DOI: 10.13382/j.jemi.B2306678

基于动态贝叶斯 LS-SVM 的水下节点移动预测定位算法*

彭 铎 曹 坚 黎亚亚
(兰州理工大学计算机与通信学院 兰州 730050)

摘 要:针对水下无线传感器网络环境的复杂性和节点的动态性所导致的节点定位精度低的问题,提出了一种基于动态贝叶斯 LS-SVM 的水下无线传感器网络节点移动预测定位算法;该算法以信标节点到通信半径内所有信标节点的距离和跳数矩阵作为训练集;利用贝叶斯证据框架构建贝叶斯 LS-SVM 模型,将未知节点与信标节点之间的跳数向量作为测试集;将测试集代入到训练好的贝叶斯 LS-SVM 模型中来确定节点之间的距离,进而建立节点与信标节点距离矩阵的方程并利用最大似然估计法对未知节点坐标进行估算;最后,通过循环迭代的方式对所有未知节点进行定位的同时使用自适应增减算法动态调整模型参数和预测模型,以适应数据的动态变化;实验结果表明,该算法相同的节点密度下相较于 SLMP 算法、RTLC 算法、NDSMP 算法以及 MPL 算法的平均定位误差分别降低了 24.77%、22.25%、3.1%、6.5%,有效地实现了水下未知节点的动态定位。

关键词: 水下无线传感器网络;贝叶斯证据框架;自适应增减算法;移动预测;定位算法
中图分类号: TN92 **文献标识码**: A **国家标准学科分类代码**: 510.5015

Underwater node movement prediction and positioning algorithm based on dynamic bayes LS-SVM

Peng Duo Cao Jian Li Yaya
(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In order to solve the problem of low node positioning accuracy caused by complexity of underwater wireless sensor network environment and node dynamics, a node movement prediction and positioning algorithm based on dynamic Bayes LS-SVM was proposed in this paper. In this algorithm, the distance and hop matrix from the beacon node to all beacon nodes within the communication radius are used as the training set, and the normalization process is carried out. The Bayesian LS-SVM model was constructed using Bayesian evidence framework, and the hop number vector between the unknown node and the beacon node was taken as the test set to determine the distance between the node and the beacon node. Then the equation of the distance matrix between the node and the beacon node was established and the maximum likelihood estimation method was used to estimate the coordinates of the unknown node. Finally, all unknown nodes were located by iterative method, and the adaptive increment and subtraction algorithm was used to dynamically adjust the model parameters and prediction model to adapt to the dynamic changes of data. The experimental results show that the average positioning error of the algorithm is reduced by 24.77%, 22.25%, 3.1%, and 6.5% compared with the SLMP algorithm, RTLC algorithm, NDSMP algorithm, and MPL algorithm under the same node density, effectively realizing underwater positioning. Dynamic positioning of unknown nodes.

Keywords: UWSN; Bayesian evidence framework; adaptive increment and subtraction algorithm; mobile prediction; location algorithm

0 引 言

长期以来,水下无线传感器网络[1](underwater wireless sensor networks, UWSN)在国家层面一直受到重视,特别是在海洋资源探测[2]、海洋环境治理[3]、自然灾害预防和军事防御[4]等领域,使得这些问题备受国家关注。随着水下无线传感器网络技术的不断发展,水下节

收稿日期: 2023-06-30 Received Date: 2023-06-30
*基金项目:国家自然科学基金(61663024,62061024)、甘肃省高校创新基金(2020A-021)项目资助

点定位问题已成为一个重要的研究方向。而在水下环境中,由于水的折射率和衰减以及复杂的海底地形,节点之间的通信信号受到很大的影响,导致节点定位具有挑战性[5]。传统的水下节点定位方法主要基于测距技术或信号强度指示技术[6](received signal strength indicator, RSSI),但这些方法在实际应用中存在许多限制和不足之处。为了进一步提高我国海洋物理环境的精细观测水平,实现"智能海洋"[7],移动节点已成为国家海洋经济发展的重要议题,因此如何提高移动节点[8]的定位精度成为水下无线传感器网络研究的重点之一。

面对这些研究问题,许多研究人员开发了不同的算法和解决方案。例如,Zhang 等[9]提出了一种基于 UWSNs 中节点预测的节点定位算法。他们采用了分层优化策略和节点位置预测来设计定位算法,以降低通信成本并提高节点的定位精度;庞琬佳[10]提出了一种基于 RSS 的水下节点激光定位方法。该方法利用节点发射激光束,信标节点装有光强接收器,通过机器学习中的光强序列值作为特征训练值对节点进行定位,从而提高了节点的定位精度;晋泽炎等[11]提出了一种基于洋流模型的节点实时定位算法。他们利用洋流模型消除流动性对节点定位的影响,提高了定位的准确性,并保证了信息的时效性;杨振诚[12]提出了一种基于改进的回溯搜索优化算法的水下移动节点定位算法。该算法在未知节点定位阶段利用协作机制和水下物体群动性预测节点的位置信息,从而在减少算法运行时间的同时提高了网络的定位精度;刘丽萍等[13]提出了一种基于节点运动模型的预测定位算法,使用高斯径向基函数构造节点的运动模型来实现高性能节点定位;谢宇芳等[14]提出了一种基于最大似然算法的水下节点定位方法,通过将定位周期内不同时刻的测量值转换为定位周期初始时刻的测量值,利用最大似然算法实现 UWSN 的移动节点定位。尽管这些算法在一定程度上提高了水下节点的定位精度,但仍存在一些不足,使得在复杂的水下环境中难以获得理想的定位精度。因此,需要针对水下环境的特点和需求,开发和构建新的节点运动模型,以进一步提高水下节点的定位精度和性能。

根据以上研究,为了进一步提高水下传感器网络节点的定位精度,本文提出了一种基于动态贝叶斯 LS-SVM 的水下节点移动预测定位算法(underwater node movement prediction and positioning algorithm based on dynamic Bayesian LS-SVM, BLSM)。该算法利用潮汐模型[15]来描述水下传感器节点的运动模型,结合了动态贝叶斯算法[16]和 LS-SVM 算法的优点,构建贝叶斯 LS-SVM 模型得到未知节点的距离矩阵,通过最大似然估计法建立相应矩阵方程来解决未知节点的位置估计问题。最后,将估计到的节点坐标数据代入到节点的运动模型公式中,得到节点当前的运动速度,进而得到节点的三维位置。通过仿真实验的验证,该方法降低了定位通信消耗,提高了定位覆盖率以及定位精度。

1　网络模型

1.1　水下无线传感器网络模型

如图 1 所示,该水下三维传感器网络模型由 3 种类型的节点组成,包括浮标节点、未知节点和信标节点[17]。在这个网络模型中,沿海基站[18]承担着收集、处理、整合和传输网络中的数据信息的任务,并负责节点的位置计算。浮标节点是位于水面上的节点,它们可以通过卫星进行定位,从而提供准确的位置信息给传感器节点。浮标节点在网络中起到辅助定位的作用,帮助其他节点确定自身的位置;未知节点是水下传感器网络中的普通节点,它们不具备自我定位的能力,只能进行信息存储和转发;信标节点是网络中的特殊节点,其位置已经事先确定。这些节点的位置信息被用作参考,用于节点定位和位置计算。

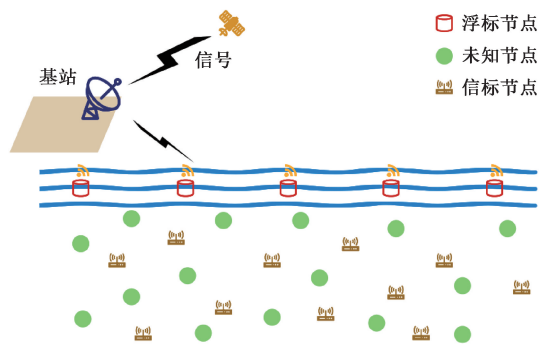

图 1　水下无线传感器网络节点分布图

Fig. 1　Node distribution of underwater wireless sensor network

1.2　水下传感器节点运动模型

在海洋学中,海洋被视为一种分层的旋转流体[19],其水流运动可以分为水平方向和垂直方向两个方面。水平方向的水流运动涉及近海和远洋水流的运动规律,以及海岸流、边界流和洋流等现象。这些水流运动通常由地球自转、风力、地形和海水密度等因素共同驱动,并且具有一定的时空尺度。垂直方向的水流运动包括热盐环流、海底边界层和深海水文循环等现象。为模拟沿海的潮汐运动模型,潮汐模型由一系列时间和空间基函数组成,包括潮汐分量的频率。一维数学表达式为:

$$\xi(x,t)=\xi_0(x)+\sum_{i=1}^{N}\left[g_i(x)\cos\omega_i t\right]+\sum_{i=1}^{N}\left[h_i(x)\sin\omega_i t\right] \tag{1}$$

式中:x 表示潮流的位置,ξ 是 x 位置潮汐分量的潮汐速

度(通常南北方向的流速为 v,东西方向的流速是 u),N 是潮汐分量的数量($1 \leqslant i \leqslant N$)。此外,$\omega$ 是潮汐的频率,$\cos\omega_i t$ 和 $\sin\omega_i t$ 是潮汐成分量的时间基函数,$\xi_0(x)$ 是观察到的平均流速。

如图2所示,水下传感器节点受浮力、洋流和拉力的共同作用下,使电缆始终保持平直状态。节点以锚点为中心,电缆长度为半径在半球上运动,节点的运动模型在一定的时间和空间范围内保持一致性。

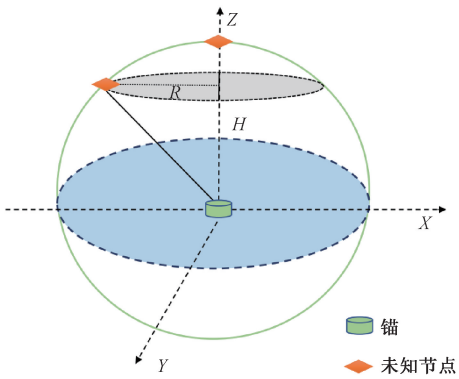

图2　水下传感器节点的运动范围

Fig. 2　Motion range of underwater sensor nodes

图3为水下传感器节点 P 在水中的受力图。其静止状态如图3(a)所示,此时水下传感器节点 P 仅受到向下的重力 G、电缆的张力 F_l 以及向上的浮力 F_b。如图3(b)所示,其中 F_a 为水流对节点的冲击力。从图中可以看出,水下传感器节点的运动主要受洋流的影响,但电缆张力将节点的运动限制在有限的范围内。

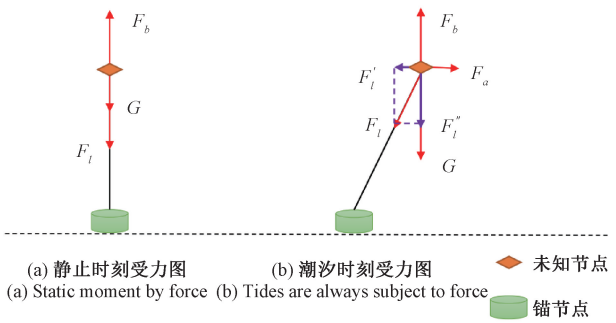

图3　传感器节点受力分析示意图

Fig. 3　Schematic diagram of stress analysis of sensor nodes

1.3　运动模型的应用

在水下传感器节点定位算法中,潮汐模型模拟了水下潮汐现象,其中每个节点的位置会随时间变化而变化。通过考虑节点的速度、加速度和方向等运动参数,可以预测节点在未来时间点的位置进而减小由于动态环境引起的定位误差。节点的运动信息可以用于校正定位,从而可以提高节点的定位精度。而通过对水下传感器节点进行受力分析,由牛顿第二定律可知张力、加速度以及速度之间的关系,从而求得未来时间 t 时刻的速度,将其代入到潮汐运动模型中即可得到 t 时刻未知节点 P 的二维位置坐标。

因此,设节点重为 m,水的密度为 ρ,F'_l 和 F''_l 分别是张力 F_l 在水平方向和垂直方向的分量,计算公式如下:

$$F'_l = \sqrt{F_l^2 - (F_b - G)^2} \tag{2}$$

$$F''_l = F_b - G \tag{3}$$

其中,浮力 $F_b = \rho g V$,重力 $F_l = mg$。

在水下传感器节点的运动模型中,可以用拉格朗日方法描述水下传感器节点的运动变量。

$$\vec{\boldsymbol{f}} = \vec{\boldsymbol{f}}(x,y,t) \tag{4}$$

因此,由牛顿第二定律可知,张力在水平方向的分量 F'_l 以及速度和加速度之间的关系如下所示:

$$F_l \Rightarrow \begin{cases} F'_l(x,y,t) \\ F''_l(x,y,t) \end{cases} \tag{5}$$

$$a' = a'(x,y,t) = \frac{F'_l(x,y,t)}{m} \tag{6}$$

$$a'' = a''(x,y,t) = \frac{F''_l(x,y,t)}{m} \tag{7}$$

$$v'(x,y,t) = \int \vec{\boldsymbol{a}'}(x,y,t)\,\mathrm{d}t = \int \frac{F'_l(x,y,t)}{m}\mathrm{d}t \tag{8}$$

$$v''(x,y,t) = \int \vec{\boldsymbol{a}''}(x,y,t)\,\mathrm{d}t = \int \frac{F''_l(x,y,t)}{m}\mathrm{d}t \tag{9}$$

其中,(x,y,t) 是水下二维坐标;a' 为受张力 F'_l 作用在时间 a'' 时刻的加速度;a'' 为受张力 F''_l 作用在时间 v' 时刻的加速度;v' 为二维平面中受张力 F'_l 作用在时间 v'' 时刻的速度;v'' 为二维平面中受张力 F''_l 作用在时间 t 时刻的速度。

在潮汐运动模型中,由潮汐的时间和空间基础上上述公式可表示为:

$$f(\boldsymbol{\tau},t) = \int a'(\boldsymbol{\tau},t)\,\mathrm{d}t = \int \frac{F'_l(\boldsymbol{\tau},t)}{m}\mathrm{d}t \tag{10}$$

此时,式(10)中的 $\boldsymbol{\tau}$ 为二维坐标;f 为二维坐标 $\boldsymbol{\tau}$ 处的速度。基于该潮汐运动模型,则节点的运动模型为分力 F'_l 产生的速度和潮汐产生的速度共同作用的结果。

$$\zeta_n(\boldsymbol{\tau},t) = \zeta(\boldsymbol{\tau},t) + \zeta'(\boldsymbol{\tau},t) \tag{11}$$

$$\zeta_{\mathrm{Node}}(\boldsymbol{\tau},t) = \zeta_0(\boldsymbol{\tau}) + \sum_{i=1}^{N}[g_i(\boldsymbol{\tau})\cos\omega_i t] + \sum_{i=1}^{N}[h_i(\boldsymbol{\tau})\sin\omega_i t] + \int \frac{F'_l(\boldsymbol{\tau},t)}{m}\mathrm{d}t \tag{12}$$

$$\zeta_0(\boldsymbol{\tau}) = \sum_{j=1}^{M} k_{1,j}\phi_j(\boldsymbol{\tau}) \tag{13}$$

$$g_i(\boldsymbol{\tau}) = \sum_{j=1}^{M} k_{2,j}\phi_j(\boldsymbol{\tau}) \tag{14}$$

$$h_i(\tau) = \sum_{j=1}^{M} k_{2i+1,j}\phi_j(\tau) \tag{15}$$

$$\phi_j(\tau) = \exp\left(\frac{-\parallel \tau - c_i \parallel^2}{2\sigma^2}\right) \tag{16}$$

式中：M 为径向基函数的数量；N 是潮汐的数量；$k_{i,j}$ 是高斯径向基函数的系数；$\zeta_0(\tau)$，$g_i(\tau)$，$h_i(\tau)$ 是与节点位置有关的方程；c_i 是第 1 个高斯径向基函数的中心；σ 是径向基函数的宽度。

2　算法思想

2.1　最小二乘支持向量机

最小二乘支持向量机[20]（least squares support vector machine，LS-SVM）是一种支持向量机的变形，它采用最小二乘法（least squares）作为损失函数，通过求解一个线性或非线性方程组来得到分类器。因此，函数的拟合问题可表示为如下的优化问题：

$$\min J(\omega, e) = \min\left(\frac{\mu}{2}\parallel \omega \parallel^2 + \frac{\zeta}{2}\sum_{i=1}^{N} e_i^2\right) \tag{17}$$

$$\text{s.t.}\quad y_i = \langle \omega, \varphi(x_i)\rangle + b + e_i \quad i = 1,2,\cdots,N \qquad \gamma > 0 \tag{18}$$

式中：μ 和 ζ 是超参数；$\varphi(x_i)$ 为非线性映射函数；e_i 为回归误差；ω 为权重；b 为偏差项。

根据式（17）、（18）将模型变化到对偶空间中，得到相应的拉格朗日函数：

$$L(\omega, b, e, \alpha) = \frac{\mu}{2}\omega + \frac{\zeta}{2}\sum_{i=1}^{N} e_i^2 - \sum_{i=1}^{N}\alpha_i\langle \omega, \varphi(x_i)\rangle + b + e_i - y_i \tag{19}$$

由 KKT（Karush-Kuhn-Tucher）最优条件对式（19）求偏导，由此可得式（20）：

$$\begin{cases} \dfrac{\partial L}{\partial \omega} = 0 \Rightarrow \omega = \sum_{i=1}^{N}\alpha_i\varphi(x_i) \\ \dfrac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^{N}\alpha_i = 0 \\ \dfrac{\partial L}{\partial e_i} = 0 \Rightarrow \alpha = \sigma e_i \\ \dfrac{\partial L}{\partial \alpha_i} = 0 \Rightarrow \langle \omega, \varphi(x_i)\rangle + b + e_i - y_i = 0 \end{cases} \tag{20}$$

将式（20）代入到式（19）中，消去 e_i 和 ω 可得矩阵等式如式（21）所示：

$$\begin{bmatrix} 0 & 1^{\mathrm{T}} \\ 1 & \boldsymbol{K} + \gamma^{-1}\boldsymbol{E} \end{bmatrix}\begin{bmatrix} \boldsymbol{b} \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \boldsymbol{y} \end{bmatrix} \tag{21}$$

其中，$\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \cdots, \alpha_N]^{\mathrm{T}}$；$\boldsymbol{y} == [y_1, y_2, \cdots, y_N]^{\mathrm{T}}$；$\boldsymbol{K}$ 为核矩阵；$\boldsymbol{E}$ 为单位矩阵。

通过求解式（21）得出相应的判别函数为：

$$f(x) = \operatorname{sgn}\left[\sum_{i=1}^{N}\alpha_i K(x, x_i) + b\right] \tag{22}$$

式中：$K(x, x_i) = \exp\left\{-\dfrac{\parallel x - x_i \parallel^2}{\sigma^2}\right\}$ 为满足 Mercer 定理的径向基函数，其中，正则化参数 γ 和核函数系数 σ 通过贝叶斯证据框架选择。

2.2　基于贝叶斯证据框架的 LS-SVM

贝叶斯证据框架[21]是一种用于模型选择的方法，它基于贝叶斯定理和贝叶斯假设，通过计算数据集在给定模型下的概率来确定最优的模型。在本文中，贝叶斯证据框架被应用于 LS-SVM 模型参数的优选，以减少建模时间。贝叶斯证据框架的核心思想[22]是利用已有的先验知识和观测数据来更新对未知量的概率分布。在贝叶斯证据框架中，使用贝叶斯公式来计算后验概率分布，即给定观测数据后未知量的概率分布。通过比较不同模型或不同参数取值的概率，选择概率最大的模型或参数作为最优解或进行预测。

在本文中，贝叶斯证据框架用于优选 LS-SVM 模型的参数和核函数系数。通过计算不同参数和核函数组合下数据集的后验概率分布[23]，可以确定最优的参数和核函数组合，从而得到更准确的节点定位结果。这种方法可以减少建模时间，同时提高模型的预测性能。

第 1 层推断：给定节点数据的坐标点 $D = \{x_i, y_i\}$，$(i = 1,2,\cdots,k)$ 和 LS-SVM 模型 H 中的正则化参数 ω，则根据贝叶斯准则，可求得模型参数 ω 和 b 如式（23）所示：

$$p(\boldsymbol{w}, b \mid D, \lg\mu, \lg\zeta, H) = \frac{p(\boldsymbol{w}, b \mid \lg\mu, \lg\zeta, H)\,p(D \mid \boldsymbol{w}, b, \lg\mu, \lg\zeta, H)}{p(D \mid \lg\mu, \lg\zeta, H)} \tag{23}$$

式中：$p(\boldsymbol{w}, b \mid \lg\mu, \lg\zeta, H)$ 为先验概率；$p(D \mid \lg\mu, \lg\zeta, H)$ 为标准化的常数，即对所有的 $\boldsymbol{\omega}$ 和 b 的积分值为 1；$p(D \mid \boldsymbol{w}, b, \lg\mu, \lg\zeta, H)$ 为似然估计。

第 2 层推断：应用贝叶斯定理可由数据 D 推导出正则化参数 $\gamma = \zeta/\mu$，且假设超参数满足均值分布，则可得式（24）如下：

$$p(\lg\mu, \lg\zeta \mid D, H) = \frac{p(\lg\mu, \lg\zeta \mid H)\,p(D \mid \lg\mu, \lg\zeta, H)}{p(D \mid H)} \tag{24}$$

第 3 层推断：根据贝叶斯准备，选择不同的核函数来获取不同模型的后验概率为：

$$p(H_j \mid D) = \frac{p(D \mid H_j)\,p(H_j)}{p(D)} \propto p(D \mid H_j) \tag{25}$$

2.3　自适应增减算法

在水下环境中，节点的移动性会导致新的节点信息

产生,为了动态跟踪和提高未知节点的定位精度,在预测模型中产生新的数据时,需要将该新信息加入到节点的预测模型,并适当调整模型参数。为了实现这一目标,本文采用了自适应增减算法[24]。自适应增减算法根据节点定位的准确性需求,通过动态增加和减少数据样本来平衡类别分布,以改善模型性能。具体而言,动态贝叶斯 LS-SVM 的动态训练和学习过程包括数据样本的增加和减少两个关键步骤,以始终保持所需的预测精度。

在训练阶段,当发现节点的定位精度下降或需要适应新的节点移动模式时,自适应增减算法可以动态增加训练数据样本。通过收集新的节点位置数据并将其加入训练集,可以更新和调整模型的参数和核函数系数,以提高预测模型的准确性。相反,在测试阶段,如果节点的定位精度已经满足要求或发现一些训练数据对模型的贡献较小,自适应增减算法可以动态减少数据样本。通过剔除一些不必要的训练数据,可以简化模型的复杂度,并提高算法的效率和运行速度。

通过自适应增减算法的动态训练和学习过程,动态贝叶斯 LS-SVM 能够根据节点定位的需求和环境变化,灵活地调整模型的参数和数据样本,以保持预测精度并适应节点移动的变化。这种自适应性能够提高算法的适用性和鲁棒性,从而提高水下节点移动预测的性能和效果。

3 动态贝叶斯 LS-SVM 水下节点定位算法

基于动态贝叶斯 LS-SVM 的水下节点定位算法包括主要的训练阶段和测试阶段,其算法预测模型[25]的输入和输出之间呈现非线性关系,LS-SVM 被用于实现该模型。该算法的关键点在于使用 LS-SVM 实现输入和输出之间的非线性关系,通过贝叶斯证据框架推导出模型的参数和核函数系数,从而提高节点定位的准确性。同时,通过增加样本、减少样本和反馈的超参数,实现贝叶斯 LS-SVM 的节点定位预测,以提高算法的性能和适应性。

3.1 训练阶段

在水下无线传感器网络中,信标节点可以通过与水面上的信标节点进行通信,从而获得自身的位置。但节点由于受水流的影响,所以锚节点在定位自身的同时还承担了预测节点移动模式的功能。假设水中有 N 个节点,其中 M 个为信标节点。由经典的 DV-Hop[26] 定位算法可知,信标节点之间的跳数信息为:

$$\boldsymbol{H} = [H_1, H_2, \cdots, H_M] \tag{26}$$

其中,H_i 为信标节点 i 到通信半径内所有信标节点的跳数向量,可表示为:

$$\boldsymbol{H}_i = [h_{i,1}, h_{i,2}, \cdots, h_{i,s}]^{\mathrm{T}}, (0 < s < M) \tag{27}$$

而信标节点之间的距离信息为:

$$Dis = [d_1, d_2, \cdots, d_M] \tag{28}$$

其中,信标节点 i 到通信半径内所有信标节点的距离向量为:

$$Dis_i = [d_{i,1}, d_{i,2}, \cdots, d_{i,s}], (0 < s < M) \tag{29}$$

信标节点 i 的跳数向量和距离向量构成训练数据集 T_i:

$$T_i = \{(H_1, d_{i,1}), (H_2, d_{i,2}), \cdots, (H_s, d_{i,s})\} \tag{30}$$

最终,将得到的训练数据集 T_i 输入到动态贝叶斯 LS-SVM 模型中进行训练。而当有新的信息加入到训练模型中时,需以训练数据增加前求得的参数 γ 为初始值,由式(25)重新计算新样本下的 $\bar{\gamma}$,完成正则化参数的更新,并通过自适应增减算法重新训练新的 LS-SVM。

3.2 测试阶段

获取未知节点 j 到通信半径内所有信标节点的跳数向量作为测试集:

$$\boldsymbol{H}_j = [h_{i,1}, h_{j,2}, \cdots, h_{j,s}]^{\mathrm{T}}, (0 < s < M) \tag{31}$$

将该测试集输入到训练好的动态贝叶斯 LS-SVM 模型中,预测得到未知节点的距离信息:

$$Dis_j = [LS_1(h_{j,1}), LS_2(h_{j,2}), \cdots, LS_s(h_{j,s})] \tag{32}$$

其中,$h_{j,s}$ 为未知节点与其通信半径内信标节点的跳数信息。$LS_s(h_{j,s})$ 为未知节点与其通信半径内信标节点之间的距离信息。

3.3 节点定位阶段

将预测得到的未知节点的距离信息利用最大似然估计法对所求未知节点 P 的坐标 (x, y) 进行估计。根据最大似然估计法原理可知:

$$\begin{cases} (x - x_1)^2 + (y - y_1)^2 = Dis_1^2 \\ (x - x_2)^2 + (y - y_2)^2 = Dis_1^2 \\ \vdots \\ (x - x_j)^2 + (y - y_j)^2 = Dis_j^2 \end{cases} \tag{33}$$

将式(33)中前 $j-1$ 项方程,分别减去最后一个方程,化简可得式(34):

$$\begin{cases} -2(x_1 - x_j)x - 2(y_1 - y_j)y = Dis_1^2 - \\ Dis_j^2 - x_1^2 + x_j^2 - y_1^2 + y_j^2 \\ -2(x_2 - x_j)x - 2(y_2 - y_j)y = Dis_2^2 - \\ Dis_j^2 - x_2^2 + x_j^2 - y_2^2 + y_j^2 \\ \vdots \\ -2(x_{j-1} - x_j)x - 2(y_{j-1} - y_j)y = Dis_{j-1}^2 - \\ Dis_j^2 - x_{j-1}^2 + x_j^2 - y_{j-1}^2 + y_j^2 \end{cases} \tag{34}$$

将式(34)以矩阵的方式表示为 $\boldsymbol{AX} = \boldsymbol{b}$,其中 $\boldsymbol{A}$、$\boldsymbol{b}$、$\boldsymbol{X}$ 分别由式(35)、(36)、(37)表示。

$$\boldsymbol{A} = 2 \times \begin{bmatrix} x_1 - x_j & y_1 - y_j \\ x_2 - x_j & y_2 - y_j \\ \vdots & \vdots \\ x_{j-1} - x_j & y_{j-1} - y_j \end{bmatrix} \tag{35}$$

$$\boldsymbol{b}=\begin{bmatrix} x_1^2-x_j^2+y_1^2-y_j^2+Dis_j^2-Dis_1^2 \\ x_2^2-x_j^2+y_2^2-y_j^2+Dis_j^2-Dis_2^2 \\ \vdots \\ x_{j-1}^2-x_j^2+y_{j-1}^2-y_j^2+Dis_j^2-Dis_{j-1}^2 \end{bmatrix} \tag{36}$$

$$\boldsymbol{X}=\begin{bmatrix} x \\ y \end{bmatrix} \tag{37}$$

由式(35)~(37)可得,待定位节点的二维坐标 $P(x,y)$。节点由深度传感器测量可知未知节点 P 的最终坐标为 (x,y,h)。

在获得节点的二维坐标后,就可以进入节点运动预测阶段。

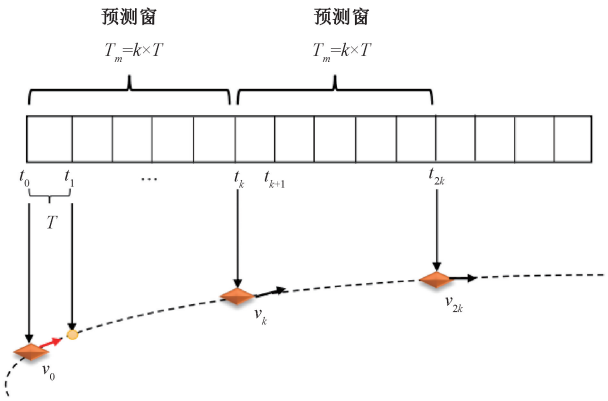

图 4　时间预测窗

Fig. 4　Time prediction window

如图 4 所示,运动预测算法将整个定位过程的时间划分为多个预测窗口,预测窗口的长度设为 T_m,节点每间隔 T_m 进行一次实际定位,算法中的每个预测窗口为一个预测单元。

假设预测窗口内相邻预测时段节点的运动行为没有突变,算法利用前一个预测窗口的速度测量值预测前一个预测窗口内节点的运动行为。预测窗口长度为定位周期 T 的整数倍:$T_m=k\times T$。

在运动预测算法中,$(v_0,v_1,\cdots,v_i,\cdots,v_k)$ 表示水下传感器节点在预测窗口内各定位周期的预测速度,即 ξ'。在第 i 个定位周期,水下传感器节点可以用式(38)预测第 i 个周期的位置:

$$Node(i)=Node(i-1)+T\times\hat{v}_{i-1} \tag{38}$$

式中:$Node(i)$ 为水下传感器节点在定位周期 i 内的二维位置;$Node(i-1)$ 为水下传感器节点在前一次定位周期 $i-1$ 的二维坐标;$\hat{v}_{i-1}$ 为前一段定位周期内的速度;T 为一个定位周期的长度。

因此,设传感器节点的深度为 $H(i)$,则前一时刻的深度为 $H(i-1)$,可知:

$$H(i)=H(i-1)+T\times v'' \tag{39}$$

则预测得到的未知节点坐标为:

$$(x_i,y_i,h_i)=(x_{i-1},y_{i-1},h_{i-1})+T\times\xi_{Node(i-1)} \tag{40}$$

式中:(x_i,y_i,h_i) 为水下传感器节点在 i 时刻的位置;$(x_{i-1},y_{i-1},h_{i-1})$ 为水下传感器节点前一刻的位置;$\xi_{Node(i-1)}$ 为节点前一个定位周期的速度。

最后,将未知节点 $P(x,y,h)$ 代入到节点运动模型式(8)中,得到此时的速度。根据式(38)对预测得到预测窗口内第 1 个定位周期的二维位置,并将坐标代入到节点运动模型式(8)中,得到第一个定位周期的速度。一直循环预测到第 k 个周期,节点将定位到实际位置。移动预测算法的定位误差由实际位置与预测位置的差值来确定,循环直至所有未知节点完成定位。

3.4　节点定位流程

在水下传感器网络中,节点的位置移动受到潮汐、洋流等环境因素的影响,这可能导致定位算法的定位精度下降[27]。为了防止传感器节点受水流影响离开所部署的网络区域,一些算法会将传感器节点固定在水底,使节点处于静止状态,从而避免节点移动引起的定位误差。另一些算法则采用锚定策略[28],将信标节点固定在海底,而普通节点在一定范围内可以随水流进行活动,但节点在移动过程中保持相对稳定的深度。

如图 5 所示为使用 Python 进行潮汐运动模拟时节点随水流移动的情况。图中显示了 30 个节点,圆点表示节点的初始位置,实线连接着初始位置和 1 200 s 后节点的新位置的五角星。通过这种模拟,可以观察节点在水流作用下的移动情况。通过考虑节点移动的情况,可以提高算法的鲁棒性和适应性,从而提高水下节点移动预测定位的精度和准确性。

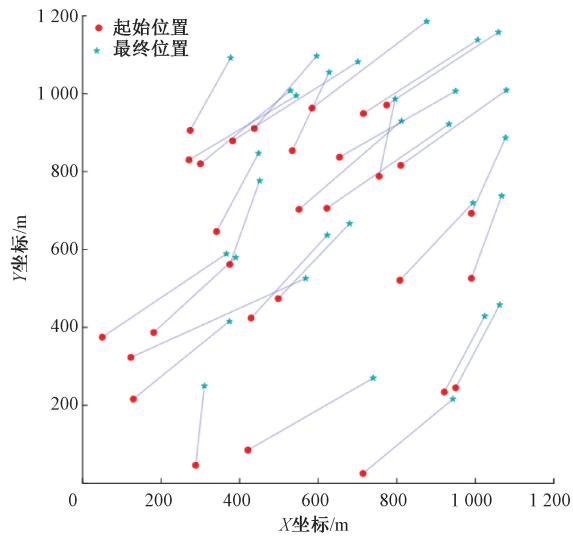

图 5　潮汐运动中节点移动示意图

Fig. 5　Schematic diagram of node movement in tidal movement

动态贝叶斯 LS-SVM 节点定位流程如下：

步骤 1）数据采集和预处理。通过水下无线传感器网络获取信标节点 i 到通信半径内的所有信标节点的距离和跳数矩阵。同时，获取未知节点到周围信标节点的跳数矩阵，并对其所获得的跳数矩阵进行归一化处理。

步骤 2）构建训练集。将信标节点 i 到通信半径内的所有信标节点的跳数矩阵作为输入训练集，到所有信标节点之间的距离作为输出训练集。

步骤 3）生成贝叶斯 LS-SVM 模型。通过求解式(21)得到优化参数 ω 和 b；优化参数 μ 和 ξ 由式(24)求得，并得到正则化参数 λ。最后，计算优化参数 μ 和 ξ 下的后验概率 $p(H_j \mid D)$。通过调整 σ 的值来获得最大后验概率 $p(H_j \mid D)$ 时所对应的参数 μ，ξ 和 σ 为 LS-SVM 的最优参数。

步骤 4）使用自适应增减算法进行模型参数的优化。随着新的样本信息不断加入到模型中，通过自适应增减算法动态地改变核函数的参数来调整模型参数，从而训练出一个新的贝叶斯 LS-SVM。

步骤 5）预测未知节点到信标节点的距离向量。将未知节点 j 与该信标节点的跳数向量作为测试集，并代入到训练好的动态贝叶斯 LS-SVM 模型中进行预测，得到节点之间的距离矩阵。同时，对其预测结果进行反归一化处理。

步骤 6）估算未知节点坐标。利用未知节点与信标节点的距离矩阵建立方程，利用最大似然估计法对节点二维坐标进行位置估计。

步骤 7）节点移动预测。将估计到的节点坐标代入到节点的运动模型式(8)中，得到节点当前的运动速度，根据式(38)得到未知节点在第 1 个时间预测窗内的二维位置。

步骤 8）完成所有未知节点定位。循环步骤 7）持续预测到第 k 周期，此时未知节点将被定位到实际位置，然后进入下一个预测窗口并循环直到所有未知节点完成定位。

4　实验结果与分析

本次仿真实验使用 Python 3.9 作为仿真平台，针对沿海环境下的水下无线传感器网络进行监控，实现了基于动态贝叶斯的 LS-SVM 水下节点移动预测定位。定义节点密度为邻居节点的平均数量[29]。本文通过分析节点密度对定位覆盖率、平均定位误差、平均能耗、时间复杂度以及同一节点密度下不同算法的定位结果五个方面的影响，对所提出的 BLSM 算法与经典的 SLMP 算法、文献[11]提出的 RTLC 算法、文献[30]中提出的 NDSMP 算法[30]以及文献[9]提出的 MPL 算法进行了实验对比分析。

4.1　仿真环境设置

在本次仿真实验中，设置了 200 个传感器节点在一个大小为 500×500×500 的水下区域中进行随机分布。其中，有 20 个浮标节点分布在水面上，30 个信标节点和 150 个普通节点分别分布在水下区域中。假设节点之间的通信半径是一个规则的圆形，信标节点的通信半径为 200 m，未知节点的通信半径为 100 m。此外，考虑到部署在近岸区域的传感器节点深度可以通过深度传感器测量，本文假设节点深度已知，不考虑深度对位置的影响。节点的运动模型采用了 2.2 节中描述的沿海潮汐运动模型。每次仿真的时间长度为 1 200 s，但本文只研究最初的 200 s 内的节点移动模型。

在实验中，将对比分析本文提出的 BLSM 算法与经典的 SLMP 算法、文献[6]中提出的 RTLC 算法、文献[30]中提出的 NDSMP 算法[30]以及文献[4]提出的 MPL 算法的性能差异。通过比较，来评估这些算法在水下传感器网络定位问题上的表现。

4.2　性能分析

本文从定位覆盖率、平均定位误差和平均能耗 3 个方面对算法进行性能分析。

1）定位覆盖率为：

$$\eta = \frac{n_{loc}}{n} \times 100\% \tag{41}$$

式中：n_{loc} 为已定位的普通节点的数量；n 为全部普通节点的数量。

2）平均定位误差为：

$$error = \frac{1}{n}\sum_{i=1}^{n}\sqrt{(x_i - x_i')^2 + (y_i - y_i')^2} \tag{42}$$

式中：为第 i 个节点的真实坐标；(x_i', y_i') 为第 i 个节点的预测坐标。

3）平均通信能耗为：

$$E_{avg} = \frac{1}{N}\left(\sum_{i=1}^{n_s} E_{iS} + \sum_{i=1}^{n_r} E_{iR}\right) \tag{43}$$

式中：E_{iS} 为节点发送数据的能耗；E_{iR} 为节点接收数据的能耗；N 为已定位节点的个数；n_s 和 n_r 分别为节点发送和接收数据的次数。

1）定位覆盖率的实验结果与分析

在仿真实验中，分别研究不同节点密度对定位覆盖度的影响。将本文所提出的 BLSM 算法与经典的 SLMP 算法、文献[6]提出的 RTLC 算法、文献[21]中提出的 NDSMP 算法以及文献[4]提出的 MPL 算法进行比较如图 5 所示。

图 5 显示了在不同节点密度下时对 BLSM 算法以及 SLMP 算法、RTLC 算法、NDSMP 算法和 MPL 算法定位覆

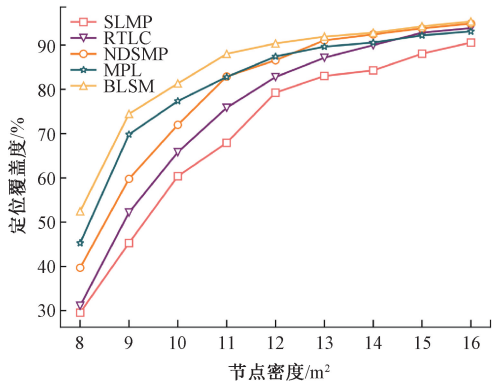

图 6　定位覆盖度与节点密度的关系

Fig. 6　Relationship between positioning coverage and node density

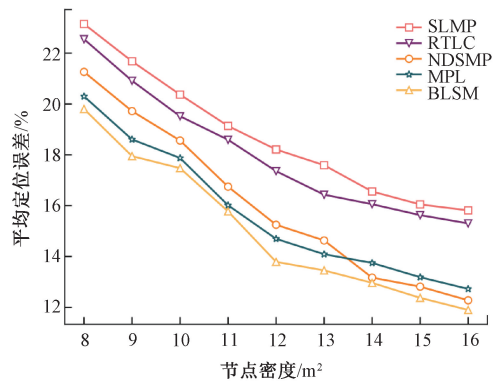

图 7　平均定位误差与节点密度的关系

Fig. 7　Relation between average positioning error and node density

盖度的影响。由图可知,节点的定位覆盖度随着水声传感器节点密度的增加而单调增加。当节点密度为 16 时,5 种算法的定位覆盖度基本相同。

由于本文提出的 BLSM 算法采用自适应增减算法对模型参数进行动态优化。通过自适应增减算法,BLSM 算法能够根据新数据的变化动态调整模型参数,使得模型能够更好地适应节点移动的变化。在训练过程中,BLSM 算法选择节点通信半径内的信标节点和邻居节点来构建训练样本,这种训练方式有助于提高节点定位的覆盖度,使得更多的节点能够准确地被定位。因此,在节点密度较低的水下网络中,本文提出的 BLSM 算法比其他算法具有更高的定位覆盖度和性能。

2)平均定位误差的实验结果与分析

众所周知,信标节点的定位误差对整个水下无线传感器网络的定位精度具有重要影响。根据图 6 所示,随着无线传感器网络节点密度的增加,5 种算法的平均定位误差都呈现下降的趋势。其中,BLSM 算法由于具有较高的节点定位覆盖度,使得普通节点能够接收到更多的节点定位信息,从而降低了平均定位误差并表现出优于其他 4 种算法的结果。

这 5 种算法在进行未知节点定位时都需要利用信标节点进行定位。当可利用的信标节点越多时,定位误差也随之降低。BLSM 算法通过充分利用邻居节点的信息,提高了模型的预测准确性,从而降低了平均定位误差。当节点密度为 16 时,BLSM 算法相较于其他 4 种算法的平均定位误差分别降低了 24.77%、22.25%、3.1%、6.5%。因此,BLSM 算法基于潮汐模型对节点运动模型的研究相较于其他算法直接采用线性运动预测模型相比,更符合水下节点的实际运动情况,使得 BLSM 算法的平均定位误差较低,最终大大提高了节点的定位精度。

3)平均通信能耗的实验结果与分析

根据图 7 所示,随着无线传感器网络节点密度的增加,平均通信能耗呈现先迅速降低,然后逐渐趋于平缓的趋势。在这五种算法中,BLSM 算法表现出较低的平均通信能耗。首先,BLSM 算法通过提供精确的节点定位结果,使得节点能够更有效地选择通信路径。其次,BLSM 算法采用自适应的参数优化,使得模型能够更好地适应节点移动和网络变化。通过动态调整模型参数,BLSM 算法可以更准确地预测节点位置,从而避免了不必要的数据包传输和通信过程中的能耗浪费。因此,使用 BLSM 算法的节点平均通信能耗明显低于其他 3 种算法。

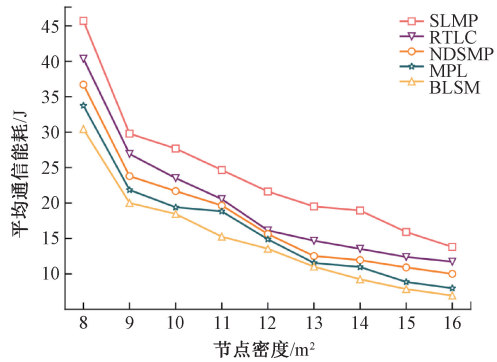

图 8　节点密度与平均通信能耗的关系

Fig. 8　Relation between node density and average communication energy consumption

4)运行时间的实验结果与分析

在水下无线传感器网络定位算法中,由于节点能源有限,算法的复杂度也成为评判算法优良的一项重要指标。在实验仿真中,由于 SLMP 中的 Durbin 算法计算复杂度为 $O(N^2)$;RTLC 算法中的卡尔曼算法计算复杂度为 $O(N^2)$;NDSMP 算法中 TOA 定位算法的复杂度为 $O(D\times N)$;MPL 算法中全局最优解的计算复杂度为 $O(N)$,局部最优解的计算复杂度为 $O(N)$,更新个体的

额外复杂度为 $O(D \times N)$，因此整体计算复杂度约为 $O(D \times N)$；BLSM 算法中训练复杂度为 $O(D \times N^2)$。测试复杂度为 $O(N_S \times \frac{N}{N_S} \times D)$。最大似然法获得最优位置估计的复杂度为 $O(N^2)$。因此整体复杂度计算大约为 $O(2 \times D \times N^2)$. 从图 8 的柱状图可以看出，符合本文的分析。BLSM 算法定位精度高于 RTLC 算法、NDSMP 算法以及 MPL 算法，但运行时间也高。因此需要根据实际情况在定位精度和算法复杂度之间权衡。

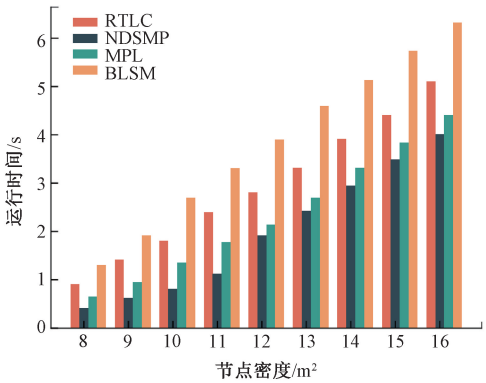

图 9　运行时间与节点密度的关系

Fig. 9　Running time vs. node density

5）同一节点密度下的定位结果分析

图 9 所示为节点密度为 10 时，不同方法的定位结果图。由图可知，BLSM 算法相较于其他 4 种算法具有更高的节点定位效率和定位覆盖度。在此节点密度下，BLSM 算法以及 SLMP 算法、RTLC 算法、NDSMP 算法和 MPL 算法的定位覆盖度分别为 84.51%、64.35%、67.42%、72.18%以及 78.67%。

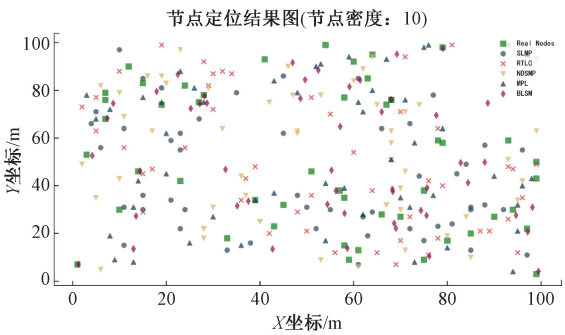

图 10　节点定位结果图

Fig. 10　Node positioning result diagram

5　结　论

本文提出了一种基于动态贝叶斯 LS-SVM 水下节点移动定位预测算法，解决了复杂的水下环境中由节点的移动性所造成的定位精度低的问题。在该算法中，分析了沿海水流的运动规律，根据水下传感器节点的运动规律，预测每个传感器节点的位置，有效地解决了节点的移动性问题。为了进一步降低能耗，提高节点定位精度，采用自适应的参数优化，使得模型能够更好地适应节点移动和网络变化。通过实验仿真结果显示，在相同的水下传感器节点密度下，与传统的 SLMP 算法、RTLC 算法、NDSMP 算法和 MPL 算法相比，本文所提出的 BLSM 定位算法可以大大降低节点通信能耗，具有较高的定位覆盖率和较低的定位误差。

综合来看，本文所提出的算法在水下传感器网络节点定位中具有重要的启示作用。然而，也需要注意到该算法存在一些不足之处。首先，该算法对大量的节点位置数据进行训练和预测，这对于大规模水下传感器网络来说可能难以获取足够的节点位置数据，特别是在数据稀缺的情况下。因此，算法的预测性能可能会受到限制。其次，在实际应用中，还需要进一步研究和改进该算法，以提高其鲁棒性和适应性，使其能够适应不同的水下环境和节点移动模式。

参考文献

[1] 陈连顺. 水下无线传感器网络定位算法综述[J]. 数字技术与应用，2017(9)：131-133.
CHEN L SH. Overview of positioning algorithms for underwater wireless sensor networks [J]. Digital Technology and Applications, 2017(9):131-133.

[2] 张弛，张保衡，张静，等. 水下无线传感器网络定位技术综述[J]. 计算机应用，2022，42(S1)：226-235.
ZHANG CH, ZHANG B H, ZHANG J, et al. Overview of underwater wireless sensor network positioning technology [J]. Computer Applications, 2022, 42(S1): 226-235.

[3] RANI S, SANGWAN A, KUMAR K, et al. A review and analysis of localization techniques in underwater wireless sensor networks [J]. Computers, Materials & Continua, 2023, 75(3):5697-5715.

[4] SATHISH K, VENKATA R C, ANBAZHAGAN R, et al. Review of localization and clustering in USV and AUV for underwater wireless sensor networks [C]. Telecom. MDPI, 2023, 4(1): 43-64.

[5] 康晓月. 基于移动节点的水下无线传感器网络定位算法的研究[D]. 青岛：青岛科技大学，2020.
KANG X Y. Research on positioning algorithm of underwater wireless sensor network based on mobile nodes[D]. Qingdao: Qingdao University of Science and Technology, 2020.

[6] 乐志伟，王浩，谢小军. 基于 RSSI 障碍势能矫正的定位算法[J]. 电子测量与仪器学报，2017，31(2)：

200-207.
LE ZH W, WANG H, XIE X J. Positioning algorithm based on RSSI obstacle potential energy correction [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(2): 200-207.

[7] 魏蕴波,魏连锁,丁永胜. 基于洋流运动态势的移动预测水下定位研究[J]. 数学的实践与认识,2016,46(11):178-186.
WEI Y B, WEI L S, DING Y SH. Research on mobile prediction underwater positioning based on ocean current movement [J]. Practice and Understanding of Mathematics, 2016, 46(11): 178-186.

[8] 王鑫,田艺,蒋华,等. 基于锚节点移动路径动态规划的定位算法[J]. 计算机工程与设计,2020,41(8):2135-2140.
WANG X, TIAN Y, JIANG H, et al. Positioning algorithm based on dynamic planning of anchor node movement path [J]. Computer Engineering and Design, 2020, 41(8): 2135-2140.

[9] ZHANG W B, HAN G J, WANG X, et al. A node location algorithm based on node movement prediction in underwater acoustic sensor networks [J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 3166-3178.

[10] 庞琬佳. 基于神经网络的水下节点光学定位方法研究[D]. 成都:电子科技大学,2022.
PANG W J. Research on underwater node optical positioning method based on neural network [D]. Chengdu: University of Electronic Science and Technology of China, 2022.

[11] 晋泽炎,吕伟杰,刘丽萍. 基于洋流模型的水下传感器网络实时定位算法[J]. 传感器与微系统,2017,36(12):149-152,156.
JIN Z Y, LYU W J, LIU L P. Real-time positioning algorithm for underwater sensor networks based on ocean current model [J]. Sensors and Microsystems, 2017, 36(12): 149-152,156.

[12] 杨振诚. 基于优化算法的水下无线传感器网络预测定位算法研究[D]. 南京:南京邮电大学,2020.
YANG ZH CH. Research on predictive positioning algorithm for underwater wireless sensor networks based on optimization algorithm [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.

[13] 刘丽萍,陈梦,晋泽炎. UWSNs 节点运动模型及预测定位[J]. 哈尔滨工业大学学报,2018,50(9):156-163.
LIU L P, CHEN M, JIN Z Y. UWSNs node motion model and predictive positioning [J]. Journal of Harbin Institute of Technology, 2018, 50(9): 156-163.

[14] 谢宇芳,孙海信,齐洁. 一种有效的水下目标波达角估计方法[J]. 厦门大学学报(自然科学版),2017,56(2):264-270.
XIE Y F, SUN H X, QI J. An effective method for estimating the angle of arrival of underwater targets [J]. Journal of Xiamen University (Natural Science Edition), 2017, 56(2): 264-270.

[15] 郝诗雅. 基于非视距和区域过滤的水声传感器网络移动定位研究[D]. 石家庄:河北师范大学,2021.
HAO SH Y. Research on mobile positioning of hydroacoustic sensor network based on non-line-of-sight and area filtering [D]. Shijiazhuang: Hebei Normal University, 2021.

[16] LIAO H R, TSAI S B, HUANG CH X. Research on the B2C online marketing effect based on the LS-SVM algorithm and multimodel fusion [J]. Mathematical Problems in Engineering, 2021, 2021.

[17] 孙宇晶. 水下无线传感器网络节点部署优化研究[J]. 物联网技术,2021,11(4):34-35,38.
SUN Y J. Research on node deployment optimization of underwater wireless sensor network [J]. Internet of Things Technology, 2021, 11(4): 34-35,38.

[18] 陈梦. 水下传感器网络节点运动预测模型及定位机制研究[D]. 天津:天津大学,2018.
CHEN M. Research on node motion prediction model and positioning mechanism of underwater sensor network [D]. Tianjin: Tianjin University, 2018.

[19] 李健华. 近海与河口区域沉积层与上覆水体间水动力的数学模型及特性研究[D]. 广州:华南理工大学,2018.
LI J H. Research on the mathematical model and characteristics of hydrodynamics between sedimentary layers and overlying water bodies in offshore and estuary areas [D]. Guangzhou: South China University of Technology, 2018.

[20] YANG X, TAN L, HE L. A robust least squares support vector machine for regression and classification with noise[J]. Neurocomputing, 2014, 140: 41-52.

[21] KIM Y D, JANG T, HAN B, et al. Learning to select pre-trained deep representations with Bayesian evidence framework [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016, DOI:10.1109/CVPR.2016.574.

[22] HUAN J, CAO W J, QIN Y L. Prediction of dissolved oxygen in aquaculture based on EEMD and LSSVM optimized by the Bayesian evidence framework [J]. Computers and Electronics in Agriculture, 2018, 150.

[23] 李享. 基于动态贝叶斯网络的无线通信系统可靠性分

析与故障诊断[D]. 成都:电子科技大学,2021.
LI X. Reliability analysis and fault diagnosis of wireless communication systems based on dynamic Bayesian network [D]. Chengdu: University of Electronic Science and Technology of China, 2021.

[24] WU Y, CHEN Y, WANG L, et al. Large scale incremental learning[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 374-382.

[25] GANG Q, MUHAMMAD A, KHAN Z U, et al. Machine learning-based prediction of node localization accuracy in IIoT-based MI-UWSNs and design of a TD coil for omnidirectional communication [J]. Sustainability, 2022, 14(15): 9683.

[26] 潘志远,卜凡亮. 基于蜣螂算法优化的 DV-Hop 定位算法[J/OL]. 电子测量与仪器学报:1-10[2023-09-07]. http://kns. cnki. net/kcms/detail/11. 2488. TN. 20230803. 1820. 026. html.
PAN ZH Y, BU F L. DV-Hop positioning algorithm based on dung beetle algorithm optimization [J/OL]. Journal of Electronic Measurement and Instrumentation: 1-10[2023-09-07]. http://kns. cnki. net /kcms/detail/11. 2488. TN. 20230803. 1820. 026. html.

[27] 刘禹. 基于运动模型的水下传感器网络节点定位算法的研究[D]. 长春:吉林大学,2015.
LIU Y. Research on node positioning algorithm of underwater sensor network based on motion model [D]. Changchun: Jilin University, 2015.

[28] ZHANG C, XIE T, YANG K, et al. Positioning optimisation based on particle quality prediction in wireless sensor networks[J]. IET Networks, 2019, 8(2): 107-113.

[29] BACANIN N, SARAC M, BUDIMIROVIC N, et al. Smart wireless health care system using graph LSTM pollution prediction and dragonfly node localization[J]. Sustainable Computing: Informatics and Systems, 2022, 35: 100711.

[30] LI R, YIN H, WANG J, et al. Study on node localization of underwater sensor networks based on node dynamic selection and movement prediction [C]. 2021 13th International Conference on Communication Software and Networks (ICCSN). IEEE, 2021: 1-5.

作者简介

彭铎(通信作者),1998 年于甘肃工业大学获得学士学位,2009 年于兰州理工大学获得硕士学位,2019 年于兰州理工大学获得博士学位,现为兰州理工大学副教授,主要研究方向为无线传感器网络、光纤通信。

E-mail: pengduo7642@ 163. com

Peng Duo (Corresponding author) received his B. Sc. degree from Gansu University of Technology in 1998, his M. Sc. degree from Lanzhou University of Technology in 2009, and his Ph. D. degree from Lanzhou University of Technology in 2019. He is now an associate professor at Lanzhou University of Technology. His main research interests include wireless sensors、networks and fiber optic communications.

曹坚,2021 年于商洛学院获得学士学位,现为兰州理工大学硕士研究生,主要研究方向为无线传感器网络。

E-mail: caojian0618@ 163. com

Cao Jian received his B. Sc. degree from Shangluo University in 2021. He is now a M. Sc. candidate at Lanzhou University of Technology. His main research interest includes wireless sensor networks.

黎亚亚,2022 年于陇东学院获得学士学位,现为兰州理工大学硕士研究生,主要研究方向为无线传感器网络。

E-mail:1395242956@ qq. com

Li Yaya received her B. Sc. degree from Longdong University in 2022. She is now a M. Sc. candidate at Lanzhou University of Technology. Her main research interest includes wireless sensor networks.