

模型误差影响下基于CNN+BiLSTM神经网络的非圆信号目标直接跟踪算法

尹洁昕^{1,2}, 王鼎^{1,2*}, 杨欣³, 杨宾^{1,2}

(1. 中国人民解放军战略支援部队信息工程大学信息工程学院, 河南郑州 450001;
2. 国家数字交换系统工程技术研究中心, 河南郑州 450002; 3. 郑州大学计算机与人工智能学院, 河南郑州 450001)

摘要: 针对运动观测阵列状态误差与接收频率抖动同时影响下的非圆信号无源跟踪问题, 提出了一种基于卷积神经网络(Convolutional Neural Network, CNN)+双向长短时记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)的直接跟踪算法. 该算法首先利用多运动观测阵列信号各频带间的相关性与辐射源信号的非圆特性, 建立模型误差影响下的扩展多站观测矢量; 接着利用多个观测时隙内扩展多站观测矢量的信号子空间构造空时特征输入序列; 然后设计基于CNN与BiLSTM混合神经网络的直接跟踪模型, 通过训练实现对非圆目标的轨迹矢量直接估计. 本文算法是从原始数据信号子空间中估计轨迹矢量的直接跟踪模式, 相比传统“观测参数估计+滤波轨迹跟踪”的两步估计模式, 具有更高的估计精度. 由于本文算法在神经网络训练过程中学习到模型误差的信息, 因此能够实现对多种误差的校正. 仿真结果表明, 本文算法较传统两步跟踪算法与现有直接跟踪算法均具有更高的轨迹估计精度, 能够明显提升模型误差影响下多站协同跟踪的鲁棒性.

关键词: 直接跟踪; 非圆信号; 模型误差; 卷积神经网络; 双向长短时记忆网络

基金项目: 国家自然科学基金(No.61901526, No.62171469, No.62071029); 军事科技领域青年人才托举工程(No.2022-JCJQ-QT-028); 全军共用信息系统装备预先研究专用技术项目(No.315087701)

中图分类号: TN911.7

文献标识码: A

文章编号: 0372-2112(2024)04-1315-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230525

Direct Tracking for a Non-Circular Source Based on CNN+BiLSTM Neural Network in the Presence of Modeling Errors

YIN Jie-xin^{1,2}, WANG Ding^{1,2*}, YANG Xin³, YANG Bin^{1,2}

(1. Institute of Information System Engineering, PLA Strategic Support Force Information Engineering University, Zhengzhou, Henan 450001, China;

2. National Digital Switching System Engineering and Technology Research Center, Zhengzhou, Henan 450002, China;

3. Institute of Computer and Artificial Intelligence, Zhengzhou University, Zhengzhou, Henan 450001, China)

Abstract: In order to track a non-circular source target under the influence of both the state errors of moving observer arrays and frequency jitter deviations, this paper proposes a direct tracking algorithm based on the CNN (Convolutional Neural Network) + BiLSTM (Bi-directional Long Short-Term Memory) neural network. The proposed algorithm first exploits the correlation between the received array signals of multiple moving observers in various frequency bands and the non-circular property of the radiation source signals. Therefore, an extended multi-station observation vector is established in the presence of modeling errors. Then, the non-circular signal subspaces of the extended multi-station observation vectors within multiple observing timeslots are used to form the spatiotemporal feature input sequence. Subsequently, the direct tracking model for a non-circular source target based on CNN and BiLSTM neural network is designed. After training this neural network, the trajectory vector for a non-circular source target in several timeslots can be directly determined. Because the proposed algorithm estimates the target trajectory vector directly from the subspaces of the original array signals, it has higher estimation accuracy

compared to the traditional two-step tracking methods which extract measurement parameters and then estimate the trajectory from them. As the information of modeling errors can be learned from training the neural network, this algorithm can achieve the calibration for modeling errors. The simulation results show that the proposed algorithm has higher trajectory estimation accuracy compared to the traditional two-step tracking algorithm and existing direct tracking algorithm. It significantly improves the robustness of multi-station collaborative tracking under the influence of modeling errors.

Key words: direct tracking; noncircular signal; modeling error; convolutional neural network; bi-directional long short-term memory

Foundation Item(s): National Natural Science Foundation of China (No.61901526, No.62171469, No.62071029); Youth Talent Recruitment Project in the Military Science and Technology Field (No.2022-JCJQ-QT-028); Special Technical Project for Pre-research of Military Shared Information System Equipment (No.315087701)

1 引言

利用高速运动平台实现对电磁辐射源的无源定位在通信、雷达、导航、目标监测、遥测遥控、地震勘测、射电天文、紧急救助、安全管理等诸多领域发挥着重要作用。无人机作为空中快速机动平台,可搭载雷达、光电、通信等传感设备^[1],通过无源定位跟踪技术对目标进行侦察定位与跟踪,本文重点研究机载运动平台对空中快速机动目标的定位跟踪问题。

运动平台无源定位跟踪具有速度快、自由灵活、实时性强等特点^[1],但其同时存在以下问题:(1)运动平台体积有限、装载能力受限,只能依赖尽可能小孔径的天线阵列实现基于方位信息^[2](Direction Of Arrival, DOA)的定位跟踪,导致对目标定位精度不高等问题^[3]。(2)状态信息(包括观测站航迹^[4]与姿态参数^[5]等)是运动平台的重要参数,其测量值不可避免存在随机误差(即真实值与标称预设值之间的误差),而运动平台定位非常依赖观测站的状态信息,较小的状态误差将带来极大的定位误差。(3)由于机载平台和目标都处于高速运动状态,往往需要更多观测参数的精确测量,基于多普勒频差^[6-9](Frequency Difference Of Arrival, FDOA)信息或者到达时间差^[10-17](Time Difference Of Arrival, TDOA)信息的运动多站定位系统能够提供精准的定位跟踪信息,但是由于运动平台本振频率不稳定^[18]与同步误差等问题^[19],较小的频率抖动与同步误差也会带来较大的定位偏差。(4)现有运动平台定位系统大多采用“两步估计”模式,即首先从各运动观测站回传的信号中提取 DOA/FDOA/TDOA 等参数形成目标的点迹,再根据运动观测站的航迹姿态等信息,通过状态方程利用滤波算法对目标的航迹进行跟踪处理^[20,21],且很少考虑运动观测站的状态误差、同步时钟误差与频率抖动等多种误差同时存在的情况。由于“两步估计”模式中参数估计与滤波跟踪相分离,无法保证测量参数结果与真实目标航迹信息相匹配,同时参数估计的误差可能在后续处理过程中被进

一步放大,从而导致信息损失,所以无法获得最优估计性能。对此,文献[22]与文献[23]针对匀速运动目标的定位问题,利用接收信号中时延与多普勒等参数信息,先后提出了基于粒子滤波与进化粒子滤波的直接跟踪算法,其基本思想是从原始信号抽样中直接获取目标的航迹参数,无需再估计其他中间观测量,相比于传统“两步估计”模式的跟踪方法,这种(单步)直接跟踪技术具有更高的估计精度^[24-30],然而,文献[22,23]均没有考虑站址误差、频率抖动等多种误差的影响。

针对上述问题,考虑非圆信号是现代通信系统中的常用信号(例如广泛使用的 BPSK(Binary Phase Shift Keying)、PAM(Pulse Amplitude Modulation)、MASK(Multiple Amplitude Shift Keying)等调制信号)^[24,25,30-33],若利用非圆信号椭圆协方差矩阵不为零的特点,则能够增加可用信息,继而提升估计精度,因此本文研究多个运动观测阵列对非圆信号运动辐射源的跟踪场景,假设存在运动观测平台航迹与姿态误差、接收频率抖动等多种误差,提出了一种模型误差条件下基于卷积神经网络(Convolutional Neural Network, CNN)与双向长短时记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)的非圆信号目标直接跟踪算法。该算法利用多个运动观测阵列接收信号各频带之间的相关性与信号的非圆特性将小孔径阵列虚拟扩展为大孔径阵列,同时引入(单步)直接跟踪方式^[22,23],通过设计基于 CNN+BiLSTM 混合神经网络的非圆信号直接跟踪模型,训练完成轨迹矢量的直接估计。由于神经网络为输入和输出之间关系难以表示或不容易建模的问题提供了一种有效的求解方法^[30],在训练的过程中也学习到模型误差(包括观测站的状态误差与频率抖动偏差)的信息。仿真结果表明,本文所提算法在多种情况下均可以明显提升跟踪结果对模型误差的鲁棒性。

2 非圆信号

若 s 为非圆信号,则有 $E(ss^H) \neq \mathbf{0}$ 且 $E(ss^H) \neq \mathbf{0}^{[31]}$,其中 $E(\cdot)$ 表示求期望. 因此,有关非圆信号的算法可以通过利用椭圆协方差矩阵不为零的特点. 具体地,对于非圆信号 s (随机矢量 \mathbf{s} 中某个信号),有

$$E(s^2) = \rho e^{j\phi} E(|s|^2) \quad (1)$$

其中, ρ 为信号的非圆率,取值为 $0 \leq \rho \leq 1$; ϕ 为信号的非圆相角,其中非圆率 ρ 的大小由信号的调制方式决定. 当 $\rho = 1$ 时为最大非圆率信号,也可以称之为狭义非圆信号, BPSK、MASK、PAM 等调制信号都是常见的最大非圆率信号,此外很多信号例如 OQPSK (Offset Quadrature Phase Shift Keying) 信号与 MSK (Minimum Shift Keying) 信号经过预处理也能够转换为最大非圆率信号^[32]. 最大非圆率信号具有一个重要性质,即其均能够由实信号通过移相得到^[24]:

$$s = s_0 e^{-j\varphi} \quad (2)$$

其中, s_0 为信号的实部; $\varphi = \phi/2$ 为初相,取值为其非圆相角的一半. 由于最大非圆率信号具有上述性质,很多子空间类测向与直接定位算法都能够扩展到相应的非圆信号算法^[33-36],本文算法研究也是利用最大非圆率信号的特殊性质展开的.

3 面向非圆信号的直接跟踪观测信号模型

3.1 多种误差条件下联合空域与多普勒频率信息的多站观测窄带信号模型

考虑一个运动多阵列联合定位跟踪系统,该系统包含 L 个运动观测站,每个观测站由 M 元的阵列构成,现有稳态远场(视距内)的一个运动目标发射窄带非圆信号. 不失一般性,本文考虑二维平面的定位跟踪场景. 针对窄带信号的入射情况,可以忽略时差对信号到达不同观测站的复包络的影响^[26]. 那么假设观测阵列在 K 个时隙段内不同预设位置上观测目标辐射的信号,每个时隙观测时长为 T ,则第 l ($1 \leq l \leq L$) 个观测阵列在第 k ($1 \leq k \leq K$) 个预设观测位置上(即观测时隙内)以采样周期 T_s 采集的 N 点阵列信号时域模型可以表示为

$$\mathbf{r}_l^{(k)}(n) = \beta_l^{(k)} \mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\zeta}_l^{(k)}) s^{(k)}(nT_s - t_{k0}) \exp(j2\pi \tilde{f}_l^{(k)} nT_s) + \mathbf{e}_l^{(k)}(n), \quad 1 \leq k \leq K; 1 \leq l \leq L; 0 \leq n \leq N-1 \quad (3)$$

其中 $\mathbf{p}^{(k)} \in \mathbb{R}^{2 \times 1}$ 表示运动辐射目标在第 k 个观测时隙内的位置矢量; $\mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\zeta}_l^{(k)}) \in \mathbb{C}^{M \times 1}$ 表示运动辐射源在第 k 个观测时隙内相对于第 l 个观测阵列的流形矢量,与其相应的到达角度 $\theta_l^{(k)}(\mathbf{p}^{(k)}, \hat{\zeta}_l^{(k)})$ 有关; $s^{(k)}(nT_s - t_{k0})$ 表示辐射源信号在第 k 个观测时隙内 t_{k0} 时刻发射的复包络;

$\tilde{f}_l^{(k)}$ 为第 l 个观测阵列在第 k 个观测时隙内接收辐射源信号的频率; $\mathbf{e}_l^{(k)}(n)$ 表示第 l 个观测阵列在第 k 个观测时隙内接收辐射源信号时的阵列噪声矢量; $\beta_l^{(k)}$ 为第 l 个观测阵列在第 k 个观测时隙内接收辐射源信号时的信道传播复系数; $\hat{\zeta}_l^{(k)} = ((\hat{\mathbf{u}}_l^{(k)})^T, (\hat{\mathbf{u}}_l^{(k)})^T, \hat{\gamma}_l^{(k)})^T$ 表示第 l 个观测阵列在第 k 个观测时隙内观测辐射源信号时的真实状态矢量,包括位置矢量 $\hat{\mathbf{u}}_l^{(k)}$ 与速度矢量 $\hat{\mathbf{u}}_l^{(k)}$,以及平台姿态角 $\hat{\gamma}_l^{(k)}$,假设其真实状态 $\hat{\zeta}_l^{(k)}$ 与预设状态 $\zeta_l^{(k)}$ 之间存在随机误差,即

$$\hat{\zeta}_l^{(k)} = \zeta_l^{(k)} + \mathbf{e}_l^{(k)}, \quad 1 \leq k \leq K; 1 \leq l \leq L \quad (4)$$

其中, $\zeta_l^{(k)} = ((\mathbf{u}_l^{(k)})^T, (\mathbf{u}_l^{(k)})^T, \gamma_l^{(k)})^T$, 其中 $\mathbf{u}_l^{(k)}$ 与 $\dot{\mathbf{u}}_l^{(k)}$ 表示第 l 个观测阵列在第 k 个观测时隙内的预设位置与速度矢量, $\gamma_l^{(k)}$ 表示相应的观测平台姿态角预设值, $\mathbf{e}_l^{(k)}$ 为随机状态误差.

在二维平面的定位场景中,到达角度 $\theta_l^{(k)}(\mathbf{p}^{(k)}, \hat{\zeta}_l^{(k)})$ 与运动辐射信源在第 k 个观测时隙内的位置矢量、观测阵列真实状态矢量之间的代数关系为

$$\theta_l^{(k)}(\mathbf{p}^{(k)}, \hat{\zeta}_l^{(k)}) = \arctan \frac{\mathbf{p}^{(k)}(2) - \hat{\mathbf{u}}_l^{(k)}(2)}{\mathbf{p}^{(k)}(1) - \hat{\mathbf{u}}_l^{(k)}(1)} + \hat{\gamma}_l^{(k)}, \quad 1 \leq k \leq K; 1 \leq l \leq L \quad (5)$$

假设由于频率不稳定等原因导致第 l 个观测站在第 k 个观测时隙内的本振频率与辐射源载波频率 f_c 之间存在频偏 $v_l^{(k)}$,那么将接收信号经过下变频到基带信号后,观测频率 $\tilde{f}_l^{(k)}$ 变为^[18]

$$\tilde{f}_l^{(k)}(\mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\zeta}_l^{(k)}, v_l^{(k)}) = v_l^{(k)} + f_l^{(k)}(\mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\zeta}_l^{(k)}), \quad 1 \leq k \leq K; 1 \leq l \leq L \quad (6)$$

其中, $f_l^{(k)}(\mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\zeta}_l^{(k)})$ 是由于观测站与目标之间的相对运动产生的多普勒频偏,其与运动辐射信源在第 k 个观测时隙内的位置矢量 $\mathbf{p}^{(k)}$ 、速度矢量 $\dot{\mathbf{p}}^{(k)}$,以及观测阵列真实状态矢量之间的代数关系为

$$f_l^{(k)}(\mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\zeta}_l^{(k)}) = \frac{f_c (\dot{\mathbf{p}}^{(k)} - \hat{\mathbf{u}}_l^{(k)})^T (\mathbf{p}^{(k)} - \hat{\mathbf{u}}_l^{(k)})}{c \|\mathbf{p}^{(k)} - \hat{\mathbf{u}}_l^{(k)}\|_2}, \quad 1 \leq k \leq K; 1 \leq l \leq L \quad (7)$$

其中, c 为电磁波的传播速度; $\|\cdot\|_2$ 表示矢量的 Euclidean 范数.

进一步根据式(3),可以将下变频后的基带信号 $\mathbf{r}_l^{(k)}(n)$ 表示为

$$\mathbf{r}_l^{(k)}(n) = \beta_l^{(k)} \mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\zeta}_l^{(k)}) s^{(k)}(nT_s - t_{k0}) \cdot \exp(j2\pi \tilde{f}_l^{(k)}(\mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\zeta}_l^{(k)}, v_l^{(k)}) nT_s) + \mathbf{e}_l^{(k)}(n), \quad 1 \leq k \leq K; 1 \leq l \leq L; 0 \leq n \leq N-1 \quad (8)$$

利用非圆信号时域性质(见式(2)), $\mathbf{r}_l^{(k)}(n)$ 可以表示为

$$\mathbf{r}_l^{(k)}(n) = \beta_l^{(k)} \mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}) s_0^{(k)}(n) e^{j\varphi_k} \exp(j2\pi \bar{f}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}, v_l^{(k)}) n T_s) + \boldsymbol{\varepsilon}_l^{(k)}(n), \quad 1 \leq k \leq K; 1 \leq l \leq L; 0 \leq n \leq N-1 \quad (9)$$

其中, $s_0^{(k)}(n)$ 为非圆信号实部, φ_k 为第 k 个观测时隙内非圆信号初相. 式(9)建立了多种误差条件下联合空域与频域信息的多站观测窄带信号模型, $\mathbf{r}_l^{(k)}(n)$ 包含了所有关于第 k 个观测时隙内的目标位置信息(包括角度与多普勒频率信息).

3.2 频域分段预处理

为了从信号子空间中直接挖掘目标信号的 DOA 与 FDOA 信息, 基于信号子空间的思想^[37], 需要构造具有相同流形矢量的多个观测矢量采样数据. 然而, 3.1 节建立的信号模型(见式(9))中, 观测矢量 $\mathbf{r}_l^{(k)}(n)$ 与 $\exp(j2\pi \bar{f}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}, v_l^{(k)}) n T_s)$ 均与采样点数 n 有关, 即不同采样时刻的 $\mathbf{r}_l^{(k)}(n)$ 不具有相同的流形矢量. 为此, 本小节将通过频域滤波的分段处理, 构造不同频带的观测矢量, 使其具有相同的流形矢量, 再利用多个阵列接收信号各频带之间的相关性, 进一步构造多站观测矢量 $\mathbf{r}^{(k)}(n, j) \in \mathbb{C}^{LM \times 1}$, 将小孔径阵列虚拟扩展为更大孔径的阵列.

根据式(9), 利用傅里叶变换的频移性质^[38], 可以将第 l 个观测站在第 k 个观测时隙内接收到的 N 点基带采样信号 $\mathbf{r}_l^{(k)}(n)$ 的(序列)傅里叶变换表示为

$$\begin{aligned} \bar{\mathbf{r}}_l^{(k)}(f) &= \beta_l^{(k)} \mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}) e^{j\varphi_k} \bar{s}_0^{(k)}(f - \bar{f}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}, v_l^{(k)})/F_s) + \bar{\boldsymbol{\varepsilon}}_l^{(k)}(f), \\ 1 \leq k \leq K; 1 \leq l \leq L \end{aligned} \quad (10)$$

其中, $\bar{s}_0^{(k)}(f)$ 是信号 $s_0^{(k)}(n)$ 的序列傅里叶变换; $\bar{\boldsymbol{\varepsilon}}_l^{(k)}(f)$ 是噪声 $\boldsymbol{\varepsilon}_l^{(k)}(n)$ 的序列傅里叶变换; $F_s = 1/T_s$ 为采样频率.

$$\begin{aligned} \mathbf{r}^{(k)}(n, j) &= \left((\mathbf{r}_1^{(k)}(n, j))^T, (\mathbf{r}_2^{(k)}(n, j))^T, \dots, (\mathbf{r}_L^{(k)}(n, j))^T \right)^T \\ &= \boldsymbol{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \cdot \boldsymbol{\beta}^{(k)} \cdot e^{j\varphi_k} s_0^{(k)}(n, j) + \boldsymbol{\varepsilon}^{(k)}(n, j), \quad 1 \leq k \leq K; 1 \leq j \leq J; 0 \leq n \leq N-1 \end{aligned} \quad (13)$$

其中, $\boldsymbol{\varepsilon}^{(k)}(n, j) = ((\boldsymbol{\varepsilon}_1^{(k)}(n, j))^T, (\boldsymbol{\varepsilon}_2^{(k)}(n, j))^T, \dots, (\boldsymbol{\varepsilon}_L^{(k)}(n, j))^T)^T$; $\boldsymbol{\beta}^{(k)} = (\beta_1^{(k)}, \beta_2^{(k)}, \dots, \beta_L^{(k)})^T$; $\hat{\boldsymbol{\zeta}}^{(k)} = ((\hat{\boldsymbol{\zeta}}_1^{(k)})^T, (\hat{\boldsymbol{\zeta}}_2^{(k)})^T, \dots, (\hat{\boldsymbol{\zeta}}_L^{(k)})^T)^T$; $\mathbf{v}^{(k)} = (v_1^{(k)}, v_2^{(k)}, \dots, v_L^{(k)})^T$; $\boldsymbol{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)})$ 的表达式为

$$\begin{aligned} \boldsymbol{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) &= \text{blkdiag} \left(\mathbf{a}_1^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_1^{(k)}) \exp(j2\pi \bar{f}_1^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_1^{(k)}, v_1^{(k)}) n T_s), \mathbf{a}_2^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_2^{(k)}) \right. \\ &\quad \left. \cdot \exp(j2\pi \bar{f}_2^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_2^{(k)}, v_2^{(k)}) n T_s), \dots, \mathbf{a}_L^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_L^{(k)}) \exp(j2\pi \bar{f}_L^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_L^{(k)}, v_L^{(k)}) n T_s) \right) \\ &\quad + (\boldsymbol{\varepsilon}^{(k)}(n, j))^*, \quad 1 \leq k \leq K; 1 \leq j \leq J; 0 \leq n \leq N-1 \end{aligned} \quad (14)$$

式中, $\text{blkdiag}(\cdot)$ 表示由矩阵或矢量作为对角元素构成的块状对角矩阵.

3.3 面向非圆信号的扩展多站观测矢量

由于 $s_0^{(k)}(n)$ 为实序列, 且 J 个带滤波器的系数也为实数, 因此滤波后的信号 $s_0^{(k)}(n, j)$ 仍为实序列. 根据式(13), 可以将 $\mathbf{r}^{(k)}(n, j)$ 的共轭可表示为

$$\begin{aligned} (\mathbf{r}^{(k)}(n, j))^* &= \left((\mathbf{r}_1^{(k)}(n, j))^T, (\mathbf{r}_2^{(k)}(n, j))^T, \dots, (\mathbf{r}_L^{(k)}(n, j))^T \right)^H \\ &= (\boldsymbol{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \boldsymbol{\beta}^{(k)})^* \cdot e^{-j\varphi_k} s_0^{(k)}(n, j) \end{aligned}$$

接着, 将第 l 个观测站在第 k 个时隙内的基带采样信号 $\mathbf{r}_l^{(k)}(n)$ 通过 J 个不完全重叠的数字实系数带通滤波器(近似理想带通滤波器; 带宽为 $B_j (1 \leq j \leq J)$), 那么根据式(10), 第 $j (1 \leq j \leq J)$ 个带滤波器的输出频域信号可以表示

$$\begin{aligned} \bar{\mathbf{r}}_l^{(k)}(f, j) &= \beta_l^{(k)} \mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}) e^{j\varphi_k} \bar{s}_0^{(k)}(f - \bar{f}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}, v_l^{(k)})/F_s, j) + \bar{\boldsymbol{\varepsilon}}_l^{(k)}(f, j), \\ 1 \leq k \leq K; 1 \leq l \leq L; 1 \leq j \leq J \end{aligned} \quad (11)$$

其中, $\bar{s}_0^{(k)}(f, j)$ 与 $\bar{\boldsymbol{\varepsilon}}_l^{(k)}(f, j)$ 分别表示 $s_0^{(k)}(f)$ 与 $\boldsymbol{\varepsilon}_l^{(k)}(f)$ 通过第 $j (1 \leq j \leq J)$ 个带滤波器的频域输出. 需要强调的是, 为了保证各观测站通过第 $j (1 \leq j \leq J)$ 个带滤波器的输出信号无相位畸变, 每个观测站所采用的第 $j (1 \leq j \leq J)$ 个带滤波器系数是完全相同的, 从而不会影响最终的跟踪结果.

根据傅里叶变换的频移性质, 可以将第 $j (1 \leq j \leq J)$ 个带滤波器的输出时域信号近似表示为^[39]

$$\begin{aligned} \mathbf{r}_l^{(k)}(n, j) &= \beta_l^{(k)} \mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}) e^{j\varphi_k} s_0^{(k)}(n, j) \cdot \exp(j2\pi \bar{f}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}, v_l^{(k)}) n T_s) + \boldsymbol{\varepsilon}_l^{(k)}(n, j), \\ 1 \leq k \leq K; 1 \leq l \leq L; 1 \leq j \leq J; 0 \leq n \leq N-1 \end{aligned} \quad (12)$$

其中, $s_0^{(k)}(n, j)$ 与 $\boldsymbol{\varepsilon}_l^{(k)}(n, j)$ 分别是 $s_0^{(k)}(f, j)$ 与 $\boldsymbol{\varepsilon}_l^{(k)}(f, j)$ 对应的时域信号. 至此, 构造的 $\mathbf{r}_l^{(k)}(n, j)$ 在不同频带 j 上具有相同的流形矢量 $\mathbf{a}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}) \exp(j2\pi \bar{f}_l^{(k)}(\mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}_l^{(k)}, v_l^{(k)}) n T_s)$.

接着, 将各观测站通过第 $j (1 \leq j \leq J)$ 个带滤波器的信号 $\mathbf{r}_l^{(k)}(n, j)$ 组成一个高维多站观测矢量 $\mathbf{r}^{(k)}(n, j)$, 即

结合式(13)和式(15), 按如下形式构造扩展观测矢量:

$$\begin{aligned} \tilde{\mathbf{r}}^{(k)}(n, j) &= \left((\mathbf{r}^{(k)}(n, j))^T, (\mathbf{r}^{(k)}(n, j))^H \right)^T \\ &= \tilde{\boldsymbol{\Gamma}}^{(k)}(n, \mathbf{p}^{(k)}, \hat{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \tilde{\boldsymbol{\beta}}^{(k)} s_0^{(k)}(n, j) + \tilde{\boldsymbol{\varepsilon}}^{(k)}(n, j), \\ 1 \leq k \leq K; 1 \leq j \leq J; 0 \leq n \leq N-1 \end{aligned} \quad (16)$$

其中,

$$\begin{cases} \tilde{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) = \text{blkdiag}(\Gamma^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}), (\Gamma^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)})^*) \\ \tilde{\boldsymbol{\beta}}^{(k)} = ((\boldsymbol{\beta}^{(k)})^T e^{j\varphi_s}, (\boldsymbol{\beta}^{(k)})^H e^{-j\varphi_s})^T \\ \tilde{\boldsymbol{\varepsilon}}^{(k)}(n, j) = ((\boldsymbol{\varepsilon}^{(k)}(n, j))^T, (\boldsymbol{\varepsilon}^{(k)}(n, j))^H)^T \end{cases} \quad (17)$$

从式(16)中可以看出,本小节利用信号的非圆特性构造了扩展多站观测矢量 $\tilde{\mathbf{r}}^{(k)}(n, j) \in \mathbb{C}^{2LM \times 1}$, 相比于原始的阵列观测矢量 $\mathbf{r}_l^{(k)}(n) \in \mathbb{C}^{M \times 1}$ (见式(9)), 进一步将孔径阵列进行了虚拟扩展.

4 基于 CNN+BiLSTM 神经网络的直接跟踪

4.1 基于多个观测时隙的空时特征提取

针对 3.3 节建立的扩展多站观测矢量 (见式(16)), 可以将其第 n 个时间分量上的协方差矩阵表示为

$$\begin{aligned} \mathbf{R}_r^{(k)}(n) &= \mathbb{E}(\tilde{\mathbf{r}}^{(k)}(n, j) \cdot (\tilde{\mathbf{r}}^{(k)}(n, j))^H) \\ &= \tilde{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \cdot \tilde{\boldsymbol{\beta}}^{(k)} \cdot \mathbf{R}_s^{(k)}(n) \cdot \\ &\quad (\tilde{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \cdot \tilde{\boldsymbol{\beta}}^{(k)})^H + (\sigma_n^{(k)})^2 \mathbf{I}_{2LM} \end{aligned} \quad (18)$$

其中, $\mathbf{R}_s^{(k)}(n) = \mathbb{E}(s_0^{(k)}(n, j) \cdot (s_0^{(k)}(n, j))^*)$ 为非圆信号源在第 k 个观测时隙内第 n 个时间分量上的协方差矩阵; $(\sigma_n^{(k)})^2$ 为在第 k 个观测时隙内阵列天线的噪声功率.

根据子空间原理^[33, 34, 37], 对 $\mathbf{R}_r^{(k)}(n)$ 进行特征值分解, 由

$$\mathbf{R}_r^{(k)}(n) = (\sigma_s^{(k)})^2 \mathbf{u}_s^{(k)}(n) (\mathbf{u}_s^{(k)}(n))^H + (\sigma_n^{(k)})^2 \mathbf{U}_n^{(k)}(n) (\mathbf{U}_n^{(k)}(n))^H \quad (19)$$

式(19)中, $(\sigma_s^{(k)})^2$ 为 $\mathbf{R}_r^{(k)}(n)$ 的最大特征值; $\mathbf{u}_s^{(k)}(n) \in \mathbb{C}^{2LM \times 1}$ 是与大特征值 $(\sigma_s^{(k)})^2$ 对应的非圆扩展信号子空间, 与 $\tilde{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \cdot \tilde{\boldsymbol{\beta}}^{(k)}$ 线性相关; $\mathbf{U}_n^{(k)}(n) \in \mathbb{C}^{2LM \times (2LM-1)}$ 是与 $2LM-1$ 个小特征值 (即 $(\sigma_n^{(k)})^2$) 对应的噪声子空间.

实际中, 由于带通滤波后的信号为高采信号, 其包含了冗余信息, 可以先通过抽取对 $\tilde{\mathbf{r}}^{(k)}(n, j)$ 进行去除冗余处理, 令

$$\tilde{\mathbf{r}}^{(k)}(n, j) = \tilde{\mathbf{r}}^{(k)}(In, j), \quad 0 \leq n \leq \lfloor N/I \rfloor; 1 \leq k \leq K; 1 \leq j \leq J \quad (20)$$

其中, I 为满足奈奎斯特采样速率的高采倍数; $\lfloor \cdot \rfloor$ 表示向下取整数.

进而可以利用 $\tilde{\mathbf{r}}^{(k)}(n, j)$ 对扩展协方差矩阵 $\mathbf{R}_r^{(k)}(n)$ 进行估计, 相应非圆信号扩展子空间的估计量记为 $\hat{\mathbf{u}}_s^{(k)}(n)$ ($0 \leq n \leq \lfloor N/I \rfloor; 1 \leq k \leq K$).

由于 $\hat{\mathbf{u}}_s^{(k)}(n)$ 与 $\tilde{\Gamma}^{(k)}(n, \mathbf{p}^{(k)}, \dot{\mathbf{p}}^{(k)}, \hat{\boldsymbol{\zeta}}^{(k)}, \mathbf{v}^{(k)}) \cdot \tilde{\boldsymbol{\beta}}^{(k)}$ 线性相关, 它也包含了在第 k 个观测时隙内目标的位置信息与模型误差信息, 因此将其作为第 k 个观测时隙内空间特征矢量的一部分. 考虑神经网络的输入只能为实数, 可

以构造如下实矢量:

$$\mathbf{x}^{(k)}(n) = \begin{pmatrix} \text{Re}(\hat{\mathbf{u}}_s^{(k)}(n)) \\ \text{Im}(\hat{\mathbf{u}}_s^{(k)}(n)) \end{pmatrix}, \quad 0 \leq n \leq \lfloor \frac{N}{I} \rfloor; 1 \leq k \leq K \quad (21)$$

式(21)中, $\text{Re}(\cdot)$ 、 $\text{Im}(\cdot)$ 分别表示取矩阵或者矢量的实部、虚部.

另一方面, 由于本文考虑了观测平台状态误差等模型误差的影响, 因此引入 L 个运动观测站在第 k ($1 \leq k \leq K$) 个位置上观测目标时的预设状态矢量 $\boldsymbol{\zeta}^{(k)} = ((\boldsymbol{\zeta}_1^{(k)})^T, (\boldsymbol{\zeta}_2^{(k)})^T, \dots, (\boldsymbol{\zeta}_L^{(k)})^T)^T$ 作为空间特征矢量的另一部分, 进而将 $\boldsymbol{\zeta}^{(k)}$ 与 $\mathbf{x}^{(k)}(n)$ 组成关于在第 k ($1 \leq k \leq K$) 个时隙内的空间特征矢量, 其具体表达式为

$$\boldsymbol{\eta}^{(k)} = ((\boldsymbol{\zeta}^{(k)})^T, (\mathbf{x}^{(k)}(0))^T, (\mathbf{x}^{(k)}(1))^T, \dots, (\mathbf{x}^{(k)}(\lfloor N/I \rfloor))^T)^T, \quad 1 \leq k \leq K \quad (22)$$

为了得到目标在 K 个时隙内的轨迹估计值, 需要将 K 个时隙内的空间特征矢量组成一个空时特征序列作为神经网络的输入序列, 即构造如下输入序列:

$$\boldsymbol{\Psi} = (\boldsymbol{\eta}^{(1)}, \boldsymbol{\eta}^{(2)}, \dots, \boldsymbol{\eta}^{(K)}) \quad (23)$$

因此, 在目标区域内设置 D 个运动辅助非圆信号辐射源产生训练集, 将每个辅助信源对应的空时特征序列 $\boldsymbol{\Psi}_d = (\boldsymbol{\eta}_d^{(1)}, \boldsymbol{\eta}_d^{(2)}, \dots, \boldsymbol{\eta}_d^{(K)})$ ($1 \leq d \leq D$) 作为训练输入; 将每个运动辅助信源在 K 个观测时隙内的轨迹矢量组成一个序列作为输出序列, 即

$$\mathbf{P}_d = (\mathbf{p}_d^{(1)}, \mathbf{p}_d^{(2)}, \dots, \mathbf{p}_d^{(K)}), \quad 1 \leq d \leq D \quad (24)$$

需要说明的是, 为保证并提升学习效果, 辅助源应当尽量满足与目标辐射源具有相似的空时频特性. 例如, 辅助源在空间上可随机分布在感兴趣的目标区域范围, 时域波形应满足非圆特性, 频率可随机分布在感兴趣的目标频带范围.

4.2 基于 CNN+BiLSTM 神经网络的直接跟踪模型

本文首先利用 3 层 CNN^[40] 提取各个时隙内非圆信号子空间的空间特征信息, 考虑循环神经网络处理时间序列的优异特性, 接着利用 4 层 BiLSTM 网络来学习目标在多个时隙间的空时特征信息, 设计用于直接跟踪的 CNN+BiLSTM 神经网络结构如图 1 所示, 结构参数如表 1 所示, 其中 $\text{dim}(\cdot)$ 表示矢量的维度.

通过训练学习 CNN+BiLSTM 神经网络完成轨迹矢量的直接估计, 同时在训练过程中神经网络也学习到模型误差信息. 因此, 该算法可以实现模型误差下的高精度鲁棒直接跟踪.

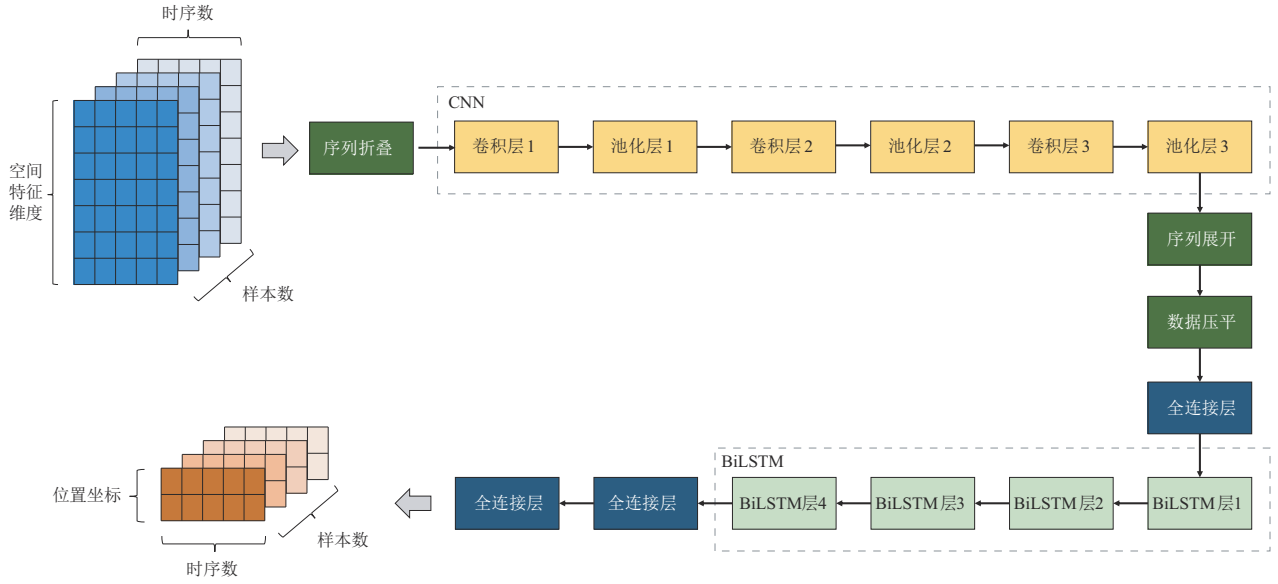


图1 基于CNN+BiLSTM神经网络的直接定位模型示意图

表1 CNN+BiLSTM神经网络构成参数

名称	网络构成参数
输入层	初始大小: $\dim(\boldsymbol{\eta}) \times 1$, 长度: K
卷积层1	卷积核: $2M^2 \times 1$, 通道数:64, 步幅:1
池化层1	Batch Normalization + ReLU + 平均池化 3×1
卷积层2	卷积核: $2M^2 \times 1$, 通道数:128, 步幅:1
池化层2	Batch Normalization + ReLU + 平均池化 3×1
卷积层3	卷积核: $2M^2 \times 1$, 通道数:256, 步幅:1
池化层3	Batch Normalization + ReLU + 平均池化 3×1
全连接层	线性, 输出大小: 256×1 , 长度: K
BiLSTM1	隐藏节点数:256, 长度: K
BiLSTM2	隐藏节点数:256, 长度: K
BiLSTM3	隐藏节点数:256, 长度: K
BiLSTM4	隐藏节点数:256, 长度: K
全连接层	Leaky ReLU, 输出大小: 128×1 , 长度: K
全连接层	Leaky ReLU, 输出大小: $\dim(\boldsymbol{p}) \times 1$, 长度: K
输出层	输出大小: $\dim(\boldsymbol{p}) \times 1$, 长度: K

4.3 正则化处理

4.3.1 输入输出标准化处理

对神经网络输入输出的标准化处理既可以提升模型的收敛速度,也可以提升模型的收敛精度^[30].针对神经网络训练集的输入数据,将 D 个运动辅助非圆信号辐射源在 K 个观测位置上的空间特征矢量 $\boldsymbol{\eta}_d^{(k)}$ ($1 \leq d \leq D$; $1 \leq k \leq K$)进行标准差归一化处理,得到 $\boldsymbol{\eta}'_d^{(k)}$ ($1 \leq d \leq D$; $1 \leq k \leq K$).然后,将第 d ($1 \leq d \leq D$)个运动辅助信源在 K 个观测位置上的归一化空间特征矢量组成归一化空时特征序列作为输入序列:

$$\boldsymbol{\Psi}'_d = (\boldsymbol{\eta}'_d^{(1)}, \boldsymbol{\eta}'_d^{(2)}, \dots, \boldsymbol{\eta}'_d^{(K)}), \quad 1 \leq d \leq D \quad (25)$$

针对神经网络训练集的输出数据,将 D 个运动辅

助信源在 K 个观测时隙内的真实位置矢量 $\boldsymbol{p}_d^{(k)}$ ($1 \leq d \leq D$; $1 \leq k \leq K$)进行最大最小归一化处理,得到 $\boldsymbol{p}'_d^{(k)}$ ($1 \leq d \leq D$; $1 \leq k \leq K$).然后,将第 d ($1 \leq d \leq D$)个运动辅助信源在 K 个观测时隙内的归一化位置矢量组成归一化轨迹序列作为输出序列:

$$\boldsymbol{P}'_d = (\boldsymbol{p}'_d^{(1)}, \boldsymbol{p}'_d^{(2)}, \dots, \boldsymbol{p}'_d^{(K)}), \quad 1 \leq d \leq D \quad (26)$$

最后,将 $\boldsymbol{\Psi}'_d$ 作为CNN+BiLSTM神经网络的输入,将 \boldsymbol{P}'_d 作为CNN+BiLSTM神经网络的输出,共有 D 组这样的输入序列-输出序列对,利用它们对神经网络进行训练.

4.3.2 网络训练的正则化处理

本算法通过随机化训练样本分布来防止网络训练过拟合.如图2所示,假设目标与辅助信源的运动模型为恒定速度(Constant Velocity, CV),训练样本的初始位置均匀分布在 $40 \text{ km} \times 40 \text{ km}$ 的方形区域内(见图中红色虚线),其中红色三角形为训练样本的初始位置,绿色线条为训练样本的运动轨迹,训练样本初始速度大小和方向分别在 $[100 \text{ m/s}, 200 \text{ m/s}]$, $[0^\circ, 360^\circ]$ 范围内随机产生,位置与速度分别加有均值为 0 m 、方差为 0.5 m^2 与均值为 0 m/s 、方差为 $1 (\text{m/s})^2$ 的高斯机动噪声.

4.4 算法原理总结

图3给出了基于CNN+BiLSTM神经网络的非圆信号目标直接跟踪算法原理框图:首先产生随机化分布的训练样本轨迹;然后,将多个运动观测站在各个观测位置上的阵列接收信号进行多个子窄带的预滤波,进而利用多运动观测阵列接收信号各频带之间的相关性与信号源的非圆特性,建立扩展多站观测矢量;接着,利用扩展多站观测矢量的信号子空间构造空间特征矢量,将多个观测时隙内得到的空间特征矢量组成空时特征输入




图2 随机化训练样本轨迹分布图

序列,并进行归一化处理;将空时特征输入序列通过 CNN 网络提取每个时隙内的信号子空间特征矢量,再通过 BiLSTM 网络提取轨迹特征矢量,输出轨迹估计结果;同时将每个训练样本的真实轨迹矢量组成输出轨迹序列,进行归一化处理;最后,利用训练样本的归一化空时特征序列与输出轨迹序列来训练 CNN+BiLSTM 神经网络,当训练结束后该神经网络就可用于实现对多种误差影响下运动非圆信号辐射源的直接跟踪。

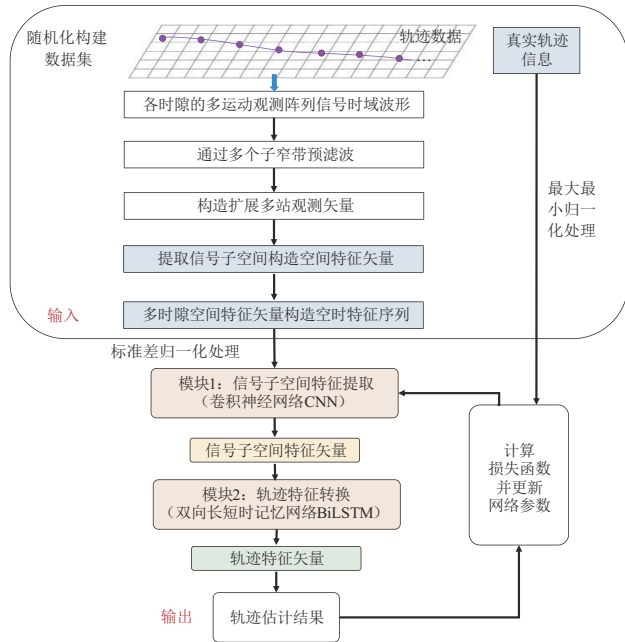


图3 基于 CNN+BiLSTM 神经网络的非圆信号目标直接跟踪算法原理框图

4.5 多目标场景的推广与讨论

本文基于 CNN+BiLSTM 神经网络的非圆信号目标直接跟踪算法是针对单个非圆信号目标提出的,没有考虑多目标的跟踪场景,本节将对如何将该算法推广至多目标跟踪场景进行分析与讨论,具体研究作为

本文未来所要拓展的研究方向。

文献[41]提出了一种基于神经网络的多目标直接定位算法,该算法首先将待定位区域划分为多个子区域,利用不同的神经网络依次通过检测、空域滤波、位置估计等步骤实现多个目标的定位,其中检测用于检测划分子区域内是否存在目标信号源,空域滤波用于去除其他子区域的干扰信号。借鉴文献[41]的多目标定位处理方法,针对实际中可能遇到的多目标跟踪场景,考虑通过 2 个阶段完成多目标的直接跟踪。第一阶段:在跟踪的初始观测时隙内,将监测区域划分为多个子区域,通过对各子区域的目标检测完成多目标的检测与分离;第二阶段:针对初始位置位于不同子区域的目标轨迹,分别利用空域滤波去除干扰信号,再利用本文所提非圆信号直接跟踪网络模型对各目标进行跟踪(分子区域训练网络参数)。针对多目标场景的直接跟踪流程示意图如图 4 所示,该处理方法将多目标的跟踪问题拆分为多个单目标的跟踪问题进行处理,其中单目标的跟踪可以采用本文的直接跟踪模型进行训练学习。

针对多目标场景下的跟踪分辨率问题,一方面本算法已经利用多个阵列接收信号各频带间的相关性与辐射源信号的非圆特性,将小孔径阵列虚拟扩展为大孔径阵列,该大孔径阵列本身就具有更高的空间分辨能力;另一方面根据如图 4 所示的多目标跟踪处理流程,跟踪分辨率也取决于在初始时隙内网格子区域划分的大小,网格子区域越小分辨率越高。针对不同目标运动轨迹存在交叉或间距较近等多目标跟踪场景,可以增加设置距离较近或者运动轨迹存在交叉等轨迹复杂多变的训练数据,进而通过多目标的检测与分离阶段进行轨迹分离,再利用空域滤波进一步去除其他子区域的干扰信号,最后利用本文所提 CNN+BiLSTM 神经网络直接跟踪模型进行训练学习。

5 数值仿真与结果分析

为了验证本文所提算法性能的优越性,该部分通过数值仿真将未考虑模型误差影响的传统两步跟踪算法(利用信号非圆特性)、基于粒子滤波的直接跟踪算法^[22],与本文算法的跟踪性能进行对比。其中,两步跟踪方法首先根据 3.3 节建立的非圆信号扩展多站观测矢量(见式(16)),估计各观测站在各时隙内接收信号的角度与多普勒参数,再利用观测站的预设状态通过扩展卡尔曼滤波估计目标在各时隙内的位置。仿真在配置为 Intel Core i7CPU、32 GB RAM 和 NVIDIA GeForce RTX 2070 Super Max-Q GPU 的计算机上完成。

仿真场景设置为空空定位场景,即观测站为机载观测阵列,目标为空中高速运动目标。假设运动目标辐射信号为远场窄带 BPSK 信号(最大非圆率信号),载波

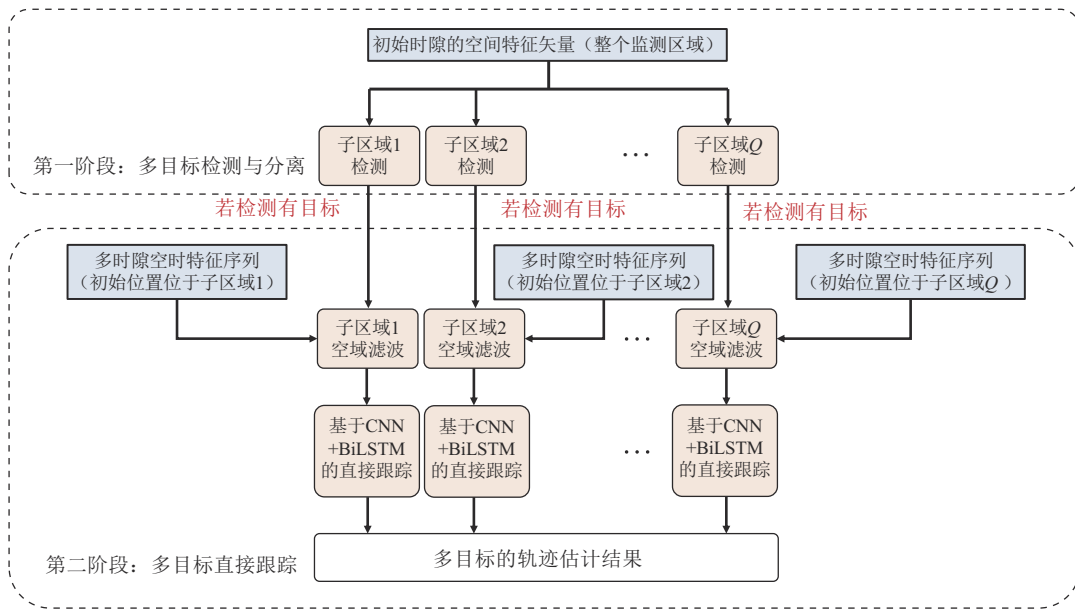


图4 针对多目标场景的直接跟踪流程示意图

频率为 1 300 MHz、带宽为 5 kHz,非圆相位在 $[0^\circ, 360^\circ]$ 范围内随机产生. 假设有 3 个运动观测站对非圆目标进行观测,每个观测站沿 Y 轴方向安装 3 元均匀线阵,阵元间距等于半倍波长. 3 个观测站的初始位置分别位于 $(0, 0)$ km、 $(48.2, 0.11)$ km、 $(0, -55.42)$ km,观测站在目标区域周围以 $(0, 160)$ m/s 为预设速度作匀速直线运动巡逻监测,监测持续时间为 30 s,其预设轨迹如图 5 所示. 3 个观测站每隔 1 s 观测并采集一次目标辐射的非圆信号,共 30 个观测时隙,每个观测站在 30 个时隙内的预设位置在运动直线上等间隔分布,表 2 给出了具体预设位置参数. 实际中在每个观测位置上存在 20 dB 的随机位置误差(m)、14 dB 的随机速度误差(m/s),以及 5 dB 的随机姿态角误差($^\circ$),各观测站的本振频率相对于发射信号载频存在随机频率抖动,频差标准差分别为 3 Hz. 假设每个观测时隙长度为 10 ms,采样率为 10 kHz,采样点数为 100. 各观测站将各时隙内采集的离散数据分别通过 $J=3$ 个带通滤波器,每个滤波器带宽约为 1.5 kHz,由于高采倍数大于 3,因此令 $I=3$,按照式(22)与式(23)构造神经网络的输入矩阵. 仿真中将目标与辅助信源的运动模型设为恒定速度,为防止深度神经网络的过拟合,利用 4.3.2 节的描述方式随机产生训练样本轨迹. 网络训练过程中总共使用了 20 000 组训练样本,其中 2 000 组为测试样本,采用表 3 中的训练参数完成网络训练.

数值仿真分为 5 组,每组蒙特卡洛仿真次数均为 200 次,采用轨迹估计均方根误差(Root Mean Square Error, RMSE)、轨迹估计误差的(经验)累积分布函数、以及各观测时隙内逐点定位误差等参数来评价算法的跟踪性能,其中对轨迹估计均方根误差 $RMSE_p$ 的统计采

用如下计算公式:

$$RMSE_p = \sqrt{\frac{1}{200} \sum_{i=1}^{200} \frac{1}{K} \sum_{k=1}^K \| \mathbf{p}_i^{(k)} - \hat{\mathbf{p}}_i^{(k)} \|_2^2} \quad (27)$$

去中, $\mathbf{p}_i^{(k)}$ 表示第 i 次仿真中目标在第 k 个时隙内的真实位置; $\hat{\mathbf{p}}_i^{(k)}$ 表示第 i 次仿真中对目标在第 k 个时隙内位置的估计值.

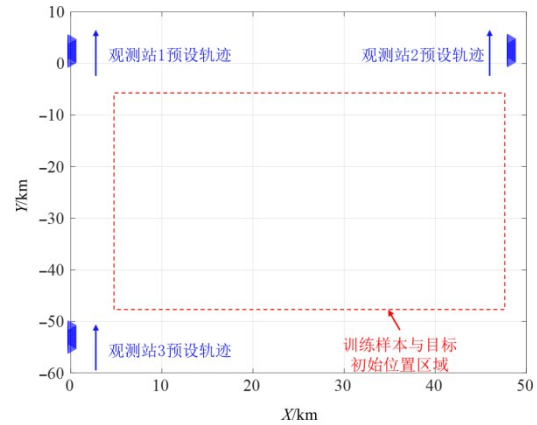


图5 观测站与目标位置几何分布场景示意图

5.1 关于不同目标轨迹的跟踪性能仿真

首先,依次在信噪比为 5 dB 和 15 dB 的条件下,随机产生 10 条运动目标轨迹,其初始位置在如图 5 所示的初始位置区域内随机选取,初始速度大小和方向分别在 $[100 \text{ m/s}, 200 \text{ m/s}]$, $[0^\circ, 360^\circ]$ 范围内随机产生,位置速度分别加有均值为 0 m、方差为 0.5 m^2 与均值为 0 m/s、方差为 $1 (\text{m/s})^2$ 的高斯机动噪声. 图 6 与图 7 分别给出了信噪比为 5 dB 与 15 dB 条件下,本文算法与传统的两

表 2 各观测站的预设位置参数

观测时隙	观测站 1 位置		观测站 2 位置		观测站 3 位置	
	x/km	y/km	x/km	y/km	x/km	y/km
1	0	0	48.2	0.11	0	-55.42
2	0	0.16	48.2	0.27	0	-55.26
3	0	0.32	48.2	0.43	0	-55.10
4	0	0.48	48.2	0.59	0	-54.94
5	0	0.64	48.2	0.75	0	-54.78
6	0	0.80	48.2	0.91	0	-54.62
7	0	0.96	48.2	1.07	0	-54.46
8	0	1.12	48.2	1.23	0	-54.30
9	0	1.28	48.2	1.39	0	-54.14
10	0	1.44	48.2	1.55	0	-53.98
11	0	1.60	48.2	1.71	0	-53.82
12	0	1.76	48.2	1.87	0	-53.66
13	0	1.92	48.2	2.03	0	-53.50
14	0	2.08	48.2	2.19	0	-53.34
15	0	2.24	48.2	2.35	0	-53.18
16	0	2.40	48.2	2.51	0	-53.02
17	0	2.56	48.2	2.67	0	-52.86
18	0	2.72	48.2	2.83	0	-52.70
19	0	2.88	48.2	2.99	0	-52.54
20	0	3.04	48.2	3.15	0	-52.38
21	0	3.20	48.2	3.31	0	-52.22
22	0	3.36	48.2	3.47	0	-52.06
23	0	3.52	48.2	3.63	0	-51.90
24	0	3.68	48.2	3.79	0	-51.74
25	0	3.84	48.2	3.95	0	-51.58
26	0	4.00	48.2	4.11	0	-51.42
27	0	4.16	48.2	4.27	0	-51.26
28	0	4.32	48.2	4.43	0	-51.10
29	0	4.48	48.2	4.59	0	-50.94
30	0	4.64	48.2	4.75	0	-50.78

表 3 CNN+BiLSTM 神经网络训练参数设置

参数类型	取值
迭代轮数	100
批量大小	32
初始学习率	0.001
学习率策略	分段调整
学习率调整间隔	1 epoch
学习率调整倍数	0.9
Adam 衰减率 λ_1	0.9
Adam 衰减率 λ_2	0.995

步跟踪算法(利用信号非圆特性)、基于粒子滤波的直接跟踪算法^[22]对 10 条不同运动轨迹的轨迹估计均方根误差,其统计方式如式(27)。从图 6 与图 7 中可以看出:由于基于粒子滤波的直接跟踪算法^[22]没有利用信号非

圆特性且没有考虑多种模型误差的影响,其轨迹估计精度最差;传统两步跟踪算法虽然利用非圆特性,但由于两步估计模式导致信息损失且没有考虑多种模型误差的影响,其轨迹估计精度比基于粒子滤波的直接跟踪算法^[22]仅有略微提升;本文所提直接跟踪技术结合了信号非圆特性与直接跟踪思想,可以在多种目标轨迹条件下明显提升对非圆目标的轨迹估计精度,说明本文所设计与训练的 CNN+BiLSTM 神经网络可以实现对多种模型误差的校正,且对不同目标运动轨迹具有较好的泛化性。此外,对比图 6 与图 7,可以发现本文算法的跟踪精度随着信噪比的增加有明显提升,而另外两种对比算法的跟踪精度随着信噪比的增加改善不大,这是因为对比算法未对模型误差进行校正,因此即使信噪比增加至 15 dB 时,其性能仍然受到模型误差的影响,导致其跟踪性能没有明显改善。




图 6 信噪比为 5 dB 条件下不同运动轨迹的轨迹估计均方根误差





图 7 信噪比为 15 dB 条件下不同运动轨迹的轨迹估计均方根误差


5.2 关于轨迹估计误差累积分布函数的仿真

本组仿真以同样的方式产生 2 条运动目标轨迹,其中第 1 条运动轨迹从 (23.78, -21.83) km 出发,初始速度大小和方向分别为 167.3 m/s, 27.1°;第 2 条运动轨迹从 (34.81, -15.26) km 出发,初始速度大小和方向分别为

126.1 m/s, 275.7°. 在目标到达观测站的信噪比分别为 5 dB 与 15 dB 的条件下, 基于 200 次蒙特卡洛仿真结果, 图 8 与图 9 分别给了针对两条运动轨迹的轨迹估计误差的累积分布函数曲线, 可以看出在两种信噪比条件下本文算法的轨迹估计误差累积分布函数均明显高于传统两步跟踪算法(利用信号非圆特性)与基于粒子滤波的直接跟踪算法^[22], 说明新算法在多种模型误差影响下的整体轨迹估计误差范围更小、精度更高。



(a) SNR=5 dB




(b) SNR=15 dB


图 8 第 1 条运动轨迹的轨迹估计误差累积分布函数曲线

5.3 关于逐点定位性能的仿真

在与 5.2 节相同仿真条件下, 本组仿真将利用箱线图展示算法在各时隙内的逐点定位性能. 令信噪比分别为 5 dB 和 15 dB, 基于 200 次蒙特卡洛仿真结果, 依次画出本文算法与传统两步跟踪算法(利用信号非圆特性)、基于粒子滤波的直接跟踪算法^[22]针对两条运动轨迹的逐点定位误差箱型图, 结果如图 10~13 所示. 可以看出, 相比于其他两种未考虑模型误差影响的跟踪算法, 本文算法对各观测时隙内目标位置的估计误差更小, 误差分布也更加集中, 说明本文算法的整条轨迹估计性能和逐点定位性能都更加稳定. 此外, 仿真结果显示本文算法



(a) SNR=5 dB



(b) SNR=15 dB


图 9 第 2 条运动轨迹的轨迹估计误差累积分布函数曲线

在中间观测时隙内的定位误差更小、两端观测时隙内的定位误差更大, 这是因为本文算法采用 BiLSTM 网络模型, 能够更好地利用空时特征序列在时间上的前后信息. 由于 BiLSTM 网络中各时隙间的时序依赖关系是相同的, 那么中间观测时隙的位置估计能够同时获取更多的前后向信息, 因此定位误差更小; 而两端观测时隙的位置估计能够获取的前后向信息不对称, 难以充分利用前后向信息, 因而定位误差更大.


5.4 不同观测预设位置场景下的跟踪性能仿真

本组仿真将研究观测站在运动直线上具有不同预设位置时的跟踪性能. 令 3 个观测站的初始位置保持不变, 在目标区域周围仍以 (0, 160) m/s 为预设速度作匀速直线运动巡逻监测, 依次在 30 个观测时隙内采集目标辐射的非圆信号. 不同之处在于, 本组仿真中改变各观测时隙内的预设位置, 预设 3 个观测站在每隔 1 s 内随机选取时刻采集一次目标信号, 即每个观测站在 30 个观测时隙内的预设位置是在运动直线上非等间隔随机分布的, 表 4 给出了具体预设位置参数.


在上述观测场景下, 本组仿真分别在信噪比为 5 dB




(a) 本文算法




(a) 本文算法




(b) 针对非圆信号的两步跟踪算法



(b) 针对非圆信号的两步跟踪算法



(c) 已有直接跟踪算法



(c) 已有直接跟踪算法

图 10 第 1 条运动轨迹的逐点定位误差箱型图(SNR=5 dB)


图 11 第 1 条运动轨迹的逐点定位误差箱型图(SNR=15 dB)

与 15 dB 的条件下,对与 5.1 节中的 10 条运动轨迹进行跟踪,图 14 与图 15 分别给出了两种信噪比条件下的轨迹估计均方根误差,其统计方式如式(27). 将图 14、图 15 与图 6、图 7 进行对比,可以看出:针对观测站在直线上预设位置不同的两种场景,本文算法在相同信噪比条件下的跟踪精度差别不大;在两种观测预设位置场景下,本文算法的跟踪精度均明显优于针对非圆信号


的两步跟踪算法与现有直接跟踪算法.

5.5 关于平均运行时间的仿真


神经网络训练过程一般都是离线完成的,一旦训练完成,本网络可用于在线的跟踪任务,避免了多维参数优化所需的谱峰搜索或者迭代计算. 为了对各种算法的计算复杂度进行对比,本组仿真将仿真参数与 5.2 节设置得相同,统计了针对非圆信号的两步跟踪算法、




(a) 本文算法




(a) 本文算法




(b) 针对非圆信号的两步跟踪算法



(b) 针对非圆信号的两步跟踪算法



(c) 已有直接跟踪算法



(c) 已有直接跟踪算法

图12 第2条运动轨迹的逐点定位误差箱型图(SNR=5 dB)


图13 第2条运动轨迹的逐点定位误差箱型图(SNR=15 dB)

基于粒子滤波的直接跟踪算法^[22],与本文直接跟踪算法在线跟踪时200次蒙特卡洛仿真的平均运行时间,相应的结果如表5所示.结果表明,针对非圆信号的两步跟踪算法由于需要“观测参数估计+滤波轨迹跟踪”两

步估计步骤,其运行时间最长;本文的CNN+BiLSTM直接跟踪模型在进行在线跟踪时明显快于其他方法,说明本文算法在三种跟踪方法中的在线计算复杂度最低,具有较为高速的在线计算能力.

表 4 各观测站的预设位置参数(直线上非等间隔分布)

观测时隙	观测站 1 位置		观测站 2 位置		观测站 3 位置	
	x/km	y/km	x/km	y/km	x/km	y/km
1	0	0	48.2	0.11	0	-55.42
2	0	0.12	48.2	0.17	0	-55.34
3	0	0.25	48.2	0.39	0	-55.26
4	0	0.36	48.2	0.51	0	-54.96
5	0	0.51	48.2	0.69	0	-54.79
6	0	0.77	48.2	0.90	0	-54.73
7	0	0.82	48.2	1.04	0	-54.47
8	0	1.06	48.2	1.16	0	-54.34
9	0	1.24	48.2	1.34	0	-54.19
10	0	1.34	48.2	1.40	0	-54.06
11	0	1.54	48.2	1.63	0	-53.87
12	0	1.67	48.2	1.82	0	-53.79
13	0	1.88	48.2	1.91	0	-53.61
14	0	2.06	48.2	2.19	0	-53.49
15	0	2.21	48.2	2.30	0	-53.27
16	0	2.29	48.2	2.44	0	-53.04
17	0	2.43	48.2	2.65	0	-53.00
18	0	2.67	48.2	2.69	0	-52.70
19	0	2.72	48.2	2.88	0	-52.55
20	0	2.94	48.2	2.99	0	-52.51
21	0	3.14	48.2	3.21	0	-52.31
22	0	3.29	48.2	3.38	0	-52.22
23	0	3.40	48.2	3.52	0	-52.01
24	0	3.66	48.2	3.70	0	-51.75
25	0	3.71	48.2	3.86	0	-51.68
26	0	3.87	48.2	4.04	0	-51.51
27	0	4.09	48.2	4.12	0	-51.40
28	0	4.21	48.2	4.39	0	-51.20
29	0	4.38	48.2	4.56	0	-51.04
30	0	4.59	48.2	4.61	0	-50.92



(观测站预设位置非等间隔分布)

图 15 信噪比为 15 dB 条件下不同运动轨迹的轨迹估计均方根误差

表 5 三种跟踪方法完成 200 次在线跟踪测试的平均运行时间


方法	平均运行时间/s
本文直接跟踪算法	0.101 8
针对非圆信号的两步跟踪算法	5.223 3
基于粒子滤波的直接跟踪算法	2.326 9

6 结论

本文针对多个运动观测平台存在航迹与姿态误差、接收频率抖动等多种误差影响下的非圆信号跟踪问题,提出了一种基于 CNN+BiLSTM 神经网络的非圆信号目标直接跟踪算法. 该算法在构造神经网络输入时,结合多个阵列接收信号各频带之间的相关性与信号的非圆特性,将小孔径阵列经过二次虚拟扩展为大孔径阵列,且引入(单步)直接跟踪方式,可以从扩展多站观测矢量的非圆信号子空间中直接挖掘位置信息,进一步提升针对非圆目标的跟踪精度;设计并训练 CNN+BiLSTM 神经网络结构,能够学习轨迹映射规律与多种误差信息. 通过 5 组仿真验证了新方法的有效性和优越性,仿真结果显示该方法在实际接收模型与理想模型存在误差的定位场景中,能够明显提高多站协同跟踪的鲁棒性与稳定性.

参考文献

- [1] 黄亮, 刘忠, 石章松, 等. 无人机系统纯方位定位技术及应用[M]. 北京: 国防工业出版社, 2015.
- [2] 王鼎, 吴瑛, 张莉, 等. 无线电测向与定位理论及方法[M]. 北京: 国防工业出版社, 2016.
- [3] 朱建丰, 陈玥, 郝本建, 等. 基于合成孔径阵列的雷达辐射源被动定位技术研究[J]. 电子学报, 2017, 45(10): 2332-2336. ZHU J F, CHEN Y, HAO B J, et al. Passive radar source localization using synthetic aperture antenna array[J]. Acta Electronica Sinica, 2017, 45(10): 2332-2336. (in Chinese)
- [4] 王鼎, 尹洁昕, 张欣光, 等. 一种基于加权多维标度分析的多个非相关源 TDOA/FDOA 协同定位方法[J]. 航空学报, 2017, 38(12): 2233-2241.




(观测站预设位置非等间隔分布)

图 14 信噪比为 5 dB 条件下不同运动轨迹的轨迹估计均方根误差

- 2023, 44(7): 222-245.
- WANG D, YIN J X, ZHANG X G, et al. A TDOA/FDOA cooperative localization method for multiple disjoint sources based on weighted multidimensional scaling analysis[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(7): 222-245. (in Chinese)
- [5] 徐美玲. 无人机速度与姿态角瞬态控制技术研究[D]. 成都: 电子科技大学, 2014.
- XU M L. The Transient Control Research on the UAV Speed and Attitude Angle[D]. Chengdu: University of Electronic Science and Technology of China, 2014. (in Chinese)
- [6] WANG D, YIN J X, CHEN X, et al. Direct position determination of multiple constant modulus sources based on direction of arrival and Doppler frequency shift[J]. *Circuits, Systems and Signal Processing*, 2020, 39(1): 268-306.
- [7] HO K C, XU W. An accurate algebraic solution for moving source location using TDOA and FDOA measurements[J]. *IEEE Transactions on Signal Processing*, 2004, 52(9): 2453-2463.
- [8] LIU Z X, HU D X, ZHAO Y J, et al. Computationally efficient TDOA, FDOA and differential Doppler rate estimation algorithm for passive emitter localization[J]. *Digital Signal Processing*, 2020, 96: 102598.
- [9] YU H G, HUANG G M, GAO J, et al. An efficient constrained weighted least squares algorithm for moving source location using TDOA and FDOA measurements[J]. *IEEE Transactions on Wireless Communications*, 2012, 11(3): 44-47.
- [10] YU H G, HUANG G M, GAO J. Practical constrained least-square algorithm for moving source location using TDOA and FDOA measurements[J]. *Journal of Systems Engineering and Electronics*, 2012, 23(4): 488-494.
- [11] YI Q F, GUO F C, MENG X W, et al. Constrained location algorithms based on total least squares method using TDOA and FDOA measurements[C]//2012 IET International Conference on Automatic Control and Artificial Intelligence. London: IET, 2012: 2587-2590.
- [12] ZHANG F R, SUN Y M, WAN Q. Calibrating the error from sensor position uncertainty in TDOA-AOA localization[J]. *Signal Processing*, 2020, 166: 1-16.
- [13] CHEN X, WANG D, YIN J X, et al. Bias reduction for TDOA localization in the presence of receiver position errors and synchronization clock bias[J]. *EURASIP Journal on Advances in Signal Processing*, 2019, 7: 1-26.
- [14] 孙霆, 董春曦. 传感器参数误差下的运动目标 TDOA/FDOA 无源定位算法[J]. *航空学报*, 2020, 41(2): 257-266.
- SUN T, DONG C X. TDOA/FDOA passive localization algorithm for moving target with sensor parameter errors[J]. *Acta Aeronautica et Astronautica Sinica*, 2020, 41(2): 257-266. (in Chinese)
- [15] WANG D, YIN J X, TANG T, et al. Quadratic constrained weighted least-squares method for TDOA source localization in the presence of clock synchronization bias Analysis and solution[J]. *Digital Signal Processing*, 2018, 82(11): 237-257.
- [16] TIAN Z W, LIU W F, RU X F. Multi-target localization and tracking using TDOA and AOA measurements based on Gibbs-GLMB filtering[J]. *Sensors*, 2019, 19(24): 5437.
- [17] JING T, TIAN W, HUANG G M. TDOA-based adaptive observer trajectory optimization algorithm for tracking in passive coherent location system[J]. *The Journal of Engineering*, 2019(20): 6863-6867.
- [18] AMAR A, WEISS A J. Localization of narrowband radio emitters based on Doppler frequency shifts[J]. *IEEE Transactions on Signal Processing*, 2008, 56(11): 5500-5508.
- [19] MA F H, LIU Z M, GUO F C. Direct position determination in asynchronous sensor networks[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(9): 8790-8803.
- [20] KULIKOV G Y, KULIKOVA M V. Accurate continuous-discrete unscented Kalman filtering for estimation of nonlinear continuous-time stochastic models in radar tracking [J]. *Signal Processing*, 2017, 139: 25-35.
- [21] KULIKOV G Y, KULIKOVA M V. Estimation of maneuvering target in the presence of non-Gaussian noise: A coordinated turn case study[J]. *Signal Processing*, 2018, 145: 241-257.
- [22] SIDI A Y, WEISS A J. Delay and Doppler induced direct tracking by particle filter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2014, 50(1): 559-572.
- [23] 逯志宇, 巴斌, 任衍青, 等. 基于进化粒子滤波的数据域直接跟踪方法 [J]. *系统工程与电子技术*, 2018, 40(5): 968-975.
- LU Z Y, BA B, REN Y Q, et al. Direct trajectory determination algorithm based on evolutionary particle filter[J]. *Systems Engineering and Electronics*, 2018, 40(5): 968-975. (in Chinese)
- [24] YIN J X, WANG D, WU Y, et al. ML-based single-step estimation of the locations of strictly noncircular sources[J]. *Digital Signal Processing*, 2017, 69: 224-236.
- [25] YIN J X, WANG D, NIE F Q, et al. Single-step geolocation for a non-circular source in the presence of satellite orbit perturbations[J]. *IET Signal Processing*, 2022, 16(2): 170-200.

- [26] WANG D, YIN J X, CHEN X, et al. Direct position determination of multiple constant modulus sources based on direction of arrival and Doppler frequency shift[J]. *Circuits Systems and Signal Processing*, 2020, 39(1): 268-306.
- [27] BIALER O, RAPHAELI D, WEISS A J. Robust time-of-arrival estimation in multipath channels with OFDM signals[C]//2017 25th European Signal Processing Conference. Piscataway: IEEE, 2017: 2724-2728.
- [28] XIE J, WANG L, ZHANG W, et al. Direction finding algorithm for noncircular signals in the presence of unknown mutual coupling[C]//2018 USNC-URSI Radio Science Meeting. Piscataway: IEEE, 2018: 47-48.
- [29] LI Z, SHEN J, ZHAI H, et al. 3-D Localization for Near-Field and Strictly Noncircular Sources Via Centro-Symmetric Cross array[J]. *IEEE Sensors Journal*, 2021, 21(6): 8432-8440.
- [30] 余婉婷. 基于深度学习的机动目标轨迹跟踪关键技术研究[D]. 郑州: 战略支援部队信息工程大学, 2022.
- YU W T. Research on Key Technologies of Maneuvering Target Trajectory Tracking Based on Deep Learning[D]. Zhengzhou: PLA Strategic Support Force Information Engineering University, 2022. (in Chinese)
- [31] PICINBONO B. On circularity[J]. *IEEE Transactions on Signal Processing*, 1994, 42(12): 3473-3482.
- [32] ABEIDA H. Imagerie D' Antenne Pour Signaux Non Circulaires: Bornes de Performance et Algorithmes[D]. Orsay: Université Paris VI, 2006.
- [33] ABEIDA H, J-P DELMAS. MUSIC-like estimation of direction of arrival for noncircular sources[J]. *IEEE Transactions on Signal Processing*, 2006, 54(7): 2678-2690.
- [34] ABEIDA H, J-P DELMAS. Statistical performance of MUSIC-like algorithms in resolving noncircular sources[J]. *IEEE Transactions on Signal Processing*, 2008, 56(9): 4317-4329.
- [35] 张小飞, 曾浩威, 郑旺, 等. 多阵列中非圆信号借助于降维搜索和子空间数据融合的直接定位算法[J]. *数据采集与处理*, 2020, 35(6): 1022-1032.
- ZHANG X F, ZENG H W, ZHENG W, et al. Direct position determination of non-circular signals with multiple arrays by exploiting reduced-dimension finding and subspace data fusion[J]. *Journal of Data Acquisition and Processing*, 2020, 35(6): 1022-1032. (in Chinese)
- [36] 逯志宇, 王建辉, 秦天柱, 等. 基于对称旋转变性的非圆相干分布源直接定位算法[J]. *电子与信息学报*, 2019, 41(3): 537-543.
- LU Z Y, WANG J H, QIN T Z, et al. Direct position determination for coherently distributed noncircular source based on symmetric shift invariance[J]. *Journal of Electronics & Information Technology*, 2019, 41(3): 537-543. (in Chinese)
- [37] 王永良, 陈辉, 彭应宁. 空间谱估计理论与算法[M]. 北京: 清华大学出版社, 2005.
- [38] 吴瑛, 张莉, 张冬玲. 数字信号处理[M]. 第二版. 西安: 西安电子科技大学出版社, 2017.
- [39] TIRER T, WEISS A J. High resolution localization of narrowband radio emitters based on Doppler frequency shifts[J]. *Signal Processing*, 2017, 141: 288-298.
- [40] CHEN Y, SUN J, LIN Y, et al. Hybrid N-inception-LSTM-based aircraft coordinate prediction method for secure air traffic[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(3): 2773-2783.
- [41] CHEN X, WANG D, YIN J X, et al. A direct position-determination approach for multiple sources based on neural network computation[J]. *Sensors*, 2018, 18(6): 1925.

作者简介



尹洁昕 女, 1989年8月出生于河南省郑州市. 现为中国人民解放军战略支援部队信息工程大学信息工程学院副教授、硕士生导师. 主要研究方向为无线信号定位、阵列信号处理.
E-mail: Cindyn0807@163.com



王鼎 男, 1982年10月出生于安徽省芜湖市. 现为中国人民解放军战略支援部队信息工程大学信息工程学院副教授、博士生导师. 主要研究方向为无线信号定位、阵列信号处理.
E-mail: wang_ding814@aliyun.com



杨欣 女, 1980年3月出生于河北省遵化市. 现为郑州大学计算机与人工智能学院副教授、硕士生导师. 主要研究方向数据科学和人工智能.
E-mail: 416469463@qq.com



杨宾 男, 1974年11月出生于江西省南昌市. 现为中国人民解放军战略支援部队信息工程大学信息工程学院教授、博士生导师. 主要研究方向为无线电频谱监测.
E-mail: ybmailbox@126.com