

DOI: 10.13382/j.jemi.B2407531

基于 CNN-LSTM 声速预测的水下移动节点定位算法*

彭 铎 查海音 曹 坚 张彦博 张明虎

(兰州理工大学计算机与通信学院 兰州 730050)

摘要:本文旨在解决水下无线传感器网络中因水下环境复杂多变导致的长时延问题,该问题显著影响移动传感器节点间的信息传播效率,进而增大了节点定位误差。为此,本研究创新性地提出了一种基于 CNN-LSTM 声速预测的水下移动节点定位算法。首先,通过 K-折交叉验证法对声速数据集进行科学划分,随后构建并训练了一个融合卷积神经网络(CNN)特征提取能力与长短期记忆网络(LSTM)序列建模能力的 CNN-LSTM 混合模型。此模型有效捕捉了声速数据中的空间与时间特征,显著提升了声速预测的准确度。在定位过程中,采用该模型预测的声速值进行到达时间差(TDOA)测距,并据此对测距结果进行精细修正。进而,针对不同节点密度条件下的未知节点,算法能够自适应地选择最适宜的测距定位方法,依据参考节点数量实现精准定位。实验结果显示,与现有的 SLMP、DMP、NDSMP 及 BLSM 定位算法相比,本文提出的 MCLS 定位算法在相同信标节点条件下,定位误差均值分别降低了 46.96%、39.93%、27.64% 和 15.24%,显著提升了水下移动节点的定位精度与稳定性。

关键词:水下传感器网络;声速预测;CNN-LSTM 模型;距离修正;移动节点定位

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 mobile node location algorithm based on CNN-LSTM sound velocity prediction

Peng Duo Zha Haiyin Cao Jian Zhang Yanbo Zhang Minghu

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: This study addresses the long delay issue in underwater wireless sensor networks (UWSNs) caused by the spatio-temporal complexity and dynamics of the underwater environment, which significantly impacts the information propagation between mobile sensor nodes and consequently leads to large node localization errors. To this end, a novel underwater mobile node localization algorithm based on CNN-LSTM sound speed prediction is proposed. Initially, the sound speed dataset is partitioned using the K-fold cross-validation method. Subsequently, a hybrid CNN-LSTM model is constructed and trained, leveraging the feature extraction capability of CNN and the sequence modeling strength of LSTM. This model efficiently captures both spatial and temporal information from the sound speed dataset, thereby enhancing the prediction accuracy. During the localization process, the predicted sound speed values from the CNN-LSTM model are employed for time difference of arrival (TDOA) ranging, and the ranging values are refined accordingly. Finally, the refined ranging values are utilized to adaptively select the optimal ranging and localization method for unknown nodes under varying node densities, based on the number of reference nodes, thereby achieving precise localization of underwater mobile nodes. Experimental results demonstrate that, compared to existing localization algorithms such as SLMP, DMP, NDSMP, and BLSM, the proposed MCLS localization algorithm reduces the mean localization error by 46.96%, 39.93%, 27.64%, and 15.24%, respectively, under the same beacon node conditions, significantly improving the localization accuracy and stability of underwater mobile nodes.

Keywords: underwater sensor network; sound velocity prediction; CNN-LSTM model; distance correction; mobile node location

0 引言

水下无线传感器网络^[1] (underwater wireless sensor network, UWSN) 在海洋环境监测、资源勘探、灾害预警等^[2] 多个领域展现出了巨大的应用潜力。然而,由于海洋环境的复杂性和特殊性,节点定位技术在水下传感器网络中面临着诸多挑战。首先,海洋环境的动态变化不仅影响节点定位的准确性,还可能导致水下节点受潮汐等自然力影响而发生移动,从而需要定期更新位置信息。此外,水下传感器网络通常依赖水声信号^[3] 进行通信,这种通信方式容易受到海洋环境的影响,导致数据丢失和传输延迟。尤其是声速的变化,其不稳定性受到地理位置和季节因素的显著影响,使得基于声速的测距算法^[4] 存在较大的误差,进而影响节点定位的精度。

近年来,国内外研究人员在提升水声传感器网络移动节点定位精度方面取得了显著进展。例如,Mamta 等^[5] 提出了一种基于节点移动和传播延迟预测的定位方法,通过预测传输延迟实现精确的时间同步和节点定位。Zhan 等^[6] 提出了一种基于到达时间差 (time difference of arrival, TDOA) 和到达频率差 (frequency difference of arrival, FDOA) 的多层等梯度声速定位算法,通过建立声速剖面模型提高了定位精度。王领等^[7] 针对测量误差和传感器节点位置误差并存的问题,提出了一种双误差模型下的加权最小二乘估计法,有效提升了定位精度。Qin 等^[8] 通过联合时间同步和定位机制,结合 AUV 的移动和同步请求信号,提出了一种多层快速网格划分定位方法,显著提高了节点定位的速度和精度。

然而,目前大多数基于水声传感器网络的节点定位方法仍采用固定的声速值进行测距计算,使得其在节点定位过程中会产生较大的测距误差,从而增大节点定位误差。为了解决这一问题,提出了一种基于 CNN-LSTM 声速预测的水下移动节点定位算法 (underwater mobile node location algorithm based on CNN-LSTM sound velocity prediction, MCLS 定位算法)。该算法包括声速预测、节点预定位和测距修正 3 个阶段。首先,利用 CNN-LSTM 模型对未来月平均声速进行预测,以减小因声速变化引起的测距误差。其次,针对不同节点密度下的未知节点可根据参考节点数量自适应地选择不同的测距定位方法。最后,利用已定位的节点作为新的参考节点,辅助网络中剩余未知节点的定位,从而显著提升水下移动节点的定位精度。

1 模型分析

1.1 水下无线传感器网络模型

如图 1 所示,UWSN 网络模型由地面基站、卫星、浮标节点以及动态的水下传感器定位节点构成。每个传感器系统均与先进的压力检测设备集成,能够精确地测定其在水下的深度。因此,原本复杂的三维定位问题得以简化为更为直观的二维平面问题。在此 UWSN 网络模型中,没有任何一个传感器节点是静止固定的,它们均随着潮汐的涨落而自然移动。




图 1 UWSN 网络模型

Fig. 1 UWSN network model

1.2 水声信道模型

在当前的无线传感器网络领域中,陆地环境主要依赖卫星导航信号来实现节点间的信息交换。然而,在海洋环境中,由于海水中多种因素的共同作用,卫星导航信号存在显著衰减,变得不再适用。因此,海洋传感器网络普遍采用水声信号作为节点间通信的主要手段。尽管水声通信技术^[9] 在海洋传感网络中得到了广泛应用,但这一领域仍然面临着诸多挑战。

因此,为了更准确地计算声速,通常会考虑温度、盐度和深度等因素,并采用相应的水声声速经验公式进行估算。最常用的水声声速经验公式如式(1)所示。

$$c(T, S, z) = 1449 + 4.6T - 0.0557T^2 + 0.0003T^3 + (1.39 - 0.012T)(S - 35) + 0.017z \quad (1)$$

其中, c 为声速; T 为海水温度; S 为海水盐度; z 为深度。

由于温度、盐度、深度和 pH 值等因素随季节、时间和海洋位置的不同而呈现不规则的变化,水下声速的变化也因此具有不规则性^[10]。在浅海区域,温度和盐度的变化对声速的影响尤为显著,成为声速突变的主要因素。水中的温度梯度随着水深范围的变化而变化。如图 2 所示,可以清晰地观察到声速随着温度和深度的变化而波动。




图 2 浅海中温度对声速的影响

Fig. 2 Influence of temperature on sound velocity in shallow sea

同样地,如图 3 所示,浅海区域内的声速变化呈现出两个显著趋势:在恒定深度条件下,随着海水盐度的增加,声速呈现稳步上升的趋势;而在保持盐度一致的情况下,随着水深的增加,声速亦逐步增大。这一现象进一步证实了深度与海洋声速值之间存在紧密的相关性,即海洋声速的变化具有显著的空间相关性。




图 3 浅海中盐度对声速的影响

Fig. 3 Influence of salinity on sound velocity in shallow sea

在海洋环境中,海底声信号在传播过程中会经历扩散、分散和吸收等衰减过程。当声波从声源向远处传播时,由于几何扩散效应,信号的强度会逐渐减弱,这种现象被称为扩散损耗。在水下声学中,声波的传播机制主要可以分为圆柱形和球形两种基本类型。损耗分别用式(2)表示柱状扩散,用式(3)表示球形扩散。如式(2)和(3)所示。

$$L_{CS} = 10\log(R_t) \tag{2}$$

$$L_{SS} = 20\log(R_t) \tag{3}$$

其中, L_{CS} 、 L_{SS} 和 R_t 分别为圆柱扩散损耗、球面扩散损耗和传输距离。

在 100 Hz ~ 1 MHz 的频率范围内的吸收系数如式(4)所示,它是频率、深度和温度的函数。

$$\alpha = \frac{A_1 P_1 f_1^2}{f^2 + f_1^2} + \frac{A_2 P_2 f_2^2}{f^2 + f_2^2} + A_3 P_3 f^2 \tag{4}$$

吸收损耗为:

$$L_{ab} = (\alpha \times R_t) \times 10^{-3} \tag{5}$$

传输损耗为声波离开声源时声强度的累积损失,在浅海情景下用式(6)表示。

$$TL_{shallow} = L_{CS} + L_{ab} \tag{6}$$

如图 4 所示,为水深 100 m,温度为 27 °C,盐度为 34×10^{-12} ,pH=7.8 的浅海环境下,传输损耗和吸收损耗受频率的影响。




图 4 D=100 m 时浅海频率对声速损耗的影响

Fig. 4 Influence of shallow sea frequency on sound velocity loss when D=100 m

在该模型中,传输损耗、吸收损耗、扩散损耗和声速所考虑的参数如表 1 所示。

表 1 浅海环境参数

Table 1 Shallow sea environmental parameters	
参数	设置范围
浅海深度	0~100 m
浅海温度	30 °C ~ 24 °C
浅海盐度	$30 \times 10^{-12} \sim 35 \times 10^{-12}$
频率	100 Hz ~ 100 kHz
pH	7.8
R_t	10 m

1.3 节点运动模型

在浅海区域,潮汐^[11]是影响传感器节点运动的重要因素之一。节点的速度主要受两部分影响:一是均匀震荡的潮汐场,二是由顺时针和逆时针交替构成的无穷序列组成的剩余场。由于传感器节点配备了深度传感器,它们能够准确获取深度方向的位置信息。因此,东西方向和南北方向的无量纲速度的运动学模式如式(7)所示。

$$\begin{cases} V_x(t) = k_1 \theta \eta \sin(k_2 x) \cos(k_3 y) + \\ k_1 \theta \cos(2k_1 t) + k_4 \\ V_y(t) = -\theta \eta \cos(k_2 x) \sin(k_3 y) + k_5 \end{cases} \quad (7)$$

2 浅海声速预测模型

根据式(1)所述,海洋声速的变化是一个多元且复杂的物理现象。它主要受到海水温度、盐度和深度的直接影响,同时这些物理特性也受到海洋环境、气象条件等多种外部因素的共同作用。一般而言,随着水深的增加,海洋声速倾向于呈现出递增的趋势。然而,当水深达到一定阈值后,由于海水物理特性^[12]的变化趋于稳定,声速的增长速度会显著减缓,甚至可能呈现出稳定或微降的趋势。

此外,海洋环境的季节性变化和气象因素也会对海洋声速产生显著影响,导致声速在时间域内展现出较大的不确定性和非线性变化规律。为了深入研究这种变化规律,本研究基于中国 Arog 实时资料中心提供的数据集^[13],对浅海地区 100 m 深处的历史声速值进行了提取和分析。

为了更直观地展示海洋声速变化的时间相关性,选取了从 2004 年 1 月至 2023 年 12 月共计 240 个月的月平均声速值进行绘图,如图 5 所示。




图 5 浅海声速与时间的关系

Fig. 5 Relation between sound velocity and time in shallow water

从图 5 中可以清晰观察到,海洋声速随时间的变化展现出强烈的时间相关性,并呈现出显著的季节周期性趋势。具体来说,声速值在冬季达到一年中的最低点,而在夏季则攀升至最高点。这一现象表明,海洋声速的变化不仅受到空间维度上环境参数的影响,还与时间因素紧密相关,展现出显著的时间相关性。因此,在水下节点的定位过程中,如果仅仅采用单一的声速值进行定位计

算,可能会导致较大的误差。为了克服这一挑战,本研究通过不同深度的声速值进行预测,来提升水下节点的定位精度。

2.1 长短期记忆神经网络

长短期记忆神经网络^[14] (long short-term memory, LSTM) 是对循环神经网络 (recurrent neural network, RNN) 的改进,旨在解决 RNN 在处理长期依赖关系时遇到的梯度消失和梯度爆炸问题。LSTM 模型的核心在于其引入的“门”机制,这些门结构允许网络在信息传递过程中进行精细的控制。此外,LSTM 网络还能够减少序列长度和网格层数对网络性能的影响,使得模型在处理长序列数据时更加高效和稳定。LSTM 结构如图 6 所示,主要包括输入门、输出门和遗忘门。




图 6 LSTM 结构图

Fig. 6 LSTM structure diagram

遗忘门决定 $t-1$ 时刻记忆细胞中信息的保留和丢弃,即给定的信息可以在内存中保留多长时间以及何时重置记忆单元。输出值介于 0~1 之间,输出值接近 1,保留;输出值接近 0,丢弃。相关公式如式(8)所示。

$$f_t = \sigma(W_f \cdot [y_{t-1}, x_t] + b_f) \quad (8)$$

其中, f_t 为遗忘门参数; W_f 为遗忘门的权重; y_t 为隐藏层输出, x_t 为输入; b_f 为遗忘门偏置矩阵。

输入门决定哪些信息可以输入到记忆单元中以更新细胞的状态。相关公式如式(9)~(11)所示。

$$i_t = \sigma(W_i \cdot [y_{t-1}, x_t] + b_i) \quad (9)$$

$$C'_t = \tanh(W_C \cdot [y_{t-1}, x_t] + b_C) \quad (10)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C'_t \quad (11)$$

其中, i_t 为输入门参数; C'_t 为记忆单元的输入状态; C_t 为细胞状态; $\tanh$ 为双曲正切函数。

输出门则用于过滤记忆单元中的信息,并输出最需要的信息,以预测未来的值。相关公式如式(12)~(13)所示。

$$o_t = \sigma(W_o \cdot [y_{t-1}, x_t] + b_o) \quad (12)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (13)$$

其中, o_t 为输出门参数。

2.2 CNN-LSTM 模型

由于本研究实验数据既包含时间维度信息又涉及空

间维度信息,而经典的 LSTM 网络模型在空间特征捕捉方面存在局限性。为了克服这一挑战,引入了卷积神经网络(convolutional neural networks, CNN)模型,旨在从时间序列数据中提取关键的空间特征。在 CNN-LSTM 模型中, CNN 利用卷积操作有效地捕获数据的空间特征,随后这些特征被传递给 LSTM 网络,使其能够进一步分析和建立时间依赖性。

如图 7 所示,为 CNN-LSTM 结构图,其中 CNN-LSTM 模型的输入序列包括年份序列、月份序列、经度序列、纬度序列、温度序列、盐度序列、深度序列以及声速序列。CNN-LSTM 混合模型的设计,使得模型能够同时兼顾时间序列数据的空间和时间维度信息,从而在处理各类时间序列数据分析任务时展现出强大的适应性,并提高了特征提取的效率和准确性。




图 7 CNN-LSTM 结构图

Fig. 7 CNN-LSTM structure diagram

2.3 声速预测流程

在水下传感器网络中,节点定位作为最热门的研究方向之一。在传统的基于水声信号测距的节点定位方法中,声速常被简化为一个常量值。但在实际的海洋环境中,由于环境因素的复杂性和动态性,如水温、盐度、压力等的变化,水声信号的传播速度并不是恒定的。因此,为了更准确地预测水下声速,提出了基于 CNN-LSTM 的水下声速预测模型,该模型充分考虑声速的时空特性,实现了对声速的有效预测。

如图 8 所示,设计的声速预测模型由 3 个核心部分组成:数据预处理、模型训练和模型预测。在数据预处理阶段,采用 K-折交叉验证法对原始训练数据进行合理的划分,从而捕获水声信号传播过程中的时空特征。随后,对划分后的数据进行归一化处理,消除不同量纲和数值范围对模型训练的潜在影响,从而提高模型的稳定性和预测精度。

在模型训练阶段,将处理后的时空序列数据作为输入,用于训练 CNN-LSTM 混合神经网络模型。该模型结合了 CNN 在捕捉空间特征方面的优势和 LSTM 在处理时序依赖关系上的专长,能够同时从数据中提取出空间和时间两个维度的关键信息。通过多轮次的迭代训练,




图 8 声速预测流程图

Fig. 8 Flow chart of sound velocity prediction

模型不断调整其内部的权重和神经元阈值,以优化预测性能,直至达到最佳状态。

训练结束后,利用该模型对新的水下声速数据进行预测。只需将新的数据输入到已训练好的模型中,模型便会自动进行前向计算,并输出相应的声速预测值。

3 基于声速预测的水下移动节点定位

在水下节点定位过程中,声速通过影响声学测距方法的精度进而影响基于测距的水下节点定位算法^[15]的定位精度,本研究使用基于声速预测的测距修正的 UWSN 定位算法,该算法分为两个步骤:

1) 节点预定位,先通过到达时间差的测距方法计算信标节点和普通节点间的距离,再利用多边定位算法得到普通节点的具有测距误差的位置。

2) 修正误差,通过对信标节点和普通节点间几何关系的分析转换达到减少测距误差的目的。

3.1 TDOA 测距算法

在水下节点定位过程中,由于每个节点都配备了压力传感器,因此只需计算节点的水平坐标。其中,利用 TDOA 测量未知节点与移动信标节点之间的水平距离。

$$d_i = \frac{c_1 c_2 (t_2 - t_1)}{c_1 - c_2} \quad (14)$$

其中, c_1, c_2 分别表示信标节点发出的两个信号的速率, t_1, t_2 分别为邻居节点接收到两个信号的时间。

3.2 自适应移动节点定位算法

由于水下环境的动态性导致节点分布不均匀,因此研究按照参考节点数量的不同来选择合适的未知节点定位方案^[16]。

1) 参考节点大于等于 4 个

当未知节点处于节点密度较大的区域时,为提高节点定位精度,对于此类节点采用融合加权三边定位算法,定位示意图如图 9 所示。

其中, P 为未知节点, A, B, C, D 分别是节点的 4 个参考节点, d_1, d_2, d_3, d_4 分别是未知节点 P 到各个参考节




图 9 融合加权三边定位算法

Fig. 9 Fusion weighted trilateral positioning algorithm

点之间的水平距离,该距离由 3.1 节中的 TDOA 测距算法求出。因此,任取 3 个参考点即可组成一个三角形,以 $\triangle ABC$ 为例,设 A, B, C 3 点坐标为 $(x_1, y_1), (x_2, y_2), (x_3, y_3)$, 水平距离分别为 d_1, d_2, d_3 , 则有:

$$\begin{cases} (x_1 - x)^2 + (y_1 - y)^2 = (d_1 + r_1)^2 \\ (x_2 - x)^2 + (y_2 - y)^2 = (d_2 + r_2)^2 \\ (x_3 - x)^2 + (y_3 - y)^2 = (d_3 + R_3)^2 \end{cases} \quad (15)$$

其中, r 为近距离测距时产生的测距误差, R 为远距离测距时产生的测距误差,通过求解式(15)可得未知节点 P 的估计坐标:

$$\begin{bmatrix} \frac{x_{\Delta 1}}{y_{\Delta 2}} \end{bmatrix} = \frac{1}{2} \begin{bmatrix} x_2 - x_1 & y_2 - y_1 \\ x_3 - x_1 & y_3 - y_1 \end{bmatrix} \times \begin{bmatrix} x_{2,1}^2 + y_{2,1}^2 + (d_1 + r_1)^2 - (d_2 + r_2)^2 \\ x_{3,1}^2 + y_{3,1}^2 + (d_1 + r_1)^2 - (d_2 + R_3)^2 \end{bmatrix} \quad (16)$$

同理,对于其他 3 个三角形也可求得一个估计坐标,设在其他 4 个三角形中最终求得的估计坐标分别为: $(x_{\Delta 1}, y_{\Delta 1}), (x_{\Delta 2}, y_{\Delta 2}), (x_{\Delta 3}, y_{\Delta 3}), (x_{\Delta 4}, y_{\Delta 4})$, 则每个估计坐标的权重为:

$$w_{\Delta i} = \frac{1/d_i}{\sum_{n=1}^4 \frac{1}{d_n}} \quad (17)$$

由此可得,未知节点的水平坐标为:

$$\begin{bmatrix} x \\ y \end{bmatrix} = \sum_{i=1}^4 w_{\Delta i} \begin{bmatrix} x_{\Delta i} \\ y_{\Delta i} \end{bmatrix} \quad (18)$$

2) 参考节点为 3 个

当参考节点只有 3 个时,只能满足三边定位算法的最小数量要求。此时则使用三边定位算法对未知节点进行定位。如图 10 所示, P 为未知节点, A, B, C 为未知节点 P 的 3 个参考节点。未知节点 P 到参考节点 A, B, C 的距离分别是 d_1, d_2, d_3 , 分别以 A, B, C 为圆心, d_1, d_2, d_3 为半径画圆,其交点之处即为未知节点 P 的坐标。

未知节点 P 的求解过程如式(19)所示。

$$\begin{cases} (x_A - x)^2 + (y_A - y)^2 = d_1^2 \\ (x_B - x)^2 + (y_B - y)^2 = d_2^2 \\ (x_C - x)^2 + (y_C - y)^2 = d_3^2 \end{cases} \quad (19)$$




图 10 三边定位算法

Fig. 10 Trilateral positioning algorithm

其中, x, y 为未知节点 P 的纵横坐标;通过求解式(19)可得未知节点 P 的坐标,如式(20)所示。

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 2(x_A - x_C) & 2(y_A - y_C) \\ 2(x_B - x_C) & 2(y_B - y_C) \end{bmatrix}^{-1} \times \begin{bmatrix} x_A^2 - x_C^2 + y_A^2 - y_C^2 + d_3^2 - d_1^2 \\ x_B^2 - x_C^2 + y_B^2 - y_C^2 + d_3^2 - d_2^2 \end{bmatrix} \quad (20)$$

3) 参考节点为 2 个

当未知节点处于节点密度稀疏的区域时,将会出现网络拓扑“空洞”^[17]等问题,为提供节点定位算法的定位覆盖率,当仅有两个参考节点时,通过节点动态选择策略进行定位计算。即当未知节点 P 通信半径范围内只存在 A, B 两个参考节点时,则选择 A, B 节点公共通信半径范围内的节点 C 作为未知节点 P 的第 3 个参考节点辅助定位,如图 11 所示。未知节点 P 可主动与参考节点 A, B 进行通信,获得其与参考节点之间的距离,而未知节点 P 与辅助参考节点 C 之间的距离可由式(21)计算得出。




图 11 公共节点选择

Fig. 11 Public node selection

$$\begin{cases} \cos\alpha = \frac{d_{AB}^2 + d_{BC}^2 - d_{AC}^2}{2d_{AB} \times d_{BC}} \\ \cos\beta = \frac{d_2^2 + d_{BC}^2 - d_3^2}{2d_2 \times d_{BC}} \\ \cos(\alpha + \beta) = \frac{d_{AB}^2 + d_2^2 - d_1^2}{2d_{AB} \times d_2} \\ \cos(\alpha + \beta) = \cos\alpha\cos\beta + \sin\alpha\sin\beta \end{cases} \quad (21)$$

由式(19)可求得未知节点 P 到参考节点 C 的距离 d_3 , 最后通过三边定位算法进行计算求得未知节点坐标。

3.3 TDOA 测距修正

当移动信标节点进行纵向运动时, 会周期性地广播包含自身位置信息及时间戳的数据包。每个邻居传感器节点都可以从同一个信标节点接收到多个数据包, 并选择深度差最小的两个数据包作为参考, 从而计算水平距离。如图 12 所示, 为移动信标与节点之间的测距示意图^[18]。




图 12 移动信标与节点之间的测距

Fig. 12 Ranging between mobile beacon and node

由勾股定理可知:

$$d^2 = d_i^2 - (H - H_i)^2 \quad (22)$$

其中, $d_i = c_i \times \Delta t_i$; $\Delta t_i = t_i - (T_i - \delta/\lambda)$; δ 为相对时钟偏移; λ 为相对时钟倾斜; Δt_i 为移动信标向传感器节点发送的数据包在两者之间的传播时间。

由于水下声速会随着深度的变化而变化, 可考虑通过预测模型中推断得到的分层声速值对声波传播路径的距离进行修正计算。因此当 H_i 与 H 之间的深度差小于 15 m 时, 传播时间 Δt_i 与节点间三维距离 d 的关系可表示为:

$$d^2 = (c_i \times [t_i - (T_i - \delta/\lambda)])^2 - (H - H_i)^2 \quad (23)$$

而当 H_i 与 H 之间的深度差大于 15 m 时, 设水下声速随深度的变化函数为 $c(h)$, Δt_i 与 d 之间的关系可表示为:

$$c_i = \frac{\int_{H_2}^{H_1} c(h) dh}{H_1 - H_2} \quad (24)$$

$$d^2 = \left(\int_{H_2}^{H_1} c(h) dh \left[t_i - \left(T_i - \frac{\delta}{\lambda} \right) \right] \right)^2 - (H - H_i)^2 \quad (25)$$

通过利用声速预测模型得到的分层声速值进行测距修正, 可以显著提高水下节点测距精度, 从而减小最终节点定位结果的误差。

3.4 节点定位流程

MCLS 定位算法的具体定位流程如下:

步骤 1) 数据初始化。对所用数据中存在的异常声速值, 采用相邻数据互补法替换, 并进行 Max-Min 归一化处理;

步骤 2) 划分数据集。将处理之后的数据采用 k -折交叉验证法划分为训练集和测试集两部分;

步骤 3) 构建 CNN-LSTM 预测模型。利用划分好的训练集, 对模型进行多轮次训练, 以调节网络中相应的权重和神经元阈值, 从而使神经网络模型达到最优;

步骤 4) 声速预测。利用训练得到的 CNN-LSTM 模型对水下声速进行预测输出, 得到具有时空特性的声速值;

步骤 5) TDOA 测距修正。利用 TDOA 测距法测得参考节点与未知节点之间的水平距离, 并利用 3.3 节所提到的测距修正法对得到的水平距离进行修正, 从而减小测距误差;

步骤 6) 自适应节点定位。根据未知节点所处区域节点密度的不同, 自适应选择不同的定位方法, 并利用修正后的距离对未知节点进行精确定位;

步骤 7) 重复上述步骤 5)~6), 完成所有节点定位。

4 实验仿真与结果分析

4.1 数据来源和预处理

本研究使用的数据集是我国公开发布的全球海洋 Argo 网格数据集, 选取时间段为 2004 年 1 月到 2023 年 12 月共 240 个月。实验采用数据的前 80% 作为训练集, 剩余的数据作为测试集。当所用数据中存在异常声速值时, 采用相邻数据互补法替换。在建立模型前, 为消除不同模型之间的量纲影响, 避免模型训练复杂化, 采用最大最小归一化方法进行数据预处理。

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (26)$$

其中, x' 为归一化后数据; x 为归一化前的原始数据; $\max(x)$ 、 $\min(x)$ 分别为原始数据集的最大值和最小值。

为了验证 CNN-LSTM 模型的精确性和有效性, 将该模型与 LSTM 模型进行对比实验。其中实验使用的双层

LSTM 模型与 CNN-LSTM 模型架构的不同点在于 LSTM 模型最上层的 LSTM 层被替换为 CNN 层,而其两种模型的底层架构是相同的。模型参数设置如表 2 所示。

表 2 模型参数设置

Table 2 Model parameter settings

参数设置	双层 LSTM 模型	CNN-LSTM 模型
输入长度	60	60
优化器	Adam	Adam
迭代次数	100	100
激活函数	Tanh	Tanh
学习率	0.001	0.001
神经元丢弃率	0.5	0.5
架构	LSTM(32)-LSTM(16)	CNN(32)-LSTM(16)
核函数长度	无	5

如图 13 所示,相较于双层 LSTM 模型预测的双点划线轨迹,MCLS 算法中所构建的 CNN-LSTM 模型所预测的划线轨迹与数据集中真实声速值的实线轨迹展现出更高的重合度,预示着其预测误差更低。因此,该算法所提出的 CNN-LSTM 模型在预测精度上展现出显著优势,其预测结果更加贴近真实值,从而实现了更低的平均声速误差。




图 13 不同模型预测效果对比

Fig. 13 Comparison of prediction effects of different models

如图 14 所示,展示了不同深度声速预测结果。通过 CNN-LSTM 模型对浅海区域不同深度的声速值进行预测,充分证明了所提出的 CNN-LSTM 预测模型不仅具备高度的预测准确性,还展现了极强的可靠性,使得它在处理声速预测等复杂时空序列问题时,能够提供精准且可靠的预测结果。

4.2 定位性能分析

在本次实验中,基于 Python 3.9 平台,充分考虑了海洋中的实际环境特点,模拟了水下传感器节点的部署和动态移动。设定了一个 500 m×500 m×500 m 的三维水下立方体区域随机分布了 40 个浮标节点在水面上、10~50 个信标节点和 150 个未知节点在水下区域中,信标节




图 14 不同深度的声速预测值

Fig. 14 Predicted values of sound velocity at different depths

点配有气囊可自由上下浮动。假设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,在该浅海区域内所有节点的深度均由深度传感器测得,即节点深度已知。节点的发送信息时间为 0.1 s,海水温度和盐度分别设置为 27 ℃和 34×10^{-12} ,pH 为 7.8。通过训练好的 CNN-LSTM 模型对浅海区域内的不同深度的声速值进行预测,并结合适当的定位方法,从而实现对移动节点的精确定位。

本次实验分别从信标节点数和置信值对平均定位误差和定位覆盖度两个方面的影响对 MCLS 定位算法的性能进行分析,并于现有的 SLMP^[19] 定位算法、DMP^[20] 定位算法、NDSMP^[21] 定位算法和 BLSM^[22] 定位算法进行比较分析。其中,平均定位误差定义为所有节点的误差平均值,并将误差对通信距离 R 归一化,如式(27)所示。

$$Er = \frac{1}{N \cdot R} \sum_{i=1}^N \sqrt{(x'_i - x_i)^2 + (y'_i - y_i)^2 + (z'_i - z_i)^2}$$

(27)

通过重复 20 次实验,并统计每次实验的平均误差,定位误差由式(27)计算得到,结果如图 15 所示。由图可知,每次实验的平均定位误差的均值均在 0.1 左右波动,说明本研究所提出的 MCLS 定位算法具有较高的稳定性。

1) 信标节点比例对定位性能的影响

信标节点在实现水下节点精确定位中扮演着至关重要的角色,它们作为参考节点,为普通节点提供了关键的定位信息。因此,信标节点的数量直接影响着整个网络系统的定位性能。

如图 16 所示,对比了 MCLS 定位算法与其他 4 种算法在不同信标节点数量下的定位误差。由图可知,随着信标节点数量的增加,节点的平均定位误差呈现下降趋势。具体而言,当信标节点数量为 10 时,MCLS 定位算法




图 15 平均定位误差
Fig. 15 Average positioning error




图 17 信标节点对定位覆盖度的影响
Fig. 17 Influence of beacon nodes on positioning coverage

的定位误差均值为 0.11;而当信标节点数量增至 50 时, MCLS 定位误差均值显著减少至 0.046,此时相较于其他 3 种算法, MCLS 的定位性能仍然保持领先。这得益于 MCLS 定位算法结合 CNN-LSTM 模型准确预测不同深度下的声速值,并据此通过 TDOA 测距修正技术进一步提升了定位的准确性。




图 16 信标节点对平均定位误差的影响
Fig. 16 Influence of beacon nodes on the average positioning error

图 17 展示了 MCLS 定位算法与其他 3 种算法在不同信标节点数量下的网络定位覆盖度。从图中可以看出,在信标节点数量较少的情况下,定位算法的网络覆盖率也相应较低。然而,随着信标节点数量的增加,5 种算法的网络覆盖率均迅速上升。值得注意的是,当信标节点数量达到 35 时,网络定位覆盖度的增长速度明显放缓,直至几乎不再增加。

MCLS 定位算法之所以在信标节点数量足够多时能够展现出高于其他 4 种定位算法的定位覆盖度,是因为它充分利用了信标节点作为参考节点的优势。随着信标

节点数量的增加,网络中可供选择的参考节点也随之增多,这意味着大多数未知节点都能找到足够多的参考节点来完成精确的定位。因此, MCLS 定位算法能够显著提升网络定位覆盖度,确保更多的未知节点能够被准确地定位。

2) 置信度对定位性能的影响

在定位系统中,置信度是衡量位置估计准确性和可靠性的关键指标。对于水下无线传感器网络中的 MCLS 定位算法,置信度的高低直接关系到普通节点能否作为参考节点参与定位过程。因此,为了找到最佳的置信门限值,进行了模拟实验,通过逐渐增加置信门限值从 0.6~1,以探究不同置信值对定位性能的影响。

如图 18 所示,图中呈现了 MCLS 定位算法与 SLMP 定位算法、DMP 定位算法、NDSMP 定位算法和 BISM 定位算法的定位误差均值随置信值变化的曲线图。从图中可以观察到,随着置信值的逐渐增大,定位误差均值呈现下降趋势,这表明更高的置信度有助于提升定位精度。然而,当置信值增加到 0.9 后,5 种定位算法的定位误差均值却开始随着置信值的增加而逐渐增大。这一现象的原因在于,虽然更高的置信值使 MCLS 定位算法能够更精确地修正 TDOA 测距结果,但当置信值过度增加时,算法会过度依赖那些高置信度的节点,从而忽视了一样重要但置信度稍低的节点。这种选择性的依赖导致了在定位过程中产生较大的误差。

因此,选择合适的置信门限值对于 MCLS 定位算法的性能至关重要,需要在保证定位精度的同时,兼顾节点的多样性和信息的完整性。

如图 19 所示, MCLS 定位算法与 SLMP、DMP、NDSMP 和 BISM 4 种定位算法的定位覆盖率随置信值变化的曲线图清晰地展示了它们之间的关系。随着置信值的逐渐增加,5 种定位算法的定位覆盖度均呈现下降趋




图 18 置信值对平均定位误差的影响

Fig. 18 Influence of confidence value on average positioning error

势,并且在置信值达到 0.9 之后,下降速度明显加快,但 MCLS 定位算法的定位覆盖度整体高于其他 4 种定位算法。这一现象可以归因于 MCLS 定位算法中置信值作为参考节点筛选条件的作用。当设置较高的置信值作为筛选条件时,能够满足这一条件的节点数量将相应减少,从而导致可用作参考节点的数量降低。由于参考节点在定位过程中起着至关重要的作用,其数量的减少会直接影响到定位覆盖度,使得更多的未知节点无法获得足够的参考信息来完成定位。




图 19 置信值对定位覆盖度的影响

Fig. 19 Influence of confidence on positioning coverage

因此,在实际应用中,选择合适的置信门限值对于 MCLS 定位算法的定位性能至关重要。需要在保证定位精度的同时,综合考虑定位覆盖率和参考节点的数量,以实现最优的定位效果。

3) 定位效果图

在信标节点个数设定为 40 且置信值设为 0.7 的条件下,对比了各定位算法的定位效果,如图 20 所示。从图中可以明显看出, MCLS 定位算法在定位效率和定位

覆盖度方面均表现出显著优势。在此信标节点个数下, MCLS 定位算法的定位覆盖度高达 94.62%,明显高于 MDP 定位算法的 79.92%、NDSMP 定位算法的 84.75% 以及 BLSM 定位算法的 90.58%。这一结果充分证明了 MCLS 定位算法在复杂水下无线传感器网络环境中,能够有效利用信标节点信息,实现高效且准确的节点定位。




图 20 各算法定位效果对比图

Fig. 20 Comparison of positioning effects of various algorithms

MCLS 定位算法之所以能够在定位效率和覆盖度上取得如此显著的优势,主要得益于其独特的定位机制。通过精准预测声速值、采用 TDOA 测距修正以及根据水下节点分布情况选择不同定位方法等手段, MCLS 定位算法能够在保证定位精度的同时,实现更广泛的网络覆盖,从而为水下无线传感器网络提供更加可靠的位置信息服务。

5 结 论

本文围绕水下无线传感器网络中移动节点定位精度的提升这一核心问题,创新性地提出了一种基于 CNN-LSTM 声速预测的水下移动节点定位算法 (MCLS 定位算法)。该研究的核心思路在于利用卷积神经网络 (CNN) 强大的特征提取能力与长短期记忆网络 (LSTM) 在序列数据处理上的优势,构建了一个混合模型以精确预测复杂水下环境中的声速变化,进而克服因声速波动导致的定位误差。此核心技术不仅解决了传统方法难以有效捕捉声速动态特性的难题,还通过引入自适应定位策略,针对不同节点密度灵活调整定位方法,显著提升了算法的适用性和定位精度。

本研究的难点技术主要体现在两方面:一是如何高效融合 CNN 与 LSTM 以准确预测声速,这要求模型既能捕捉声速数据的空间特征,又能理解其时序变化;二是在如何在复杂多变的水下环境中,基于预测声速值实现移动节点的精确定位,这涉及对传统 TDOA 测距方法的优化

与改进,以及自适应定位策略的设计。

本文的工作充分展示了 CNN-LSTM 模型在声速预测及水下节点定位领域的巨大潜力,其先进性体现在对复杂环境的高精度适应性以及对传统方法的显著改进。此外,针对实际应用中可能遇到的计算复杂度问题,本文虽已提出优化思路,但未来工作应进一步探索轻量化模型架构,或结合分布式计算技术,以降低算法的计算资源消耗,提高算法在实际应用中的效率和可扩展性。展望未来,随着水下传感器网络技术的不断发展,本文所提出的 MCLS 定位算法有望在海洋监测、水下导航等领域发挥重要作用,推动水下定位技术的进一步发展。

参考文献

- [1] 苏毅珊,张贺贺,张瑞,等. 水下无线传感器网络安全研究综述[J]. 电子与信息学报, 2023, 45(3): 1121-1133.
SU Y SH, ZHANG H H, ZHANG R, et al. Review on underwater wireless sensor network security [J]. Journal of Electronics and Information Technology, 2023, 45(3): 1121-1133.
- [2] ISLAM I S, SEOKJOO S. Survey on multi-path routing protocols of underwater wireless sensor networks: Advancement and applications [J]. Electronics, 2022, 11(21): 3467-3467.
- [3] 孙玉臣,陈维义,王平波,等. 蛙人水下声信号特征研究综述[J]. 声学技术, 2022, 41(4): 479-488.
SUN Y CH, CHEN W Y, WANG P B, et al. Frogman underwater acoustic signal characteristics research review [J]. Journal of Acoustic Technology, 2022, 9(4): 479-488.
- [4] 郝梦华. 基于浅海多径结构的复合码水声测距研究[D]. 天津: 天津大学, 2020.
HAO M H. Composite code based on the structure of shallow sea multipath underwater acoustic ranging research [D]. Tianjin: Tianjin University, 2020.
- [5] MAMTA N, NITIN G. Energy efficient localization through node mobility and propagation delay prediction in underwater wireless sensor network [J]. Wireless Personal Communications, 2021, 122(3): 2667-2685.
- [6] ZHAN D ZH, WANG S T, CAI SH G, et al. Acoustic localization with multi-layer iso gradient sound speed profile using TDOA and FDOA [J]. Frontiers of Information Technology Electronic Engineering, 2023, 24(1): 164-175.
- [7] 王领,申晓红,康玉柱,等. 水声传感器网络信号到达时间差目标定位的最小二乘法估计性能[J]. 兵工学报, 2020, 41(3): 542-551.
WANG L, SHEN X H, KANG Y ZH, et al. Estimation performance of least square method for signal arrival time difference in underwater acoustic sensor networks [J]. Journal of Ordnance Engineering, 2019, 41(3): 542-551.
- [8] QIN Y H, SUN Y H, LIN H R, et al. Joint time synchronization and localization of underwater mobile node[J]. Wireless Networks, 2023, 29(8): 3737-3746.
- [9] 代伟. 水声信道特性与信号在水声信道中的传播特性研究[J]. 舰船电子工程, 2023, 43(7): 200-204.
DAI W. Study on characteristics of underwater acoustic channel and signal propagation characteristics in underwater acoustic channel [J]. Ship Electronic Engineering, 2023, 43(7): 200-204.
- [10] 邓玉芬,蒋其伟,吴双林,等. 海底底质特性对浅海声传播影响分析[J]. 海洋测绘, 2023, 43(4): 33-37.
DENG Y F, JIANG Q W, WU SH L, et al. Analysis of the influence of submarine sediment characteristics on sound propagation in shallow sea [J]. Marine Surveying and Mapping, 2023, 43(4): 33-37.
- [11] 邬红涛. 基于全球潮汐模型的东海海域潮汐性质空间分布[J]. 海岸工程, 2021, 40(4): 269-276.
WU H T. Spatial distribution of tidal properties in the East China Sea based on global tidal model [J]. Coastal Engineering, 2021, 40(4): 269-276.
- [12] LIANG ZH, MENG CH X, XIAO H T. Comparison of sound propagation characteristic between deep and shallow water [J]. Applied Mechanics and Materials, 2014, 577: 1198-1201.
- [13] 谢春虎,徐苗苗,曹莎莎,等. 基于梯度依赖客观分析技术的全球 Argo 网格化数据集: 构建及初步应用[J]. 海洋学研究, 2019, 37(4): 24-35.
XIE CH H, XU M M, CAO SH SH, et al. Global Argo grid-based data set based on gradient-dependent objective analysis: construction and preliminary application [J]. Journal of Marine Sciences, 2019, 37(4): 24-35.
- [14] 王世明,张少童,娄嘉奕. 基于 CNN-LSTM-ARIMA 的超短期风速预测研究[J/OL]. 新能源进展, 1-9 [2024-05-01]. <http://kns.cnki.net/kcms/detail/44.1698.TK.20240109.1025.002.html>. WANG SH M, ZHANG SH T, LOU J Y. Research on ultra-short term wind speed prediction based on CNN-LSTM-ARIMA [J/OL]. New energy development, 1-9 [2024-05-01]. <http://kns.cnki.net/kcms/detail/44.1698.TK.20240109.1025.002.html>.
- [15] 纪平,郭瑛. 基于长短期记忆网络修正测距的水下定位算法[J]. 计算机与现代化, 2022(2): 52-57.
JI P, GUO Y. Underwater location algorithm based on long short term memory network modified ranging [J]. Computer and Modernization, 2022(2): 52-57.
- [16] 张瑞. 海洋传感器网络的节点定位与轨迹预测研究[D]. 青岛: 青岛科技大学, 2023.

ZHANG R. Ocean sensor network node location and trajectory prediction research [D]. Qingdao: Qingdao University of Science and Technology, 2023.

- [17] 刘浩然,覃玉华,邓玉静,等. 基于双层修正无迹卡尔曼的水下节点定位算法[J]. 仪器仪表学报, 2020, 41(3): 142-149.

LIU H R, QIN Y H, DENG Y J, et al. Based on double fixed no trace kalman underwater node localization algorithm [J]. Journal of Instruments and Meters, 2020, 9 (3) : 142-149.

- [18] 陈嘉兴,程杰,董云玲,等. 基于弯曲声线和测距修正的水下节点定位算法[J]. 电子学报, 2022, 50(7): 1567-1572.

CHEN J X, CHENG J, DONG Y L, et al. Underwater node location algorithm based on bending sound line and distance correction [J]. Acta Electronica Sinica, 2022, 50(7): 1567-1572.

- [19] 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.

JIN Z Y, LYU W J, LIU L P. Real-time positioning algorithm for underwater sensor network based on ocean current model [J]. Sensors and Microsystems, 2017, 36(12): 149-152.

- [20] ZHANG W, HAN G, 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.

- [21] LI R, YIN H X, WANG J Y, 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.

- [22] 彭铎,曹坚,黎亚亚. 基于动态贝叶斯 LS-SVM 的水下节点移动预测定位算法[J]. 电子测量与仪器学报, 2023, 37(10): 134-144.

PENG D, CAO J, LI Y Y. Underwater node movement prediction and positioning algorithm based on dynamic Bayes LS-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2023, 5 (10) : 134-144.

作者简介



彭铎, 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 received his B. Sc. degree from Gansu University

of Technology in 1998, the M. Sc. degree from Lanzhou University of Technology in 2009, and the Ph. D. degree from Lanzhou University of Technology in 2019. He is now an associate professor of Lanzhou University of Technology. His main research interests include wireless sensor networks and fibre-optic communication.



查海音(通信作者), 2023 年于宝鸡文理学院获得学士学位, 现为兰州理工大学在读硕士研究生, 主要研究方向为无线传感器网络。

E-mail: 17868468842@163.com

Cha Haiyin (Corresponding author)

received her B. Sc. degree from Baoji College of Arts and Sciences in 2023. She is now a M. Sc. candidate at Lanzhou University of Science and Technology. Her main research interest includes wireless sensor networks.



曹坚, 2021 年于商洛学院获得学士学位, 2024 年于兰州理工大学获得硕士学位, 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 College in 2021 and the M. S. degree from Lanzhou University of Science and Technology in 2024. His main research interest includes wireless sensor networks.



张彦博, 2022 年于华北科技学院获得学士学位, 现为兰州理工大学在读硕士研究生, 主要研究方向为无线通信理论与技术, 室内定位。

E-mail: 2788875969@qq.com

Zhang Yanbo received his B. Sc. degree

from North China Institute of Science and Technology in 2022. He is now a M. Sc. candidate at Lanzhou University of Science and Technology. His main research interests include wireless communication theory and technology, indoor positioning.



张明虎: 2006 年于天水师范学院获得学士学位, 2012 年于兰州大学获得硕士学位, 2021 年于中国科学院大学获得博士学位, 现为兰州理工大学计算机与通信学院副教授, 主要研究方向为物联网、计算机视觉、遥感图像处理。

E-mail: zhangmh@lut.edu.cn

Zhang Minghu received his B. Sc. degree from Tianshui Normal College in 2006, the M. Sc. degree from Lanzhou University in 2012, and the Ph. D. degree from University of Chinese Academy of Sciences in 2021. He is now an Associate Professor at the School of Computer and Communication, Lanzhou University of Science and Technology. His main research interests include internet of things, computer vision, and remote sensing image processing.