

<http://bhxb.buaa.edu.cn> [jbuaa@buaa.edu.cn](mailto:jbuaa@buaa.edu.cn)

DOI: 10.13700/j.bh.1001-5965.2024.0013

# 基于轻量化 BiLSTM 的多源雷达多目标跟踪点航数据关联算法

代睿\*, 李洁, 何立火, 高新波

(西安电子科技大学 电子工程学院, 西安 710071)

**摘要:** 针对密集杂波环境下多源雷达多目标跟踪容易出现数据关联错误、精细化建模数据关联算法计算量大的问题, 提出一种基于轻量化双向长短期记忆 (BiLSTM) 网络的多源雷达多目标跟踪点航数据关联算法。构造杂波环境下雷达回波与目标航迹之间的多源雷达关联事件矩阵; 基于多源雷达点迹与多目标航迹量测预测, 借助最小最大标准化处理, 设计归一化的距离特征张量; 以归一化的距离特征张量为输入、以关联事件矩阵为输出, 建立基于轻量化 BiLSTM 的多源雷达多目标点迹/航迹数据关联网络模型。针对每个目标航迹, 以每个雷达输出的最大概率对应的雷达点迹作为关联量测, 利用卡尔曼滤波实现航迹更新。密集杂波环境下多雷达协同跟踪多目标仿真结果表明: 所提算法在关联准确率与跟踪精度方面与集中式联合概率数据关联滤波结果基本一致, 明显优于概率数据关联滤波、最近邻数据关联滤波、基于全连接层的点航关联滤波算法和基于长短期记忆 (LSTM) 网络的点航关联滤波算法; 但平均运行时间明显小于联合概率数据关联滤波, 与最近邻数据关联滤波几乎一致。

**关键词:** 数据关联; 多目标跟踪; 多源雷达; 双向长短期记忆网络; 轻量化神经网络

**中图分类号:** TN953

**文献标志码:** A

**文章编号:** 1001-5965(2026)04-1139-09

随着雷达技术日新月异的快速发展, 雷达多目标跟踪技术在诸如反导拦截、空中搏斗、交通管控、无人驾驶等军民领域受到了越来越多的关注<sup>[1-3]</sup>。随着实际环境的复杂多变, 系统规模的与日俱增, 跟踪质量需求的日益提升, 利用单雷达提供的感知信息对探测视野内感兴趣目标进行实时跟踪已很难满足要求<sup>[3]</sup>。因此, 往往需要多平台多源雷达协同实现高质量多目标跟踪<sup>[6]</sup>。作为多目标跟踪核心技术之一的数据关联, 也逐渐从单一雷达情况发展至多源雷达情况, 成为制约跟踪质量的关键因素, 受到国内外学者的广泛关注<sup>[1-2,6]</sup>。

早期多目标跟踪数据关联算法往往针对单雷

达展开。基于近邻思想, Singer 等提出最近邻数据关联 (nearest neighbor data association, NNDA) 算法, 通过在跟踪波门内判定统计距离最近的雷达点迹并将其作为目标有效回波, 利用卡尔曼滤波获得目标位置、速度等在线递推估计, 实现稀疏杂波下多批次目标跟踪<sup>[7]</sup>。考虑雷达回波往往受杂波干扰, 且跟踪波门内可能存在多个雷达点迹, Bar-Shalom 等提出概率数据关联 (probabilistic data association, PDA) 算法, 实现波门内所有雷达点迹对目标状态的加权更新<sup>[8]</sup>。考虑到不同目标航迹对应的跟踪波门可能相交, 并导致同一回波落入多个波门之内, Bar-Shalom 等提出联合概率数据关联 (joint PDA,

收稿日期: 2024-01-10; 录用日期: 2024-03-21; 网络出版时间: 2024-04-15 20:01

网络出版地址: [link.cnki.net/urlid/11.2625.V.20240412.1504.003](http://link.cnki.net/urlid/11.2625.V.20240412.1504.003)

基金项目: 国家自然科学基金 (62036007, 62276203)

\* 通信作者. E-mail: [dairui168@126.com](mailto:dairui168@126.com)

**引用格式:** 代睿, 李洁, 何立火, 等. 基于轻量化 BiLSTM 的多源雷达多目标跟踪点航数据关联算法 [J]. 北京航空航天大学学报, 2026, 52 (4): 1139-1147. DAI R, LI J, HE L H, et al. Light-weight BiLSTM-based data association algorithm between echoes and tracks for multi-radar multi-target tracking [J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52 (4): 1139-1147 (in Chinese).

JPDA)算法,通过关联事件的有效拆分,保证同一雷达回波仅更新一个目标航迹,实现了密集杂波下多目标数据关联<sup>[8]</sup>。基于上述关联思想,相关学者提出了一系列改进算法,例如,基于所有目标统计距离最小的全局 NNDA(global NNDA, GNNDA)、考虑目标存在概率的综合 PDA(integrated PDA, IPDA)、考虑关联准确率与计算代价折中的集合 JPDA(set JPDA, SJPDA)等<sup>[9-11]</sup>。此外,考虑每个新接收到雷达点迹可能来自新目标、虚警或已有航迹,Reid 提出多假设跟踪(multiple hypothesis tracking, MHT)方法<sup>[12]</sup>,通过对建立的时间窗内多个候选假设的概率评估及管理来实现多目标跟踪,并衍生出面向假设和面向航迹的 MHT 两类经典实现<sup>[12-13]</sup>。

借助随机有限集理论建模观测视域内多目标/多回波模型, Mahler 提出概率假设密度(probability hypothesis density, PHD)滤波<sup>[14]</sup>,避免了显式的数据关联求解,受到了多目标跟踪领域的广泛关注,并衍生出一系列诸如势 PHD(cardinalized PHD, CPHD)滤波、多伯努利滤波、广义标签多伯努利滤波等衍生方法<sup>[14-15]</sup>。

上述无论经典数据关联算法还是 PHD 滤波方法,往往都是基于模型驱动实现的,如 JPDA 算法依赖于雷达点迹似然分布、PHD 滤波依赖于杂波分布模型等。事实上,在复杂环境下,对多目标跟踪系统进行准确建模往往非常困难。近年来,随着计算机算力的飞速发展,以海量样本数据为驱动并结合实际应用的深度学习<sup>[16]</sup>正逐步改变,甚至替代基于严格数学推导的模型驱动方法,其在目标跟踪领域也逐渐崭露头角,受到越来越多关注<sup>[17-18]</sup>。借助长短期记忆(long short-term memory, LSTM)网络表征目标机动运动, Liu 等提出无杂波环境下基于深度学习的机动目标跟踪方法,在训练样本充裕的条件下,相比于传统跟踪算法,获得了更高的跟踪精度<sup>[19]</sup>。考虑状态空间建模存在先验未知参数, Revach 等提出神经网络辅助下卡尔曼滤波方法,在非合作单目标跟踪中进行了仿真验证<sup>[20]</sup>。针对杂波环境下多目标跟踪, Milan 等借助循环神经网络,提出基于 LSTM 的多目标数据关联方法,实现新生目标、持续目标与拟消失目标的有效跟踪<sup>[21]</sup>。Liu 等利用 LSTM 构造了 DeepDA,通过时间反向传播算法结合 RMSProp 优化实现对 DeepDA 的监督训练,直接得到杂波环境下雷达点迹/目标航迹的关联概率,在多目标交叉等典型场景进行了验证<sup>[22]</sup>。Verma 等针对三维强机动目标跟踪,构建了包括状态预测、状态滤波更新、航迹管理及数据关联等模块化端到端的雷达多目标跟踪方法,并在广义最优次模式分配

度量下验证了所提方法的有效性<sup>[23]</sup>。此外,李文娜等设计了一种基于 Transformer 网络的多目标跟踪数据关联方法,利用掩蔽交叉熵损失与重叠度损失相结合的损失函数来优化网络参数,解决了多目标与多量测的匹配问题<sup>[24]</sup>。

然而,上述深度学习多目标数据关联方法仅针对单一雷达情况。对于多源雷达多目标跟踪数据关联而言,传统模型驱动数据关联方法在单雷达数据关联基础上,要么采取雷达点迹扩维形式进行处理,要么利用序贯方式对多源雷达点迹一一关联<sup>[6]</sup>。针对多源雷达多目标跟踪数据关联,如何既能继承网络的泛化能力和自学习能力,又能充分挖掘多源雷达数据特征,以保证数据关联的准确性,从而获得优于单雷达多目标跟踪的航迹质量,具有重要的工程应用价值但仍然是一个开放的问题。

基于上述讨论,考虑多源雷达数据关联本质上是一类依赖于历史数据推理当前决策的过程,本文提出基于轻量化 BiLSTM(bi-directional LSTM)的多源雷达多目标跟踪点航数据关联算法。具体创新点如下:首先,设计了多源雷达点迹数据归一化预处理方法,以构造适应于深度神经网络的特征张量输入;其次,构建了面向多源雷达多目标跟踪的轻量化 BiLSTM 数据关联网络,实现多雷达下关联概率矩阵的在线学习;最后,借助关联概率矩阵最值寻优,完成可变目标数量的 0/1 关联结果输出,并借助卡尔曼滤波实现目标状态的更新输出。仿真结果表明,在密集杂波环境下,本文算法在运行时间较少的情况下获得了满意的跟踪精度。

## 1 问题描述

考虑  $S$  个雷达协同对感兴趣区域进行多目标跟踪,目标个数最大为  $N$ 。记第  $i$  个目标服从的离散时间动力学运动方程为

$$\mathbf{x}_{i,k} = \mathbf{F}_{i,k-1}\mathbf{x}_{i,k-1} + \mathbf{w}_{i,k-1} \quad (1)$$

式中:  $\mathbf{x}_{i,k} \in \mathbf{R}^{n_x}$ , 表示  $k$  时刻第  $i$  个目标的状态向量;  $\mathbf{F}_{i,k-1}$  为第  $i$  个目标的状态转移矩阵;  $\mathbf{w}_{i,k-1}$  为均值为 0、协方差为  $\mathbf{Q}_{i,k-1}$  的高斯白噪声,即  $\mathbf{w}_{i,k-1} \sim \mathcal{N}(0, \mathbf{Q}_{i,k-1})$ , 其代表目标运动建模的不确定性。

假设第  $i$  个目标被第  $j$  个雷达 ( $j = 1, 2, \dots, S$ ) 有效探测且获得的相应雷达点迹为  $\mathbf{z}_{j,k}^\ell$ , 则相应量测模型为

$$\mathbf{z}_{j,k}^\ell = \mathbf{H}_{j,k}^\ell \mathbf{x}_{i,k} + \mathbf{v}_{j,k}^\ell \quad (2)$$

式中:  $\mathbf{H}_{j,k}^\ell$  为第  $j$  个雷达中第  $\ell$  个量测的量测矩阵;  $\mathbf{v}_{j,k}^\ell$  为量测噪声,其为零均值、协方差为  $\mathbf{R}_{j,k}$  的高斯白噪声。对于第  $j$  个雷达而言,受复杂环境的影响,

其在 $k$ 时刻获得的雷达点迹可能仅包含部分(受检测概率限制,往往并非全部)真实目标回波,且可能包含虚假杂波。因此,记 $k$ 时刻第 $j$ 个雷达获得的雷达点迹集合 $Z_{j,k} = \{z_{j,k}^\ell, \ell = 1, 2, \dots, m_{j,k}\}$ 。 $m_{j,k}$ 表示第 $j$ 个雷达在 $k$ 时刻获得的雷达点迹总个数。

假设 $k$ 时刻存在 $N_k$ 条目标航迹需要与各雷达点迹集合 $\{Z_{1,k}, Z_{2,k}, \dots, Z_{S,k}\}$ 中相应点迹进行关联,并在此基础上利用卡尔曼滤波获得各目标航迹的状态更新。本文假定每个雷达点迹至多与一条目标航迹关联,且每条目标航迹至多关联每个雷达的一个点迹。换言之,多源雷达多目标数据关联即寻找关联矩阵:

$$\mathbf{A}_k = [\mathbf{A}_{1,k} \quad \mathbf{A}_{2,k} \quad \dots \quad \mathbf{A}_{S,k}] \quad (3)$$

式中: $\mathbf{A}_{j,k}$ 表示 $k$ 时刻第 $j$ 个雷达点迹集合 $Z_{j,k}$ 与 $N_k$ 个目标航迹的关联结果,且 $\mathbf{A}_{j,k} = [a_{j,k}^{\tau\ell}]$ ,其中, $\tau = 1, 2, \dots, N_k$ 表示第 $\tau$ 个目标航迹, $\ell = 1, 2, \dots, m_{j,k}$ 表示集合 $Z_{j,k}$ 中第 $\ell$ 个雷达点迹。进一步地:

$$a_{j,k}^{\tau\ell} = \begin{cases} 1 & z_{j,k}^\ell \text{来自目标}\tau \\ 0 & z_{j,k}^\ell \text{与目标}\tau \text{无关} \end{cases} \quad (4)$$

且

$$\begin{cases} \sum_{\tau=1}^{N_k} a_{j,k}^{\tau\ell} \leq 1 \\ \sum_{\ell=1}^{m_{j,k}} a_{j,k}^{\tau\ell} \leq 1 \end{cases} \quad (5)$$

即 $Z_{j,k}$ 中第 $\ell$ 个雷达点迹可能来自某个目标、也可能为杂波;第 $\tau$ 个目标可能与某个雷达点迹关联,也可能未关联到任一雷达点迹。

在获得 $k$ 时刻多源雷达关联结果后,基于式(1)和式(2),借助卡尔曼滤波即可获得相应目标航迹的状态更新,并继续进行第 $k+1$ 步的多源雷达多目标数据关联跟踪。依次递推,即可获得探测视野内多目标跟踪航迹。

模型驱动的多源雷达数据关联方法在假设量测噪声分布、杂波分布先验已知的前提下,类似于单一雷达数据关联方法,借助式(5)的约束条件并进行适当变形,通过复杂地在线寻优来获得式(3)的近似求解。然而,可靠的先验建模,特别是杂波分布模型,往往难以事先获得,且实际应用环境的复杂多变也常常造成先验建模存在失配风险。事实上,相比于跟踪系统准确建模,利用累积/仿真的大量经人工判定的雷达点迹/目标航迹关联结果,学习其内在结构特征,构建多源雷达多目标跟踪数据关联深度神经网络,相比于模型驱动数据关联方法,往往能够获得更快、且准确性更高的雷达点迹/

目标航迹关联结果,从而为高质量目标跟踪提供可靠量测数据。

## 2 本文算法

考虑不同雷达获得的雷达点迹数据取值范围不同,不利于后续深神经网络的处理,首先,对所有雷达点迹数据进行预处理,构造归一化的特征张量。在此基础上,考虑数据关联本质上是一类利用历史累积事件决策当前事件的过程,借助BiLSTM在时序处理、自学习和非线性变换等方面的优势,构造基于轻量化BiLSTM的多源雷达多目标数据关联深度神经网络,输出取值在 $[0,1]$ 之间的概率关联矩阵。最后,利用最值寻优,实现可变目标数目的0/1关联结果输出。考虑到重杂波环境或多目标交叉运动等典型场景,雷达点迹/目标航迹关联结果与过去时刻和未来时刻关联结果都有直接相关性,因此,采取BiLSTM进行关联事件学习。同时,“轻量化”是指采取少层或单层BiLSTM模块来实现数据关联网络,以便进行快速的网络训练,适用不同场景下多源雷达多目标跟踪。

### 2.1 多源雷达点迹数据特征张量构造

$k$ 时刻多源雷达协同跟踪 $N_k(N_k \leq N)$ 个目标,记 $k-1$ 时刻第 $i$ 个目标航迹的状态估计为 $\hat{\mathbf{x}}_{i,k-1}$ ,借助卡尔曼滤波,可获得 $k$ 时刻该目标在全局坐标系对应的量测预测为 $\hat{z}_{i,k|k-1}$ 。

对于雷达 $j$ 在 $k$ 时刻获得的所有雷达点迹 $z_{j,k}^\ell$ (假设其已转换至全局统一坐标系), $\ell = 1, 2, \dots, m_{j,k}$ ,构造其与 $\hat{z}_{i,k|k-1}$ 的距离度量,即

$$d_{j,k}^{\ell} \triangleq \|\hat{z}_{i,k|k-1} - z_{j,k}^\ell\| \quad (6)$$

式中: $\|\cdot\|$ 表示合适的距离范数,如欧氏距离或考量测噪声标准差的马氏距离<sup>[25]</sup>。

针对每个目标航迹与每个雷达的任一点迹,进行上述距离求取操作,进而组成特征张量 $\mathbf{D}_k \in \mathbf{R}^{N_k \times \sum_{j=1}^S m_{j,k}}$ 。若此时被跟踪航迹个数小于 $N$ ,则对最后的 $N - N_k$ 行填0。考虑不同雷达点迹之间、雷达点迹/预测量测间的距离远近不一,为进一步提高深度神经网络模型精度和收敛速度,对特征张量进行如下最大最小标准化处理,即

$$\tilde{d}_k^{\tau q} = \frac{d_k^{\tau q} - \min\{d_k^{\tau q}\}}{\max\{d_k^{\tau q}\} - \min\{d_k^{\tau q}\}} \quad (7)$$

式中: $\tau = 1, 2, \dots, N, q = 1, 2, \dots, \sum_{j=1}^S m_{j,k}$ , $d_k^{\tau q}$ 为 $\mathbf{D}_k$ 中第 $\tau$ 行、第 $q$ 列元素; $\min\{d_k^{\tau q}\}$ 和 $\max\{d_k^{\tau q}\}$ 分别表示 $\mathbf{D}_k$ 中的最小值和最大值。经过式(7)转换,以 $\tilde{d}_k^{\tau q} \in [0,1]$

作为元素构造归一化特征张量  $\tilde{D}_k$ , 将  $\tilde{D}_k$  作为后续深度神经网络的输入。

### 2.2 基于轻量化 BiLSTM 的多源雷达多目标点迹/航迹关联

本节给出多源雷达多目标点迹航数据关联深度神经网络, 本文以归一化特征张量  $\tilde{D}_k = [\tilde{D}_{1,k}, \tilde{D}_{2,k}, \dots, \tilde{D}_{S,k}]$  为输入, 输出各雷达点迹集合与目标航迹的关联矩阵  $A'_k \in \mathbf{R}^{(N+1) \times \sum_{j=1}^N m_{j,k}}$ , 其中, 第  $\sum_{r=1}^{j-1} m_{r,k} + 1$  到  $\sum_{r=1}^j m_{r,k}$  列表示第  $j$  个雷达的关联概率矩阵  $A'_{j,k}$ , 最后一行表示相应雷达点迹未关联到任一目标航迹。

基于轻量化 BiLSTM 的多源雷达多目标点迹/航迹关联深度神经网络如图 1 所示。“轻量化”是相对于多层 BiLSTM 网络而言, 轻量化网络可以明显降低网络模型复杂程度、减少参数量, 以提升多平台多目标点迹/航迹关联的时间效率。在本文后续仿真中, 采取一层 BiLSTM 网络。

如图 1 所示,  $\ell_j$  表示第  $j$  个雷达的第  $\ell_j$  个点迹, 且  $j = 1, 2, \dots, S$ 。同时,  $\ell_j = 1, 2, \dots, M$ , 对于第  $j$  个雷达点迹集合而言, 若  $m_{j,k} < M$ , 则剩余雷达点迹通过  $\mathbf{0}$

补齐。

首先, 归一化的距离特征张量输入 BiLSTM 层, BiLSTM 包含前向 LSTM 和后向 LSTM 单元, 用于学习时间顺序关联事件和时间逆序关联事件的结构特征, 同时把输入的低维特征向量映射到高维空间进行表示。本文  $h_\tau^f$  和  $h_\tau^b$  分别表示第  $\tau$  个前向 LSTM 和后向 LSTM 的隐层状态,  $\tau = 0$  代表相应的初始输入, 该模块将前向和后向的隐向量进行拼接后输出。经过 BiLSTM 层, 网络输出维数为  $N \times Q$ , 其中,  $Q$  表示该 BiLSTM 层神经元个数。随后, BiLSTM 的输出通过维度重整, 获得每个雷达对应的高维特征, 从而将上一层输出的各目标特征向量重构为多通道向量, 且通道数与雷达个数保持一致。维度重整后输出维数为  $1 \times S \times Q'$ , 其中,  $Q' = Q/S$ 。再次, 应用一维卷积核进行特征降维, 将高维特征的维数映射到每一平台最大回波维数, 本文卷积核大小为  $3 \times 3$ 。通过多通道卷积滤波后, 输出维数为  $1 \times S \times M'$ , 其中,  $M' = M + 1$ 。最后, Softmax 层将输出的低维向量转换为范围在  $(0, 1)$  且相加为 1 的概率分布, 通过拉平多通道内各航迹与相应雷达点迹

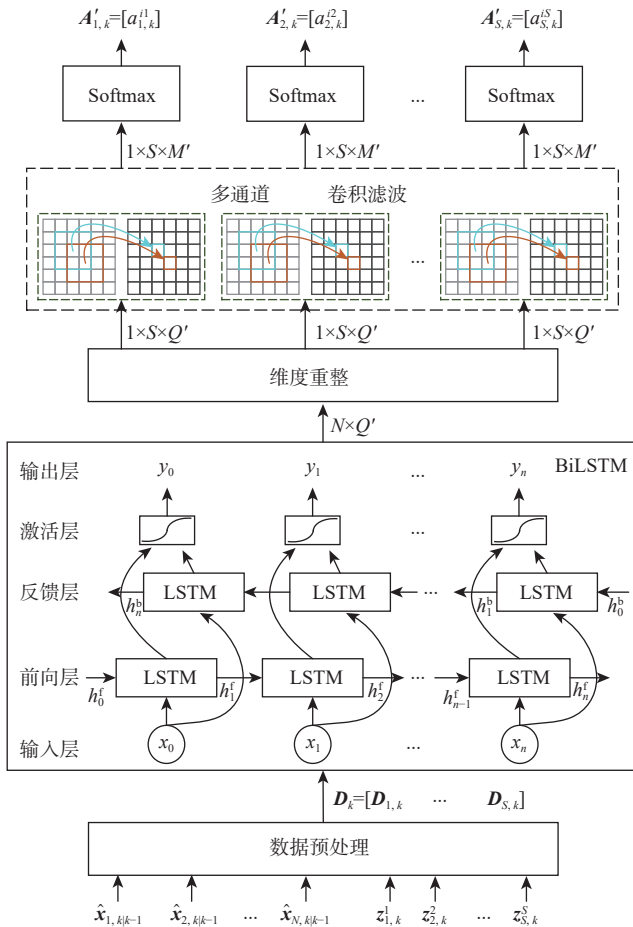


图 1 基于轻量化 BiLSTM 的多源雷达多目标点迹航迹关联

Fig. 1 Light-weight BiLSTM-based data association between multiple echoes and multiple tracks for multiple radars tracking multiple targets

的概率分布向量得到最终的关联概率矩阵。

对于多源雷达多目标跟踪点航数据关联, 不同雷达点航关联结果相互影响, 由于 BiLSTM 网络自身结构特性, 其可以充分考虑各雷达点迹关联结果间的影响, 这也是选择 BiLSTM 网络设计数据关联深度神经网络的主体网络的关键因素。

此外, 多源雷达多目标数据关联深度神经网络的损失函数表示如下:

$$l_{\text{loss}} = \sum_{j=1}^S \sum_{i=1}^N \|A'_{j,k}(i, \cdot) - A^*_{j,k}(i, \cdot)\|_2 \quad (8)$$

式中:  $A'_{j,k}(i, \cdot)$  和  $A^*_{j,k}(i, \cdot)$  分别为网络输出的第  $i$  个目标与雷达  $j$  点迹集合  $Z_{j,k}$  的关联概率和相应的真实关联概率;  $\|\cdot\|_2$  表示向量 2 范数。

### 2.3 关联结果判决

在获得关联概率矩阵后, 对于每个雷达点迹  $z_{j,k}^\ell (\ell = 1, 2, \dots, m_{j,k}, j = 1, 2, \dots, S)$ , 若有:

$$\tilde{a}_{j,k}^{\ell} = \max\{a_{j,k}^{\ell}, \dots, a_{j,k}^{N\ell}, a_{j,k}^{(N+1)\ell}\} \quad (9)$$

则当  $1 \leq i' \leq T_k$  时, 该雷达点迹与第  $i'$  条目标航迹关联, 基于式 (1) 和式 (2), 利用卡尔曼滤波可获得该航迹在  $k$  时刻的状态更新; 当  $i' > T_k$  时, 该雷达点迹未关联到任意一条目标航迹, 其或为杂波点, 或为新生目标点迹, 应转至航迹起始过程进行处理。

## 3 仿真验证

考虑二维平面直角坐标系  $O\xi\eta$  下多源雷达多目标跟踪。本文雷达数目  $S = 3$ 。所有目标均进行匀速直线运动, 目标状态皆为  $\mathbf{x}_k \triangleq [\xi_k, \dot{\xi}_k, \eta_k, \dot{\eta}_k]^\top$ , 其中,  $\xi_k$  和  $\eta_k$  分别表示  $\xi$  轴和  $\eta$  轴的位置,  $\dot{\xi}_k$  和  $\dot{\eta}_k$  分别表示  $\xi$  轴和  $\eta$  轴的速度。本文所有目标皆进行近似匀速直线运动, 运动方程如式 (1) 所示, 且状态转移矩阵和过程噪声协方差如下:

$$\begin{cases} \mathbf{F}_k = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix} \otimes \mathbf{I}_2 \\ \mathbf{Q}_{i,k} = \begin{bmatrix} T^3 & T^2 \\ 3 & 2 \\ T^2 & 1 \end{bmatrix} \otimes (\varepsilon \mathbf{I}_2) \end{cases} \quad (10)$$

式中:  $\varepsilon = 10^{-4}$ ; “ $\otimes$ ” 表示克罗内克积;  $T$  为采样时刻, 本文  $T = 1$  s;  $\mathbf{I}_2$  为  $2 \times 2$  的单位矩阵。

各雷达进行坐标转换后均位于坐标原点, 且相应量测模型中  $\mathbf{H}_k = [10] \otimes \mathbf{I}_2$ ,  $\mathbf{R}_k = 15^2 \mathbf{I}_2$ 。考虑密集杂波场景, 杂波均匀分布在探测视域内, 杂波密度  $\lambda = 10^{-3}$ , 且杂波数目皆服从参数为  $\lambda$  的泊松分布。

在 Windows10 系统上进行实验, 采取 Pytorch 深度学习框架。实验平台硬件配置如下: CPU 参数 Intel Core i7-10700k, GPU 参数 NVIDIA GeForce

RTX 2070 SUPER 8 GB, 内存为 32 GB。训练过程中, 使用 Adam 算法, 进行 BiLSTM 网络参数学习。

在仿真实验中, 仿真直线运动轨迹共 280 000 条, 每 4 条轨迹形成一个多目标场景, 总计仿真 70 000 个场景, 其中, 50 000 个场景用于训练深度神经网络, 20 000 个场景用于算法测试。在每个场景中, 所有目标同时出现, 同时消失, 目标运动时间为 30 s。需要说明, 所有训练场景和测试场景, 目标过程噪声不同、杂波出现位置及时刻不同且量测噪声不同。同时, 50 000 个训练场景和 20 000 个测试场景不存在重复场景。本文在所构建的多源雷达多目标数据关联深度神经网络中, 采取一层 BiLSTM 层, 隐藏单元数 160 个, 卷积核大小为  $3 \times 3$ 。图 2 为密集杂波多目标仿真轨迹与多源雷达点迹示意图。图中, 4 个目标皆从左至右运动, 在 12 s 左右 4 个目标存在两两航迹交叉; 在 20 s 左右, 目标 1 和目标 2、目标 3 和目标 4 再次出现航迹交叉。




图 2 密集杂波环境下多目标轨迹与多源雷达点迹示意图  
Fig. 2 Illustration of multiple target trajectories and echoes from multiple radars in dense clutter environment

本文算法与集中式 JPDA、PDA 和 NNDA 等概率统计框架下点航关联算法 (分别记为 JPDAF、PDAF 和 NNDAF) 及将 BiLSTM 替换为全连接层和 LSTM 等数据驱动下点航关联算法 (分别记为 FCL 和 LSTM) 进行仿真对比。同时, 皆采取卡尔曼滤波实现目标航迹更新。LSTM 和 FCL 的网络层数及神经元个数设置与本文算法保持一致。

图 3 和图 4 为单次测试下目标真实轨迹与跟踪航迹的对比示意图。明显地, 对于 JPDAF 和本文算法而言, 皆能准确地获得所有目标的跟踪航迹; 对于 PDAF 和 NNDAF 而言, 由于其不能适应密集杂波环境, 总是会有跟偏的情况; 对于 FCL 和 LSTM 而言, 由于两者皆无法可靠学习不同雷达点航关联结果的相关性, 也出现了部分航迹跟踪误差较大的现象。为清晰对比不同算法的跟踪结果, 并未采取航迹终结措施。

针对测试场景, 图 5 和图 6 给出了各对比算法

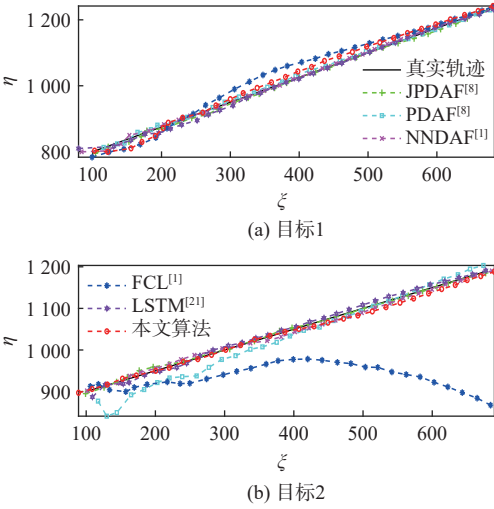


图3 单次测试下目标1和目标2真实轨迹与跟踪航迹对比  
Fig. 3 Comparison between true trajectories and estimated tracks of targets 1 and 2 in a single testing scenario




图4 单次测试下目标3和目标4真实轨迹与跟踪航迹对比  
Fig. 4 Comparison between true trajectories and estimated tracks of targets 3 and 4 in a single testing scenario

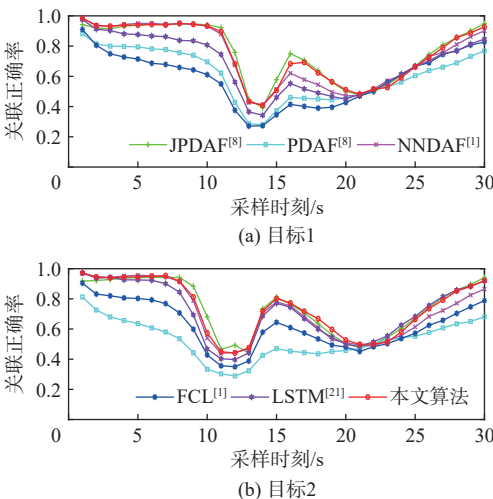


图5 测试场景下目标1和目标2的关联正确率  
Fig. 5 Association accuracies of targets 1 and 2 in the testing scenario

针对不同目标所统计的关联准确率。此外,图7和图8给出了各对比算法针对不同目标的位置估计均方根误差曲线,同时,表1给出了各对比算法的平均运行时间。本文针对目标*i*,其关联准确率计算如下:

$$\bar{\rho}_{i,k} \triangleq \sum_{t=1}^M \sum_{j=1}^S \rho_{jk}^{i(t)} / (S \times M) \quad (11)$$

式中:*k*为采样时刻; $\rho_{jk}^{i(t)}$ 为相应算法在第*t*次测试中目标*i*与雷达*j*正确的回波点的关联概率;*M*为测试总次数。针对目标*i*,其位置估计均方根误差计算如下:

$$R_{MSE,k}^i = \sqrt{\sum_{t=1}^M \left( (\xi_k^{i(t)} - \hat{\xi}_k^{i(t)})^2 + (\eta_k^{i(t)} - \hat{\eta}_k^{i(t)})^2 \right) / M} \quad (12)$$

式中: $[\xi_k^{i(t)}, \eta_k^{i(t)}]^T$ 为第*t*次测试中目标*i*的真实位置;




图6 测试场景下目标3和目标4的关联正确率  
Fig. 6 Association accuracies of targets 3 and 4 in the testing scenario

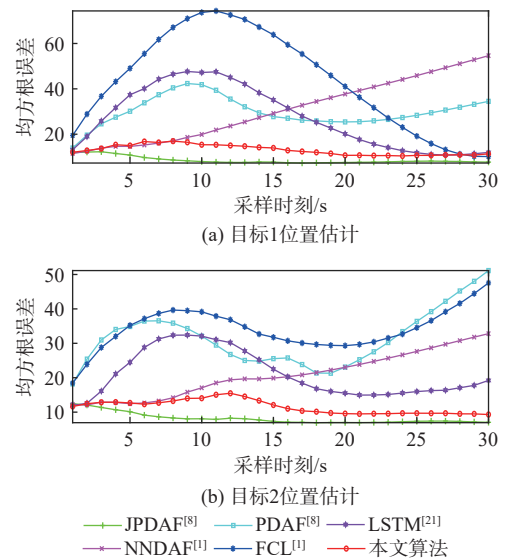


图7 测试场景下目标1和目标2的位置估计均方根误差  
Fig. 7 Root mean square errors of estimated positions of targets 1 and 2 in the testing scenario

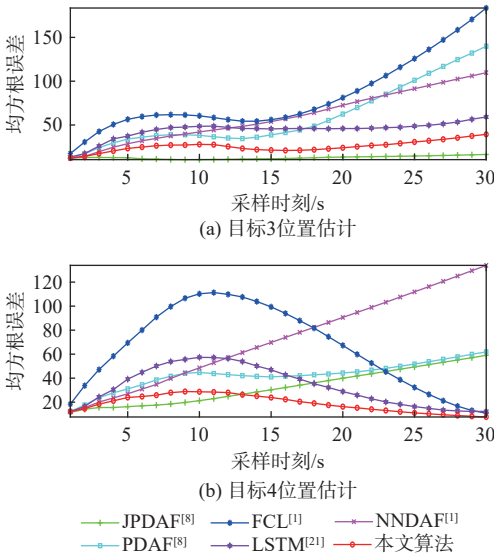


图 8 测试场景下目标 3 和目标 4 的位置估计均方根误差  
Fig. 8 Root mean square errors of estimated positions of targets 3 and 4 in the testing scenario

$[\hat{x}_k^{(i)}, \hat{y}_k^{(i)}]^T$  为相应航迹的位置估计。

如图 5 和图 6 所示, 本文算法的关联准确率仅次于最优的 JPDAF 算法, 两者皆优于 PDAF、NNDAF、FCL 和 LSTM 算法。同时, 如图 7 和 8 所示, 针对目标 1、目标 2 和目标 3, 本文算法的位置估计均方根误差大于相应的最优 JPDA 算法; 针对目标 4, 本文算法的位置估计均方根误差在第 13 s~第 30 s 小于相应的最优 JPDAF。更为关键地, 针对所跟踪的所有目标, 本文算法的位置估计均方根误差皆小于相应的 PDAF、NNDAF、FCL 和 LSTM 的位置估计均方根误差。此外, 由表 1 可知, 在该测试场景下, 本文算法的平均运行时间与 FCL、LSTM 的平均运行时间基本一致, 且与 NNDAF 的平均运行时间相当, 小于 PDAF 的平均运行时间。JPDAF 的平均运行时间是其他对比算法的 10 倍左右。

综上所述, 本文算法在关联准确率及跟踪精度方面与集中式最优 JPDAF 算法基本相当, 而平均运行时间仅是 JPDAF 算法的 7.3%。同时, 相比于概率统计框架下 PDAF 和 NNDAF 算法及数据驱动

表 1 测试场景下不同对比算法平均运行时间

Table 1 Average running time of different compared algorithms in testing scenarios

算法	平均运行时间/s
JPDAF <sup>[8]</sup>	9.504 6
PDAF <sup>[8]</sup>	0.989 5
NNDAF <sup>[1]</sup>	0.692 4
FCL <sup>[1]</sup>	0.701 3
LSTM <sup>[21]</sup>	0.665 5
本文算法	0.696 2

下 FCL 和 LSTM 算法, 本文算法具有更小的跟踪误差和更高的关联准确率, 且上述算法的平均运行时间基本维持在同一数量级。因此, 针对非合作目标跟踪中对跟踪精度与实时性都要求较高的场景, 相比于对比算法, 本文算法具有更优性能。

### 4 结 论

为解决密集杂波下多源雷达多目标跟踪时易关联错误且计算量大的问题, 本文提出一种基于轻量化 BiLSTM 的多源雷达多目标跟踪点航数据关联算法。

1) 通过将多源雷达多目标数据关联看作时间序列预测问题, 构建了轻量化 BiLSTM 的多雷达数据关联深度神经网络, 实现了密集杂波下端到端的多源雷达多目标可靠关联。

2) 本文算法的关联准确率及跟踪精度与多源雷达下集中式联合概率数据关联滤波算法基本相当, 与相应的概率数据关联滤波、最近邻数据关联滤波、基于全连接网络的点航关联滤波和基于 LSTM 的点航关联滤波算法相比, 具有更好的跟踪精度和关联准确率。

3) 本文算法由于采取轻量化结构, 其平均运行时间相比集中式联合概率数据关联滤波算法缩短了 10 倍左右, 基本与最近邻数据关联滤波相当。

### 参考文献 (References)

[1] 何友, 修建娟, 刘瑜, 等. 雷达数据处理及应用[M]. 4 版. 北京: 电子工业出版社, 2022.  
HE Y, XIU J J, LIU Y, et al. Radar data processing with applications[M]. 4th ed. Beijing: Publishing House of Electronics Industry, 2022(in Chinese).

[2] 韩崇昭, 朱洪艳, 段战胜. 多源信息融合[M]. 3 版. 北京: 清华大学出版社, 2022.  
HAN C Z, ZHU H Y, DUAN Z S. Multisource information fusion[M]. 3rd ed. Beijing: Tsinghua University Press, 2022(in Chinese).

[3] 罗亚伦, 廖育荣, 李兆铭, 等. 高超目标跟踪 CKF 自适应交互多模型跟踪算法[J]. 北京航空航天大学学报, 2024, 50(7): 2272-2283.  
LUO Y L, LIAO Y R, LI Z M, et al. Strong tracking CKF adaptive interactive multiple model tracking algorithm based on hypersonic target[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(7): 2272-2283(in Chinese).

[4] 胡浩然, 陈树新, 吴昊, 等. 基于变分贝叶斯的连续-离散最大相关熵 CKF 算法[J]. 北京航空航天大学学报, 2023, 49(10): 2859-2866.  
HU H R, CHEN S X, WU H, et al. Continuous-discrete maximum correntropy CKF algorithm based on variational Bayes[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(10): 2859-2866(in Chinese).

[5] 宋丽萍, 陈德峰, 田甜, 等. 基于雷达测距和测速的 GEO 目标实

- 时关联算法[J]. 北京航空航天大学学报, 2023, 49(8): 2167-2175.
- SONG L P, CHEN D F, TIAN T, et al. A real-time correlation algorithm for GEO targets based on radar ranging and velocity measurement[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(8): 2167-2175(in Chinese).
- [6] 曾雅俊, 王俊, 魏少明, 等. 分布式多传感器多目标跟踪方法综述[J]. 雷达学报, 2023, 12(1): 197-213.
- ZENG Y J, WANG J, WEI S M, et al. Review of the method for distributed multi-sensor multi-target tracking[J]. Journal of Radars, 2023, 12(1): 197-213(in Chinese).
- [7] SINGER R A, SEA R G. New results in optimizing surveillance system tracking and data correlation performance in dense multitarget environment[J]. IEEE Transactions on Automatic Control, 1973, 18(6): 571-582.
- [8] BAR-SHALOM Y, DAUM F, HUANG J. The probabilistic data association filter[J]. IEEE Control Systems Magazine, 2009, 29(6): 82-100.
- [9] SINHA A, DING Z, KIRUBARAJAN T, et al. Track quality based multitarget tracking approach for global nearest-neighbor association[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(2): 1179-1191.
- [10] MUSICKI D, SUVOROVA S. Tracking in clutter using IMM-IP-DA-based algorithms[J]. IEEE Transactions on Aerospace and Electronic Systems, 2008, 44(1): 111-126.
- [11] SVENSSON L, SVENSSON D, GUERRIERO M, et al. Set JPDA filter for multitarget tracking[J]. IEEE Transactions on Signal Processing, 2011, 59(10): 4677-4691.
- [12] REID D B. An algorithm for tracking multiple targets[J]. IEEE Transactions on Automatic Control, 1979, AC-24: 843-854.
- [13] KIM C, LI F X, CIPTADI A, et al. Multiple hypothesis tracking revisited[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2015: 4696-4704.
- [14] MAHLER R P. Statistical multisource-multitarget information fusion[M]. Norwood: Artech House, 2007.
- [15] 陆小科, 张志国, 孙进平, 等. 基于杂波量测集约束的改进 MS-MeMber 滤波器[J]. 北京航空航天大学学报, 2021, 47(9): 1748-1755.
- LU X K, ZHANG Z G, SUN J P, et al. An improved multi-sensor MeMber filter based on clutter measurement set constraint[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(9): 1748-1755(in Chinese).
- [16] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [17] WRABEL A, GRAEF R, BROSCHE T. A survey of artificial intelligence approaches for target surveillance with radar sensors[J]. IEEE Aerospace and Electronic Systems Magazine, 2021, 36(7): 26-43.
- [18] CHONG C Y. An overview of machine learning methods for multiple target tracking[C]//Proceedings of the IEEE 24th International Conference on Information Fusion. Piscataway: IEEE Press, 2021: 1-9.
- [19] LIU J X, WANG Z L, XU M. DeepMTT: a deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network[J]. Information Fusion, 2020, 53: 289-304.
- [20] REVACH G, SHLEZINGER N, NI X Y, et al. KalmanNet: neural network aided Kalman filtering for partially known dynamics[J]. IEEE Transactions on Signal Processing, 2022, 70: 1532-1547.
- [21] MILAN A, REZATOFIHI S H, DICK A, et al. Online multi-target tracking using recurrent neural networks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2017, 31(1): 4225-4232.
- [22] LIU H J, ZHANG H, MERTZ C. DeepDA: LSTM-based deep data association network for multi-targets tracking in clutter[C]//Proceedings of the 22th International Conference on Information Fusion. Piscataway: IEEE Press, 2019: 1-8.
- [23] VERMA R, RAJESH R, EASWARAN M S. Modular multitarget tracking using long short-term memory networks[J]. Journal of Aerospace Information Systems, 2021, 18(10): 751-754.
- [24] 李文娜, 张顺生, 王文钦. 基于 Transformer 网络的机载雷达多目标跟踪方法[J]. 雷达学报, 2022, 11(3): 469-478.
- LI W N, ZHANG S S, WANG W Q. Multi-target tracking method for airborne radar based on transformer network[J]. Journal of Radar, 2022, 11(3): 469-478(in Chinese).
- [25] ZENG S, WANG X Y, DUAN X J, et al. Kernelized Mahalanobis distance for fuzzy clustering[J]. IEEE Transactions on Fuzzy Systems, 2021, 29(10): 3103-3117.

# Light-weight BiLSTM-based data association algorithm between echoes and tracks for multi-radar multi-target tracking

DAI Rui\*, LI Jie, HE Lihuo, GAO Xinbo

(School of Electronic Engineering, Xidian University, Xi'an 710071, China)

**Abstract:** This paper proposes a data-driven algorithm, i.e., a light-weight bi-directional long short-term memory (BiLSTM) network-based intelligent data association between echoes and tracks for multi-radar multi-target tracking, in light of the issue that data association is prone to error and that exact modeling-based algorithms have enormous computational costs for multi-radar multi-target tracking in dense clutter environments. The first step is to build the multi-radar association matrix, whose constituent is the association result between target tracks and radar echoes. Based on multi-radar echoes and predicted measurements, the distance tensor is designed based on max-min normalization. The light-weight BiLSTM networks-based multi-radar multi-target data association network is put forward, by taking the above normalized distance tensor and multi-radar association matrix as the input and output. And the measurement corresponding to the maximum probability is treated as the associated one to update every track through implementing a Kalman filter for each radar. The simulation results of multi-radar tracking multi-target in dense clutter environment show that the association accuracy and tracking precision of the proposed algorithm are similar with those of the centralized joint probability data association filter, which are much better than those of probability data association filter, nearest neighbor data association filter, fully connected layer-based data association filter and long short-term memory (LSTM) networks-based data association filter. Furthermore, compared to the centralized joint probability data association filter, which is nearly equal to the nearest neighbor data association filter, the proposed algorithm's average running time is significantly shorter.

**Keywords:** data association; multi-target tracking; multi-radar; bi-directional long short-term memory networks; light-weight neural networks