

文章编号: 2095-4980(2022)12-1269-08

基于雷达量测时空特征的航迹起始方法

沈光铭¹, 许 雄², 樊玉琦^{*1}

(1.合肥工业大学 计算机与信息工程学院, 安徽 合肥 230601;
2.电子信息系统复杂电磁环境效应国家重点实验室, 河南 洛阳 471003)

摘 要: 日益拥挤、复杂的空域环境, 使得确定真实目标航迹的起始尤为主要。现有关于雷达目标航迹起始的研究大多只考虑了实时性或起始率中的一种, 难以在强杂波环境下完成快速而准确的航迹起始。本文提出一种适用于强杂波环境的基于深度学习和雷达量测时空(DLTS)特征的航迹起始算法。该算法首先从雷达量测组合中筛选出候选集, 并从中提取出量测组合的时序变化和空间分布向量, 作为一维卷积神经网络(1DCNN)和门控循环单元(GRU)混合模型的输入, 获得量测组合的时间和空间维度特征, 再将二者合并得到时空特征。最后对经过自注意力处理的时空特征进行真假航迹分类, 完成航迹起始。在仿真实验中, DLTS算法在强杂波环境下能够在时间损耗与逻辑法相近的情况下有效提高真假航迹起始率性能。

关键词: 航迹起始; 深度学习; 雷达

中图分类号: TN959

文献标志码: A

doi: 10.11805/TKYDA2021148

A track initiation algorithm based on temporal-spatial characteristics of radar measurement

SHEN Guangming¹, XU Xiong², FAN Yuqi^{*1}

(1.School of Computer Science and Information Engineering, Hefei University of Technology, Hefei Anhui 230601, China;
2.State Key Laboratory of Complex Electromagnetic Environment Effects on Electronics and Information Systems,
Luoyang Henan 471003, China)

Abstract: The increasingly crowded and complex airspace environment makes it necessary to determine the initiation of the true target track. Most existing research on radar target track initiation only considers one of real-time or initiation rate, and it is difficult to complete fast and accurate track initiation in a strong clutter environment. In this paper, a track initiation algorithm is proposed based on Deep Learning and Temporal-Spatial(DLTS) characteristics of radar measurement suitable for strong clutter environment. The algorithm first selects the candidate set from the radar measurement combinations, and next extracts the temporal change vector and spatial distribution vector of the measurement combination, and uses them as the input of the One-dimensional Convolutional Neural Network(1DCNN) and Gated Recurrent Unit(GRU) hybrid model to obtain the time dimensional characteristics and space dimensional characteristics of the measurement combination, then merge the two to get the temporal-spatial characteristics. Finally, the true and false tracks are classified with the temporal-spatial characteristics processed by self-attention, and the track initiation is completed. The simulations show that DLTS algorithm can effectively improve the performance of the true and false track initiation rate when the time loss is similar to that of the logic method in the strong clutter environment.

Keywords: track initiation; deep learning; radar

收稿日期: 2021-04-14; 修回日期: 2021-05-31

基金项目: 电子信息系统复杂电磁环境效应国家重点实验室开放课题资助项目(CEMEE2018Z0102B); 电子信息系统复杂电磁环境效应国家重点实验室委托课题资助项目(CEMEE20200415-09)

*通信作者: 樊玉琦 email:yuqi.fan@hfut.edu.cn

对于现代雷达,目标跟踪是其最基本的任务之一^[1]。航迹起始,是指在雷达未实现稳定的目标跟踪之前所进行的航迹确立过程,它是目标跟踪任务的首要问题和关键组成部分。由于雷达探测环境的日益复杂化,尤其是强杂波环境的干扰和相关先验知识的缺少,使雷达量测的不确定性变得非常严峻,雷达目标的航迹起始问题正逐渐成为雷达数据处理算法研究的主要问题^[2]。

目前已有的雷达目标航迹起始方法主要包括两大类:以直观法^[3]、逻辑法^[4]及其改进算法^[5-7]为代表的顺序处理方法;以 Hough 变换法^[8]及其改进算法^[9]为代表的批处理方法。其中,顺序处理方法在弱杂波环境下具有计算量小、起始速度快的优点,能够取得较好的起始效果。但在强杂波环境下,顺序处理方法容易出现量测数据“组合爆炸”的问题,并且对先验知识的依赖严重。而 Hough 变换法本身具有良好的鲁棒性和不受维度空间、线条形状影响的变换能力,因此批处理方法在强杂波环境下能够更准确地实现航迹起始。值得注意的是,在强杂波环境下批处理方法的计算量巨大,导致其计算效率低下,无法快速起始航迹^[10]。如何在强杂波环境下快速且准确地起始航迹,是传统航迹起始方法面临的主要问题。近年来,随着机器学习的快速发展,尤其是其中的深度学习技术,为航迹起始问题提供了全新的思路^[11-13]。将航迹起始问题转换为真实与虚假航迹的鉴别、区分问题,即深度学习模型二分类问题,通过构建相关样本数据集对深度学习模型进行训练以实现分类能力。这种方式能够大幅降低模型对先验知识的依赖,同时,当杂波背景环境改变时,模型能够自适应调节内部参数,从而提高模型的鲁棒性和自适应能力。然而,现有基于机器学习的航迹起始方法所使用的模型结构较为简单,提取得到的特征维度单一,没有充分发挥神经网络模型的特征提取能力,使得模型对真假航迹的辨别能力不足,从而难以在强杂波环境下完成快速而准确的航迹起始任务。

本文针对强杂波环境下航迹起始问题,提出了一种基于深度学习和雷达量测时空(DLTS)特征的航迹起始算法,该算法将航迹起始问题转换为针对雷达量测组合的真假航迹辨别问题,综合考虑量测组合的时间和空间维度信息对真假航迹辨别的影响,在保证航迹的快速起始的前提下提高强杂波环境下真假航迹辨别能力。该算法首先通过设置基于目标运动学规律的约束从量测组合集中选取出符合约束规则的量测组合构成候选集以提高起始效率。然后,从候选集的量测组合中提取出包含时间维度信息的时序变化向量和空间维度信息的空间分布向量,将其作为基于深度学习技术的门控循环单元(GRU)和一维卷积神经网络(1DCNN)混合模型的输入,从而提取出时间维度特征和空间维度特征,并将其合并得到量测组合的时空特征。接下来,使用自注意力机制为不同维度的时空特征赋予不同的权重以提高模型的真假航迹辨别能力。最后使用由全连接层和 Sigmoid 函数构成的分类器对量测组合进行分类以实现真假航迹的辨别,从而完成航迹起始。实验结果表明,DLTS 算法能够在强杂波环境下实现航迹的快速、准确起始。

1 问题定义

本文使用笛卡尔直角坐标系中的横坐标 x 、纵坐标 y 以及时间戳 t 来描述单个雷达量测。如,雷达扫描周期 c_i 中的某个雷达量测可以表示为: $p_i(c_i) = (x_i(c_i), y_i(c_i), t_i(c_i))$, $1 \leq i \leq nc_i$, 其中 nc_i 为扫描周期 c_i 的雷达量测总数,扫描周期 c_i 雷达量测数据集 $D(c_i)$ 可以表示为: $D(c_i) = \{p_1(c_i), p_2(c_i), \dots, p_{nc_i}(c_i)\}$ 。因此,对于连续 n 个扫描周期雷达量测组合集可以表示为: $D = \{D(c_1), D(c_2), \dots, D(c_n)\}$ 。通过从每个扫描周期中选取出一个雷达量测进行组合,可以得到总数为 $\prod_{i=1}^n nc_i$ 的量测组合集 $\{p_{s_1}(c_1), p_{s_2}(c_2), \dots, p_{s_n}(c_n)\} (1 \leq s_i \leq nc_i)$ 。为了进行深度学习模型的训练与测试,本文将量测组合分为两类:真实航迹和虚假航迹。具体来说,设定代表真实航迹的量测组合的标签值为 1,代表虚假航迹的量测组合的标签值为 0。本研究的目标是针对连续 n 个扫描周期雷达量测数据,正确分类连续 n 个扫描周期的雷达量测组合集中每个量测组合,找到所有标签值为 1 即真实航迹的量测组合,从而实现航迹起始。

2 方法

对强杂波环境下航迹起始问题,本文提出一种基于深度学习和雷达量测时空特征的航迹起始算法。该算法的具体流程如图 1 所示。首先从量测组合集中筛选出候选集,并提取出候选集中量测组合的时序变化向量和空间分布向量,将其作为 1DCNN 和 GRU 混合模型的输入,以得到时间维度特征和空间维度特征,并将其合并获得时空特征。接下来,使用自注意力机制为不同维度的时空特征赋予不同的权重,再输入到分类器中对量测组合进行分类以实现真假航迹的辨别,从而完成航迹起始。

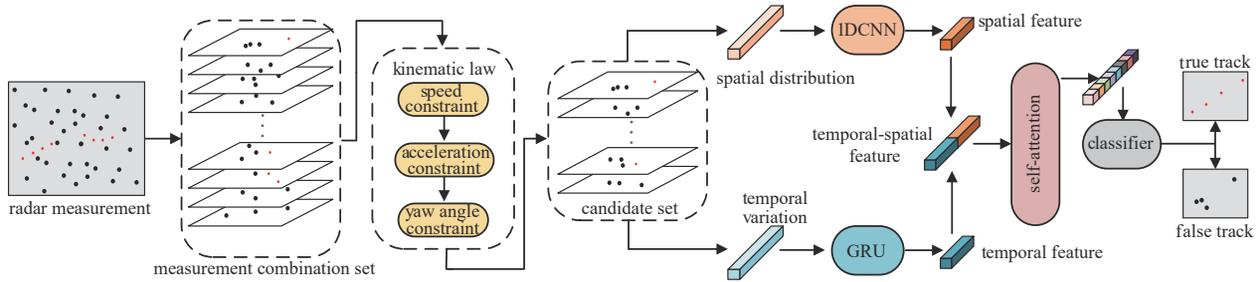


Fig.1 Overview of algorithm DLTS
图 1 DLTS 算法概览

2.1 候选集的选取

航迹起始是一种检测问题，无法直接将雷达量测数据作为基于深度学习的神经网络模型的输入用于起始航迹。因此，本文将航迹起始问题转化为针对量测组合的分类问题。由于在强杂波环境下量测组合的数量将非常庞大，如果直接将所有量测组合输入到神经网络模型，必然导致算法时间性能的大幅下降和存储空间的大量消耗。考虑到实时性对航迹起始算法的重要性，本文首先从量测组合集中选取部分量测组合组成候选集用于航迹起始。由于大量的量测组合是由杂波组成，不符合现实世界中的目标运动学规律，因此，本文设置了 4 条基于目标运动学规律的约束规则用于从量测组合中选取出候选集。

1) 考虑现实世界中飞行目标的速度存在着限制，本文设置了目标最大速度 v_{max} 和目标最小速度 v_{min} 用于从量测组合中选取候选集。假设任意量测组合中相邻扫描周期的 2 个量测 A 和 B 之间距离为 d ，雷达扫描周期为 T ，则飞行目标的速度应当满足：

$$v_{min} < |d/T| < v_{max} \tag{1}$$

2) 现实世界中目标移动时的加速度也同样存在限制，本文设置了目标最大加速度 a_{max} 和最小加速度 a_{min} 用于从量测组合中选取候选集。假设任意量测组合中相邻扫描周期的量测点迹 A 和 B 、 B 和 C 之间的距离分别为 d_1 和 d_2 ，则飞行目标的加速度应当满足：

$$a_{min} < |(d_1 - d_2)/T^2| < a_{max} \tag{2}$$

3) 偏航角是指相邻目标航向角的变化值，如图 2 所示。在现实世界中，目标航向的变化是受限制的，因此偏航角也存在限制。本文设置相邻目标偏航角的最小值和最大值分别为 θ_{min} 和 θ_{max} ，假设任意量测组合中相邻扫描周期的量测点迹 A 和 B 、 B 和 C 的向量分别为 r_{AB}, r_{BC} ，则飞行目标的航向角应当满足：

$$\theta_{min} < \left| \arccos \left(\frac{r_{AB} \cdot r_{BC}}{|r_{AB}| \cdot |r_{BC}|} \right) \right| < \theta_{max} \tag{3}$$

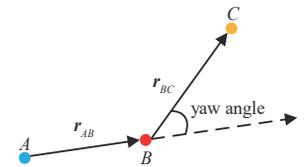


Fig.2 Definition of drift angle
图 2 偏航角含义

2.2 时空向量的提取

量测组合的基本时空信息无法直观地表达其航迹类型信息，神经网络难以建立从基本时空信息到航迹类型的有效映射。只有将这些基本时空信息转化成神经网络模型可以理解的数据信息，才能有效地对候选集中的量测组合进行分类从而实现有效的航迹起始。因此，在将候选集输入到神经网络模型前，有必要从候选集的量测组合中提取出模型能够接受的信息向量作为模型的输入数据用于航迹起始。

2.2.1 空间分布向量

虚假航迹由杂波组成，其在空间位置分布上呈现不规律性。因此，与符合飞行目标运动学规律的真实航迹相比，虚假航迹在空间分布上是不同的，通过捕捉量测组合的空间分布特征，有助于实现量测组合的分类。为了获得量测组合的空间维度特征，本文从候选集中的量测组合中提取了包含空间维度信息的时间分布向量用于空间维度特征的提取。

假设某一包含 n 个雷达量测的量测组合表示为 $[(x_1, y_1, t_1), (x_2, y_2, t_2), \dots, (x_n, y_n, t_n)]$ ，每个量测组合的空间分布向量由距离、偏航角、曲率 3 种信息共同组成。其中，距离指的是量测组合中相邻扫描周期的 2 个雷达量测的欧式距离。对于包含 n 个雷达量测的量测组合，可以得到 $n-1$ 个距离信息，计算公式如下，其中 $i=1, 2, \dots, n-1$ 。

$$d_i = \sqrt{(x_{i+1}^2 - x_i^2) + (y_{i+1}^2 - y_i^2)} \quad (4)$$

偏航角指的是量测组合中相邻的 2 个量测向量之间的夹角。对于包含 n 个雷达量测的量测组合，可以得到 $n-2$ 个偏航角信息。计算公式如下，其中 $i=1, 2, \dots, n-2$ 。

$$d\theta_i = \arccos \left(\frac{(x_{i+2} - x_{i+1})(x_{i+1} - x_i) + (y_{i+2} - y_{i+1})(y_{i+1} - y_i)}{\sqrt{(x_{i+2} - x_{i+1})^2 + (y_{i+2} - y_{i+1})^2} \cdot \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}} \right) \quad (5)$$

曲率指的是量测组合中连续的 3 个量测组成的曲线所对应的圆半径的倒数，能够反映这 3 个量测组成的曲线的平滑程度。对于包含 n 个雷达量测的量测组合，可以得到 $n-2$ 个曲率信息。计算公式如下，其中 $i=1, 2, \dots, n-2$ 。

$$cc = \sqrt{(a+b-c)(a-b+c)(b+c-a)(a+b+c)} / abc \quad (6)$$

式中： $a = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}$ ； $b = \sqrt{(x_{i+2} - x_{i+1})^2 + (y_{i+2} - y_{i+1})^2}$ ； $c = \sqrt{(x_{i+2} - x_i)^2 + (y_{i+2} - y_i)^2}$ 。

2.2.2 时序变化向量

除了考虑量测组合的空间分布信息对其分类的影响外，在时间维度上，量测组合是由时间上连续的量测组成的。真实航迹的时间维度特征应当是随着时间的推移而有序变化，而部分虚假航迹的量测组合则可能在时间维度上是无序的。为了使用神经网络模型提取出候选集中量测组合的时间维度特征，本文考虑从候选集的量测组合中提取出包含量测组合时间维度信息的时序变化向量以作为神经网络模型的输入。

假设某一包含 n 个雷达量测的量测组合表示为 $[(x_1, y_1, t_1), (x_2, y_2, t_2), \dots, (x_n, y_n, t_n)]$ 。本文提取了量测组合的速度、加速度、航向角 3 种信息共同组成时序变化向量。其中，真实航迹的速度随着时间推移应当平滑且有限度地变化。对于包含 n 个雷达量测的量测组合，可以得到 $n-1$ 个速度信息，计算公式如下，其中 $i=1, 2, \dots, n-1$ 。

$$v_i = \sqrt{(x_{i+1}^2 - x_i^2) + (y_{i+1}^2 - y_i^2)} / T \quad (7)$$

加速度随着速度的变化而不断变化。对于包含 n 个雷达量测的量测组合，可以得到 $n-2$ 个加速度信息，计算公式如下，其中 $(i=1, 2, \dots, n-2)$ 。

$$a_i = \left(\sqrt{(x_{i+2}^2 - x_{i+1}^2) + (y_{i+2}^2 - y_{i+1}^2)} - \sqrt{(x_{i+1}^2 - x_i^2) + (y_{i+1}^2 - y_i^2)} \right) / T^2 \quad (8)$$

航向角指的是目标飞行方向与正北方向的夹角，取值范围为 $(-180^\circ, 180^\circ]$ 。对于包含 n 个雷达量测的量测组合，可以得到 $n-1$ 个航向角信息，计算公式如下：

$$h\theta_i = \begin{cases} \arccos \left((y_{i+1} - y_i) / \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \right) \frac{180}{\pi}, & x_{i+1} > x_i \\ -\arccos \left((y_{i+1} - y_i) / \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \right) \frac{180}{\pi}, & x_{i+1} < x_i \end{cases} \quad (9)$$

2.3 神经网络模型的构建

本文构建了一个基于深度学习的神经网络模型用于从时序变化向量和空间分布向量中提取出量测组合的时空特征，并根据时空特征完成对量测组合的分类，从而实现航迹起始。该神经网络模型主要由两部分组成：特征提取器模型和分类器模型。

2.3.1 特征提取器模型

特征提取器模型由 3 个模块组成：1DCNN 模块，GRU 模块和特征合并模块，负责从时序变化向量和空间分布向量中提取出量测组合的时间和空间维度特征。

具体来说，考虑到空间分布向量蕴含着量测组合的空间维度信息，为了减少神经网络对其空间分布信息的破坏，本文选用 1DCNN 从空间分布向量中提取出空间分布特征。本文构建的 1DCNN 模块由 2 层卷积层和池化层组成，每个卷积层的输入均在经过 BN 层和非线性函数 ReLU 的激活后进入池化层。对于一个由连续 4 个扫描周期的量测组成的大小为 1×12 的量测组合，提取得到 1×8 的空间分布向量并作为 1DCNN 模块的输入，经过卷积和池化处理后，输出大小为 1×4 的空间维度特征。

同时，考虑到时序变化向量在时间维度的连续性，本文选用 GRU 来提取量测组合的时间维度特征。与其他 2 种常用于时序数据处理的神经网络模型：循环神经网络(Recurrent Neural Network, RNN)和长短期记忆网络(Long

Short-Term Memory, LSTM)相比, GRU 能够在改善 RNN 长时记忆缺失导致时序特征提取能力不足问题的同时, 较 LSTM 减少了中间参数, 在运算速度和性能上更有优势, 对提高算法实时性有着重要作用。

以大小为 1×7 的时序变化向量作为 GRU 模块的输入, 首先经过一层 GRU 网络, 再经过 Flatten 处理后输入到有 4 个神经元的全连接层进行降维, 输出与空间维度特征维度相同的大小为 1×4 的时间维度特征。

为了综合利用量测组合的时间空间维度信息用于量测组合的分类, 本文将大小均为 1×4 的时间维度特征和空间维度特征进行了合并, 得到大小为 1×8 的时空特征作为分类器的输入。

2.3.2 分类器模型

分类器模型以特征提取器模块得到的时空特征为输入, 对量测组合进行分类, 实现真假航迹的辨别。它由 2 个模块组成: 自注意力模块和全连接模块。

具体来说, 自注意力机制是一种特殊形式的注意力机制, 其本质思想是从众多信息中快速高效筛选出对目标任务最有价值的信息。考虑到时空特征中每个维度的属性特征对分类的影响不同, 本文针对时空特征使用自注意力机制自动为不同维度赋予不同的权重, 更有助于分类的信息能够发挥更大的作用, 从而提高分类准确率。时空特征经过自注意力机制处理后, 得到大小为 1×8 的自注意时空特征, 可认为是量测组合时空信息的高层次表示。

最后, 以自注意时空特征为输入, 构建了由 2 个全连接层组成的全连接模块, 全连接层的神经元个数分别设置为 4 和 1, 并在第 2 层使用 Sigmoid 激活函数实现量测组合的二分类。

3 实验

3.1 实验环境和数据集

为了检验 DLTS 算法的有效性, 以及在强杂波环境下的航迹起始效果, 本文进行了强杂波环境下航迹起始的仿真实验。

在仿真实验中, 本文参考文献[5]实验参数, 设置了大小为 $100 \text{ km} \times 100 \text{ km}$ 的雷达量测区域, 假设有 5 个空中目标做匀速直线运动, 初始位置和运动方向随机, 速度的范围为 $300 \sim 500 \text{ m/s}$ 。同时, 设置雷达测距和测角误差分别为 40 m 和 0.2° , 雷达的扫描周期为 5 s , 共进行 4 次扫描。此外, 本文根据文献[14]所示算法, 按照泊松分布确定每个雷达扫描周期的杂波个数。具体来说, 当给出杂波密度参数 λ , 则在 $(0,1)$ 区间产生均匀分布的随机数 γ , 根据公式(10)从而得到服从均值为 λ 的泊松分布的杂波个数 J 。其中, 每个周期的 J 个杂波随机分布在雷达量测区域内。

$$e^{-\lambda} \sum_{j=0}^{J-1} \frac{\lambda^j}{j!} < r < e^{-\lambda} \sum_{j=0}^J \frac{\lambda^j}{j!} \quad J=1, 2, \dots \quad (10)$$

在训练神经网络模型时, 本文从仿真生成的杂波数据中选取 10 000 条符合候选集条件的虚假航迹量测组合, 加上 10 000 条真实航迹量测组合, 并将所有数据混合打乱, 作为模型的训练集。模型测试阶段, 在相同仿真环境下对每组实验进行 50 次蒙特卡罗仿真得到实验结果。其中, 在训练阶段, 每个量测组合都有对应的标签值, 而测试阶段的量测组合没有。

3.2 实验设置

3.2.1 评价标准

本实验采用航迹起始任务常用的 3 个评价指标来评估 DLTS 算法的航迹起始性能^[5], 分别为: 真实航迹起始率、虚假航迹起始率、平均起始时间。

真实航迹起始率表示起始的航迹中真实航迹的比例, 如式(11)所示。

$$P_c = \sum_{i=1}^N \sum_{j=1}^M I_{ij} / (M \cdot N) \quad (11)$$

式中: N 为蒙特卡罗仿真实验次数; M 为真实航迹数; I_{ij} 表示第 i 次仿真实验中第 j 个真实航迹是否被成功起始, $I_{ij} = 1$ 表示第 j 个真实航迹被成功起始; $I_{ij} = 0$ 表示第 j 个航迹未被成功起始。

虚假航迹起始率表示起始的航迹中虚假航迹的比例, 如式(12)所示。

$$P_f = \sum_{i=1}^N f_i / \sum_{i=1}^N n_i \quad (12)$$

式中： f_i 和 n_i 分别表示第 i 次仿真实验中起始的虚假航迹个数和起始的航迹总数。

平均起始时间表示 N 次蒙特卡罗仿真实验的平均执行时间，如式(13)所示。

$$T_{\text{step}} = \sum_{i=1}^N t_i / N \quad (13)$$

式中 t_i 表示第 i 次仿真实验的执行时间。

3.2.2 网络参数选择

实验构建混合模型来实现船舶类型的识别。实验中，每次模型训练的批次大小为 128，选择 Adam 作为优化器，损失函数使用分类交叉熵，采用早停止准则设定训练次数，当准确率没有提升时停止训练，并设置首次出现最终准确率的训练次数为最大训练次数。对于 1DCNN 模块，设置第一个卷积层的滤波器个数为 8，卷积核大小为 3；设置第二个卷积层的滤波器个数为 4，卷积核大小为 2。对于 GRU 模块，设置输出单元个数为 4。

3.3 实验结果与分析

3.3.1 不同杂波密度参数对航迹起始效果的影响

为验证 DLTS 算法性能，特别是强杂波环境下的起始能力，本小节研究不同杂波密度参数 λ 对性能的影响。表 1 显示了当杂波密度参数 λ 分别为 50,100,150,200 和 250 时，DLTS 算法的 3 种评价指标表现。可以看出，真实航迹起始率随着 λ 的不断增大而呈现下降的趋势，但是下降的幅度较小，特别是当 λ 较大时，由于神经网络模型具有较强的抗干扰能力，DLTS 算法的真实航迹起始率仍保持在较高的水准；虚假航迹起始率随着 λ 的不断增大而出现一定的提高，在 λ 较大时，这一现象比较明显，此时由于量测组合的数量庞大，使得存在一些虚假航迹的量测组合在特征分布上与真实航迹较为接近，模型出现误判的现象；随着 λ 的不断增大，量测组合的数量呈指数级增加，DLTS 算法依靠候选集的选取，大幅降低了需要处理的量测组合数量，且神经网络模型分类速度较快，使得 DLTS 算法的平均起始时间呈线性增加，在强杂波环境下仍保持较高的起始效率。

表 1 不同杂波密度参数 λ 下航迹起始性能

Table 1 Track initiation performance with different values of clutter density parameter λ

parameter	$\lambda=50$	$\lambda=100$	$\lambda=150$	$\lambda=200$	$\lambda=250$
true track initiation rate	0.991	0.984	0.978	0.971	0.962
false track initiation rate	0.014	0.046	0.087	0.138	0.203
average initiation time/s	1.048	1.325	2.436	3.972	4.877

3.3.2 不同航迹起始算法的对比实验

将 DLTS 算法与目前航迹起始领域常用的直观法、逻辑法、Hough 变换法和基于 CNN 的航迹起始算法^[12]在同一仿真环境下进行对比，以验证 DLTS 算法的性能。

图 3 显示了不同航迹起始算法在不同杂波密度参数 λ 下的真实航迹起始率对比。可以看出，在弱杂波环境下，5 种算法的真实航迹起始率都较高。随着杂波密度的不断增大，5 种算法的真实航迹起始率均呈现出不同程度的下降。其中，直观法的下降幅度较大，Hough 变换法和逻辑法的下降幅度较小，均能较好地识别出真实航迹。而 DLTS 算法在杂波密度参数 λ 低于 200 的情况下与 CNN 算法表现类似，当 λ 高于 200 后，DLTS 算法较 CNN 算法有明显的优势。这是由于 DLTS 算法从空间和时间两个维度对量测组合进行识别，对量测组合的特征提取能力较 CNN 更强，具有更好的抗干扰能力。

图 4 显示了不同航迹起始算法在不同杂波密度参数 λ 下的虚假航迹起始率对比。可以看出，随着杂波密度的不断增大，5 种算法的虚假航迹起始率均呈现上升的趋势。其中，逻辑法和直观法算法简单，抗干扰能力较弱，在强杂波环境下的虚假航迹起始率远高于弱杂波环境。Hough 算法由于具有天然的鲁棒性从而在强杂波环境下表现出了较强的抗干扰能力。DLTS 算法得益于对时间和空间维度特征的综合考虑与神经网络模型所带来的出色的辨别能力，在强杂波环境下具有远强于其他 4 种算法的抗干扰能力，能够准确地辨别出虚假航迹，使得虚假航迹起始率显著低于其他 4 种算法。

图 5 显示了不同航迹起始算法在不同杂波密度参数 λ 下的平均起始时间对比。可以看出，5 种算法的平均起

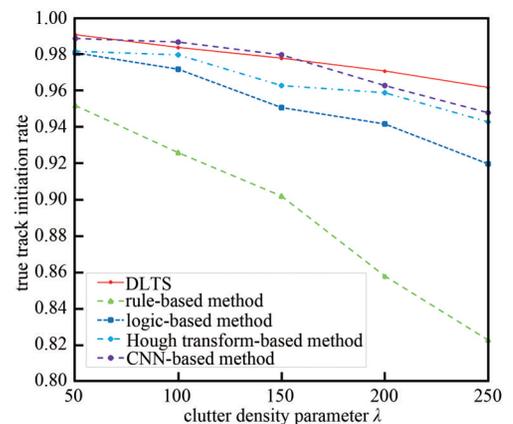


Fig.3 True track initiation rate of different algorithms

图 3 不同算法的真实航迹起始率

始时间均随 λ 的不断增大而增大。在低杂波环境下，5种算法的平均起始时间相差较小。在强杂波环境下，Hough变化法的计算量显著增大导致其平均起始时间呈指数级增加，而其他4种算法的平均起始时间较低杂波环境下小幅上涨。由于结构更复杂和参数更多，DLTS算法的耗时略长于直观法、逻辑法和基于CNN的算法，但是实时性较Hough变化法有着显著的优势。

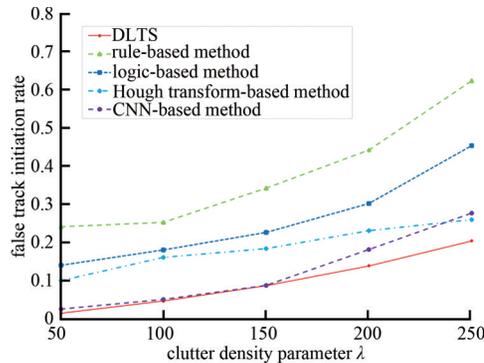


Fig.4 False track initiation rate of different algorithms
图4 不同算法的虚假航迹起始率

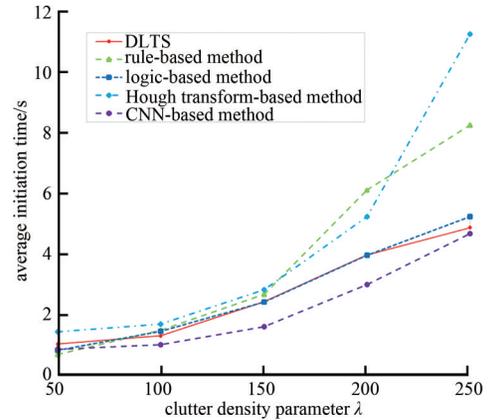


Fig.5 Average track initiation time of different algorithms
图5 不同算法的平均起始时间

总体来说，在低杂波环境下5者差异不明显。在强杂波环境下，直观法和逻辑法虽然平均起始时间较短，但在真假航迹起始率上均表现较差；Hough变化法在起始航迹时耗时较多；基于CNN的算法由于结构更简单，参数更少，因此实时性略强于DLTS算法，但其特征提取能力影响了在强杂波环境下的航迹起始表现。DLTS算法在耗时与逻辑法相近的情况下，实现了比Hough变化法更准确的航迹起始性能。验证了本文通过提取候选集并使用神经网络模型进行量测组合分类能有效地减少计算负担，在强杂波环境下实现快速起始，同时，时间和空间维度特征的提取保证了强杂波环境下真假航迹辨别能力的准确性，使DLTS算法在强杂波环境下能在较短时间内准确地实现航迹起始。

3.3.3 不同航迹起始算法的离线训练时间对比

基于CNN的航迹起始算法和DLTS算法相对于其他对比算法，在强杂波环境下的表现更好，且二者均为基于深度学习的监督式方法，本文对比了二者的深度学习模型在不同杂波密度参数下所需的离线训练时间。特别地，本文使用早停策略以获得训练结束的时间，每遍历完一次训练集就进行一个测试，若连续7次针对测试集的识别准确率没有提高，则结束训练。

从图6看出，在 $\lambda=50$ 时，DLTS算法的离线训练时间长于基于CNN的算法。随着杂波密度的增加，尤其是 $\lambda=250$ 时，DLTS算法的离线训练时间已经远低于基于CNN的算法，这是因为DLTS算法的深度学习模型的学习能力更强，更容易学习到量测组合到航迹类型的映射关系，从而更快地达到收敛。

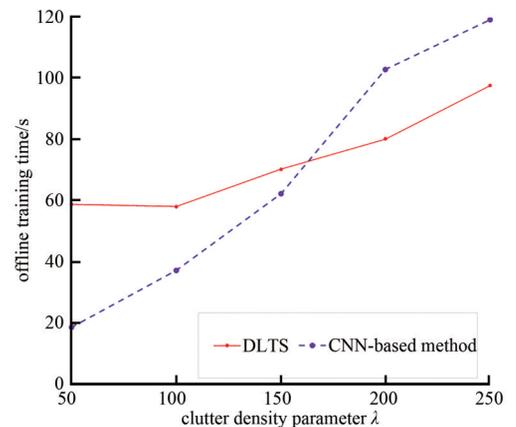


Fig.6 Offline training time of different algorithms
图6 不同算法的离线训练时间

4 结论

本文针对航迹起始问题，提出了基于深度学习和雷达量测时空特征的航迹起始算法。该算法首先从量测组合集中选取出符合运动学概率的量测组合作为候选集，以减少不必要的时间损耗；然后分别从候选集的量测组合中提取出空间分布向量与时序变化向量，并将其输入到基于深度学习的1DCNN+GRU自注意力混合模型中提取出量测组合的空间和时间维度特征；再通过自注意力机制为这2种特征赋予不同的注意力权重得到时空联合特征；最后使用分类器对时空联合特征进行分类，实现对真假航迹的辨别，完成航迹的起始。仿真实验和结果表明，本文提出的航迹起始算法能够在强杂波环境下较短时间内准确地起始航迹。

综上所述，本文所提算法在强杂波环境下能够在较短时间内有效起始目标航迹，并抑制虚假航迹，具有良好的工程应用前景。但在算法的时间性能上仍有改进的空间。在今后基于深度学习的航迹起始研究中，应当考虑在保证特征提取能力的前提下尽可能地降低神经网络模型的结构复杂度，提高算法的时间性能。

参考文献:

- [1] 赵德功,夏永红,匡华星,等. 逻辑法航迹起始算法性能研究[J]. 雷达与对抗, 2016,36(1):18–23. (ZHAO Degong, XIA Yonghong, KUANG Huaxing, et al. Performance analysis of track initiation algorithm with logic method[J]. Radar & ECM, 2016, 36(1):18–23.)
- [2] HU Z, LEUNG H, BLANCHETTE M. Statistical performance analysis of track initiation techniques[J]. IEEE Transactions on Signal Processing, 1997,45(2):445–456.
- [3] MAYOR M A, CARROLL R L. A multi-target track initiation algorithm[C]// American Control Conference. Minneapolis, MN, USA:IEEE, 1987:1128–1130.
- [4] TRUNK G V, WILSON J D. Track initiation of occasionally unresolved radar targets[J]. IEEE Transactions on Aerospace & Electronic Systems, 1981,17(1):122–130.
- [5] 赵崇丞,王君,邵雷. 基于网格聚类的弹道目标航迹起始算法[J]. 火力与指挥控制, 2018,43(7):37–41,46. (ZHAO Chongcheng, WANG Jun, SHAO Lei. Track initiation algorithm of ballistic target based on grid clustering[J]. Fire Control & Command Control, 2018,43(7):37–41,46.)
- [6] 张星,杜嘉薇,陈汗龙,等. 一种基于斜距离信息的探测系统航迹起始算法[J]. 电子科技, 2017,30(8):36–39. (ZHANG Xing, DU Jiawei, CHEN Hanlong, et al. A track initiation algorithm for detection system based on oblique distance information[J]. Electronic Science and Technology, 2017,30(8):36–39.)
- [7] 靳标,李聪,张贞凯. 回波幅度信息辅助的群目标航迹起始方法[J]. 雷达学报, 2020,9(4):723–729. (JIN Biao, LI Cong, ZHANG Zhenkai. Group target track initiation method aided by echo amplitude information[J]. Journal of Radars, 2020,9(4):723–729.)
- [8] SMITH M C. Feature space transform for multitarget detection[C]// 1980 19th IEEE Conference on Decision and Control including the Symposium on Adaptive Processes. Albuquerque, NM, USA:IEEE, 1981:835–836.
- [9] 李家强,赵荣华,陈金立,等. 基于蚁群相似度加权霍夫变换的航迹起始[J]. 传感技术学报, 2016,29(4):552–558. (LI Jiaqiang, ZHAO Ronghua, CHEN Jinli, et al. Weighted Hough transform algorithm based on ant colony similarity for track initiation[J]. Journal of Transduction Technology, 2016,29(4):552–558.)
- [10] 刘红亮,但晓东,周生华,等. 一种基于跟踪信息的多基雷达系统航迹起始算法[J]. 电子与信息学报, 2015,37(10):2536–2540. (LIU Hongliang, DAN Xiaodong, ZHOU Shenghua, et al. A track initiation algorithm for multisite radar systems based on tracking information[J]. Journal of Electronics & Information Technology, 2015,37(10):2536–2540.)
- [11] 史建涛,孙俊,杨予昊,等. 基于机器学习支持向量机的海面目标航迹起始算法研究及应用[J]. 现代雷达, 2019,41(11):20–24, 29. (SHI Jiantao, SUN Jun, YANG Yuhao, et al. A study and application of track initiation of sea surface targets based on machine learning support vector machine[J]. Modern Radar, 2019,41(11):20–24,29.)
- [12] YUN Z, YANG S, LI H, et al. A novel multi-target track initiation method based on convolution neural network[C]// 2017 International Workshop on Remote Sensing with Intelligent Processing(RSIP). Shanghai, China:IEEE, 2017:1–5.
- [13] 熊风,王干,白杨,等. 基于卷积神经网络的雷达航迹起始方法[J]. 电子测量技术, 2020,43(10):78–83. (XIONG Feng, WANG Gan, BAI Yang, et al. Radar track initiation method based on the convolutional neural network[J]. Electronic Measurement Technology, 2020,43(10):78–83.)
- [14] 蔡庆宇. 相控阵雷达数据处理及其仿真技术[M]. 北京:国防工业出版社, 1997. (CAI Qingyu. Phased array radar data processing and its simulation techniques[M]. Beijing:National Defense Industry Press, 1997.)

作者简介:

沈光铭(1996-), 男, 硕士, 主要研究方向为人工智能、雷达信息处理.email:981185881@qq.com.

许雄(1985-), 男, 博士, 副研究员, 主要研究方向为雷达信号处理.

樊玉琦(1976-), 男, 博士, 副教授, 主要研究方向为人工智能、云计算、区块链等.