

基于深度学习网络模型的端到端航迹关联



黄虹玮^{1,2} 刘玉娇³ 沈卓恺¹ 张少伟³ 陈志敏² 高 阳¹

1 南京大学计算机科学与技术系 南京 210093

2 中国卫星海上测控部 江苏 无锡 214431

3 上海航天控制技术研究所 上海 201109

(312403172@qq.com)

摘 要 为提高雷达数据处理中航迹关联的智能性,充分利用目标的特征信息,并简化系统处理流程,提出了一种基于深度学习网络模型的端到端航迹关联算法。首先分析了基于神经网络的航迹关联存在样本细节少、处理流程繁杂的问题,然后提出了端到端的深度学习模型。该模型根据航迹关联数据的处理特征,改进了卷积神经网络结构用于特征提取,充分利用了长短期记忆网络对历史信息 and 将来信息的处理能力,并分析了前后航迹的关联性。在对原始数据进行卡尔曼滤波后,将全部航迹信息特征作为输入,并由基于卷积神经网络特征提取的长短期记忆深度神经网络模型直接输出航迹关联结果。仿真结果表明,提出的模型可以充分学习推演目标的多个特征信息,具有较高的航迹关联准确率,对航迹关联的智能化分析具有一定的参考价值。

关键词: 深度学习;卷积神经网络;长短期记忆网络;航迹关联

中图法分类号 TP391

End-to-end Track Association Based on Deep Learning Network Model

HUANG Hong-wei^{1,2}, LIU Yu-jiao³, SHEN Zhuo-kai¹, ZHANG Shao-wei³, CHEN Zhi-min³ and GAO Yang¹

1 Department of Computer Science and Technology, Nanjing University, Nanjing 210093, China

2 China Satellite Maritime TT&C Department, Wuxi, Jiangsu 214431, China

3 Shanghai Aerospace Control Technology Institute, Shanghai 201109, China

Abstract In order to improve the intelligence of track association in radar data processing, make full use of the characteristic information of the target and simplify the processing flow, an end-to-end track association algorithm based on deep learning network model was proposed. Firstly, this paper analyzed the problem that the track correlation based on neural network has few sample details and complex processing flow. Then, it proposed an end-to-end deep learning model, which takes all the track information features as input. According to the processing characteristics of track correlation data, the convolutional neural networks structure is improved for feature extraction, and the processing ability of long short-term memory neural network for historical information and future information is fully utilized to analyze the correlation of track before and after. After the original data is processed with Kalman filtering, the final track correlation results are directly output through the long short-term memory deep neural network model based on the convolutional neural networks features extracting. In this paper, the precision, recall and accuracy were set to verify the performance of the track association model. The simulation results show that the proposed model can fully learn multiple feature information of the target and has a high track association accuracy, which has reference value for the intelligent analysis of track association.

Keywords Deep learning, Convolutional neural networks, Long short-term memory, Track association

1 引言

航迹关联作为雷达数据处理的核心,一旦发生错误,会在实际应用场景中带来巨大的损失^[1]。用于航迹关联的传统方法主要分为两大类:极大似然类数据互联算法和贝叶斯数据互联算法。随着技术的发展,神经网络算法和机器学习方法也逐步被引入航迹关联中。Lin 等研究了基于 BP (Back

Propagation) 神经网络的航迹关联方法^[6],从增加样本数据和改变网络结构两方面对算法进行改进,提高了关联的概率,但普适性有待提高,整体学习能力有限。Bai 等研究了改进神经网络的航迹关联算法^[7],重新定义了马氏距离,加快了收敛速度,并将其推广到多传感器网络模型;但当传感器的数量增加时,该算法的计算量将呈指数级增长。Tian 等研究了基于神经网络的多传感器模糊航迹关联算法^[8],提出了一种新的三

到稿日期:2019-04-08 返修日期:2019-08-13 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61432008,U1435214)

This work was supported by the National Natural Science Foundation of China (61432008,U1435214).

通信作者:高阳(gaoy@nju.edu.cn)

神经网络模型用以解决三维分配问题。其选用的网络寻优方法是一种确定性算法,不可避免地使问题易陷入局部最优解。Zhang 等研究了人工神经网络在航迹关联中的应用^[9],利用了神经网络的泛化能力以及自组织自适应的学习功能,能够很好地解决复杂航迹关联问题。该模型的输入仅使用了目标的位置和速度信息,对目标特征的学习不够充分。

目前,在航迹关联中,大部分机器学习方法仅在整个处理流程的局部环节采用了自学习算法,模型简单,并且与传统的航迹关联流程类似,仍然需要通过先验知识将数据处理成特征,再对特征进行分类;训练特征的模块与分类模块是割裂开的,特征细节容易被忽略。此外,LSTM(Long Short-Term Memory)方法虽然可以从时序特征中学习全局长期依赖特征来表征客户的潜在行为趋势,但无法有效捕捉时序特征中的局部高重要性特征。卷积神经网络(Convolutional Neural Networks,CNN)由于存在窗口机制,可以较好地学习局部高重要性特征,但其感受野局限于窗口之内,无法很好地获取时序特征中的全局长期依赖特征。为了提高雷达数据处理中航迹关联的智能性,充分利用目标的特征信息,并简化系统处理流程,本文针对高分辨距离像^[10-13](High Range Resolution Profiles,HRRP)提出了一种基于深度学习网络模型的端到端航迹关联算法,由基于 CNN 特征提取的长短期记忆网络(Long Short-Term Memory,LSTM)深度神经网络模型直接输出航迹关联结果,因此可以将多层次的特征提取器与识别器统一训练^[14],建立端到端系统以缩减人工预处理和结果分析环节,尽可能使模型从原始输入到最终输入,给模型更多可以根据数据自动调节的空间,增加模型的整体契合度。

2 算法分析

2.1 基于神经网络航迹关联的基本思想

利用神经网络进行航迹关联的基本思想是:将已知的航迹信息作为神经网络的输入,输出下一个时刻目标点可能出现的位置,并将其作为预测值,然后利用现有的航迹关联算法^[15](如最近邻关联法、K 近邻单匹配算法、K 近邻多匹配算法)得到关联值^[16],如图 1 所示。




图 1 基于神经网络的航迹关联算法模型

Fig. 1 Model of track association algorithm based on neural network

假设航迹关联的全部输入量为:

$$\mathbf{X}^m = \{x_1^m, x_2^m, x_3^m, x_4^m, x_5^m, x_6^m, x_7^m, x_8^m\}' \quad (1)$$

其中, m 表示第 m 条航迹; $x_1^m, x_2^m, x_3^m, x_4^m, x_5^m, x_6^m, x_7^m, x_8^m$ 分别代表时间、方位、距离、幅度、信噪比、方位跨度、距离跨度、EP 值。考虑到输入量的特征空间比较大,可能存在较多的冗余和噪声,采用 PCA 主成分分析方法对这 8 维数据进行降维。构建目标主成分局部能量比的准则为:输入量或者输入量的组合对航迹关联正确率的影响大于 85%。基于已有的民航数据,统计输入量对航迹关联准确率的影响,得到时间和方位信息的特征值最大,因此将 $\mathbf{X}^m$ 降到 2 维空间,得到 $\mathbf{X}^{(1)m}$ 。

$$\mathbf{X}^m \rightarrow \mathbf{X}^{(1)m} = \{x_1^m, x_2^m\}' \quad (2)$$

采用 MLP 神经网络模型对 $\mathbf{X}^{(1)k}$ 组成的数据集进行滤波,得到下一时刻的预测点方位信息 $\mathbf{Y}^k$ 。预测模型如图 2 所示。




图 2 基于 MLP 神经网络的航迹预测模型

Fig. 2 Track prediction model based on MLP neural network

根据参考圈数在下一圈中找到波门与预测点 $\mathbf{Y}^m$ 欧氏距离最近的 k 个最近邻,再从 k 个最近邻中寻找与航迹片断中最后一个点欧氏距离最近的点作为航迹关联的结果 $\mathbf{Z}^m$,如图 3 所示。




图 3 k 近邻单匹配关联法示意图

Fig. 3 Diagram of k numbers of nearest neighbor single matching association method

2.2 存在的问题

一般的基于神经网络的航迹关联算法与传统航迹关联算法的流程一致,即在航迹预测时采用神经网络算法进行自学习,分析特征量 $\mathbf{X}^{(1)m}$ 与预测点 $\mathbf{Y}^m$ 之间的逻辑。其中,为了降低计算量并加快运算速度,采用 PCA 降维,仅保留 2 个输入量进行分析。由于样本细节减少,网络权重值可能偏大或者偏小,容易导致学习结果陷入局部最小,从而影响学习效果。当网络达不到训练的标准时,航迹预测的结果将发散,从而对关联的判决产生负面影响。

因此,寻找一种能够保留所有输入量样本的细节信息,简化航迹关联的算法流程,进而直接得出最终关联结果的方法,对于航迹关联来说具有重要的研究意义。

3 基于深度学习的端到端航迹关联

3.1 基于深度学习的端到端模型

基于深度学习的航迹关联算法的一个重要特点是其提供端到端(end-to-end)系统的能力,简化了整个算法的流程,可以通过模型接收一个输入后直接输出结果,如图 4 所示。




图 4 基于深度学习的端到端算法模型

Fig. 4 Model of end-to-end algorithm based on deep learning

取航迹信息的全部特征量 $\mathbf{X}^m$ 作为模型输入,通过深度神经网络的分析推理,直接得到航迹关联的结果值 $\mathbf{Z}^m$,即输入一条待判断的航迹信息,模型输出该航迹是否为一条真实航迹。

为了解决实际雷达数据不连续的问题,先采用卡尔曼滤波算法对实际数据进行完善,再对整个轨迹进行平滑处理,使得真实航迹样本相比于虚假航迹样本具有更加鲜明的特征。

3.2 基于深度学习的航迹关联模型

CNN 是应用最广的深度学习方法之一。CNN 不关注序列中元素的顺序关系,更注重提取深层次的特征。多层 CNN 可以学习到高层抽象特征之间的复杂关系,并将特征值进行正确分类。将 CNN 应用于雷达数据处理时^[17],可以有效避免对数据进行复杂的预处理^[18],使识别准确率相比深度感知机高出 10% 左右^[19],并且其对 HRRP 进行识别时鲁棒性较强^[20]。

航迹关联信息处理的显著特征是存在时序上的数据关联性。由于 CNN 模型不能提取与时间相关的特征信息,而循环神经网络 (Recurrent Neural Network, RNN) 具备这个能力^[21],因此本文采用 RNN 中的长短时记忆循环神经网络 (Long Short-Term Memory recurrent neural network, LSTM) 对 CNN 提取的特征进行分类^[22],并根据序列数据的特征进行端到端航迹关联,解决了时间序列数据之间的依赖性问题,提高了关联准确率。

(1) 基于 CNN 的特征提取。CNN 一般包括卷积层、池化层、全连接层和分类器。在学习过程中,其主要针对网络中的卷积层、池化层、全连接层进行训练,舍弃分类器。航迹数据共有 8 个输入参数,为了充分提取特征,本文选择 8 个 5×1 大小的卷积核进行学习。通过对雷达数据的特征值进行卷积,并在加入偏置后通过激活函数激活,得到最终的特征值^[23]。

$$x'_i = f(\sum_{i=M_j} x_i^{l-1} * k_{ij}^l + b_j^l) \tag{3}$$

其中, x 表示长度为 N 的一维输入数据, l 是层号, M_j 表示长度为 T 的未知航迹的集合, j 是未知航迹的集合序号, k 为卷积核, b 为偏置, n 是卷积核序号。多个非线性隐藏层允许深度神经网络得到输入数据的复杂的分等级的特征值。

在学习过程中,需要通过反向迭代更新网络参数,使网络获得稳定的识别效果。当训练误差小于阈值时,训练结束。训练误差由下式表示:

$$E^N = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^c (t_k^n - y_k^n)^2 \tag{4}$$

其中, t_k^n 表示第 n 个样本对应标签的第 k 维, y_k^n 表示第 n 个样本对应网络输出的第 k 维, N 表示训练样本数, c 表示待识别的种类数。

池化层在每次卷积后,通过下采样减小数据规模。本文采用最大池化算法,取卷积层输出的每个向量的最大值作为最大池化的输出结果。将所有最大池化结果连接起来,得到池化层的输出结果:

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \tag{5}$$

对池化层输出的结果进行排序,得到全连接层的输出结果:

$$\mathbf{X}' = f(\omega^{\text{full}} \cdot \mathbf{X} + \mathbf{b}^{\text{full}}) \tag{6}$$

其中, ω^{full} 为全连接层的权重, $\mathbf{b}^{\text{full}}$ 为全连接层的偏置。

该网络包含 2 个卷积层、2 个最大池化层和 1 个全连接层,将全连接层输出的排序后的特征值作为 LSTM 的输入。

(2) 基于 LSTM 的航迹关联。RNN 被广泛用于序列数据建模,但经典 RNN 容易发生梯度弥散或者梯度爆炸的现象,导致模型无法正常更新。LSTM 较好地缓解了这些问题,其采用记忆单元来丢弃和更新神经单元的信息,能够把序列数

据中的远距离依赖信息引入模型的学习中,得到较好的结果。

LSTM 的基本单元由细胞状态、输入门、遗忘门以及输出门组成,其中细胞状态是 LSTM 基本单元的关键组成部分,可以保证信息的有效流通。LSTM 的具体结构如图 5 所示。




图 5 LSTM 的基本单元结构
Fig. 5 Cell structure of LSTM

假设 t 时刻的输入向量为 $\mathbf{X}'_t$, 遗忘门为 f_t , 输入门为 i_t , 输出门为 o_t , 存储单元为 c_t , 输出向量为 h_t ; $t-1$ 时刻 LSTM 的网络单元的输出为 h_{t-1} , 存储单元信息为 c_{t-1} ; w 和 b 分别表示权重和偏置。具体公式如下:

$$\mathbf{X}'' = \begin{bmatrix} \mathbf{X}'_t \\ h_{t-1} \end{bmatrix} \tag{7}$$

$$f_t = \sigma(w_f \mathbf{X}'' + b_f) \tag{8}$$

$$i_t = \sigma(w_i \mathbf{X}'' + b_i) \tag{9}$$

$$o_t = \sigma(w_o \mathbf{X}'' + b_o) \tag{10}$$

$$c_t = f_t * c_{t-1} + i_t * \tanh(w_c \cdot \mathbf{X}'' + b_c) \tag{11}$$

$$h_t = o_t * \tanh c_t \tag{12}$$

LSTM 的输入门、输出门和遗忘门之间的交互决定了信息去留,而遗忘门能够控制单元状态中保留哪些以前的有效信息,从而解决了数据依赖性强问题。如此循环,在迭代完一次之后,计算准确率将作为预测值和实际值之间的差距。

在 2 层 LSTM 结束后,将其输出结果接入 2 层全连接层,并由 softmax 函数得到网络的识别结果:

$$\mathbf{z} = \text{softmax}(\omega'^{\text{full}} \cdot \mathbf{h}_t + \mathbf{b}'^{\text{full}}) \tag{13}$$

该网络包含 2 个 LSTM 层、2 个全连接层和 1 个分类器。分类器的输出结果为 1 时,认为航迹关联;结果为 0 时,认为航迹不关联。

(3) 基于 CNN 特征提取的 LSTM 端到端的深度神经网络模型。本文设计了图 6 所示的基于 CNN 特征提取的 LSTM 端到端的深度神经网络模型。




图 6 基于 CNN 特征提取的 LSTM 端到端的深度神经网络模型
Fig. 6 End-to-end model of LSTM deep neural network based on CNN features extracting

该算法的伪代码如算法 1 所示。

算法 1 基于 CNN 特征提取的 LSTM 端到端的航迹关联算法
输入:时间步为 T、长度为 N 的一维距离像矩阵($T \times N$),长度为 3 的位置矩阵($T \times 3$)。

输出:长度为 2 的向量。

- Step 1 一维距离像特征提取,输入 $T \times N$
卷积层 Conv1,卷积核为 1×5 ,步长为 1,输出 $T \times (N-4)$ 。
卷积层 Conv2,卷积核为 1×5 ,步长为 1,输出 $T \times (N-8)$ 。
- Step 2 位置信息特征提取,输入 $T \times 3$
全连接层 FC1,输出 $T \times 8$ 。
- Step 3 特征拼接
将一维距离像的输出特征与位置特征进行拼接,得到 $T \times N$ 的特征矩阵。
- Step 4 时间信息提取
将每个时刻的向量输入长度为 T 的 LSTM 网络中,LSTM cell 的输出为 1×32 的向量。
- Step 5 分类器
全连接层 FC2 和 FC3 输出长度为 2 的向量。

对于每一条长度为 T 的未知航迹,在每个时刻有长度为 N 的一维输入数据。首先通过预处理方法将两端的噪声点过滤掉,之后对每一个时刻的一维数据进行特征提取,再将所有输入数据提取的特征值整理为最终的总特征,随后将其输入 LSTM 网络中,提取 LSTM 最后一个时刻的输出作为结果,再经两层全连接层得到最终的分类结果。

基于 CNN 特征提取的 LSTM 端到端的深度神经网络模型首先将经过预处理的序列数据作为模型初始输入卷积神经网络中进行特征提取,以提取不同的特征;然后将提取到的不同特征向量作为 LSTM 的输入,通过学习模型分类出不同的类型。输入数据为预处理之后的序列数据,将该一维序列数据作为 CNN 特征提取模型的输入,通过卷积神经网络的卷积和池化交替得到特征向量,并用 LSTM 代替 CNN 的全连接层,将 CNN 特征提取得到的特征向量作为 LSTM 的输入,基于 LSTM 的长期记忆功能,对输入的长序列数据根据门的控制选择性地输出保留的数据,从而准确识别出活动,提高了活动识别的准确率。

从算法复杂度的角度分析,使用神经网络可使算法的空间复杂度与输入的数据量无关而仅与模型的大小相关。所提模型的时间复杂度为 $O(T \times N \times K^2)$,其中 T 为时间步的长度, N 为截取的一维距离像长度, K 为使用的卷积核大小。

本文方法利用 CNN 能够自动提取原始数据特征向量的优势,减少了神经网络需要训练的参数,并且利用了 LSTM 处理依赖性强的数据的优势进行数据处理,通过不断调整相关参数,得到了可靠的数据处理结果。

4 对比与仿真

4.1 实测数据仿真

将原始数据集按照 7:3 的比例随机划分为训练数据与测试数据。训练集的数据样本数量为 66 309,测试集中未知航迹的数量为 13671。实验环境为 python3,pytorch0.4.0,并且在 CPU 上完成运算。

本文选取了查准率、查全率和准确率 3 个指标作为深度

学习模型性能的评价标准。

假设 TP 为航迹关联结果是正确航线且实际为正确航线的样本数; FP 为航迹关联结果是正确航线但实际为虚假航线的样本数; FN 为航迹关联结果是虚假航线但实际为正确航线的样本数; TN 为航迹关联结果是虚假航线且实际也为虚假航线的样本数; ALL 表示参与学习的所有样本。

查准率:

$$P_1 = \frac{TP}{TP + FP}$$

(14)

查全率:

$$P_2 = \frac{TP}{TP + FN}$$

(15)

准确率:

$$P_3 = \frac{TP + TN}{ALL}$$

(16)

深度学习网络模型的建立过程中存在大量的超参数,这些超参数对模型的实验效果有着不同程度的影响。为了寻找较优的参数设置,本文针对不同的参数对实验结果的影响进行了多组对比实验,分析并得出了学习模型的最优参数;同时,将深度学习网络模型的准确率与神经网络滤波关联方式得到的准确率进行了对比分析。

4.1.1 基于深度学习端到端的模型参数优化

(1)时间步长

针对不同时间步长(timestep)对结果的影响进行对比实验,在保持其他参数不变的条件下改变 $timestep$ 的取值,具体的实验结果如表 1 所列。

表 1 不同 timestep 对模型性能的影响

Table 1 Effect of different timestep on model performance

<i>timestep</i>	<i>batchsize</i>	<i>learning rate</i>	P_1	P_2	P_3
5	1024	0.01	0.85	0.75	0.78
6	1024	0.01	0.87	0.76	0.80
7	1024	0.01	0.86	0.75	0.78
8	1024	0.01	0.85	0.75	0.78
9	1024	0.01	0.85	0.74	0.77

(2)批尺寸

针对不同批尺寸(batchsize)对结果的影响进行对比实验,在保持其他参数不变的条件下改变 $batchsize$ 的取值,具体的实验结果如表 2 所列。

表 2 不同 batchsize 对模型性能的影响

Table 2 Effect of different batchsize on model performance

<i>timestep</i>	<i>batchsize</i>	<i>learning rate</i>	P_1	P_2	P_3
6	128	0.01	0.59	0.51	0.53
6	256	0.01	0.62	0.59	0.60
6	512	0.01	0.81	0.70	0.73
6	1024	0.01	0.87	0.76	0.80
6	2048	0.01	0.83	0.73	0.78

(3)学习率

针对不同学习率对结果的影响进行对比实验,在保持其他参数不变的条件下改变学习率的取值,具体的实验结果如表 3 所列。

通过以上的参数实验可以发现,当 $timestep$ 为 6、 $batchsize$ 为 1024、学习率为 0.01 时,模型的效果最佳。

表 3 不同学习率对模型性能的影响

Table 3 Effect of different learning rates on model performance

timestep	batchsize	learning rate	P_1	P_2	P_3
6	1024	0.001	0.83	0.75	0.76
6	1024	0.005	0.85	0.75	0.76
6	1024	0.010	0.87	0.76	0.80
6	1024	0.015	0.85	0.75	0.76
6	1024	0.020	0.83	0.75	0.76

4.1.2 航迹关联结果对比

选取相同的雷达数据,对基于神经网络滤波算法的航迹关联模型(Model₁)和基于深度学习的端到端的航迹关联模型(Model₂)进行对比分析。

设置相同的学习模型参数:timestep 为 6, batchsize 为 1024,学习率为 0.01。将所有样本分为 $k=50$ 组,分别计算两个关联模型对每组数据分析得到的正确率的平均值 $m_1, m_2, \dots, m_k$,然后对其进一步求平均得到每个关联模型的最终正确率:

$$Mean_{P_3} = \frac{m_1 + m_2 + \dots + m_k}{k}$$

(17)

两个模型的计算结果如图 8 所示。统计得到 Model₁ 的正确率为 0.879, Model₂ 的正确率为 0.898,即基于深度学习的端到端的航迹关联模型的识别正确率比基于神经网络滤波算法的航迹关联模型的识别正确率提高了 2.16%。




图 7 两个学习模型的识别正确率的对比

Fig. 7 Comparison of recognition accuracy of two learning models

本文利用 CNN 能够实现特征提取及其封装的优势,并基于 LSTM 能够记忆依赖性很强的数据之间的关系的优势,提出了基于深度学习网络模型的端到端航迹关联,解决了序列数据特征提取和数据依赖问题。该方法首先将预处理过的序列数据特征输入 CNN 中提取特征向量,然后将提取的不同特征向量作为 LSTM 的输入,再利用 LSTM 中输入门、遗忘门和输出门的相互作用解决依赖性强的数据对实验的影响问题,从而提升了航迹关联的准确性。

4.2 模拟数据仿真

设置局部节点的数目为 4,且每个局部节点均配有一部 2D 雷达;60 批空中目标在一个二维平面上进行变速运动。构建二维坐标,目标初始位置在 $(-24\,000\text{ m}, -25\,000\text{ m})$ 与 $(24\,000\text{ m}, 24\,000\text{ m})$ 之间正态分布,初速度在 $(68\text{ m/s}, 432\text{ m/s})$ 之间均匀分布,加速度大小在 $(0.9\text{ m/s}^2, 53\text{ m/s}^2)$ 之间均匀分布,初始航向与加速度的方向均在 $(0, 2\pi)$ 之间均匀分布。将加权法、修正法、最近邻域法与本文深度学习网络航迹关联方法进行仿真对比。

设目标状态为 $\mathbf{X}=(\mathbf{x}, \dot{\mathbf{x}}, \mathbf{y}, \dot{\mathbf{y}})$,输入信号 $u(t)=0$,则直角坐标系 XOY 下的量测值 $\mathbf{Z}(t)$ 为:

$$\mathbf{Z}(t)=\begin{bmatrix} \mathbf{z}_1(t) \\ \mathbf{z}_2(t) \end{bmatrix}=\begin{bmatrix} \mathbf{x}(t) \\ \mathbf{y}(t) \end{bmatrix}=\begin{bmatrix} \rho \cos \theta \\ \rho \sin \theta \end{bmatrix}$$

(18)

其中, ρ 为极坐标系下雷达的目标径向距离, θ 为极坐标系下雷达的方位角测量数据。状态方程为:

$$\mathbf{X}(t+1)=\begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{X}(t)+\begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} \mathbf{V}(t)$$

(19)

其中, T 为采样间隔,在实验中 $T=1\text{ s}$ 。量测方程为:

$$\mathbf{Z}(t+1)=\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{X}(t+1)+\mathbf{W}(t+1)$$

(20)

其中,状态转移矩阵为 $\Phi=\begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}$,过程噪声分布矩

阵表示为 $\mathbf{G}=\begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/20 \end{bmatrix}$, $\mathbf{W}(t+1)$ 为具有零均值的白

色高斯量测噪声序列。

令测量向量为 $\mathbf{Z}=(x, y)'$,则量测矩阵表示为:

$$\mathbf{H}=\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

(21)

在模拟目标运动时,设噪声序列 $\mathbf{V}(t)$ 的正定协方差 $\mathbf{Q}(t)$ 为:

$$\begin{cases} \mathbf{Q}(t)=\begin{bmatrix} \mathbf{q}_{11}(t) & 0 \\ 0 & \mathbf{q}_{22}(t) \end{bmatrix} \\ \sqrt{\mathbf{q}_{11}(t)}=15 \times 10^{-2} \cdot \dot{\mathbf{x}}(t), \sqrt{\mathbf{q}_{22}(t)}=15 \times 10^{-2} \cdot \dot{\mathbf{y}}(t) \end{cases}$$

(22)

局部节点共 4 个,每个局部节点上均配有雷达,即有雷达 1、雷达 2、雷达 3 和雷达 4,令它们的测距和测角误差分别为 $\sigma_{\rho_1}, \sigma_{\theta_1}, \sigma_{\rho_2}, \sigma_{\theta_2}, \sigma_{\rho_3}, \sigma_{\theta_3}, \sigma_{\rho_4}, \sigma_{\theta_4}$,具体如表 4 所列。

表 4 雷达参数设置表

Table 4 Radar parameter setting

	雷达 1	雷达 2	雷达 3	雷达 4
$\sigma_{\rho}(\text{m})$	150	200	250	100
$\sigma_{\theta}(\text{rad})$	0.024	0.014	0.013	0.020

局部节点的滤波在直角坐标系中完成,测量误差的协方差矩阵为:

$$\mathbf{R}(t)=\begin{bmatrix} \sigma_x^2(t) & \sigma_{xy}(t) \\ \sigma_{yx}(t) & \sigma_y^2(t) \end{bmatrix}$$

(23)

其中:

$$\begin{cases} \sigma_x^2(t)=\sigma_{\rho}^2 \cos^2 \theta(t)+\rho^2(t) \sigma_{\theta}^2 \sin^2 \theta(t) \\ \sigma_y^2(t)=\sigma_{\rho}^2 \sin^2 \theta(t)+\rho^2(t) \sigma_{\theta}^2 \cos^2 \theta(t) \\ \sigma_{xy}(t)=\sigma_{yx}(t)=[\sigma_{\rho}^2-\rho^2(t) \sigma_{\theta}^2] \sin \theta(t) \cos \theta(t) \end{cases}$$

(24)

其中, σ_{ρ} 为雷达的测距, σ_{θ} 为雷达的侧角误差, $\rho(t)$ 和 $\theta(t)$ 分别为目标在 t 时刻的斜距和方位角。

在实验中,为排除过程噪声估计的影响,设过程噪声的规律已知,并通过状态估计速度形成噪声估计,其强度通过噪声

系数 Q 调节。滤波选用卡尔曼滤波,其初始状态设为:

$$\begin{cases} \mathbf{x}(1|1)=\mathbf{Z}_1(1) \\ \mathbf{y}(1|1)=\mathbf{Z}_2(1) \\ \mathbf{x}(1|1)=[\mathbf{Z}_1(1)-\mathbf{Z}_1(0)]/T \\ \mathbf{y}(1|1)=[\mathbf{Z}_2(1)-\mathbf{Z}_2(0)]/T \end{cases} \quad (25)$$

系统初始协方差为:

$$\mathbf{P}(1|1)=\begin{bmatrix} \sigma_x^2 & \sigma_x^2 & T & \sigma_{xy} \\ \sigma_x^2/T & 2\sigma_x^2/T^2 & \sigma_{xy}/T & 2\sigma_{xy}/T^2 \\ \sigma_{yx} & \sigma_{yx} & T & \sigma_y^2 \\ \sigma_{yx} & T & 2\sigma_{yx} & T^2 \end{bmatrix} \quad (26)$$

在仿真实验中,每种算法仿真 100 次,并对 100 次仿真结果取平均值。60 批目标在二维平面上模拟变速运动,具有在速度上变化的过程噪声。仿真实验结果如表 5 所列。

表 5 不同方法的关联结果

Table 5 Associated results of different methods

航迹关联算法	运算时间/s	关联准确率/%	关联错误率/%
加权法	2.21	65.72	27.93
修正法	3.39	67.86	27.04
最近邻域法	1.57	64.93	31.01
深度学习网络	4.25	88.20	10.79
航迹关联方法			

从表 5 可以看出:1)本文深度学习网络航迹关联方法在平均航迹关联判决的准确率上都比加权法、修正法以及最近邻域法有了明显提高;2)当多源探测系统中部分传感器出现不理想的滤波数据时,深度学习网络航迹关联方法能够表现出更为理想的关联性能;3)本文深度学习网络航迹关联方法的运算复杂度有一定提升,但可以满足雷达系统对航迹关联实时性的要求,且关联准确率有明显提升,其综合性能具有明显优势。

结束语 为了能够在航迹关联时使用更多的特征信息,本文设计了一种端到端的深度神经网络模型,该模型的输入为全部的航迹信息,输出该航迹是否为一条真实航迹的结论。深度学习模型记忆并处理雷达数据的滤波、特征提取和航迹预测,既保留了样本细节,提高了泛化能力,又简化了系统整体的处理流程。仿真结果表明,本文提出的模型可以充分学习推演目标的多个特征信息,具有较高的航迹关联准确率,对航迹关联的智能化分析具有一定的参考价值。但是,将深度学习模型应用于雷达数据处理所提取出的特征的可解释性,还有待进一步的分析及考证。

参 考 文 献

[1] PENG D, JING Z, GONG D, et al. Maneuvering multi-target tracking based on variable structure multiple model GMCPHD filter[J]. Signal Processing, 2017, 141(12): 158-167.

[2] LIN H T, ZHOU Y, CHENG Y, et al. ESM /Radar Track Association Based on BP Neural Network[J]. Modern Radar, 2009, 31(4): 65-69.

[3] BAI H F, GAO M. Improved CHNN Algorithm For Track-to-Track Association [J]. Modern Defence Technology, 2014, 42(2): 145-149.

[4] TIAN B G, CHEN J. Algorithm of Fuzzy Track Correlation in Multisensor System Based on Neural Network[J]. Ship Electronic Engineering, 2009, 29(11): 133-138.

[5] ZHANG C P, CUI P Y, ZHANG Y J, et al. Application of arti-

ficial neural network in track correlation[J]. Journal of Natural Science of HeiLongJiang University, 2006, 23(1): 38-45.

[6] WANG C, XIA H Y, LIU Y P, et al. Spatial resolution enhancement of coherent Doppler wind lidar using joint time-frequency analysis[J]. Optics Communications, 2018, 424: 48-53.

[7] AI X F, WANG L D, WANG M X, et al. Bistatic high-range resolution profiles of wobbling targets[C]//Proceedings of IET International Radar Conference 2015, 2015: 1-4.

[8] BERNDT R J. Aircraft micro-Doppler feature extraction from high range resolution profiles[C]//Proceedings of 2015 IEEE Radar Conference, 2015: 457-462.

[9] KIM K T. Focusing of high range resolution profiles of moving targets using stepped frequency waveforms[J]. IET Radar, Sonar & Navigation, 2010, 4(4): 564-575.

[10] LI S, ZHANG Z M, WANG H P, et al. General Purpose Pol-SAR Classifier Based on Deep Learning Algorithm[J]. Aerospace Shanghai, 2018, 35(3): 1-7.

[11] LI S, WANG Y F. A distributed multi-sensor track association algorithm based on K-means clustering[J]. Telecommunication Engineering, 2018, 58(3): 295-299.

[12] JING B J. Research on Recognition of Radar Emitter Based on Deep Learning[D]. Xi'an: Xidian University, 2017.

[13] SHI E, LI Q, GU D Q, et al. Weather radar echo extrapolation method based on convolutional neural networks[J]. Journal of Computer Applications, 2018, 38(3): 661-665.

[14] WANG J, ZHENG T, LEI P, et al. Study on Deep Learning in Radar[J]. Journal of Radars, 2018, 7(4): 395-410.

[15] LUNDEN J, KOIVUNEN V. Deep learning for HRRP-based target recognition in multistatic radar systems[C]//Proceedings of 2016 IEEE Radar Conference, 2016: 1-6.

[16] ZHANG H. RF stealth based airborne radar system simulation and HRRP target recognition research[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2016.

[17] JITHESH V, SAGAYARAJ M J, SRINIVASA K G. LSTM recurrent neural networks for high resolution range profile based radar target classification[C]//Proceedings of the 2017 3rd International Conference on Computational Intelligence & Communication Technology, 2017: 1-6.

[18] JARMO L, VISA K. Deep learning for HRRP-based target recognition in multistatic radar systems[C]//2016 IEEE Radar Conference, 2016: 1-6.

[19] YIN W F, YANG X Z, ZHANG L, et al. ECG Monitoring System Integrated With IR-UWB Radar Based on CNN[J]. IEEE Access, 2016, 4: 6344-6350.



HUANG Hong-wei, born in 1986, Ph.D. His main research interests include stream data mining, online learning, and few-shot learning.



GAO Yang, Ph.D, professor, deputy director. His research interests include artificial intelligence and machine learning.