

一种深度学习航迹关联方法

崔亚奇,何友,唐田田,熊伟
(海军航空大学信息融合研究所,山东烟台264001)

摘要: 根据机器学习当中的理论方法,通过输入和输出数据设计,把信息融合领域的航迹关联问题,转换为机器学习领域中的分类识别问题,研究提出了一种深度学习航迹关联方法. 仿真结果表明:所提方法在关联性能和自适应能力方面优于对比方法,具有较好的应用前景.

关键词: 航迹关联;深度学习;机器学习;卷积神经网络;多层神经网络

中图分类号: TP953;TN957 **文献标识码:** A **文章编号:** 0372-2112(2022)03-0759-05

电子学报 URL:http://www.ejournal.org.cn

DOI:10.12263/DZXB.20200299

A Deep Learning Track Correlation Method

CUI Ya-qi, HE You, TANG Tian-tian, XIONG Wei

(Institute of Information Fusion, Naval Aeronautical University, Yantai, Shandong 264001, China)

Abstract: According to the theories and methods in machine learning, we converted the track correlation problem in the field of information fusion to a classification recognition problem in the field of machine learning by designing the input data and output data. In advance, a deep learning track correlation method was proposed in this paper. The experiments illustrate that the new method is better than the compared methods in the aspect of correlation performance and adaptation abilities. Thus, the new method would have a good applied foreground.

Key words: track correlation; deep learning; machine learning; convolutional neural network; multilayer neural network

1 前言

在多源航迹关联方面,国内外学者已开展多年研究,取得了系列成果. 根据所解决问题的不同,现有关联方法^[1-4]可简单划分为经典关联、抗差关联以及编队关联等不同算法系列. 但现有多源航迹关联算法仅能解决特定场景中的关联问题,换一种场景即难以适用,缺乏对各种不同场景关联问题系统性考虑. 据此,本文借鉴机器学习^[5,6]当中的思想方法,把多源信息融合领域中的航迹关联问题转换映射为机器学习领域中的分类识别问题,研究提出具有样本学习能力,能适应场景变化的深度学习关联方法,以有效解决多场景关联问题. 最后通过仿真实验,对算法的可行性和有效性进行验证. 需要说明的是由于多源航迹关联问题可以分解为多个两信源航迹关联问题来分别进行处理,因此本文主要以两信源航迹关联问题为例,对深度学习航迹关联方法进行研究.

2 关联问题建模

本节首先对多源航迹关联问题进行描述,然后构建关联场景输入数据、关联特征输入数据、关联判决输出数据和损失函数,从而最终把航迹关联问题转换为分类识别问题.

2.1 问题描述

假定信源1上报的航迹集为 $\Theta_1 = \{U_{1,1}, U_{1,2}, \dots, U_{1,n}\}$,共 n 条航迹段,信源2上报的航迹集为 $\Theta_2 = \{U_{2,1}, U_{2,2}, \dots, U_{2,m}\}$,共 m 条航迹段. 每个航迹段 $U_{s,i}$ 由 u 个航迹点构成, $U_{s,i} = \{\mathbf{x}_{s,i}^1, \mathbf{x}_{s,i}^2, \dots, \mathbf{x}_{s,i}^u\}$,每个航迹点 $\mathbf{x}_{s,i}^t$ 由 X 方向位置、 Y 方向位置、航速、航向等信息分量构成, $\mathbf{x}_{s,i}^t = [x_{s,i}^t \ y_{s,i}^t \ v_{s,i}^t \ c_{s,i}^t]$,其中 U 的下标分别表示信源号和航迹批号,信源号 s 为1或2, x 的下标表示与 U 相同,上标表示航迹点时间. 需要说明的是,虽然实际中不同信源间由于更新周期不同,航迹点时间、相同时段内航迹点数量是不同的,但可以通过插值拟合,实现不同信

源航迹间的时间对齐.

假定信源 1 与信源 2 航迹批号对应关系为

$$j = o(i) \quad (1)$$

其中, $o(\cdot)$ 表示同一目标两信源航迹批号映射函数, 输入为信源 1 的航迹批号, 输出为信源 2 的对应关联批号, 如果信源 1 在信源 2 中没有关联航迹, 则输出为 0.

多源航迹关联问题实质上就是基于各信源上报航迹 Θ , 求解最优 $\delta(\cdot)$, 进而获得航迹批号对应关系, 即航迹关联关系.

2.2 问题表征

下面从关联场景输入数据、关联特征输入数据、关联判决输出数据和损失函数等四个方面, 对关联问题进行重新表征, 从而把关联问题建模为分类识别问题, 具体建模方法如下:

(1) 基于 t 时刻两信源航迹信息, 计算构建关联场景输入数据. 该数据具有图像数据结构, 具体计算方法为:

(a) 根据空间位置大小, 分别对两信源 t 时刻航迹点位置进行内部排序, 得到每个航迹在信源内部的序号 l ;

$$l = I_s(i) \quad (2)$$

$$i = I_s^{-1}(l) \quad (3)$$

其中, $I_s(\cdot)$ 为信源 s 的排序函数, 输入为航迹批号, 输出为航迹序号, $I_s^{-1}(\cdot)$ 为 $I_s(\cdot)$ 的逆函数, $I_s(i)$ 取值范围为从 1 到信源航迹数 n 或 m , 并满足如下约束: 如果 $x'_{s,i} > x'_{s,j}$, 则 $I(i) > I(j)$; 如果 $x'_{s,i} = x'_{s,j}$ 且 $y'_{s,i} > y'_{s,j}$, 则 $I(i) > I(j)$.

(b) 在同一信源内部或不同信源之间, 按照航迹序号顺序, 依次计算任意两个航迹间 t 时刻距离 $C_{e,t,l,k}$, 并把其作为第 l 行、第 k 列元素, 构建关联场景输入数据 $C_{e,t}$;

$$C_{e,t,l,k} = \sqrt{\left| x'_{s_1, I^{-1}(l)} - x'_{s_2, I^{-1}(k)} \right|^2 + \left| y'_{s_1, I^{-1}(l)} - y'_{s_2, I^{-1}(k)} \right|^2} \quad (4)$$

其中, $C_{e,t,l,k}$ 下标分别表示不同的两信源组合 e 、不同的时刻 t 以及航迹序号 l, k ; $e=1$ 时, 表示两信源 1 航迹间的距离, 此时式中 $s_1=1$ 和 $s_2=1$, $e=2$ 时, 表示两信源 2 航迹间的距离, 此时式中 $s_1=2$ 和 $s_2=2$, $e=3$ 时, 表示信源 1 与信源 2 两个航迹间的距离, 此时式中 $s_1=1$ 和 $s_2=2$; $C_{e,t}$ 是二维矩阵, 航迹序号 l, k 同时也表示元素 $C_{e,t,l,k}$ 在矩阵 $C_{e,t}$ 中的位置, 由于信源 1 上报 n 条航迹, 信源 2 上报 m 条航迹, 可知 $r_{1,t}$ 的张量大小为 $n \times n$, $r_{2,t}$ 的大小为 $m \times m$, $r_{3,t}$ 的大小为 $n \times m$.

(c) 设定目标场景分布范围, 对关联场景输入数据 $C_{e,t}$ 进行归一化处理, 得到标准关联场景输入数据 $\tilde{C}_{e,t}$;

$$\tilde{C}_{e,t} = \frac{C_{e,t}}{L_C} \quad (5)$$

其中, L_C 为目标场景分布范围的直径, 为标量, 与 $r_{e,t}$ 相除, 表示对矩阵内的每一个元素进行相除操作.

(2) 对于待关联的信源 1 航迹 i 和信源 2 航迹 j , 分别计算两个航迹段在位置、航速和航向上的统计距离, 作为关联特征输入数据 $D_{i,j}$. 具体计算方法为:

$$D_{i,j} = [d_r(i,j) \quad d_v(i,j) \quad d_c(i,j)]^T \quad (6)$$

$$d_r(i,j) = \frac{\sqrt{\frac{1}{u} \sum_{i=t-u+1}^t \left(|x'_{1,i} - x'_{2,j}|^2 + |y'_{1,i} - y'_{2,j}|^2 \right)}}{2(\sigma_{1,r}^2 + \sigma_{2,r}^2)} \quad (7)$$

$$d_v(i,j) = \frac{\sqrt{\frac{1}{u} \sum_{i=t-u+1}^t |v'_{1,i} - v'_{2,j}|^2}}{2(\sigma_{1,v}^2 + \sigma_{2,v}^2)} \quad (8)$$

$$d_c(i,j) = \frac{\sqrt{\frac{1}{u} \sum_{i=t-u+1}^t |c'_{1,i} - c'_{2,j}|^2}}{2(\sigma_{1,c}^2 + \sigma_{2,c}^2)} \quad (9)$$

其中, $\sigma_{1,r}^2, \sigma_{1,v}^2, \sigma_{1,c}^2, \sigma_{2,r}^2, \sigma_{2,v}^2, \sigma_{2,c}^2$ 分别为信源 1 和信源 2 航迹滤波给出或统计得到的位置、航速、航向估计协方差.

(3) 然后采用 0-1 编码方式, 对信源 1 航迹 i 和信源 2 航迹 j 间的关联关系进行编码, 得到关联判决输出数据 $y_{l,i,j}$;

$$\begin{cases} y_{l,i,j} = 1, & j = o(i) \\ y_{l,i,j} = 0, & j \neq o(i) \end{cases} \quad (10)$$

(4) t 时刻, 信源 1 与信源 2 航迹间的关联问题可分解为多个不同航迹对间的关联问题, 而每个航迹对间的关联判决问题, 可转为一个简单的二分类问题, 因此可采用交叉熵损失函数 L , 如下式所示.

$$L = - \sum_{i=1}^n \sum_{j=1}^m y_{l,i,j} \log(\tilde{y}_{l,i,j}) \quad (11)$$

其中, $y_{l,i,j}$ 为 t 时刻网络的期望输出结果, $\tilde{y}_{l,i,j}$ 为网络实际输出结果.

3 深度学习航迹关联算法

基于航迹关联问题表征所得到的关联场景输入数据 $\tilde{C}_{e,t}$ 、关联特征输入数据 $D_{l,i,j}$ 、关联判决输出数据 $y_{l,i,j}$ 和损失函数 L , 采用深度学习技术, 设计深度学习航迹关联算法步骤如下:

步骤 1: 首先设定最大航迹数量为 N , 然后对 t 时刻三个关联场景输入数据 $\tilde{C}_{e,t}$ 进行零值周边填充预处理, 使它们大小相同, 均为 $N \times N$, 最后把他们合并在一起, 变为 $N \times N \times 3$ 张量 \tilde{C}_t ;

步骤 2: 采用深度卷积神经网络对 \tilde{C}_t 进行嵌入表示处理, 得到关联场景的向量表示 V_C ;

步骤 3: 采用多层神经网络对关联特征输入数据

$D_{i,j}$ 进行升维处理,得到关联特征的高维表示 V_D ;

步骤4:把关联场景向量表示 V_C 和关联特征高维表示 V_D 合并在一起,采用多层神经网络进行处理,得到网络输出为 $\hat{y}_{i,j}$,其中最后一层神经网络的激励函数为 Sigmoid 函数;

步骤5:采用典型数据集,根据交叉熵损失函数 L ,按照步骤1~步骤4,对神经网络进行训练,得到神经网络的权重.

其中,对于步骤2~步骤4,网络典型结构如图1所示,包括场景嵌入网络、特征升维网络和关联判决网络三大部分.后续根据关联问题复杂度和神经网络训练效果,可进一步对该网络结构进行调整.

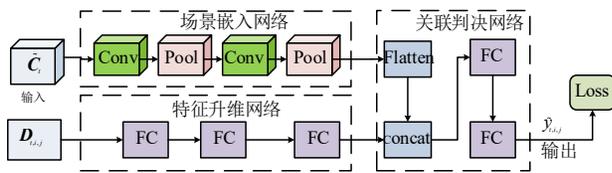


图1 深度学习航迹关联神经网络

在求得信源1和信源2之间任意两个航迹间关联判决 $\hat{y}_{i,j}$ 后,将其作为第 i 行、第 j 列元素,可组合得到关联矩阵 \hat{y}_r .进一步采用最大关联系数和阈值判别原则进行关联判断,即可得到最终的关联结果,其中判别阈值为0.5.

4 实验验证

本节基于仿真实验,并通过与传统经典航迹关联方法进行性能比较,来对深度学习航迹关联方法的可行性和有效性进行验证.其中传统经典航迹关联方法,后简称为传统方法,其关联系数采用航迹间统计距离进行计算,关联关系分配采用最大关联系数和阈值判别原则进行判断.

4.1 仿真设置

假设场景内目标数量在16~32之间均匀分布,目标做零均值高斯白噪声加速运动, X 方向和 Y 方向加速度标准差均为 2 m/s^2 ,目标初始位置、初始航速和初始航向均服从均匀分布,分布区间分别为 $-5\text{ km}\sim 5\text{ km}$ 、 $50\text{ m/s}\sim 100\text{ m/s}$ 和 $0^\circ\sim 360^\circ$.信源1和信源2对目标的发现概率均为0.9,量测周期均为4s,得到的航迹段包含5个航迹点,在 X 方向位置、 Y 方向位置量测上存在零均值高斯白噪声,其标准方差分别为 $[50\text{ m}, 50\text{ m}]$ 和 $[70\text{ m}, 70\text{ m}]$.信源2还存在系统误差,大小服从均匀分布,分布范围为 $0\text{ m}\sim 200\text{ m}$.

在本仿真所使用的深度学习航迹关联神经网络中, \tilde{C}_t 大小为 $32\times 32\times 3$, $D_{i,j}$ 大小为 1×3 .场景嵌入网

络设置为:第一个卷积模块的通道数设置为3,卷积核大小为 $3\times 3\times 3$,最后卷积模块的通道数设置为1,卷积核大小为 $4\times 4\times 3$,它们的激励函数均采用 ReLu 线性整流函数,池化模块均采用最大池化方法,池大小为 2×2 .特征升维网络中的三个全连接层神经元个数分别为8、16和36,它们的激励函数均采用 ReLu 线性整流函数.关联判决网络中全连接层神经元个数分别为8和1,第一个激励函数为 ReLu 线性整流函数,第二个为 Sigmoid 函数.网络训练设置具体为:网络权重寻优采用 Adam 方法,训练周期为50,每个训练周期生成1000个场景数据,每个场景数据内,信源1与信源2任意一个航迹关联对为一条训练样本,所有的关联对为一批训练样本.

4.2 仿真结果

单个仿真场景内,信源1与信源2典型目标航迹分布如图2所示,50次训练周期,深度学习航迹关联神经网络训练验证结果如图3所示,基于训练好的深度学习航迹关联神经网络,对新生成的信源1与信源2航迹关联结果如图4所示.

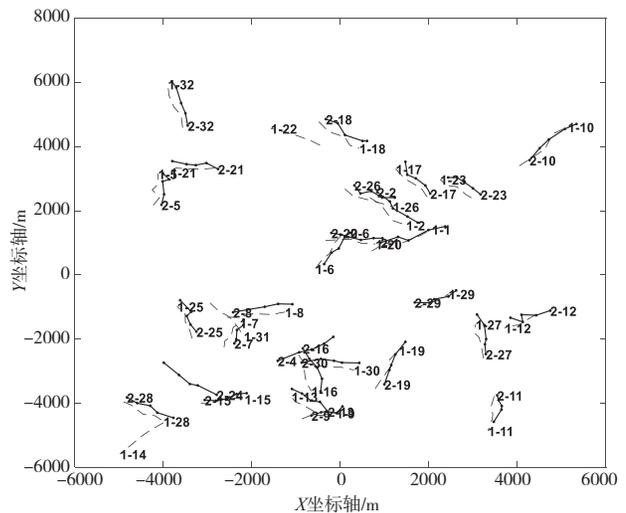


图2 典型场景信源1与信源2目标航迹分布

由图2可知,仿真场景中目标分布随机,不同信源间目标航迹在位置、航速、航向等方面具有明显差异.多次仿真,场景变化较大,表明仿真中包含的关联场景模式多.其中图中标注1-a,表示信源1航迹批号a,2-b表示信源2航迹批号b,为便于清晰显示,信源1航迹批号标注在航迹的最新航迹点处,信源2标注在最老航迹点处.

由图3可知,深度学习航迹关联神经网络在训练过程中分类准确率不断升高,模型损失不断地减小,表示深度学习航迹关联神经网络能稳定收敛.

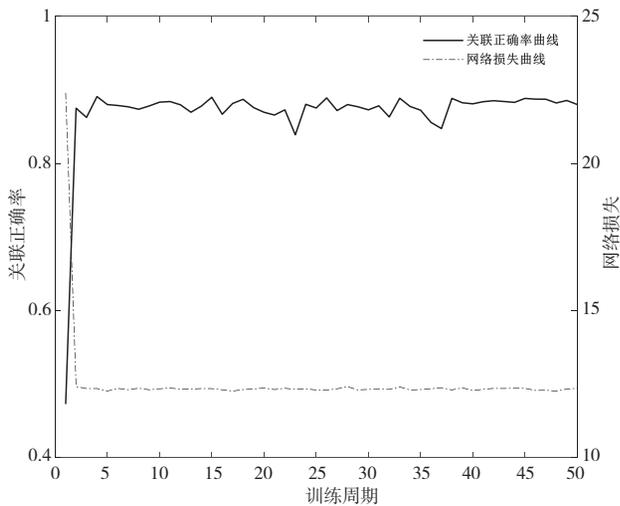


图3 网络训练损失和关联准确率变化曲线

由图4具体关联效果可知,对于新生成的信源1与信源2航迹,训练好的深度学习航迹关联神经网络给出的关联判决准确率较高,达到87.5%左右,表明深度学习航迹关联神经网络具有良好的泛化能力,实际可用性高。其中图中标注1-a-b,表示信源1航迹批号a,与信源2航迹批号b关联,其他与图2相同。

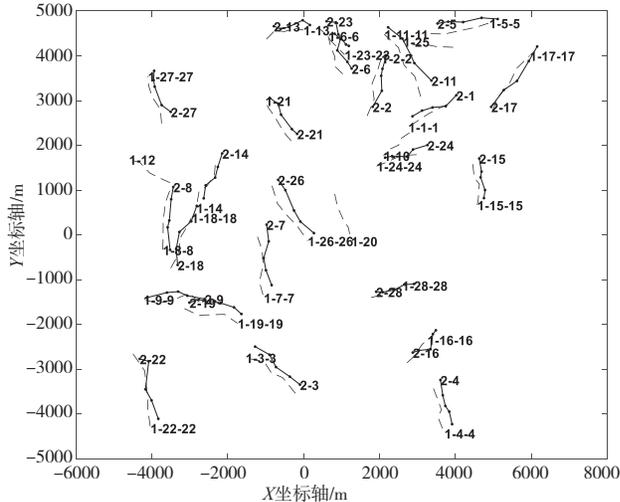


图4 已训练网络关联判决结果

进一步采用蒙特卡洛仿真方法,仿真次数10000次,并对比传统关联方法,包括统计双门限法^[1]、抗差关联方法^[3]和编队关联方法^[4],对深度学习关联方法的关联性能进行统计比较。结果如表1所示。由于仿真场景中目标数量、目标运动和信源量测具有较强的随机性,致使整个蒙特卡洛仿真中包含的场景模式较多,而传统关联方法仅能适应单一场景,譬如统计双门限法仅能适用无系统误差场景关联问题,抗差关联方法可适

应系统误差场景,但在非系统误差场景下关联效果并不理想,因此传统算法的整体统计表现差于深度学习关联方法。

表1 蒙特卡洛仿真关联性能比较(单位%)

关联指标	门限法	抗差法	编队法	深度学习
正确关联率	65.92	56.82	43.79	87.47
错误关联率	29.22	38.01	49.21	8.76

5 结论

本文借鉴机器学习的理论和方法,通过把目标跟踪和信息融合领域的航迹关联问题,诠释并转换为机器学习领域中的分类识别问题,然后采用深度卷积神经网络,研究提出了深度学习航迹关联方法,仿真结果表明:该算法对于混合场景具有较强适应性,优于传统方法。后续,将收集实测雷达数据,标注构建航迹关联实测数据集,以进一步加强算法实用效能验证。

参考文献

- [1] 陈世友,肖厚,刘颖. 航迹关联不确定度的表示[J]. 电子学报, 2011, 39(7):1589-1593.
CHEN S Y, XIAO H, LIU H. Expression of track correlation uncertainty[J]. Acta Electronica Sinica, 2011, 39(7): 1589-1593. (in Chinese)
- [2] 李洋,张靖. 基于自适应滑动窗均值OSPA航迹关联算法[J]. 电子学报, 2016, 44(2): 353-357.
LI Y, ZHANG J. Track fusion based on the mean OSPA distance with an adaptive sliding window[J]. Acta Electronica Sinica, 2016, 44(2):353-357. (in Chinese)
- [3] 李保珠,董云龙,丁昊,等. 基于高斯混合模型的航迹抗差关联算法[J]. 航空学报, 2019, 40(6): 221-229.
LI B Z, DONG Y L, DING H. Anti-bias track association algorithm based on Gaussian mixture model[J]. Acta Aeronautica ET Astronautica Sinica, 2019, 40(6): 221-229. (in Chinese)
- [4] 王刚,汪秋莹. 利用JPDA进行编队目标的多雷达航迹关联应用研究[J]. 现代雷达, 2019, 41(4):39-42.
WANG G, WANG Q Y. Multi-radar track association of formation targets based on JPDA[J]. Modern Radar, 2019, 41(4):39-42. (in Chinese)
- [5] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. 2015, 521(7553):436.
- [6] 秦鑫,黄洁,查雄,等. 基于扩张残差网络的雷达辐射源信号识别[J]. 电子学报, 2020, 48(3): 456-462.

QIN Xin, HUANG Jie, ZHA Xiong, et al. Radar emitter signal recognition based on dilated residual network[J]. Acta Electronica Sinica, 2020, 48(3): 456-462. (in Chinese)

作者简介



崔亚奇 男,1987年生,河南人,博士,副教授,主持国家自然科学基金青年基金1项,入选中国科协青年人才托举工程,获中国航空学会科技进步二等奖1项、省部级科技进步二等奖2项,发表学术论文32篇,其中SCI 11篇、EI 17篇,获授权国家发明专利10项、登记软件著作权3项、出版专著2部、译著1部,协助指导硕博研究生12名,其中1名获山东省优秀博士学位论文、1名获中国航空学会优秀硕士学位论文。目前主要研究方向为雷达数据处理、多源信息融合和人工智能交叉应用等。

E-mail: cui_yaqi@126.com



何友 男,1956年生,吉林人,信息融合专家。1982年、1988年获海军工程大学学士和硕士学位,1997年获清华大学博士学位,曾在德国布伦瑞克工业大学作访问学者。现为海战场信息感知与融合技术军队重点实验室主任、教授、博士生导师,中国指挥与控制学会副理事长,中国电子学会、中国航空学会常务理事,中国航空学会信息融合分会主任委员,IET Fellow等。