

观测站参数误差下联合多特征融合注意力机制的 TDOA/FDOA 多机无源定位算法

彭 铎, 刘明硕, 谢 堃

(兰州理工大学 计算机与人工智能学院, 兰州 730050)

摘 要:在实际定位场景下,观测站通常被设置在实时移动的平台,导致观测站测量的待测目标运动状态信息存在观测噪声误差。这些误差会影响观测站接收的信息,进而导致目标源位置估计产生较大的偏差。为解决该问题,提出了一种观测站参数误差下融合注意力机制(AM)的卷积神经网络(CNN)和双向长短期记忆(BiLSTM)网络的时差频差(TDOA/FDOA)多机无源定位算法,同时该算法结合了改进的两步加权最小二乘法和 CNN-BiLSTM-Attention 模型。通过修正测量值并改善两步法在存在观测噪声的情况下估计性能下降的问题,提高了定位精度。仿真对比结果表明,本文提出的算法在存在观测噪声的情况下表现出良好的性能。

关键词:无源定位;时差频差;双向长短期记忆网络;注意力机制;两步加权最小二乘

中图分类号:TP393 **文献标志码:**A **文章编号:**1671-5497(2025)11-3751-11

DOI:10.13229/j.cnki.jdxbgxb.20240295

Observation station parameter error joint multi-feature fusion attention mechanism TDOA/FDOA multi-aircraft passive localization algorithm

PENG Duo, LIU Ming-shuo, XIE Kun

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

Abstract: In the real-world positioning environment, observation stations are often set on mobile platforms, leading to measurement noise errors in the motion state information of the target to be measured as detected by the observation stations. These errors can affect the information received by the observation stations, thereby causing significant deviations in the estimation of the target source's position. To address this issue, a time-difference frequency-difference (TDOA/FDOA) multi-aircraft passive localization algorithm is proposed, which fusion the attention mechanism (AM), convolutional neural network (CNN), and bidirectional long short-term memory (BiLSTM) network under observation station parameter errors. Meanwhile, which integrates an improved two-step weighted least squares method and a

收稿日期:2024-03-22.

基金项目:国家自然科学基金项目(62061024,62265010);甘肃省科技计划项目(23YFGA0062);甘肃省创新基金项目(2022A-215).

作者简介:彭铎(1976-),男,副教授,博士.研究方向:无线传感器网络,光纤网络,无线通信.

E-mail:pengduo7642@163.com

CNN-BiLSTM-Attention model. By correcting measurement values and improving the issue of the estimation performance degradation of the two-step method in the presence of observation noise, the accuracy of localization is improved. The results of the simulation comparisons show that the algorithm proposed in this paper demonstrates good performance in the presence of observation noise.

Key words: passive localization; time-difference frequency-difference; bidirectional long short-term memory network; attention mechanism; two-step weighted least squares

0 引言

无源定位技术是一种在目标发生机动时,仍然能准确跟踪目标运动轨迹的技术^[1,2]。该技术主要依赖于建立和利用目标运动模型,通过传感器获取目标的有噪观测值,再借助信号处理技术估计目标的状态特征,如位置、速度等^[3,4]。

目前,针对目标源和参考观测站之间存在相对运动的情况,研究者提出了多种方法,以提高位置估计精度并实现对移动辐射源的速度估计^[5,6]。文献[7]提出了一种基于泰勒级数展开的非完全约束加权最小二乘法,用于改进 TDOA/FDOA 联合定位。然而,当观测站观测噪声过大且无法估计时,该方法第一步的观测定位会产生较大的误差,导致二次规划对目标观测定位误差的改进效果并不明显^[8-10]。文献[11]针对观测站存在位置误差时传统时差定位方法精度不足的问题,提出了一种基于观测站精确距离信息的高精度时差定位方法。不同于传统的两步加权最小二乘法,这在实际应用场景中是一个明显的局限性,因为低信噪比环境常导致定位精度大幅下降。此外,文献[12]提出了一种考虑观测站位置状态信息存在随机误差的移动辐射源定位方法,该方法利用到达时间差和到达频率差测量值。然而,麻雀优化算法容易出现早熟、局部最优、收敛速度慢等问题,使得定位效果不稳定。综上所述,目前针对目标源和参考观测站之间存在相对运动的情况,虽然已经提出了一些方法以提高位置估计精度并实现对移动辐射源的速度估计,但是这些方法在噪声较大或观测站位置状态信息存在随机误差的情况下,仍存在一定的局限性和改进空间。文献[13]针对锚点位置误差,提出了 EM 算法,该算法通过迭代优化锚点位置提高节点定位精度,且收敛快速、结果准确,尤其适用于锚点位置不准确的场景。但是文献[13]的算法对运动锚节点的定位精度较差。文献[14]提出了一种联合同步和本地

化框架的算法,该算法不仅考虑了节点的位置估计,还处理了时钟偏差问题。通过利用正则化理论和改进泰勒级数,该算法能够给出信源位置和时钟偏差的代数解,并在不准确的初始条件下保持较高的鲁棒性。但是该算法对传感器节点要求过高,且通信开销较大。

研究者主要从修正 TDOA/FDOA 值和解决两步加权最小二乘法在求解非线性方程组时出现的一系列数学问题两个角度,解决 TDOA/FDOA 联合定位中定位精度受限的问题。在修正 TDOA/FDOA 值方面,受时差频差测量误差、非视距传播、基站选择、算法复杂度等因素影响,TDOA/FDOA 无源定位精度受限,特别是在环境复杂多变的情况下。机器学习强大的建模能力为克服 TDOA/FDOA 无源定位精度受限提供了新的思路。为了解决时差频差测量存在误差的问题,文献[15]提出了一种基于改进双向长短期记忆(Bidirectional long short-term memory, BiLSTM)神经网络的方法,该方法结合了小波包变换和 BiLSTM 网络的强大功能。通过 Daubechies 10 和 Symlets 8 小波包变换对振动数据进行时频特征分解,再利用 BiLSTM 网络捕捉时序信息,该方法能够准确识别轴承的故障类型和程度。该方法不仅有效处理了振动数据的非平稳特性,还通过引入注意力机制进一步提升了模型性能。由此可以看出,BiLSTM 神经网络可以解决多种预测问题,并且具有良好的预测精度。本文提出了一种融合注意力机制(Attention mechanism, AM)的卷积神经网络(Convolutional neural network, CNN)和 BiLSTM 网络的 TDOA/FDOA 修正方法,将数据检测与深度学习模型相结合,以提升 TDOA/FDOA 测量精度。本文主要贡献如下:

(1) 本文提出一种联合 CNN-BiLSTM-Attention 的深度学习混合模型,用于处理 TDOA/FDOA 值。其中,CNN 用于提取局部特征;BiL-

STM用于捕捉时序信息;Attention机制不仅可以帮助模型关注对修正起重要作用的特征,还可以降低预测误差。

(2)改进的两步加权最小二乘法可以更好地处理非线性问题,使算法在复杂环境下的性能更加稳定。同时,该算法能够通过加权矩阵平衡不同观测站的测量误差,从而提高整体定位的准确性。

(3)本文通过验证不同数量的移动观测站对位置估计误差和速度估计误差的影响发现,增加观测站的数量并没有显著提升位置估计和速度估计的准确性,如果一直增加观测站的数量,就会造成资源浪费和数据过载。因此,在增加观测站数据的同时,需进行合理的数据筛选和分析,以确保

数据的有效性和可靠性。

1 融合注意力机制和CNN-BiLSTM的TDOA/FDOA修正方法

1.1 TDOA/FDOA修正框架

本文旨在噪声影响严重的环境下,当样本受到严重干扰且噪声大小难以估计时,对TDOA/FDOA值进行修正,使之能够在低信噪比条件下实现优越的修正效果,从而提高定位精度。对此本文提出TDOA/FDOA值修正方法,该方法结合了数据检测和深度学习模型^[16]。该方法的整体修正架构如图1所示,主要包括3个模块,即数据预处理模块、TDOA/FDOA修正模块和预测效果评估模块。




图1 TDOA/FDOA修正框架

Fig. 1 TDOA/FDOA correction framework

数据预处理模块用于对原始数据进行清洗、转换和归一化处理,以提高数据的可靠性和有效性。

TDOA/FDOA修正模块用于对定位系统中的时间差异和频率差异进行修正,以提高定位精度和准确性。该模块可以根据实际情况对观测站测量数据进行修正,消除误差和噪声,从而提高定位系统的性能。

预测效果评估模块用于对建立的预测模型进行评估和验证,以确定模型的准确性和可靠性,从而帮助用户了解模型的预测效果。

1.2 CNN-BiLSTM的TDOA/FDOA修正模型

CNN-BiLSTM的TDOA/FDOA修正模型是一种融合了CNN和BiLSTM的混合机器学习模型(见图2),用于提高复杂环境TDOA和FDOA测量的定位精度。该模型利用CNN自动提取特征的能力,以及BiLSTM处理序列数据时兼顾上下文信息的优势,通过学习和修正由多径效应、环境噪声、非视距传播等因素引起的定位误差,为目标位置和速度估计提供更加准确的结果。因此,CNN-BiLSTM的TDOA/FDOA修正模型能够在一定程度上提高定位精度和鲁棒性。




图2 CNN-BiLSTM-Attention模型网络结构图

Fig. 2 Network structure diagram of CNN-BiLSTM-Attention model

1.3 纵向特征提取模块

本文纵向特征提取模块的核心为 CNN。CNN 是一种能够有效捕获空间和频谱特征的深度学习模型,能够从原始输入数据中提取丰富的特征信息,其结构图如图 3 所示。在 TDOA/FDOA 修正模型中,通过对接收信号进行卷积操作,CNN 可以提取出对目标定位有帮助的关键特征,如信号的时频特性和空间分布特征,为后续目标定位提供重要的信息支持^[17]。以 TDOA/FDOA 数据作为输入,卷积运算公式为:

$$z_j^l = \sum_{i=1}^m z_j^{l-1} \times k_{ij}^l + b_j^l, j=1, 2, \dots, n \quad (1)$$

式中: z_j^l 为卷积输出第 j 个特征面的特征向量; z_j^{l-1} 为第 i 个输入的 TDOA/FDOA 值; k_{ij}^l 为连接第 i 个输入特征面的第 j 个卷积核的参数; b_j^l 为第 j 个卷积核的偏置。卷积属于线性计算,通过将输入数据与卷积核逐元素相乘后求和,可以提取数据的线性特征。同时,卷积操作在通过输入序列上滑动卷积核,能够捕获输入数据中局部模式的结构特征。




图 3 CNN 结构图

Fig. 3 CNN structure diagram

CNN 在 TDOA/FDOA 修正模型中的另一个作用是空间信息建模。目标定位涉及多个观测站接收的信号,这些信号包含的空间信息对目标的精准定位至关重要。作为一种能够有效捕获空间特征的模型,CNN 可以通过卷积操作学习不同观测站之间的空间关系,实现对空间信息的有效建模。这种空间信息建模方法有助于修正 TDOA/FDOA 估计中可能存在的误差,提高目标定位的精度和鲁棒性。

1.4 横向特征提取模块

本文横向特征提取模块的核心为 BiLSTM 网络。BiLSTM 在 TDOA/FDOA 修正模型中的关键作用是时序建模。BiLSTM 网络通过同时处理输入序列的前向和后向信息,可以更全面地理解序列数据的上下文信息。BiLSTM 网络有两个独立的 LSTM 层,一个用于处理输入序列的前向

信息,另一个用于处理后向信息。每个 LSTM 层都有各自的隐藏状态和记忆单元,可以捕捉序列中的长期依赖关系并对序列数据进行建模^[18]。

图 4 为 LSTM 单元结构,其中, x_t 为 t 时刻输入, h_t 为 t 时刻隐层输出, C_t 为 t 时刻记忆单元, C_t 为临时记忆单元, $\oplus$ 表示元素级加法运算, $\otimes$ 表示元素级乘法运算。 C_t 中的信息由遗忘门决定, C_t 的输出结果由输出门控制,具体计算公式为:

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t \otimes C_{t-1} \oplus i_t \otimes C_t \\ O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = O_t \otimes \tanh C_t \end{cases} \quad (2)$$

式中: W_f, W_i, W_c, W_o 为图 4 中各模块对应的权重矩阵; b_f, b_i, b_c, b_o 为对应网络的偏置向量; σ 为 Sigmoid 激活函数; $\tanh$ 为双曲正切激活函数。




图 4 LSTM 单元结构

Fig. 4 LSTM cell structure

此外, BiLSTM 在信息融合方面也发挥了重要作用。在 TDOA/FDOA 修正模型中,来自不同观测站的多源信息需被有效融合,以提高定位和修正的准确性。BiLSTM 凭借其双向结构,可以同时考虑过去信息和未来信息,从而更好地融合不同观测站的信息,提升整体模型的性能。BiLSTM 网络结构如图 5 所示。

BiLSTM 网络的计算公式为:

$$\begin{cases} \vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{LSTM}(x_t, \overleftarrow{h}_{t-1}) \\ y_t = \sigma(W_y \cdot [\vec{h}_t, \overleftarrow{h}_t] + b_y) \end{cases} \quad (3)$$

式中: $\vec{h}$ 为当前时刻前向隐层状态; $\overleftarrow{h}$ 为后向隐层状态; W_y 为网络的权重矩阵; b_y 为网络的偏置项。




图 5 BiLSTM 网络结构

Fig. 5 BiLSTM network structure

BiLSTM 在 TDOA/FDOA 修正模型中的另一个关键作用是时序建模。TDOA/FDOA 修正模型需对输入信号的时序信息进行建模,以便准确地计算时差或频差。BiLSTM 作为一种适合处理时序数据的神经网络结构,可以有效地学习和捕获信号中的时序模式,为 TDOA/FDOA 修正模型提供精准的时序建模能力。

1.5 注意力机制

在 TDOA/FDOA 修正模型中引入注意力机制(见图 6)后,模型可更精准地关注输入数据中与定位相关的信息,从而提高定位的准确性和稳定性。通过为不同部分数据赋予不同的注意权重,注意力机制使模型更好地理解 and 利用输入数据,从而提高整体性能^[19]。注意力机制的实现需要执行以下操作:




图 6 注意力机制

Fig. 6 Attention mechanism

(1) 对输入序列 $y=[y_1, y_2, \dots, y_n]$ 进行编码,得到一组查询向量 q 。

(2) 通过打分函数得到数据间的相似度 $[s_1, s_2, \dots, s_n]$, 具体计算公式为:

$$s(y_i, q) = V^T \tanh(W y_i + U q) \quad (4)$$

式中: V, W, U 均为待学习参数矩阵。通过 Softmax 函数对数据进行归一化,得到每组输入向量的权重,即:

$$a_i = \text{Softmax}(s(y_i, q)) = \frac{\exp(s(y_i, q))}{\sum_{i=1}^n \exp(s(y_i, q))} \quad (5)$$

(3) 根据权重和对应的值向量计算加权和,最终得到预测的 TDOA/FDOA 值 a , 即:

$$a = \sum_{i=1}^n a_i \quad (6)$$

2 基于 TDOA/FDOA 的无源定位算法

2.1 TDOA/FDOA 联合定位模型

TDOA/FDOA 联合定位模型是一种利用时差到达和频差到达测量技术实现目标定位的方法。该模型融合了时差到达和频差到达两种测量技术的优势,能够提供更准确、更可靠的目标定位结果。通过分析目标信号在不同观测站间的到达时间和频率差异, TDOA/FDOA 联合定位模型可以有效地抑制测量误差和环境干扰,从而实现对目标位置的精确定位。然而,在样本受到环境噪声影响严重且噪声大小无法估计的情况下, TDOA/FDOA 的测量会产生较大误差。

本文主要研究三维定位场景, M 个移动接收机随机部署,作为目标源 S_T 的 TDOA/FDOA 联合定位观测站。移动接收机的位置信息为 $S_i = (x_i, y_i, z_i)$, 速度信息为 $\dot{S}_i = (\dot{x}_i, \dot{y}_i, \dot{z}_i)$ 。通常选择第一个接收机作为参考接收机,称作 1 号接收机,其位置为 $S_1 = (x_1, y_1, z_1)$, 速度为 $\dot{S}_1 = (\dot{x}_1, \dot{y}_1, \dot{z}_1)$, 移动目标辐射源的位置与速度分别假设为 $S_T = (x, y, z)$, $\dot{S}_T = (\dot{x}, \dot{y}, \dot{z})$ 。为了求解移动目标辐射源的位置信息和速度信息,至少需要 4 个接收机同时产生 3 个 TDOA/FDOA 参数。因此,本文主要研究的时差频差无源定位问题,均在接收机数量 > 4 的情况下讨论。本文用上标符号“ $\circ$ ”表示物

理真实值。TDOA/FDOA 的定位场景如图 7 所示。




图 7 TDOA/FDOA 联合定位模型

Fig. 7 TDOA/FDOA joint positioning model

将 r_i^0 定义为移动目标辐射源与第 i 个接收机之间的真实距离,其计算公式为:

$$r_i^0 = \|S_T, S_i\| = \sqrt{(S_T - S_i)^T (S_T - S_i)} \quad (7)$$

由于不同接收机距离移动目标辐射源的位置各不相同,因此不同接收机接收的信号存在时间差,该时间差也反映了接收机与移动目标辐射源的距离差,其关系表达式为:

$$r_{i1}^0 = r_i^0 - r_1^0 = c\Delta t_{i1} \quad (8)$$

式中: r_{i1}^0 为第 i 个接收机与参考接收机(1号接收机)的距离差; c 为电磁波信号的传播速度。

对式(7)、式(8)进行简单数学变换后,可得 TDOA 方程,即:

$$2(S_i - S_1)^T S_T + 2r_{i1}^0 r_1^0 = S_i^T S_i - S_1^T S_1 - r_{i1}^0, \quad i = 1, 2, \dots, M \quad (9)$$

TDOA 方程只能计算移动目标辐射源的位置信息,无法估计目标速度。当移动目标辐射源与接收机存在相对运动时,接收机会测量到多普勒频率变化,利用产生的频率差即可估计目标移动速度,同时提高移动目标辐射源的位置估计精度。

设移动目标辐射源辐射的电磁波信号中心频率为 f_0 ,接收机观测的多普勒频率变化为:

$$\dot{r}_i^0 = \frac{(\dot{S}_T - \dot{S}_i)^T (\dot{S}_T - \dot{S}_i)}{r_i^0} \quad (10)$$

各接收机接收的电磁波信号与 1 号参考接收机接收的电磁波信号的频率差为:

$$f_{i1}^0 = f_i - f_1 = \frac{1}{c}(\dot{r}_i - \dot{r}_1) \quad (11)$$

同理,对式(10)、式(11)进行简单数学变换后,可得 FDOA 方程,即:

$$\begin{aligned} & (\dot{S}_i - \dot{S}_1) S_T + (S_i - S_1) \dot{S}_T + \dot{r}_{i1}^0 r_1^0 + r_{i1}^0 \dot{r}_1^0 \\ &= \dot{S}_1^T S_i - \dot{S}_1^T S_1 - \dot{r}_{i1}^0 r_{i1}^0, \quad i = 1, 2, \dots, M \end{aligned} \quad (12)$$

定义待测变量 $x = [S_T \ r_1^0 \ \dot{S}_T \ \dot{r}_1^0]^T$,其中包含移动目标辐射源的位置与速度、1号参考接收机与移动目标辐射源的真实距离、多普勒频率变化。联立 TDOA 方程和 FDOA 方程,可得:

$$G^0 x = h^0 \quad (13)$$

其中:

$$G^0 = -2 \begin{bmatrix} S_1^T & r_{21}^0 & 0^T & 0 \\ \vdots & \vdots & \vdots & \vdots \\ S_M^T & r_{M1}^0 & 0^T & 0 \\ \dot{S}_1^T & \dot{r}_{21}^0 & S_1^T & r_{21}^0 \\ \vdots & \vdots & \vdots & \vdots \\ \dot{S}_M^T & \dot{r}_{M1}^0 & S_M^T & r_{M1}^0 \end{bmatrix} \quad (14)$$

$$h^0 = \begin{bmatrix} r_{21}^0 - S_1^T S_1 \\ \vdots \\ r_{M1}^0 - S_M^T S_M \\ 2(\dot{r}_{21}^0 r_{21}^0 - \dot{S}_1^T S_1) \\ \vdots \\ 2(\dot{r}_{M1}^0 r_{M1}^0 - \dot{S}_M^T S_M) \end{bmatrix} \quad (15)$$

同时,存在以下约束关系:

$$r_1^0 = \sqrt{S_T^T S_T} \quad (16)$$

$$\dot{r}_1^0 = \frac{S_T^T \dot{S}_T}{r_1^0} \quad (17)$$

式中: G^0 、 h^0 中的 r_i^0 、 $\dot{r}_i^0$ 在实际场景中均存在噪声干扰的情况。若考虑噪声干扰产生的影响,则有:

$$Gx = h + \epsilon \quad (18)$$

式中: ϵ 为与 TDOA/FDOA 观测噪声相关的误差矩阵。此时代价函数表示为:

$$J = (Gx - h)^T W (Gx - h) \quad (19)$$

由此,移动目标辐射源的定位问题转化为在最小化代价函数 J 的前提下求解未知变量 x 。

2.2 基于改进两步加权最小二乘法的 TDOA/FDOA 定位算法

TDOA/FDOA 定位算法通过测量信号到达时间差和频率差,实现对物体位置和速度的估计。其本质是求解高度非线性的 TDOA/FDOA 方程组,两步加权最小二乘法(Two-stage weighted least squares, TSWLS)被用于求解 TDOA/

FDOA 方程组。然而,传统的两步加权最小二乘法在处理 TDOA/FDOA 定位问题时存在局限性,因此需要对其进行改进^[20]。

在两步加权最小二乘法的第二步中,为了将非线性方程线性化,本文引入 $[r_i \dot{r}_i]$ 作为辅助变量, $[S_T \dot{S}_T]$ 作为求解变量,同时将两者的关系作为第二步的估计依据。为了提高估计精度,本文考虑引入其他有效信息:

$$S_T^\circ = S_T - \Delta S \quad (20)$$

$$\dot{S}_T^\circ = \dot{S}_T - \Delta \dot{S} \quad (21)$$

将式(20)(21)重新代入式(8)(10)中,经过简单的数学运算可得:

$$S_T \Delta S - r_1 n_1 = \frac{1}{2} (S_T^T S_T + S_1^T S_1 - r_1^2) - S_1^T S_T \quad (22)$$

$$\dot{S}_T \Delta S + \dot{S}_T \Delta \dot{S} - \dot{r}_1 n_1 - r_1 \dot{n}_1 = \dot{S}_T^T S_1 + \dot{S}_1^T S_T - \dot{r}_1 r_1 - \dot{S}_1^T S_T - S_1^T \dot{S}_T \quad (23)$$

将式(22)(23)中的噪声项整理替换为:

$$\Delta S = S_T - S_T^\circ \quad (24)$$

$$\Delta \dot{S} = \dot{S}_T - \dot{S}_T^\circ \quad (25)$$

整理可得:

$$G_2 x_2 = h_2 + \epsilon_2 \quad (26)$$

式中: $x_2 = [S_T^{\circ T} \dot{S}_T^{\circ T}]^T$ 。 G_2 、 h_2 的表达式分别为:

$$G_2 = \begin{bmatrix} I & O \\ S_1^T & 0^T \\ O & I \\ \dot{S}_1^T & S_1^T \end{bmatrix} \quad (27)$$

$$h_2 = \begin{bmatrix} S_T \\ \frac{1}{2} (S_T^T S_T + S_1^T S_1 - r_1^2) \\ \dot{S}_T \\ \dot{S}_1^T S_T + \dot{S}_1^T S_1 + \dot{r}_1 r_1 \end{bmatrix} \quad (28)$$

因此, x_2 的加权最小二乘估计为:

$$x_2 = (G_2^T W_2 G_2)^{-1} G_2^T W_2 h_2 \quad (29)$$

$$B_2 = \begin{bmatrix} I & 0 & O & 0 \\ S_1^T & r_1 & 0 & 0 \\ O & 0 & I & 0 \\ \dot{S}_1^T & r_1 & S_1^T & r_1 \end{bmatrix} \quad (30)$$

此时,移动目标辐射源的位置与速度估计为:

$$S_T = U \left[\sqrt{x_2(1)}, \sqrt{x_2(2)}, \sqrt{x_2(3)} \right]^T + S_1$$

$$\dot{S}_T = U \left[\frac{x_2(4)}{\sqrt{x_2(1)}} \quad \frac{x_2(5)}{\sqrt{x_2(2)}} \quad \frac{x_2(6)}{\sqrt{x_2(3)}} \right]^T + \dot{S}_1 \quad (31)$$

$$U = \text{diag}[\text{sgn}(x_u - s_1)] \quad (32)$$

$$x_u = [x(1) \ x(2) \ x(3)]^T \quad (33)$$

式中: $\text{sgn}(\cdot)$ 为符号函数; $x(i)$ 为 x 的第 i 个元素。

总之,通过迭代计算第一步和第二步的估计值,直至两步估计的误差小于预先设定的阈值,或算法达到预设的迭代次数,即可得到目标速度和位置的最佳估计结果。

3 实验仿真

3.1 模型的预测性能验证

为了验证融合注意力机制和 CNN-BiLSTM 的 TDOA/FDOA 修正模型的预测精度,本文分别训练了 CNN、CNN-BiLSTM、CNN-BiLSTM-Attention 3 种模型进行实验仿真。对于本文所提预测模型的性能评价,采用平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE)、平均绝对百分比误差 (Mean absolute percentage error, MAPE) 和决定系数 (Coefficient of determination) R^2 作为衡量预测效果的评价指标,具体计算公式分别为:

$$\begin{cases} \text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - p_i| \\ \text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \\ \text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - p_i}{y_i} \right| \\ R^2 = 1 - \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \end{cases} \quad (34)$$

式中: n 为测试集数量; y_i 为实际的 TDOA/FDOA 值; p_i 为预测的 TDOA/FDOA 值; $\bar{y}$ 为实际数据的平均值。不同模型仿真结果如图 8 所示。

通过对比仿真中输出 1 和输出 2 的评价指标可知,本文所提修正预测模型的 MAE、RMSE、MAPE 都小于 CNN 和 CNN-BiLSTM 两种模型,证明本文模型的预测准确度高于其他两种模型;本文模型输出 1 的 R^2 为 0.999 85,输出 2 的 R^2 为




图 8 不同模型预测结果对比

Fig. 8 Comparison of prediction results of different models

0.999 4, R^2 主要用于评价模型的拟合程度, 其值越接近 1, 表示模型的质量越好。综上, 可验证本文模型相较于其他两种模型, 在预测准确性和模型质量上均具有优越性。

3.2 改进两步加权最小二乘的算法性能

本节通过仿真实验验证在融合注意力机制和 CNN-BiLSTM 的 TDOA/FDOA 修正模型下改进两步加权最小二乘定位算法 (Improved two-step weighted least squares, ImTSWLS) 的性能, 并与其他几种模型进行仿真对比。

仿真设置如下: 移动目标辐射源的位置与速度分别为 $S_T = (285, 325, 275)$, $\dot{S}_T = (-20, 15, 40)$, 采用 5 个移动的观测站对辐射源进行观测, 观测站参数设置如表 1 所示。

表 1 移动观测站位置与速度参数设置

Table 1 Setting of mobile observation station position and velocity parameters

接收机	位置/m			速度/(m·s ⁻¹)		
1	300	100	150	30	-20	20
2	400	150	100	-30	10	20
3	300	500	200	10	-20	10
4	350	200	100	10	20	30
5	-100	-100	-100	-20	20	20

由于 TDOA 和 FDOA 的测量误差相互独立, 为了便于与其他模型比较, 本文假设 TDOA 的测量误差矩阵为 Q , FDOA 的测量误差矩阵为 $0.1 \cdot Q$ 。其中, Q 的表达式为:

$$Q = \sigma^2 \begin{bmatrix} 1 & 0.5 & \cdots & 0.5 \\ 0.5 & \ddots & 0.5 & \vdots \\ \vdots & \ddots & \ddots & 0.5 \\ 0.5 & \cdots & 0.5 & 1 \end{bmatrix} \quad (35)$$

式中: σ^2 为方差。实验采用蒙特卡洛方法, 重复进行 10 000 次实验, 通过统计移动目标辐射源的位置和速度估计值的偏差与均方根误差, 验证算法性能。其中, 均方根误差的计算公式为:

$$\text{RMSE}(S_T) = \sqrt{\frac{1}{N} * \sum_{i=1}^N \|\hat{S}_T - S_T^o\|^2} \quad (36)$$

$$\text{RMSE}(\dot{S}_T) = \sqrt{\frac{1}{N} * \sum_{i=1}^N \|\dot{\hat{S}}_T - \dot{S}_T^o\|^2} \quad (37)$$

实验仿真结果如图 9 所示, 观察可知, 当噪声方差达到 10 dB 时, TSWLS、ImTSWLS、CNN-ImTSWLS 及 CNN-BiLSTM-ImTSWLS 算法的位置和速度估计偏差开始突增。其中, CNN-BiLSTM 模型融合了卷积神经网络 CNN 和双向长短期记忆网络 BiLSTM, 能够有效地提取时空特征和序列信息; 通过引入注意力机制, 模型可以自动学习并关注对定位结果影响较大的特征, 从而减小噪声干扰和多路径效应对 TDOA/FDOA 的影响。综上, 本文所提算法始终保持更小的位置与速度统计偏差。

3.3 改进两步加权最小二乘的算法性能

本文将分析 TDOA/FDOA 定位算法在不同观测站数量下的误差特性。通过模拟实验, 对比不同观测站数量下定位算法的定位误差, 并分析其来源。同时, 探讨融合注意力机制和 CNN-




图 9 目标状态估计误差曲线

Fig. 9 Error curve of target state estimation

BiLSTM 的 TDOA/FDOA 定位算法在不同观测站数量下的性能表现,并分析其优势和局限性。

为了解移动目标辐射源的位置信息和速度信息,至少需要 4 个接收机同时产生 3 个 TDOA/FDOA 参数。因此,本文主要研究的时差频差无源定位问题,在接收机数量为 5、6、7 的情况下讨论。

仿真设置如下:移动目标辐射源的位置与速度分别为 $S_T=(285, 325, 275)$ 、 $\dot{S}_T=(-20, 15, 40)$, 参数设置如表 2 所示。实验仿真结果如图 10、图 11 所示。

根据图 10 和图 11 的结果可知,七站的位置均方根误差和速度均方根误差略优于五站和六站,表明增加观测站的数量可以提高定位精度。然而,增加观测站数量也会带来算法开销增加、观测

表 2 移动观测站位置与速度参数设置

Table 2 Setting of mobile observation station position and velocity parameters

接收机	位置/m			速度/(m·s ⁻¹)		
1	300	100	150	30	-20	20
2	400	150	100	-30	10	20
3	300	500	200	10	-20	10
4	350	200	100	10	20	30
5	-100	-100	-100	-20	20	20
6	-200	100	-100	20	10	10
7	-150	140	-160	25	30	20

站部署成本增加等问题。此外,实验结果表明,持续增加观测站数量并不会显著提高定位精度,这表明增加观测站数量可能并非提高定位精度的有效方式。因此,如何平衡观测站数量和定位精度,是后续研究需解决的关键问题。




图 10 不同数量接收机的估计误差曲线

Fig. 10 Estimation error curves for different number of receivers




图 11 不同数量接收机的均方根误差曲线

Fig. 11 RMSE curves for different number of receivers

4 结束语

在实现的定位环境中,观测站常被设置在移动平台上,导致其测量的运动状态信息存在观测噪声误差。这些误差会影响观测站接收的信息,进而导致目标源位置估计产生较大的偏差。为了解决这一问题,本文提出了一种观测站参数误差下融合注意力机制的卷积神经网络和双向长短期记忆网络的时差频差多机无源定位算法,同时该算法结合了改进的两步加权最小二乘法和 CNN-BiLSTM-Attention 模型。通过修正测量值并改善两步法在存在观测噪声的情况下估计性能下降的问题,提高了定位精度。

实验结果表明,在融合注意力机制和 CNN-BiLSTM 的 TDOA/FDOA 修正模型下改进两步加权最小二乘定位算法的位置与速度估计偏差始终优于所选的对比算法。这是因为 CNN-BiLSTM 模型融合了卷积神经网络和双向长短期记忆网络,能够有效地提取时空特征和序列信息;通过引入注意力机制,模型可以自动学习并关注对定位结果影响较大的特征,从而减小噪声干扰和多路径效应对 TDOA/FDOA 的影响。

然而,进一步的实验发现,一直增加观测站数量并不会显著提高定位精度,这表明增加观测站数量并非提高定位精度的有效方式。因此,如何平衡观测站数量和定位精度,是后续研究需解决的关键问题。

参考文献:

[1] 钱志鸿,王义君. 面向物联网的无线传感器网络综

述[J]. 电子与信息学报, 2013, 35(1): 215-227.

Qian Zhi-hong, Wang Yi-jun. Review of wireless sensor networks for internet of things[J]. Journal of Electronics & Information Technology, 2013, 35(1): 215-227.

[2] 王文宇,朱磊,姚昌华,等. 机器学习助力基于优化理论的 TDOA 无源定位[J]. 信息与控制, 2022, 51(4): 385-399.

Wang Wen-yu, Zhu Lei, Yao Chang-hua, et al. Machine learning facilitates passive localization of TDOA based on optimization theory[J]. Information and Control, 2022, 51(4): 385-399.

[3] 于小强. 基于时差频差的多机无源定位及跟踪算法研究[D]. 哈尔滨: 哈尔滨工业大学信息与通信工程学院, 2021.

Yu Xiao-qiang. Research on multi-machine passive positioning and tracking algorithm based on time and frequency difference[D]. Harbin: School of Information and Communication Engineering, Harbin Institute of Technology, 2021.

[4] Li H, Sun M H, Zhou R H, et al. Hybrid TDOA/FDOA and track optimization of UAV swarm based on a-optimality[J]. Journal of Systems Engineering and Electronics, 2023, 34(1): 149-159.

[5] 孟宏宇,张建良,蔡兆龙,等. 基于 CNN-BiLSTM-Attention 的直流微电网故障诊断研究[J]. 中国电机工程学报, 2025, 45(4): 1369-1381.

Meng Hong-yu, Zhang Jian-liang, Cai Zhao-long, et al. Research on fault diagnosis of DC microgrid based on CNN-BiLSTM-Attention[J]. Proceedings of the CSEE, 2025, 45(4): 1369-1381.

[6] Liu C F, Yun J W, Su J. Direct solution for fixed source location using well-posed TDOA and FDOA

- measurements[J]. Journal of Systems Engineering and Electronics, 2020, 31(4): 666-673.
- [7] 周恭谦, 杨露菁, 刘忠. 改进的非完全约束加权最小二乘 TDOA/FDOA 无源定位方法[J]. 系统工程与电子技术, 2018, 40(8): 1686-1692.
- Zhou Gong-qian, Yang Lu-jing, Liu Zhong. Improved non-fully constrained weighted least squares TDOA/FDOA passive localization method[J]. Systems Engineering and Electronic Technology, 2018, 40(8): 1686-1692.
- [8] Wang Y B, Liang X L, Zhang J Q, et al. Robust TDOA/FDOA estimation from emitter signals for hybrid localization using UAVs[J]. Defense Technology, 2022, 18(1): 81-93.
- [9] 鲁亮亮. 基于多站 TDOA/FDOA 的通信辐射源无源定位方法研究[D]. 西安: 西安理工大学自动化与信息工程学院, 2023.
- Lu Liang-liang. Research on passive localization method of communication radiation sources based on multi-station TDOA/FDOA[D]. Xi'an: School of Automation and Information Engineering, Xi'an University of Technology, 2023.
- [10] Li Y J, Hao C Y, Li M B, et al. Moving target tracking using TDOA and FDOA measurements from two UAVs with varying baseline[C]//Proceedings of 2018 3rd International Conference on Communication, Image and Signal Processing. Bristol, UK: IOP Publishing, 2018: No. 012013.
- [11] 邓杏松, 亓亮, 朱元江, 等. 基于观测站精确距离信息的多站时差定位方法[J]. 系统工程与电子技术, 2024, 46(8): 2592-2599.
- Deng Xing-song, Qi Liang, Zhu Yuan-jiang, et al. Multi-station time difference location method based on precise distance information of observation stations[J]. Systems Engineering and Electronics Technology, 2024, 46(8): 2592-2599.
- [12] 国强, 朱国会, 李万臣. 基于混沌麻雀搜索算法的 TDOA/FDOA 定位[J]. 吉林大学学报: 工学版, 2023, 53(2): 593-600.
- Guo Qiang, Zhu Guo-hui, Li Wan-chen. TDOA/FDOA localization based on chaotic sparrow search algorithm[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(2): 593-600.
- [13] Leng M, Wu Y C. Localization of wireless sensor nodes with erroneous anchors via Em algorithm[C]//2010 IEEE Global Telecommunications Conference GLOBECOM. Piscataway, NJ: IEEE, 2010: No. 14676606.
- [14] Zheng J, Wu Y C. Joint time synchronization and localization of an unknown node in wireless sensor networks[J]. IEEE Transactions on Signal Processing, 2010, 58(3): 1309-1320.
- [15] Qiu D, Liu Z C, Zhou Y Q, et al. Modified bi-directional LSTM neural networks for rolling bearing fault diagnosis[C]//IEEE International Conference on Communications. Piscataway, NJ: IEEE, 2019: No. 8761383.
- [16] Lu Z Y, Ba B, Wang J H, et al. A direct position determination method with combined TDOA and FDOA based on particle filter[J]. Chinese Journal of Aeronautics, 2018, 31(1): 161-168.
- [17] 尹梓诺, 马海龙, 胡涛. 基于联合注意力机制和一维卷积神经网络-双向长短期记忆网络模型的流量异常检测方法[J]. 电子与信息学报, 2023, 45(10): 3719-3728.
- Yin Zi-nuo, Ma Hai-long, Hu Tao. Traffic anomaly detection method based on joint attention mechanism and one-dimensional convolutional neural network-bidirectional long short-term memory network model[J]. Journal of Electronics and Information Technology, 2023, 45(10): 3719-3728.
- [18] Hu D X, Huang Z, Zhang S Y, et al. Joint TDOA, FDOA and differential Doppler rate estimation: Method and its performance analysis[J]. Chinese Journal of Aeronautics, 2018, 31(1): 137-147.
- [19] 黄东华, 赵勇胜, 赵拥军, 等. 基于 DOA-TDOA-FDOA 的单站无源相干定位代数解[J]. 电子与信息学报, 2021, 43(3): 735-744.
- Huang Dong-hua, Zhao Yong-sheng, Zhao Yong-jun, et al. Algebraic solution of single-station passive coherent Positioning based on DOA-TDOA-FDOA[J]. Journal of Electronics & Information Technology, 2021, 43(3): 735-744.
- [20] Liu C F, Yun J W. A joint TDOA/FDOA localization algorithm using bi-iterative method with optimal step length[J]. Chinese Journal of Electronics, 2021, 30(1): 119-126.