩阵 Ψ 对测量矩阵 Φ 进行优化的目的是:使得感知矩阵 $\mathbf{A} = \Phi\Psi$ 能够更好地满足式(2)。要判断给定的矩阵 \mathbf{A} 是否满足 RIP,则需要考查其所有子集,判断对应的 RIC 是否满足条件,其计算复杂度为 $O(2^N)$ 。实际中,种群在进化过程中的每一次迭代都要对种群中的每个个体进行判断,当 N 增大到一定值时,计算量会超过可接受的范围。

非相干性准则^[17]是有限等距性质的另一种表达形式,它保证:如果测量矩阵 Φ 和变换矩阵 Ψ 不相关,则感知矩阵 $\mathbf{A} = \Phi\Psi$ 具有良好的 RIP 特性。通过非相干性准则可以将 RIP 性质转变为可量化的数值,满足遗传算法进化过程中个体适应度的取值需求。

上述染色体序列可以还原成一条完整的水下机器人测量路径,对应一个测量矩阵 Φ 。定义测量矩阵 Φ 和变换矩阵 Ψ 之间的相干系数为不同归一化列之间的最大绝对内积,即:

$$\mu(\Phi, \Psi) = \sqrt{N} \max_{1 \leq i, j \leq N} |\langle \phi_i, \psi_j \rangle| \quad (7)$$

其中, ϕ_i ($i=1, \dots, N$) 是测量矩阵 Φ 的第 i 组列向量, ψ_j 是变换矩阵 Ψ 的第 j 组列向量。相干性系数 $\mu(\Phi, \Psi)$ 的取值范围为 $\mu(\Phi, \Psi) \in [1, \sqrt{N}]$,当 $\mu(\Phi, \Psi) = 1$ 时,二者具有最大的非相干度。将式(7)作为种群进化中个体的适应度函数, μ 值越小,个体适应度就越高。

图1给出了基于压缩感知非相干性准则的遗传算法流程图,当感知矩阵对应的相干系数满足精度要求或者遗传算法达到最大迭代次数时,输出优化测量路径,此时目标信号可以被精确地重建^[16-18]。

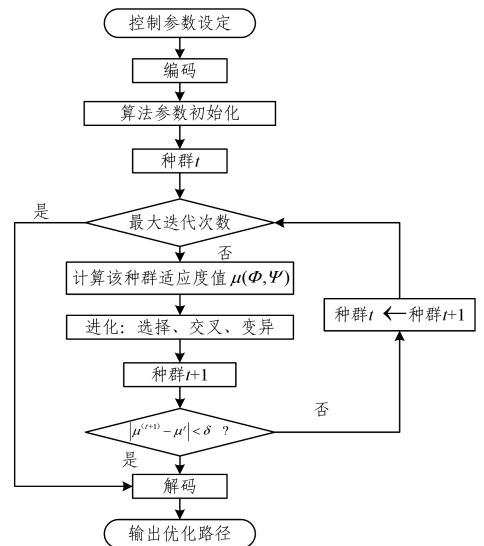


图1 测量优化算法流程图

Fig. 1 Flow chart of sampling optimization algorithm

3.2 性能评价准则

图像压缩感知问题中有两种常用于衡量重建算法性能指标^[1]:峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似度(Structural SIMilarity, SSIM)指数。PSNR估计重建的绝对误差,指待重建信号的功率最大值与使该信号失真的破坏噪声的功率之比,数学表示为:

$$PSNR=20 \times \log_{10} \left(\frac{MAX_I}{RMSE(\mathbf{F}, \mathbf{F}_{rec})} \right) \quad (8)$$

其中, MAX_I 为区域内声场的最大值, \mathbf{F}_{rec} 是重建的二维声场, $RMSE(\mathbf{F}, \mathbf{F}_{rec})$ 是原始声场和重建声场的均方根误差 RMSE (Root-Mean-Square Error), 即:

$$RMSE = \sqrt{\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N [\mathbf{F}(i, j) - \mathbf{F}_{rec}(i, j)]^2} \quad (9)$$

结构相似度是衡量两个图像之间相似程度的指标, 其定义了 3 个参数: 亮度 l (luminance)、对比度 c (contrast) 和结构 s (structure), 并通过这 3 个参数的组合来模拟人眼的感知模型, 其公式为:

$$SSIM = l(\mathbf{F}, \mathbf{F}_{rec}) \times c(\mathbf{F}, \mathbf{F}_{rec}) \times s(\mathbf{F}, \mathbf{F}_{rec}) \quad (10)$$

3 个参数的表达式为:

$$l(\mathbf{F}, \mathbf{F}_{rec}) = \frac{2\mu_F \mu_{F_{rec}} + c_1}{\mu_F^2 + \mu_{F_{rec}}^2 + c_1}$$

$$c(\mathbf{F}, \mathbf{F}_{rec}) = \frac{2\sigma_F \sigma_{F_{rec}} + c_2}{\sigma_F^2 + \sigma_{F_{rec}}^2 + c_2}$$

$$s(\mathbf{F}, \mathbf{F}_{rec}) = \frac{\sigma_{F, F_{rec}} + c_3}{\sigma_F \sigma_{F_{rec}} + c_3}$$

其中, μ_F 和 $\mu_{F_{rec}}$ 分别是 \mathbf{F} 和 \mathbf{F}_{rec} 的均值, σ_F^2 和 $\sigma_{F_{rec}}^2$ 分别是 \mathbf{F} 和 \mathbf{F}_{rec} 的方差, $\sigma_{F, F_{rec}}$ 为 \mathbf{F} 和 \mathbf{F}_{rec} 的协方差。 $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$ 和 $c_3 = \frac{C_2}{2}$ 是调节因子, L 是图像像素值的动态范围。

4 仿真实验

4.1 实验对照组

为了验证本文方法的性能, 采用两种观测方式作为对照组: 1) 随机生成测量矩阵, 形成随机测量点, 再将水下机器人对随机点的测量转化为 TSP 问题, 通过求解 TSP 问题得到水下机器人的测量路径, 该方法称为运动受限的随机测量; 2) 采用水下机器人常用的梳状搜索法生成水下机器人的测量路径。

4.1.1 运动受限的随机测量

高斯或者伯努利随机矩阵几乎与任何固定的稀疏基都不相关, 因此当测量矩阵 Φ 是一个高斯或者伯努利矩阵时, 感知矩阵能够很大概率地满足 RIP 性质。实际中通常直接将 Φ 取为随机矩阵来对图像进行分布式测量。本文选择 Φ 为高斯随机矩阵, 即 Φ 的矩阵元素 $\phi_{i,j}$ 均为独立同分布的正态随机变量, 满足:

$$\phi_{i,j} \sim N(0, \frac{1}{M}) \quad (11)$$

结合水下机器人的运动限制, 首先根据式(11)从实验区域中生成 λm 个随机测量点, 水下机器人对这些点的测量路径通过求解 TSP 或多人旅行商问题(MTSP)来得到。这里的优化问题考虑最短路径 TSP, 即确定这些测量点之后, 由水下机器人以最短行驶路径来完成测量, 后续实验结果中称该路径为高斯 TSP 路径。

4.1.2 梳状搜索

梳状搜索是水下机器人常用的一种测量方式^[21-22], 通过在不同断面上往复运动, 来执行对整个区域的覆盖搜索。本文采用静态的梳状搜索方式, 即所有的测量断面在区域内均

匀分布, 如图 2 所示。后续实验结果中称该路径为梳状路径。




图 2 梳状路径示意图

Fig. 2 Illustration of lawnmower trajectory

为与所提方法进行比较, 需要对梳状搜索路径与测量区域的相对位置参数 l , l_b 和 d_b 进行计算, 使得水下机器人完成整条路径的测量时间等于观测时间需求 T_{obs} 。

4.2 实验设定

实验数据由 HYCOM (HYbrid Coordinate Ocean Model) 海洋模式提供的温、盐数据生成。根据声速分布, 由 Bellhop 3D 模型生成区域内声强场分布图。将声强场分布作为实验的目标场, 选取三维声强场数据的二维切面作为研究对象。由于声信号近似以柱状/球形传播, 经过 Bellhop 模型计算并取二维图像后, 图 3 给出了研究区域内声源为 170 dB 时声强场的分布, 声源位置 (即中心位置) 坐标为 (21°N, 97°W), TL 分布总体上呈现为圆形, 圆以外区域没有数据。




图 3 声强场分布图

Fig. 3 Acoustic intensity field distribution

为验证所提方法的优越性, 并检验方法在更广泛的应用场景中的性能, 仿真实验将从以下几个方面展开: 1) 在同等采样率限定下, 执行 3 种方法产生测量路径, 衡量 3 种测量路径的两项重构评价指标; 2) 为验证所提方法在不同采样率下的性能, 衡量 3 种方法生成路径的两项重构指标; 3) 在圆形区域内随机选取子区域, 验证所提方法在具有不同分布特征的场重构中的性能。

4.3 实验结果

在重构实验中, 选择圆形实验区域内一片面积约为 $50 \times 50 \text{ km}^2$ 的矩形子区域作为重构区域, 声场重构时选取的网格分辨率设为 512×512 。图 4(a) — 图 4(c) 给出了 3 种方法下的测量路径, 采样率都约为 60%。仿真中设定水下机器人的速度为 0.25 m/s, 但也可以使用速度更快的水下机器人。相同的航行距离时, 速度更快所需的时间就更短, 因此水下机器人的速度对重构效果无影响。图 4(d) — 图 4(f) 给出了对应的重构结果。表 1 列出了 3 种方法下两项重构评价指标的数值, 可以看出基于本文提出的 GA 路径的重构场对应的 PSNR 和 SSIM 指标明显优于梳状路径, 也优于高斯 TSP 路径。

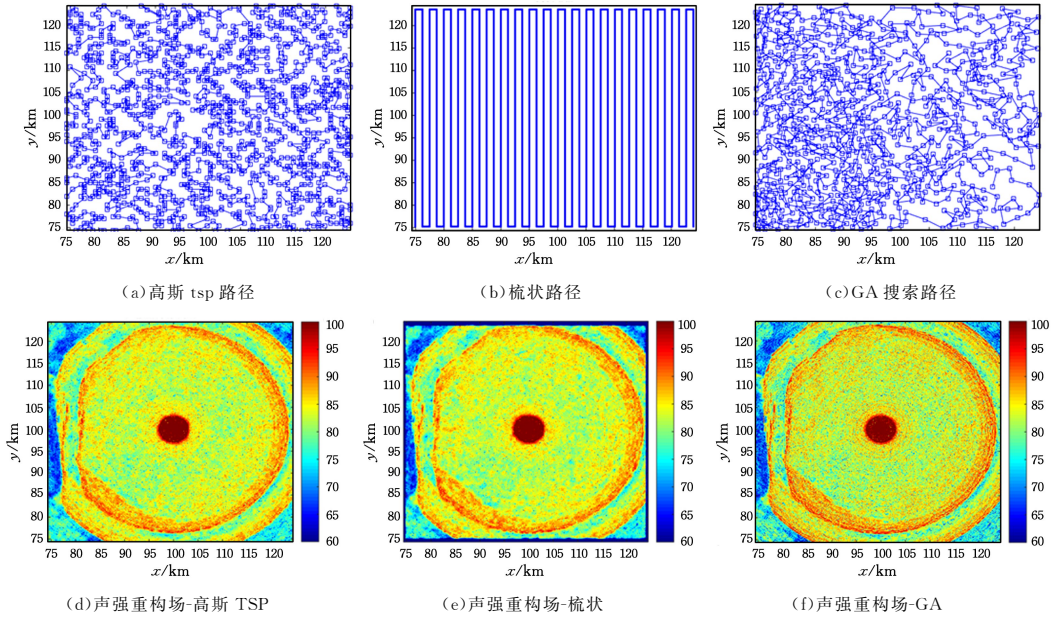


图 4 3 种方法下的测量路径图和声场重构图

Fig. 4 Sampling trajectories and TL reconstruction fields under three methods

图 5 中蓝色曲线为多次独立实验的均值,红色曲线为相应的标准差。为更清楚地显示标准差结果,图 6 给出了标准差的变化曲线。

表 1 3 种方法的重构性能

Table 1 Reconstruction performance of three methods

	PSNR /dB	SSIM
高斯 TSP	39.1382	0.9107
Lawnmower	25.9535	0.8544
GA	39.5116	0.9342




图 5 3 种方法重构性能指标随采样率变化的曲线(电子版为彩色)

Fig. 5 Changing curves of reconstruction performance metrics over sampling rates under three methods




图 6 3 种方法重构性能指标的标准差随采样率变化的曲线

Fig. 6 Changing curves of standard error of reconstruction performance metrics over sampling rates under three methods

从 PSNR 结果中可以看出,基于 GA 的方法在相同的采样率下,PSNR 值要大于其他两种方法,表明基于 GA 的方法能够指导水下机器人更有目的地进行测量。基于 GA 的方法的 PSNR 标准差要高于其他两种方法,表明基于 GA 的方法所得到结果的不确定性相对较高,但从图 5(a)可以看出,较高的不确定性并未影响算法性能的稳定性。从 SSIM 结果可以看出,基于 GA 的方法能够更快地趋近最优结果,3 种方法下 SSIM 值的标准差相当,都在 $10^{-4} \sim 10^{-3}$ 量级。

图 7 给出了采样率为 50% 的情况下,10 个不同子区域的重构情况。所选子区域与图 4 中的声强重构场面积相同,约为 $50 \times 50 \text{ km}^2$,重构网格分辨率为 512×512 。子区域在圆形实验区域内随机选取,为保证有效重构,子区域严格位于实验区域内部,即子区域不包含圆形以外的任何点。为减弱随机性的影响,对于每一个子区域,每种方法独立运行多次,取 PSNR 和 SSIM 值的均值和标准差绘制于图 7 中。




图 7 针对不同子区域重构时,3 种方法重构性能指标的变化曲线

Fig. 7 Changing curves of reconstruction performance metrics for different sub-area under three methods

从结果可以看出,基于 GA 的方法在 PSNR 和 SSIM 两项指标上均高于高斯 TSP 路径和梳状路径。3 种方法在不同子区域的重构中两项指标均较为平稳,单区域重构时多次独立实验的 PSNR 和 SSIM 值的标准差也表现平稳。图 7 所示

的实验结果表明,基于 GA 的方法在区域内特征分布场的空间结构发生变化时性能不受影响,能够保持稳定的优势性能。

结束语 针对压缩感知在声场重构中的应用,本文研究了基于遗传算法的测量优化方法。仿真实验中采用了两种代表性的测量方式作为对照组,并设计了多种实验场景,验证了所提方法的有效性和稳定性。通过本文的分析和仿真实验结果,可以得出以下结论:

1)相比另外两种测量方式,本文提出的基于 GA 的测量方法可以有效提高声场重构精度;

2)本文方法的优势在不同采样率的声场重构中能够得到保持,虽然 PSNR 的方差高于其他两种方法,但不影响方法的总体优势;

3)本文方法的优势不依赖于特定的声场分布,在不同的子区域重构中,其 PSNR 和 SSIM 均高于其他两种方法。

参 考 文 献

- [1] SUN J, YU J, ZHANG A, et al. Underwater acoustic intensity field reconstruction by kriged compressive sensing[C]// Proceedings of the Thirteenth ACM International Conference on Underwater Networks & Systems. ACM, 2018-Shenzhen: 1-5.
- [2] CAO H. Study on Compressed sensing observation method of underwater target active acoustic signal[D]. Hangzhou: Hangzhou Dianzi University, 2019.
- [3] CANDÈS E J, ROMBERG J, TAO T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information[J]. IEEE Transactions on Information Theory, 2006, 52(2): 489-509.
- [4] LIU H Y. Research on Hyperspectral image reconstruction and Super-Resolution imaging technique based on compressive sensing[D]. Xi'an: Xidian University, 2014.
- [5] CONG S, ZHANG J J. Compressive sensing theory, optimization algorithm and application in system state reconstruction[J]. Information and Control, 2017, 46(3): 267-274.
- [6] LI P, YANG Y X. Compressed sensing based acoustic data compression and reconstruction technology[J]. Technical Acoustics, 2014, 33(1): 14-20.
- [7] LI J, LIN Q H, YANG X T, et al. Method of underwater target passive ranging based on compressed sensing[J]. Information and Control, 2019, 48(1): 9-15.
- [8] WANG Q, ZHANG N W, ZHANG J C, et al. Compressed sensing for data collection in wireless sensor network[J]. Chinese Journal of Sensors and Actuators, 2014, 27(11): 1562-1567.
- [9] ZHANG B, LIU Y L, WANG K, et al. Compressive data gathering method based on probabilistic sparse random matrices[J]. Journal of Electronics & Information Technology, 2013, 36(4): 834-839.
- [10] BINGHAM B, KRAUS N, HOWE B, et al. Passive and active acoustics using an autonomous wave glider[J]. Journal of field robotics, 2012, 29(6): 911-923.
- [11] YAN S X, LI Y P, FENG X S. An AUV Adaptive sampling method based on gaussian process regression [J]. ROBOT, 2019, 41(2): 232-241.
- [12] LIU S, SUN J, YU J, et al. Sampling optimization for networked underwater gliders[C]// OCEANS 2016-Shanghai. IEEE, 2016: 1-4.
- [13] CHEN B, PANDEY P, POMPILI D. A distributed adaptive sampling solving using autonomous underwater vehicles[C]// Proceedings of the Seventh ACM International Conference on Underwater Networks and Systems. ACM, 2012: 29.
- [14] HUMMEL R, PODURI S, HOVER F, et al. Mission design for compressive sensing with mobile robots[C]// 2011 IEEE International Conference on Robotics and Automation. IEEE, 2011: 2362-2367.
- [15] HOVER F S, HUMMEL R, MITRA U, et al. One-step-ahead kinematic compressive sensing[C]// 2011 IEEE GLOBECOM Workshops (GC Wkshps). IEEE, 2011: 1314-1319.
- [16] CANDÈS E J. The restricted isometry property and its implications for compressed sensing [J]. Comptes rendus mathématique, 2008, 346(9/10): 589-592.
- [17] CANDÈS E J, ROMBERG J K, TAO T. Stable signal recovery from incomplete and inaccurate measurements[J]. Communications on Pure and Applied Mathematics: A Journal Issued by the Courant Institute of Mathematical Sciences, 2006, 59(8): 1207-1223.
- [18] CANDÈS E, ROMBERG J. Sparsity and incoherence in compressive sampling[J]. Inverse problems, 2007, 23(3): 969-985.
- [19] MIAO Z H, SUN X D, SHAO C. An Adaptive Genetic Algorithm with Parallel Mutation and Its Performance Evaluation [J]. Information and control, 2016, 45(2): 142-150.
- [20] FROLOV S, GARAU B, & BELLINGHAM J. Can we do better than the grid survey: Optimal synoptic surveys in presence of variable uncertainty and decorrelation scales[J]. Journal of Geophysical Research: Oceans, 2014, 119(8): 5071-5090.
- [21] CANDÈS E J, WAKIN M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [22] MILLER P A, FARRELL J A, ZHAO Y, et al. Autonomous underwater vehicle navigation[J]. IEEE Journal of Oceanic Engineering, 2010, 35(3): 663-678.



XU Feng, born in 1977, Ph.D, associate professor. His main research interests include robot, virtual reality and audio-visual data.