



# 计算机科学

COMPUTER SCIENCE

## 基于深度时间对比的中断航迹关联方法

侯海轮, 雷艺, 魏博, 樊玉琦

引用本文

侯海轮, 雷艺, 魏博, 樊玉琦. 基于深度时间对比的中断航迹关联方法[J]. 计算机科学, 2023, 50(11A): 220900164-9.

HOU Hailun, LEI Yi, WEI Bo, FAN Yuqi. Track Segment Association Based on Deep Temporal Contrasting [J]. Computer Science, 2023, 50(11A): 220900164-9.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [基于TCN-BiLSTM的入侵检测算法研究](#)

Study on Intrusion Detection Algorithm Based on TCN-BiLSTM

计算机科学, 2023, 50(11A): 230300142-8. <https://doi.org/10.11896/jsjcx.230300142>

### [基于多级多尺度特征提取的CNN-BiLSTM模型的中文情感分析](#)

Chinese Sentiment Analysis Based on CNN-BiLSTM Model of Multi-level and Multi-scale Feature Extraction

计算机科学, 2023, 50(5): 248-254. <https://doi.org/10.11896/jsjcx.220400069>

### [基于IPSO-BiLSTM的网络安全态势预测](#)

Network Security Situation Prediction Based on IPSO-BiLSTM

计算机科学, 2022, 49(7): 357-362. <https://doi.org/10.11896/jsjcx.210900103>

### [基于解耦-检索-生成的图像风格化描述生成模型](#)

Stylized Image Captioning Model Based on Disentangle-Retrieve-Generate

计算机科学, 2022, 49(6): 180-186. <https://doi.org/10.11896/jsjcx.211100129>

### [基于Transformer的汉字到盲文端到端自动转换](#)

End-to-End Chinese-Braille Automatic Conversion Based on Transformer

计算机科学, 2021, 48(11A): 136-141. <https://doi.org/10.11896/jsjcx.210100025>

# 基于深度时间对比的中断航迹关联方法

侯海轮 雷艺 魏博 樊玉琦

合肥工业大学计算机与信息学院 合肥 230601

(hailunhou@mail.hfut.edu.cn)

**摘要** 雷达在跟踪飞行目标时,常发生跟踪中断的现象。深度学习方法具有强大的学习能力,已被逐渐用于解决中断航迹关联问题。但已有基于深度学习的中断航迹关联方法未能充分考虑新老航迹特征之间的相似性,关联性能仍有待提升。因此提出一种基于深度时间对比的中断航迹关联算法(Track Segment Association based on Deep Temporal Contrasting, TSADTC),包括航迹特征提取模块、时间对比模块、航迹特征对比模块和分类器模块。航迹特征提取模块利用双向长短期记忆网络和编码器-解码器分别对新老航迹进行特征提取;时间对比模块分别使用一条航迹的特征预测另外一条航迹;航迹特征对比模块计算两条航迹的特征差别,并将此差别输入分类器中,以计算两条航迹关联的概率。算法将关联概率最大的航迹对作为关联航迹对。仿真实验表明,TSADTC算法能够有效提高中断航迹关联的正确关联率、错误关联率和航迹漏关联率性能。

**关键词:** 时间对比;中断航迹关联;编码器-解码器;双向长短期记忆网络

**中图分类号** TP391

## Track Segment Association Based on Deep Temporal Contrasting

HOU Hailun, LEI Yi, WEI Bo and FAN Yuqi

School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China

**Abstract** The radar's tracking of a flying target is often interrupted, which seriously affects the perception of the airfield situation. Deep learning has powerful learning capabilities and has been gradually used to solve the problem of interrupted track association. However, the existing deep learning-based interrupted track association methods fail to fully consider the similarity between the old and new track features, hence the association performance needs to be improved. Therefore, this paper proposes a track segment association algorithm based on deep temporal contrasting (TSADTC), which includes a track feature extraction module, a time comparison module, a track feature comparison module and a classifier module. The track feature extraction module uses the bidirectional LSTM (Bi-LSTM) and the encoder-decoder to extract the features of the new and the old tracks, respectively. In the time comparison module, the features of a track are used to predict the other track, so that the features of the two tracks of the same target have high similarity. The track feature comparison module calculates the feature difference of the two tracks, which is fed into the classifier to decide the association probability of the two tracks. The track pair with the largest association probability is set as the associated tracks. Experimental results show that the proposed algorithm TSADTC can effectively improve the performance of correct association rate, false association rate and missing track association rate of interrupted track association.

**Keywords** Temporal contrasting, Track segment association, Encoder-Decoder, Bi-LSTM

### 1 引言

对于雷达而言,完成稳定持续的目标跟踪是其最基本的任务之一<sup>[1]</sup>。但由于目标雷达散射截面(Radar Cross Section, RCS)起伏<sup>[2,3]</sup>、目标高速机动<sup>[4]</sup>、多普勒盲区<sup>[5-6]</sup>、雷达大的测量误差和长采样间隔等原因,经常会发生雷达对目标跟踪中断的现象<sup>[7]</sup>。在空中交通越来越拥挤、电磁频谱资源愈来愈紧张的今天,目标跟踪中断的问题更为突出<sup>[8]</sup>。目标航

迹中断造成的目标航迹批号不一致会对空管人员的决策造成很大的影响。因此,将中断前后的航迹关联起来,维持综合航迹批号的统一,具有十分迫切的需求和现实意义。

中断航迹关联方法大致可以分为两类,传统方法<sup>[9]</sup>和基于深度学习的方法<sup>[10]</sup>。

传统方法解决中断航迹关联问题最早于20世纪80年代提出。Mucci等提出了一种基于统计学的中断航迹关联方法,该方法用新航迹,即中断后的航迹,反向预测至老航迹的

基金项目:安徽省重点研发计划(201904a07020030);国家自然科学基金青年基金(62002097)

This work was supported by the Key Research and Development Program of Anhui Province, China(201904a07020030) and National Natural Science Foundation of China(62002097).

通信作者:樊玉琦(yuqi.fan@hfut.edu.cn)

最后一个时刻,利用最大似然估计来判断两航迹是否关联<sup>[11]</sup>。但现实中存在测量噪声和系统噪声,新航迹反向预测误差较大,会导致航迹错误关联和漏关联的概率较高。Yeom等将 IMM(Interacting Multiple Model)应用于中断航迹的预测工作中,用新航迹做前向预测,用老航迹做后向预测,并采用离散优化方法实现中断航迹关联<sup>[12]</sup>。然而,基于 IMM的中断航迹关联方法存在将最佳关联假设丢弃的风险。Castnnon等提出了一种新的数据化表示方法——轨迹图,它为航迹数据的存储和后续航迹关联问题的制定提供了一个紧凑而高效的结构,利用轨迹图将轨迹拼接问题转化为了一个最小成本流问题<sup>[13]</sup>。但是基于图的中断航迹关联方法只适用于航迹关联可能性满足马尔科夫属性的情况下。Qi等提出了一种基于目标属性、运动特征、使用场景等先验信息的多假设模型中断航迹关联算法,利用多假设思想,建立多种可能的目标运动模型并实施航迹预测,基于多项式拟合原理完成航迹关联<sup>[14]</sup>。然而,基于多假设模型的方法存在假设模型不合理的风险。Wang等提出了机载雷达中断航迹关联算法(以下简称“机载法”),利用目标运动特征等先验信息进行粗关联,采用对数代价函数结合二维最优分配实现中断航迹关联,并通过多项式拟合连接关联成功的航迹<sup>[15]</sup>。Zhou等提出了基于匈牙利法的机载雷达中断航迹关联的方法(以下简称“匈牙利法”),通过航迹预处理得到目标位置参数、运动特征参数,进行关联代价矩阵归一化,应用匈牙利法求解中断航迹关联问题<sup>[16]</sup>。但是,机载法和匈牙利法都有利用先验信息进行粗关联的过程,并且关联过程依赖于人为设定的阈值,会导致较高的漏关联率。

随着深度学习的快速发展,深度学习已被应用于各种飞行目标研究<sup>[17]</sup>,如雷达目标检测<sup>[18]</sup>、机动目标跟踪<sup>[19]</sup>、航迹预测<sup>[20]</sup>等,并展现出了良好的性能。深度学习也逐渐被用于解决中断航迹关联问题。Xiong等提出了基于双对比神经网络的中断航迹关联方法(Track Segment Association with Dual Contrast Neural Network, TSADCNN),该方法使用两个模块并行学习新老航迹段的高维特征表示,使得在高维空间中,属于同一目标的航迹段特征相似,属于不同目标的航迹段特征迥异。最终,将高维空间特征最近的两条新老航迹段作为关联航迹<sup>[21]</sup>。但是,该方法对两条航迹的特征是分别学习的,仅仅依靠最终的损失函数来实现两个模块之间的信息交互,难以确保在高维空间中充分地拉近同一目标之间的距离并拉远不同目标之间的距离。

综上,目前中断航迹关联的方法依旧存在着诸多问题,性能仍有待提高。传统方法存在着假设模型不合理、方法不适用、阈值不易确定等问题。虽然深度学习具有强大的特征学习能力,但已有基于深度学习的中断航迹关联方法未能充分考虑新老航迹特征之间的相似性,因此其性能仍有待提升。本文提出一种基于深度时间对比的中断航迹关联算法(TSADTC),以更好地实现中断航迹的关联。

本文的主要贡献如下:通过双向长短期记忆网络(Bi-LSTM)、编码器-解码器和深度时间对比,实现新老航迹的有

效信息交互,以更好地学习航迹的特征。该模型包括航迹特征提取模块、时间对比模块、航迹特征对比模块以及分类器模块。航迹特征提取模块对新航迹和老航迹组成的航迹对,利用 Bi-LSTM 和编码器-解码器分别对两条航迹进行特征提取;时间对比模块中,使用老航迹的特征预测新航迹,使用新航迹的特征预测老航迹,以更好地学习新老航迹的特征,使得同一目标的新老航迹具有很高的相似性;航迹特征对比模块计算两条航迹的特征差别,并将此差别输入分类器中,以计算两条航迹关联的概率。将经过训练的模型输出的航迹关联概率填充到航迹关联概率矩阵的相应位置,循环筛选关联概率最大的航迹对作为关联航迹对。仿真实验表明,TSADTC 算法能够有效提高中断航迹关联的正确关联率、错误关联率和航迹漏关联率性能。

本文第 2 章介绍了相关工作;第 3 章介绍了中断航迹关联问题和本文所提出的算法;第 4 章通过实验对所提出的算法进行了性能评估;最后总结全文。

## 2 相关工作

中断航迹关联方法可分为传统方法和深度学习方法。

传统方法大致可分为:基于统计学的方法、基于 IMM 的方法、基于图的方法、基于多假设模型的方法和基于关联代价最优化的方法。

基于统计学的方法。Mucci等提出了一种基于统计学的中断航迹关联方法,该方法用新航迹,即中断后的航迹,反向预测至老航迹的最后一个时刻,利用最大似然估计来判断两航迹是否关联<sup>[11]</sup>。Han等提出了一种基于轨迹预报的空间目标断续航迹关联算法,使用动力学模型对空间目标进行跟踪,使用中断前滤波更新值向中断后航迹预测,并将预测数据与中断后航迹前几个时刻的航迹点进行关联配对<sup>[22]</sup>。针对传统算法在目标密集、航迹交叉或分叉条件下关联正确率低的问题,Qi等基于多目标多传感器统计双门限航迹关联理论,提出了基于统计双门限的中断航迹关联算法<sup>[23]</sup>。Cao等提出了一种基于霍尔特-温特(Holt-Winters)法的双向预测和模糊分析的轨迹段关联方法,该算法通过 Holt-Winters 法双向预测轨迹段,然后使用模糊轨迹段关联算法完成轨迹段关联<sup>[24]</sup>。Sun等采用期望最大化算法估计机动目标的运动状态来进行航迹的预测,该算法考虑了模型的隐式依赖关系,即位置、速度、加速度、角速度等运动属性之间的相互依赖关系<sup>[25]</sup>。但现实中存在测量噪声和系统噪声,新航迹反向预测误差较大,会导致航迹错误关联和漏关联的概率较高。

基于 IMM 的方法。Yeom等将 IMM 应用到中断航迹的预测工作中,用新航迹做前向预测,用老航迹做后向预测,并采用离散优化方法实现中断航迹关联<sup>[12]</sup>。Lin等向 IMM 中添加了两种类型的虚拟模型,提升了 IMM 对“停-走”机动目标的跟踪能力,并提出了一种分配算法用来解决中断航迹关联问题<sup>[26]</sup>。Guo等使用 IMM 对轨迹段进行预处理,然后使用局部高斯过程(Local Gaussian Process, LGP)对轨迹段

进行预测和回溯,并完成航迹关联<sup>[27]</sup>。然而,基于 IMM 的中断航迹关联方法存在将最佳关联假设丢弃的问题,会导致错误关联。

基于图的方法。Castnnon 等提出了一种新的数据化表示方法——轨迹图,它为航迹数据的存储和后续航迹关联问题的制定提供了一个紧凑而高效的结构,利用轨迹图将轨迹拼接问题转化为了一个最小成本流问题<sup>[13]</sup>。Mori 等将要关联的航迹段视为图中的节点,将航迹段的关联关系视为图中的边,通过求解类似于多假设跟踪的优化问题来求解最佳关联假设<sup>[28]</sup>。Merwe 等将航迹建模为图中的节点,将航迹段的关联关系建模为图中的边。将卡尔曼滤波器用于目标跟踪,以及确定航迹之间的关联概率,然后使用维特比(Viterbi)数据关联算法进行求解<sup>[29]</sup>。但是基于图的中断航迹关联方法只适用于航迹关联可能性满足马尔科夫属性的情况下。

基于多假设模型的方法。Qi 等提出了一种基于目标属性、运动特征、使用场景等先验信息的多假设模型中断航迹关联算法,利用多假设思想,建立多种可能的目标运动模型并实施航迹预测,基于多项式拟合原理完成航迹关联<sup>[14]</sup>。Chai 等针对多机动目标的跟踪问题,提出了一种基于多伯努利滤波器的检测前跟踪(Multi-Bernoulli Filter Based Track-Before-Detect, MB-TBD)算法。将多个运动模型合并到基本的 MB-TBD 滤波中,然后基于最优贝叶斯滤波推导出包括预测和更新步骤的封闭形式递归方程<sup>[30]</sup>。Han 等提出了一种基于多假设运动模型的跟踪方法,将多普勒盲区和目标类别信息并入航迹片段关联的各个环节,利用目标类别信息修正分配代价函数并完成航迹关联<sup>[31]</sup>。然而,基于多假设模型的方法存在假设模型不合理的问题,会导致航迹错误关联。

基于关联代价最优化的方法。Wang 等提出基于先验信息的中断航迹关联算法,利用目标运动特征等先验信息进行粗关联,采用对数代价函数结合二维最优分配实现中断航迹关联,并通过多项式拟合连接关联成功的航迹<sup>[15]</sup>。Zhou 等研究了机载雷达航迹中断逻辑,进行航迹预处理得到目标位置参数、运动特征参数,然后进行关联代价矩阵归一化,提出了基于匈牙利法的机载雷达中断航迹关联算法<sup>[16]</sup>。Sun 等采用期望最大化算法估计机动目标的运动状态来进行航迹的预测,将条件期望函数定义为航迹关联的成本,通过最小化航迹关联的成本完成中断航迹的关联<sup>[25]</sup>。Mao 等通过对同时刻样本点之间各特征距离信息的模糊处理,获取关联隶属度,进而转化为证据理论中的基本概率指派。然后对各证据进行组合,根据连续时长内样本点的关联判定,得到最终的关联结果<sup>[32]</sup>。Yu 等提出了一种实时的离散最优关联算法,在未知导弹任何先验信息的前提下,利用速度信息对中断前后弹道外推航迹进行粗关联,将对数似然函数作为关联代价函数,采用拍卖算法完成关联代价函数的二维全局最优分配实现细关联<sup>[33]</sup>。但是,在关联的过程中,这些方法都需要人为设定关联阈值,阈值不易确定,且阈值设定的优劣会严重影响关联性能。

深度学习发展快速,并逐渐被应用于各种飞行目标研究,

在航迹关联问题上也有所应用。Xiong 等提出了 TSADC-NN,该方法使用两个模块并行学习新老航迹段的高维特征表示,从而在高维空间中使属于同一目标的航迹段变得更近,属于不同目标的航迹段变得更远。之后,可以直接选择高维空间中最近的新老航迹段对作为关联航迹<sup>[21]</sup>。Xu 等提出了基于生成对抗网络和注意力机制的中断航迹关联算法,设计了航迹态势图生成模块,将原始航迹数据转换为航迹态势图,设计航迹关联网络,消除航迹噪声并完成中断航迹关联<sup>[34]</sup>。但是这些方法没有充分的考虑新老航迹特征之间的相似性。

现有的传统中断航迹关联算法基本都依赖于假设的目标运动模型,存在着假设模型不合理、方法不适用、阈值不易确定等问题。虽然深度学习具有强大的特征学习能力,但已有的基于深度学习的中断航迹关联方法未能充分考虑新老航迹特征之间的相似性。针对现有方法的问题,本文提出了一种基于深度时间对比的中断航迹关联算法(TSADTC)。仿真实验表明,TSADTC 算法能够有效提高中断航迹关联的正确关联率、错误关联率和航迹漏关联率性能。

### 3 中断航迹关联算法

本文使用平面直角坐标系中的横坐标  $u$ 、纵坐标  $v$  以及时间  $t$  来描述雷达的单个航迹点量测。一条航迹  $T_r$  中的第  $j$  个航迹点的表示如下:

$$p_{r,j} = (u_{r,j}, v_{r,j}, \tau_{r,j}) \quad (1)$$

设一条航迹的航迹点个数为  $h$ ; 设所有老航迹构成的集合为  $T^o$ , 其中的第  $m$  条航迹为  $T_m^o$ ; 所有新航迹构成的集合为  $T^y$ , 其中的第  $n$  条航迹为  $T_n^y$ 。则由新老航迹组成的航迹对表示为:

$$TS_l = \langle T_m^o, T_n^y \rangle \quad (2)$$

其中,  $T_m^o \in T^o$  ( $m=1, 2, \dots, M$ ),  $T_n^y \in T^y$  ( $n=1, 2, \dots, N$ ),  $M$  和  $N$  分别为老航迹和新航迹集合中的航迹数量,  $l=1, 2, \dots, MN$ 。

将航迹对分为两类:关联航迹对与非关联航迹对。属于同一个飞行目标的两条航迹段为关联航迹对,否则为非关联航迹对。本文的目的是将同一目标中断前后的航迹关联起来。

本文提出一种基于深度时间对比的中断航迹关联算法(TSADTC),算法包含模型 TSADTCM 和关联概率处理两个部分。模型如图 1 所示,包括 4 个模块:航迹特征提取模块、时间对比模块、航迹特征对比模块以及分类器模块。航迹特征提取模块对新航迹和老航迹组成的航迹对,利用 Bi-LSTM 和编码器-解码器分别对两条航迹进行特征提取;时间对比模块中,使用老航迹的特征预测新航迹,使用新航迹的特征预测老航迹,以更好地学习新老航迹的特征,使得同一目标的新老航迹具有很高的相似性;航迹特征对比模块计算两条航迹的特征差别,并将此差别输入分类器中,以计算两条航迹的关联概率。关联概率处理将关联概率最大的两条航迹作为关联航迹对。

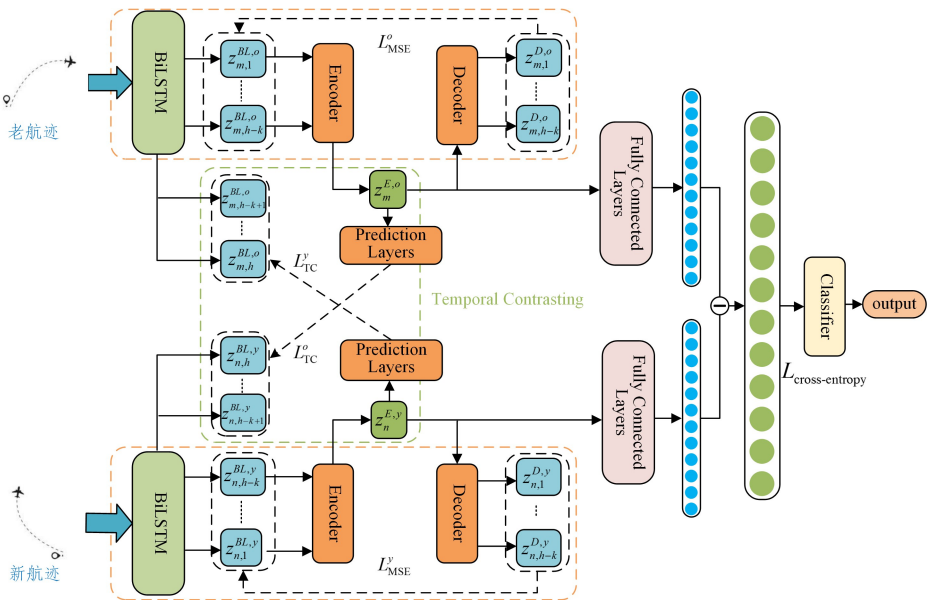


图 1 TSADTCM 模型

Fig.1 TSADTCM model

### 3.1 航迹特征提取模块

航迹特征提取模块有 2 个,分别提取新航迹和老航迹的特征,这两个航迹特征提取模块的参数是共享的。该模块依次使用 Bi-LSTM<sup>[35]</sup>和编码器-解码器<sup>[36]</sup>提取航迹的特征。

首先,航迹特征提取模块使用 Bi-LSTM 提取每个航迹点  $p_{r,j}$  的时空特征  $z_{r,j}^{BL}$ 。经过 Bi-LSTM 之后,将一条航迹所有点的特征划分成两部分,一部分被送入编码器-解码器,称这部分为“待编码特征”;另一部分作为时间对比模块内两航迹进行对比的对象,称之为“待对比特征”。设  $k$  为待进行特征对比的航迹点个数,航迹中剩余的航迹点特征为待编码特征。新航迹是将前  $k$  个航迹点的特征作为时间对比特征,老航迹是将末尾  $k$  个航迹点的特征作为时间对比特征。

其次,使用图 2 所示的编码器-解码器提取每条航迹  $T_r$  的特征  $z_r^E$ 。编码器-解码器通过最小化其输入和输出之间的均方根误差  $L_{MSE}$  (Mean-Square Error, MSE) 来提高航迹特征  $z_r^E$  的表达能力,  $L_{MSE}$  由式(3)–式(5)计算。

$$L_{MSE}^o = \frac{1}{h-k} \sum_{i=1}^{h-k} (z_{m,i}^{BL,o} - z_{m,i}^{D,o})^2 \quad (3)$$

$$L_{MSE}^y = \frac{1}{h-k} \sum_{i=1}^{h-k} (z_{n,i}^{BL,y} - z_{n,i}^{D,y})^2 \quad (4)$$

$$L_{MSE} = L_{MSE}^o + L_{MSE}^y \quad (5)$$

其中,  $L_{MSE}^o$  和  $L_{MSE}^y$  分别表示以老航迹作为输入和以新航迹作为输入的均方误差损失;  $z_{n,i}^{BL,y}$  表示新航迹的待编码特征;  $z_{m,i}^{BL,o}$  表示老航迹的待编码特征;  $z_{n,i}^{E,y}$  表示  $z_{n,i}^{BL,y}$  经解码器后的输出结果;  $z_{m,i}^{D,o}$  表示  $z_{m,i}^{E,o}$  经解码器后的输出结果。




图 2 编码器-解码器

Fig.2 Encoder-Decoder

本文使用了修改之后的 Transformer 作为编码器-解码器。航迹数据中每个航迹点往往与它前后的航迹点紧密

相关,为了利用上下文航迹点之间的关系并更好地从  $z_r^E$  重构  $z_r^{BL}$  以最小化  $L_{MSE}$ ,本文去除了经典 Transformer 中解码器的 Masked Multi-head Attention。

### 3.2 时间对比模块

时间对比模块使用老航迹的特征预测新航迹的待对比特征,使用新航迹的特征预测老航迹的待对比特征,使得属于同一目标的航迹段特征相似,而属于不同目标的航迹段特征迥异。通过这样的方式,使得模型能够更好地学习航迹的特征。时间对比模块的详细框架如图 3 所示。




图 3 时间对比模块

Fig.3 Temporal contrasting module

首先,以航迹特征  $z_r^E$  为输入,时间对比模块使用  $k$  个并行的、参数共享的全连接神经网络预测另外一条航迹的待对比特征。其中,  $k$  为待进行特征对比的航迹点个数。对于使用新航迹特征  $z_n^{E,y}$  预测老航迹的待对比特征,第  $i$  个全连接层的预测由式(6)完成。

$$Prediction_i^y = W_i^y z_n^{E,y} + b_i^y \quad (6)$$

其中,  $W_i^y$  代表第  $i$  个全连接层的系数矩阵,  $b_i^y$  代表第  $i$  个全连接层的偏置,  $Prediction_i^y$  代表新航迹的第  $i$  个预测值。将所有  $k$  个全连接层的输出进行拼接,如式(7)所示。

$$Prediction^y = Concat(Prediction_1^y, \dots, Prediction_k^y) \quad (7)$$

其中,  $Prediction^y$  为新航迹的预测值拼接之后得到的预测值。

同理可得使用老航迹特征预测新航迹待对比特征的过程,见式(8)和式(9)。

$$Prediction_i^y = W_i^y z_m^{E,y} + b_i^y \quad (8)$$

$$Prediction^o = Concat(Prediction_1^o, \dots, Prediction_k^o) \quad (9)$$

其中,  $Prediction^o$  表示老航迹的预测值进行拼接之后得到的预测值。

最后,对于某航迹,将预测值与该航迹的待对比特征进行对比。为了减小来自同一目标的新老航迹的预测值和待对比特征之间的差值,并增大来自不同目标的新老航迹的预测值和待对比特征之间的差值,本文使用对比损失(Contrastive loss)作为训练的损失函数  $L_{TC}$ ,见式(10)~式(12)。

$$L_{TC}^y = \frac{1}{2} [y^+ (d^y)^2 + (1 - y^+) \max(\text{margin} - d^y, 0)^2] \quad (10)$$

$$L_{TC}^o = \frac{1}{2} [y^+ (d^o)^2 + (1 - y^+) \max(\text{margin} - d^o, 0)^2] \quad (11)$$

$$L_{TC} = L_{TC}^o + L_{TC}^y \quad (12)$$

其中,  $L_{TC}^o$  和  $L_{TC}^y$  分别表示以老航迹作为输入和以新航迹作为输入时的对比损失,  $y^+$  表示航迹对的标签。在本任务中,当新老航迹对为同一个目标的航迹时,标签为 1;当新老航迹对不是同一个目标的航迹时,标签为 0。margin 是一个阈值。  $d^y$  为新航迹的预测值与老航迹的待对比特征之间的欧氏距离,由式(13)计算。

$$d^y = \| Prediction^y - z_{m,h-k+1,h}^{BL,o} \|_2 \quad (13)$$

其中,  $z_{m,h-k+1,h}^{BL,o}$  是老航迹的待对比特征;  $d^o$  为老航迹的预测值与新航迹的待对比特征之间的欧式距离,由式(14)计算。

$$d^o = \| Prediction^o - z_{n,h-k+1,h}^{BL,y} \|_2 \quad (14)$$

其中,  $z_{n,h-k+1,h}^{BL,y}$  是新航迹的待对比特征。

### 3.3 航迹特征对比模块

航迹特征对比模块将新航迹的特征  $z_n^{E,y}$  和老航迹的特征  $z_m^{E,o}$  进行对比,得到这两个特征的相似度。航迹特征对比模块的详细框架如图 4 所示。




图 4 航迹特征对比模块

Fig. 4 Track feature contrasting module

首先,航迹特征对比模块将新老航迹的特征  $z_n^{E,y}$  和  $z_m^{E,o}$  转换成一维向量后,输入至两个全连接层,分别得到  $f(z_m^{E,o})$  和  $f(z_n^{E,y})$ 。然后,使用曼哈顿距离作为相似度度量计算  $f(z_m^{E,o})$  和  $f(z_n^{E,y})$  的相似性,如式(15)所示:

$$Similarity = \| f(z_m^{E,o}) - f(z_n^{E,y}) \|_1 \quad (15)$$

### 3.4 分类器模块

分类器模块以两个航迹的特征相似度作为输入,经过两个维度分别为 512 和 1 的全连接层,最后通过 Sigmoid 激活函数,得到两条航迹是否关联的概率。

分类器模块使用的损失函数为二元交叉熵(Binary Cross Entropy)损失,如式(16)所示:

$$L_{\text{cross-entropy}} = -[y^+ \log(y^{\text{out}}) + (1 - y^+) \log(1 - y^{\text{out}})] \quad (16)$$

其中,  $y^+$  表示航迹对的标签;  $y^{\text{out}}$  表示模型对航迹对的预测结果。

模型的总损失由上述的编码器-解码器的均方误差损失  $L_{MSE}$ 、时间对比模块的对比损失  $L_{TC}$  以及分类器模块的二元交叉熵损失  $L_{\text{cross-entropy}}$  3 部分加权求和得到,如式(17)所示:

$$Loss = a_{\text{cross-entropy}} L_{\text{cross-entropy}} + a_{MSE} L_{MSE} + a_{TC} L_{TC} \quad (17)$$

其中,  $a_{\text{cross-entropy}}$ ,  $a_{MSE}$ ,  $a_{TC}$  分别表示 3 种损失函数的权重。

分类器的输出为两条航迹是否关联的概率值,这个值越大代表这两条航迹越可能关联。

### 3.5 关联概率处理

关联概率处理部分将模型输出的航迹对关联概率处理为最终关联结果。

首先,设置一个关联概率矩阵  $SM$  和一个关联航迹对集合  $list$ 。矩阵  $SM$  中的第  $q$  行、第  $w$  列存放第  $q$  条航迹和第  $w$  条航迹的关联概率。将模型输出的关联概率填充到  $SM$  中的相应元素位置。然后,循环搜索  $SM$  每一行中关联概率最大的两条航迹作为关联航迹对。最后,将判决为关联的航迹对添加到关联航迹对集合  $list$  中。

**算法 1** 基于深度时间对比的中断航迹关联算法

输入:航迹数据

输出:判决为关联航迹的集合  $list$

1. 初始化关联概率矩阵  $SM$
2. 初始化关联航迹对列表  $list$
3. 初始化航迹特征提取模块  $E^y$  和  $E^o$
4. 初始化时间对比模块  $TC^y$  和  $TC^o$
5. 初始化航迹特征对比模块  $S$
6. 初始化分类器  $C$
7. WHILE 训练次数没有达到  $epochs$  DO
8. 使用  $E^y$  和  $E^o$  中的 Bi-LSTM 和编码器提取新老航迹特征  $z_n^{E,y}$  和  $z_m^{E,o}$
9. 根据式(3)计算  $E^o$  的损失  $L_{MSE}^o$
10. 根据式(4)计算  $E^y$  的损失  $L_{MSE}^y$
11. 使用  $TC^o$ ,根据式(11)将航迹特征  $z_m^{E,o}$  的预测值  $Prediction^y$  与待对比特征  $z_{m,h-k+1,h}^{BL,y}$  进行对比,计算出  $TC^o$  的损失  $L_{TC}^o$
12. 使用  $TC^y$ ,根据式(10)将航迹特征  $z_n^{E,y}$  的预测值  $Prediction^o$  与待对比特征  $z_{m,h-k+1,h}^{BL,o}$  进行对比,计算出  $TC^y$  的损失  $L_{TC}^y$
13. 使用  $S$  对比新老航迹的特征  $z_m^{E,o}$  和  $z_n^{E,y}$  得到对比特征  $Similarity$
14. 使用  $C$ ,根据对比特征  $Similarity$  得到两条航迹的关联概率
15. 根据式(16)计算分类器损失  $L_{\text{cross-entropy}}$
16. 根据式(17)联合优化各模块损失
17. END WHILE
18. 将模型输出的关联概率填充到关联概率矩阵  $SM$  中的对应位置
19. FOR  $i \leftarrow 1$  to  $SM.length$  DO
20.  $SM[\max\_i][\max\_j] \leftarrow \arg \max_{1 \leq i \leq S_L, 1 \leq j \leq S_L} SM[i][j]$
21. 将  $(\max\_i, \max\_j)$  添加到  $list$
22. 将  $\max\_i$  从  $i$  的遍历序列中剔除

23. 将  $\max_j$  从  $j$  的遍历序列中剔除

24. RETURN list

## 4 实验数据与结果分析

### 4.1 实验环境和数据集

为了验证 TSADTC 算法的有效性,本文仿照文献[37]生成了相关数据集,并进行了中断航迹关联的仿真实验。

在仿真实验中,设置了  $100\text{ km} \times 100\text{ km}$  的雷达量测区域。采用随机生成目标的方式,给每个飞行目标设置随机的初始位置、初始速度以及初始运动方向。初始速度的范围是  $300\text{ m/s} \sim 600\text{ m/s}$ ,之后让目标随机地改变其运动参数,包括运动速度和运动方向,但保证二者的变化幅度不超过运动学规律的合理范围。飞行目标的相关运动参数如表 1 所列。每个目标共飞行  $50\text{ s}$ ,每秒采集一次目标的数据。数据集的  $70\%$  作为训练集,剩余的  $30\%$  作为测试集。以下 TSADTC 所有实验的  $\text{margin}$  设为 1。

表 1 目标航迹段范围  
Table 1 Ranges of target track segments

参数	值
距离/m	30 000~70 000
速度/(m/s)	300~600
方向/(°)	$0 \sim 2\pi$

### 4.2 不同损失函数权重对算法性能的影响

本文所提算法中共涉及 3 个损失函数:  $L_{TC}$ ,  $L_{MSE}$  和  $L_{\text{cross-entropy}}$ ,模型总的损失函数是这 3 个损失函数加权求和。本小节评估不同损失函数的权重对模型性能的影响。

实验中,随机生成 2000 个目标的完整航迹。对每个目标的航迹,按照时间间隔  $4\text{ s}$ ,  $6\text{ s}$ ,  $8\text{ s}$ ,  $10\text{ s}$ ,  $12\text{ s}$  对每条航迹进行拆分,每个时间间隔情况下都可以拆出 2000 条老航迹和 2000 条新航迹。之后再将同一目标的新、老航迹进行配对,组成 2000 条正样本数据,将不同目标的新、老航迹进行随机组合,组成 2000 条负样本。对 5 个不同时间间隔的数据都做如上操作,最终得到 10000 条正样本数据和 10000 条负样本数据。这 20000 条数据构成数据集。

表 2 列出了不同损失函数权重比值下,算法 TSADTC 的准确率、召回率和精度性能,其中表中最左边的  $a_{\text{cross-entropy}}$ :  $a_{MSE}$ :  $a_{TC}$  为各损失函数的权重比值。从表中可以看出,当  $a_{\text{cross-entropy}}$ :  $a_{MSE}$ :  $a_{TC} = 1 : 0.3 : 0.4$  时,模型达到了实验中的最优表现,准确率达到了  $99.68\%$ ,召回率达到了  $100\%$ ,精确率也逼近  $99\%$ 。因此,在后续的实验,设置  $a_{\text{cross-entropy}} = 1$ ,  $a_{MSE} = 0.3$ ,  $a_{TC} = 0.4$ 。

表 2 算法在不同权重组合下的性能表现

Table 2 Performance of algorithm with different weight combinations (单位: %)

$a_{\text{cross-entropy}}$ : $a_{MSE}$ : $a_{TC}$	Accuracy	Recall	Precision
1 : 0.3 : 0.4	99.68	100.0	98.99
1 : 0.4 : 0.3	99.28	99.90	98.73
0.3 : 1 : 0.4	99.20	99.97	98.44
0.4 : 1 : 0.3	99.08	99.87	98.19
0.3 : 0.4 : 1	98.43	99.77	97.14
0.4 : 0.3 : 1	98.68	99.77	97.77

### 4.3 不同算法的对比实验

为了验证 TSADTC 算法的性能,本小节选择了 3 种先进

的中断航迹关联算法作为对比对象:机载法<sup>[15]</sup>、匈牙利法<sup>[16]</sup>和 TSADCNN<sup>[21]</sup>。

机载法首先使用粗关联排除不可能关联的航迹对,然后使用对数代价函数结合二维最优分配判断剩余的航迹对是否关联。匈牙利法首先使用粗关联排除不可能关联的航迹对,然后使用匈牙利法判断剩余的航迹对是否关联。TSADCNN 首先使用两个并行的模块进行特征提取,然后根据提取的特征的相似度判断是否关联。

本节用上一小节训练好的模型做测试,测试数据集集中的飞行目标数量范围为  $[5, 50]$ 。对于每个飞行目标数量,进行了 50 次蒙特卡罗仿真。图 5 给出了目标个数为 25、中断时间为  $6\text{ s}$  的一次仿真数据,绿色点迹为中断前的航迹点,橙黄色点迹为中断后的航迹点。




图 5 仿真数据示意图(电子版为彩图)

Fig. 5 Simulation data diagram

评价标准选用航迹关联问题中常用的航迹正确关联率  $R_{ta}$ 、航迹错误关联率  $R_{fa}$  和航迹漏关联率  $R_{qa}$  这 3 个指标,其计算方法分别如式(18)~式(20)所示:。

$$R_{ta} = \frac{s_t}{s} \quad (18)$$

$$R_{fa} = \frac{s_f}{s} \quad (19)$$

$$R_{qa} = \frac{s_q}{s} \quad (20)$$

其中,  $s$  表示飞行目标的个数,  $s_t$  表示正确关联的目标个数,  $s_f$  表示错误关联的目标个数,  $s_q$  表示漏关联的目标个数。它们之间的关系满足式(21)。

$$s_t + s_f + s_q = s \quad (21)$$

航迹正确关联率、错误关联率、漏关联率之间的关系满足式(22):

$$R_{ta} + R_{fa} + R_{qa} = 1 \quad (22)$$

#### 4.3.1 不同中断时间对性能的影响

在飞行目标数量为 25 时,不同中断时间对不同航迹关联算法性能的影响如图 6、表 3 和表 4 所示。




图 6 不同航迹中断时间下的正确关联率

Fig. 6 Correct association rate with different track interrupted interval

表3 不同航迹中断时间下的漏关联率

Table 3 Missing association rate with different track interrupted interval

中断时间/s	漏关联率/%			
	机载法	匈牙利法	TSADCNN	TSADTC
4	12.80	12.8	0.24	0.00
6	5.28	5.28	0.32	0.00
8	3.68	3.68	0.24	0.08
10	3.28	3.28	0.24	0.08
12	3.36	3.36	0.08	0.08

表4 不同航迹中断时间下的错误关联率

Table 4 False association rate with different track interrupted interval

中断时间/s	漏关联率/%			
	机载法	匈牙利法	TSADCNN	TSADTC
4	0.00	0.00	2.80	0.80
6	0.16	0.16	2.80	1.60
8	0.32	0.32	4.00	1.36
10	1.12	1.36	5.68	1.84
12	1.68	2.24	10.48	3.04

图6给出了不同算法在不同航迹中断时间下的正确关联率。从图中可以看出,本文算法TSADTC的表现最好。在中断时间为4s时,关联准确率高达99.2%。之后,随着中断时间的变长,准确率虽有小幅度下降,但仍一直保持在最高的正确关联率。当中断时间为12s时,TSADTC的准确率仍能达到96.88%。机载法和匈牙利法在整个实验中的表现相近,机载法在中断时间较长时的正确关联率性能略好于匈牙利法。TSADTC相比机载法和匈牙利法的性能提升最好时可以达到12%。TSADCNN的正确关联率随着中断时间的增长有明显下降。在中断时间小于8s时,机载法和匈牙利法的正确关联率比TSADCNN低2.32%~9.76%。在中断时间超过8s时,机载法和匈牙利法的正确关联率比TSADCNN高0.24%~5.52%。

表3列出了不同算法在不同航迹中断时间下的漏关联率。从表中可以看出,本文所提算法TSADTC远远优于其他算法。在中断时间为4s和6s时,漏关联率为0。之后,随着中断时间的增长,漏关联率虽有小幅度上涨,但仍一直保持在最低的漏关联率,最高也仅仅达到0.08%。机载法和匈牙利法的漏关联率相同,在中断时间为4s时,机载法和匈牙利法的漏关联率高达12.8%。随着中断时间的变长,机载法和匈牙利法的漏关联率有所下降。TSADTC相比机载法和匈牙利法的漏关联率降低了3.2%~12.8%。TSADCNN的漏关联率随着中断时间的增长有所波动。在每一种中断时间下,TSADCNN的漏关联率都低于机载法和匈牙利法。在中断时间为12s时,TSADCNN和TSADTC漏关联率相同。其余中断时间下,TSADCNN的漏关联率都高于TSADTC。当中断时间为6s时,TSADCNN的漏关联率比TSADTC的漏关联率高0.32%。

表4列出了不同算法在不同航迹中断时间下的错误关联率。从表中可以看出,随着中断时间的变长,几种算法的错误关联率都有所上升。本文算法TSADTC获得了比TSADCNN更低的错误关联率,获得的性能提升最好时达到了7.44%。机载法和匈牙利法获得了比较相近的性能,机载法在中断时间较长时的错误关联率性能略好于匈牙利法。机载法相比TSADTC的错误关联率降低了0.8%~1.44%。

总的来说,本文算法TSADTC获得了最好的性能。TSADTC在正确关联率、错误关联率和漏关联率性能指标上,分别比TSADCNN最好时提升了7.44%,0.32%,7.44%。虽然TSADTC的错误关联率高于机载法0.8%~1.44%,但是TSADTC相比机载法的正确关联率和漏关联率性能最好时分别提升了12%和12.8%。机载法和匈牙利法在整个实验中的表现相近。机载法和匈牙利法的漏关联率相比两个深度学习算法要高得多,这是因为粗关联会排除掉不可能是关联的航迹对,且粗关联的性能取决于人工设置的阈值,因此其难以应对这种状态变化较大、且无规律的飞行目标,从而影响到算法的漏关联率和正确关联率。

#### 4.3.2 不同飞行目标数量对性能的影响

在中断时间为6s时,不同飞行目标数量对不同航迹关联算法性能的影响如图7、表5和表6所示。




图7 不同飞行目标个数下的正确关联率

Fig. 7 Correct association rate with different number of flight targets

表5 不同飞行目标个数下的漏关联率

Table 5 Missing association rate with different number of flight targets

飞行目标个数/个	漏关联率/%			
	机载法	匈牙利法	TSADCNN	TSADTC
5	3.60	3.60	0.00	0.00
10	5.20	5.20	0.60	0.00
15	4.10	4.10	0.13	0.00
20	4.30	4.30	0.00	0.00
25	5.28	5.28	0.32	0.00
30	4.60	4.60	0.13	0.00
35	4.85	4.85	0.05	0.00
40	4.05	4.05	0.10	0.00
45	3.95	3.95	0.00	0.04
50	4.40	4.04	0.00	0.00

表6 不同飞行目标个数下的错误关联率

Table 6 False association rate with different number of flight targets

飞行目标个数/个	漏关联率/%			
	机载法	匈牙利法	TSADCNN	TSADTC
5	0.00	0.00	0.80	0.00
10	0.00	0.00	0.60	0.00
15	0.03	0.03	3.07	1.33
20	0.20	0.20	3.00	1.00
25	0.16	0.16	2.80	1.60
30	0.40	0.20	4.87	2.40
35	0.47	0.47	6.92	2.98
40	0.15	0.15	6.65	3.85
45	0.50	0.45	6.89	2.80
50	0.32	0.24	8.68	2.88

图7给出了不同算法在不同飞行目标数量下的正确关联率。从图中可以看出,本文算法TSADTC的表现最好。在飞行目标数量为5和10时,关联准确率高达100%。之后,随着飞行目标数量的增加,准确率虽有下降,但仍一直保持在

最高的正确关联率。在飞行目标为 40 时, TSADTC 的准确率仍能达到 96.15%。机载法和匈牙利法在整个实验中的表现相近, 匈牙利法在飞行目标数量较多时的正确关联率性能略好于机载法。TSADTC 相比机载法和匈牙利法的性能提升最好时可以达到 5.2%。TSADCNN 的正确关联率随着飞行目标数量的增加有明显下降。TSADTC 相比 TSADCNN 的性能提升最好时可以达到 5.8%。在飞行目标数量少于 30 时, 机载法和匈牙利法的正确关联率比 TSADCNN 低 0.93%~4%。在飞行目标数量超过 30 时, 机载法和匈牙利法的正确关联率比 TSADCNN 高 0%~4.04%。

表 5 列出了不同算法在不同飞行目标数量下的漏关联率。从表中可以看出, 本文算法 TSADTC 远远优于其他算法。在飞行目标数量为 45 时, TSADTC 漏关联率为 0.04%。其余飞行目标数量下, TSADTC 的漏关联率都为 0。机载法和匈牙利法的漏关联率相同。随着飞行目标数量的增加, 机载法和匈牙利法的漏关联率有所波动。在飞行目标数量为 25 时, 机载法和匈牙利法的漏关联率高达 5.28%。TSADTC 相比机载法和匈牙利法的漏关联率降低了 3.6%~5.28%。TSADCNN 的漏关联率随着飞行目标数量的增加有所波动。在每一种飞行目标数量下, TSADCNN 的漏关联率都低于机载法和匈牙利法。TSADTC 相比 TSADCNN 的性能提升最好时可以达到 0.6%。

表 6 列出了不同算法在不同飞行目标数量下的错误关联率。从表中可以看出, 随着飞行目标数量的增加, 几种算法的错误关联率都有所上升和波动。本文算法 TSADTC 获得了比 TSADCNN 更低的错误关联率, 获得的性能提升最好时可以达到 5.8%。机载法和匈牙利法获得了比较相近的性能, 匈牙利法在飞行目标数量较多时的错误关联率性能略好于机载法。匈牙利法相比 TSADTC 的错误关联率降低了 0%~3.7%。

总的来说, 本文算法 TSADTC 获得了最好的性能。TSADTC 在正确关联率、错误关联率和漏关联率性能指标上, 分别比 TSADCNN 最好时提升了 5.8%, 5.8%, 0.6%。虽然 TSADTC 的错误关联率高于匈牙利法 0%~3.7%, 但是 TSADTC 相比匈牙利法的正确关联率和漏关联率性能最好时分别提升了 5.2% 和 5.28%。机载法和匈牙利法虽然也是最近几年才提出的, 但其思想仍是传统中断航迹关联的算法思想。机载法和匈牙利法在整个实验中的表现相近。机载法和匈牙利法的漏关联率相比两个深度学习算法要高得多, 这是因为粗关联会排除掉不可能是关联的航迹对, 且粗关联的性能取决于人工设置的阈值, 因此其难以应对这种状态变化较大、且无规律的飞行目标, 从而影响到算法的漏关联率和正确关联率。


**结束语** 本文提出了一种基于深度时间对比的中断航迹关联算法 TSADTC, 包括航迹特征提取模块、时间对比模块、航迹特征对比模块以及分类器模块。航迹特征提取模块对新航迹和老航迹组成的航迹对, 利用双向 LSTM(Bi-LSTM) 和编码器-解码器分别对两条航迹进行特征提取; 时间对比模块中, 使用老航迹的特征预测新航迹, 使用新航迹的特征预测老航迹, 以更好地学习新老航迹的特征, 使得同一目标的老航迹具有很高的相似性; 航迹特征对比模块计算两条航迹的特征差别, 并将此差别输入分类器中, 以判断两条航迹是否是

关联的。仿真实验结果显示, 本文算法 TSADTC 的综合性能远远优于其他算法, 正确关联率、漏关联率和错误关联率可分别达到 97.12%, 0% 和 2.88%, 表明其能够很好地解决中断航迹关联的问题。

## 参考文献

- [1] ZHANG S P, LIU H M L, YU K, et al. A Robust Filtering Algorithm for Radar Target Tracking[J]. Air&Space Defense, 2020, 3(1): 73-79.
- [2] BO J T, WANG G H, YU H B, et al. Hypersonic Target Detection and Correlation Algorithm under the Condition of Large Time-Space Difference[J]. Modern Defence Technology, 2021, 49(5): 56-64.
- [3] WU S Y, LI D S, XUE Q T X, et al. Research on PHD Filter Based Track-Before-Detect Algorithm of Radar Fluctuating Targets[J]. Acta Electronica Sinica, 2022, 50(3): 691-702.
- [4] WANG S L, BI D P, RUAN H L R, et al. Cognitive Radar Maneuvering Target Tracking Algorithm Based on Information Entropy Criterion[J]. Acta Electronica Sinica, 2019, 47(6): 1277-1284.
- [5] HAN W, CHEN C S, LI Z H. A Method of Track Segment Association in Doppler Blind Zone[J]. Radar Science and Technology, 2020, 18(3): 239-246.
- [6] WANG Y, HAN W. A New Plot-track Correlation Method of Multiple-target on the Condition of Doppler Blind Zone[J]. Fire Control & Command Control, 2020, 45(5): 58-63.
- [7] RAGHU J, SRIHARI P, THARMARASA R, et al. Comprehensive track segment association for improved track continuity[J]. IEEE Transactions on Aerospace and Electronic Systems, 2018, 54(5): 2463-2480.
- [8] CHEN Y L, TONG Q, SHEN T T, et al. Short-term Trajectory Prediction Model Based on Attention Mechanism and Generative Adversarial Network[J]. Journal of Computer Applications, 2022: 3292-3299.
- [9] YANG K, DANINO M, BAR-SHALOM Y, et al. Track segment association in target selection for interdiction using a single passive sensor[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(5): 3268-3278.
- [10] XIONG W, XU P, CUI Y, et al. Track Segment Association via track graph representation learning[J]. IET Radar, Sonar & Navigation, 2021, 15(11): 1458-1471.
- [11] MUCCI R, ARNOLD J, BAR-SHALOM Y. Track segment association with a distributed field of sensors[J]. The Journal of the Acoustical Society of America, 1985, 78(4): 1317-1324.
- [12] YEOM S W, KIRUBARAJAN T, BAR-SHALOM Y. Improving track continuity using track segment association[C] // 2003 IEEE Aerospace Conference Proceedings (Cat. No. 03TH8652), 2003: 4\_1925-4\_1941.
- [13] CASTNNÓN G, FINN L. Multi-target tracklet stitching through network flows[C] // 2011 Aerospace Conference. 2011: 1-7.
- [14] QI L, WANG H P, XIONG W, et al. Track Segment Association Algorithm Based on Multiple-hypothesis Models with Prior Information[J]. Systems Engineering and Electronics, 2015, 37(4): 732-739.
- [15] WANG Z H, HAN H. Tracking Segment Association Algorithm

- for Airborne Radar[J]. *Modern Radar*, 2019, 41(7): 61-64.
- [16] ZHOUX P, LI J J, ZHAO X L Z, et al. Airborne Radar Track Segment Association Based on Hungarian Algorithm[J]. *Modern Radar*, 2021, 43(6): 42-48.
- [17] ZHANG W, HU M, DU J. An end-to-end framework for flight trajectory data analysis based on deep autoencoder network[J]. *Aerospace Science and Technology*, 2022, 127: 107726.
- [18] WANG L, TANG J, LIAO Q. A study on radar target detection based on deep neural networks[J]. *IEEE Sensors Letters*, 2019, 3(3): 1-4.
- [19] LIU J, WANG Z, XU M. DeepMTT: A deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network[J]. *Information Fusion*, 2020, 53: 289-304.
- [20] RÜTTGERS M, LEE S, JEON S, et al. Prediction of a typhoon track using a generative adversarial network and satellite images[J]. *Scientific Reports*, 2019, 9(1): 1-15.
- [21] XIONG W, XU P, CUI Y, et al. Track Segment Association With Dual Contrast Neural Network[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 58(1): 247-261.
- [22] HAN L L, XIU J J, DONG K, et al. A Space Target Intermittent Track Association Algorithm Based on Trajectory Prediction[J]. *Electronics Optics & Control*, 2019, 26(12): 100-104.
- [23] QI L, WANG H P, LIU Y. Track Segment Association Algorithm Based on Statistical Binary Thresholds[J]. *Journal of Radars*, 2015, 4(3): 301-308.
- [24] CAO Y, CAO J, ZHOU Z. Track Segment Association Method Based on Bidirectional Track Prediction and Fuzzy Analysis[J/OL]. *Aerospace*, 2022, 9(5): 274. <https://doi.org/10.3390/aerospace9050274>.
- [25] SUN J, WANG N, ZHANG Z. Track Segment Association of Maneuvering Target Based on Expectation Maximization[C]// 2018 11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 2018: 1-5.
- [26] LIN L, BAR-SHALOM Y, KIRUBARAJAN T. New assignment-based data association for tracking move-stop-move targets[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2004, 40(2): 714-725.
- [27] GUO Y, ZHU J, ZHOU S, et al. A joint model and data driven track segment association algorithm for manoeuvring target tracking[J]. *IET Radar, Sonar & Navigation*, 2022, 16(10): 1670-1680.
- [28] MORI S, CHONG C Y. Performance analysis of graph-based track stitching[C]// Proceedings of the 16th International Conference on Information Fusion, 2013: 196-203.
- [29] VAN DER MERWE L J, DE VILLIERS J P. Track-stitching using graphical models and message passing[C]// Proceedings of the 16th International Conference on Information Fusion, 2013: 758-765.
- [30] CHAI L, KONG L, LI S, et al. The multiple model multi-Bernoulli filter based track-before-detect using a likelihood based adaptive birth distribution[J]. *Signal Processing*, 2020, 171: 107501.
- [31] HAN W, TANG Z Y, ZHU Z B. A Method of Tracking Targets in Doppler Blind Zone Based on Multiple-hypothesis Motion Models[J]. *Journal of Electronics & Information Technology*, 2013, 35(3): 516-523.
- [32] MAO Y F, ZHANG D L Z, WANG L W. Fuzzy Theory and Evidence Combination Based Track Segment Association for Ballistic Missile in Unpowered Phase[J]. *Electronics Optics & Control*, 2017, 24(2): 47-50.
- [33] YU J G, LIU M, CHEN J H. Ballistic Target Track Segments Association and Optimization[J]. *Acta Aeronautica et Astronautica Sinica*, 2011, 32(10): 1897-1904.
- [34] XU P L, CUI Y Q, XIONG W, et al. Generative Track Segment Consecutive Association Method[J]. *Systems Engineering and Electronics*, 2022, 44(5): 1543-1552.
- [35] QIN W, TANG J, LAO S. DeepFR: A trajectory prediction model based on deep feature representation[J]. *Information Sciences*, 2022, 604: 226-248.
- [36] LI S, JIN X, XUAN Y, et al. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting[J/OL]. *Advances in Neural Information Processing Systems*, 2019, 32. <https://proceedings.neurips.cc/paper/2019/hash/6775a0635c302542da2c32aa19d86be0-Abstract.html>.
- [37] XIU J J, ZHANG J Y, DONG K D. Research on Space-target Track Segments Association Algorithm[J]. *Journal of Ballistics*, 2020: 85-90.



**HOU Hailun**, born in 1998, postgraduate. His main research interests include spatiotemporal data mining and so on.



**FAN Yuqi**, born in 1976, Ph.D, associate professor. His main research interests include blockchain, spatiotemporal data mining and so on.