

DOI: 10.13382/j.jemi.B1902872

基于点迹时空关系的雷达目标航迹识别^{*}

樊玉琦^{1,2} 刘瑜岚¹ 许 雄³ 郭 丹¹ 温鹏飞¹

(1. 合肥工业大学 计算机与信息学院 合肥 230009; 2. 工业安全与应急技术安徽省重点实验室 合肥 230009;
3. 电子信息系统复杂电磁环境效应国家重点实验室 洛阳 471003;)

摘 要: 雷达目标航迹的识别有助于指挥员判断对方作战意图和作战任务, 从而为战场决策提供协助作用, 但目前少有文献研究目标航迹识别问题。根据雷达检测到的目标物体的时间、距离和方位等时空数据, 研究目标航迹识别问题, 并提出了一种基于雷达点迹数据时空关系的目标航迹识别算法 (TRST)。该算法首先对雷达点迹数据进行属性选择, 然后挖掘点迹数据在空间关系上的间距值特征, 最后构建递归神经网络进一步捕捉点迹数据的时空关系特征, 实现对目标航迹的分类识别。实验结果表明, TRST 算法能够有效提高目标航迹识别的准确率、精确率、召回率和 $F1-Score$ 性能。

关键词: 雷达; 目标航迹识别; 属性选择; 间距值特征; 递归神经网络

中图分类号: TN959 **文献标识码:** A **国家标准学科分类代码:** 510.70

Radar target track recognition based on spatial-temporal relationship of track points

Fan Yuqi^{1,2} Liu Yulan² Xu Xiong³ Guo Dan¹ Wen Pengfei¹

(1. School of Computer and Information, Hefei University of Technology, Hefei 230009, China;
2. Anhui Province Key Laboratory of Industry Safety and Emergency Technology, Hefei 230009, China;
3. State Key Laboratory of Complex Electromagnetic Environment Effects on Electronics
and Information System, Luoyang 471003, China)

Abstract: Radar target track recognition can help a commander to estimate the intention and tasks of the adversary, and facilitate the decision making of the commander. However, little attention has been paid on the radar target track recognition problem. Given the radar target data such as time, distance, direction, and so on, a radar target track recognition based on spatial-temporal relationship of track points is proposed to solve the problem of target track recognition. The algorithm selects the attributes of radar track data and then extracts the space characteristics of the track points in the spatial domain. The algorithm constructs the recursive neural network to capture the characteristics of the track points in the time domain and realize the classification and recognition of the target track. We conduct experiments through simulations, and the simulation results show that the proposed algorithm TRST can effectively improve the target track recognition performance in terms of accuracy, precision, recall and $F1-Score$.

Keywords: radar; target track recognition; attribute selection; interval value feature; recurrent neural network (RNN)

0 引 言

雷达作为战场上获取信息的重要军事装备能够及时、准确的获取到一定的作战区域内目标信息。因此使用雷达对目标进行识别是一个重要的研究问题。雷达目

标识别技术对于提高军队的指挥自动化、战略预警能力等具有重要作用。其主要是基于雷达回波信号提取目标特征, 实现目标属性、类别或类型的判断。

雷达目标识别的研究已有很多。文献[1]提出了一种通过频率分集雷达横截面 (RCS) 以及核散射差异识别方法, 通过使用频率分集 RCS 技术减少空间测量的时

间,解决了 RCS 包含随机成分时的识别准确率较低的问题。文献[2]提出了联合多分辨率表示的合成孔径雷达(SAR)目标识别方法,通过多分辨率描述目标特性并使用联合稀疏表示进行分类,有效提高了 SAR 目标识别性能。文献[3]研究了基于正则化增强的 SAR 目标识别,通过调整正则化系数和联合稀疏表示,实现了 SAR 目标识别。文献[4]研究了使用压缩后向散射的雷达目标识别方法,通过利用雷达目标信号的范围域中和频域中的稀疏性,实现了识别未知雷达目标。文献[5]研究了基于极化不变量的雷达目标识别方法,通过偏振不变性,可有效识别地面车辆目标。除上述介绍的识别方法之外,借助高分辨力雷达距离像可获取目标的形状结构信息,故基于高分辨力雷达成像的目标识别研究也有很多。文献[6]提出了一种自适应粒子群算法优化支持向量机(SVM)的目标分类算法,通过引入局部搜索算子增加粒子多样性有效提高了识别的准确率且鲁棒性较好。文献[7]则研究了将最小二乘法与 SVM 结合的雷达自动目标识别方法,通过最小二乘法找到类中的分布信息并将其应用于调整边界,提高了分类准确率和泛化能力。文献[8]提出了一种基于希尔伯特黄变换的雷达高分辨距离像(HRRP)目标识别方法,通过对原始 HRRP 采取预处理得到 Hilbert 谱特征和字典学习,有效的解决了 HRRP 平移敏感性问题。近年来,深度学习技术逐渐进入到雷达目标识别领域。文献[9]研究了基于卷积神经网络的雷达目标识别,通过开发的卷积因子分析(CFA)概率生成模型,解决了训练数据有限的识别问题。文献[10]研究了 t 分布随机邻居嵌入和区分性深度信念网络结合的雷达高分辨距离像目标识别方法,通过将 t 分布随机邻居嵌入和合成采样用于数据预处理,解决了不平衡 HRRP 数据问题。文献[11]则在高分辨距离像的基础上研究了目标感知循环注意力网络来进行雷达自动目标识别方法,通过递归神经网络(recursive neural network, RNN)和注意力机制发现目标区域,不仅有效的提高了识别性能且对时移敏感性也更强大。

已有的雷达目标识别技术研究主要是利用雷达回波中的频谱信息、极化特征信息、高分辨距离像等实现对目标属性、类别或类型的判断。但是,很少有研究利用雷达检测到的目标物体的时间、距离和方位等时空数据进行目标航迹的识别。雷达目标航迹的识别有助于指挥员判断对方作战意图和作战任务,从而为战场决策提供协助作用。文献[12]针对雷达点迹数据,采用卷积神经网络(convolutional neural network, CNN)进行目标航迹识别,说明了深度神经网络可用于目标航迹的识别,但其识别性能仍有待提高。值得注意的是,目标飞行物的雷达点迹数据具有时序性特征,并且点迹和点迹之间具有相关性特征,而这些特征有助于目标航迹的识别。为了提高

目标航迹识别效果,本文充分考虑目标航迹数据的时序性,挖掘了目标航迹数据的间距值特征,采用适用于处理时序数据的 RNN^[13],提出了一种基于雷达点迹数据时空关系特性的目标航迹识别算法。

本文研究雷达目标航迹识别问题,提出了一个基于雷达点迹数据时空关系特性的目标航迹识别算法 TRST。该算法首先对雷达点迹数据进行属性选择,然后挖掘出了雷达点迹数据在时空关系上的间距值特征,再构建递归神经网络进一步捕捉点迹数据的时空关系以进行目标航迹分类识别。仿真实验表明,本文提出的算法明显提高了目标航迹识别的准确率等性能指标,为指挥员分析和决策提供了辅助作用。

1 问题定义

空中目标的飞行状态可以认为是俯冲、拉起、转弯和平飞(匀速或变速直线运动)中 1 种或几种的组合。当雷达扫描线每扫过 1 圈时,目标对应于扫描区域的 1 个点,代表了本周期目标的位置、航向、速度等特征。该数据即是雷达扫描的点迹数据。按雷达的扫描周期将目标在每个周期对应的坐标存储下来,即得到目标的航迹数据。

雷达的点迹数据一般是用极坐标来表示的。本文使用方位、距离、时间来描述雷达检测到的目标的点迹数据。方位表示这个目标在极坐标下的角度;距离表示目标离雷达检测中心点的距离,设雷达所在位置为极点,则距离就是目标离极点的距离;时间表示检测到这个目标的时间。本文所使用的符号如表 1 所示。

表 1 符号定义表

Table 1 Symbol definition table

符号	定义
L	标签值
a_i	第 i 个属性
μ_k	第 k 个变量的均值
ΔS	s^2 的可接受边界值
σ_k	第 k 个变量的标准差
Δp	P 值的可接受边界值
ΔR	重合率可接受的边界值
Δr	判断系数 r^2 的可接受边界值
$x_{k,n}$	矩阵 $\mathbf{x}$ 的第 k 行第 n 列的值
b_p	第 p 个自变量对应的偏回归参数
$D_{i,j}$	第 i 个点和第 j 个点之间的间距值
$p_i(x_i, y_i, z_i)$	第 i 个点的方位: x_i , 距离: y_i 时间: z_i

航迹由 N 个点组成,表示如下:

$$p_1(x_1, y_1, z_1), p_2(x_2, y_2, z_2), \dots, p_N(x_N, y_N, z_N)$$

航迹种类为直线型、圆弧型、圆周型、椭圆型、抛物线型和 S 型。为每种航迹分配 1 个标签值,如表 2 所示。1 条由 N 个点组成的航迹数据加上该条航迹的标签值构成

了 1 条完整的航迹数据,即为标签化的航迹数据。定义为标签化航迹数据,格式如下:

$$p_1(x_1,y_1,z_1),p_2(x_2,y_2,z_2),\cdots,p_N(x_N,y_N,z_N),\cdots$$

表 2 类别-标签表

Table 2 Type-label table

航迹种类	标签值(L)
抛物线型	1
弧型	2
椭圆型	3
直线型	4
S 型	5
圆周型	6

综上,在一段时间内,空中目标的飞行轨迹可为直线型、圆弧型、圆周型、椭圆型、抛物线型、和 S 型的一种。本研究通过对雷达目标航迹数据进行处理,挖掘出雷达点迹数据时空关系的特征,再构建递归神经网络模型来实现对雷达目标航迹的识别。

2 基于点迹数据时空关系的航迹识别算法

本文提出了一种基于雷达点迹数据时空关系特性的目标航迹识别算法 (TRST)。TRST 算法结构如图 1 所示。




图 1 TRST 算法结构

Fig. 1 TRST algorithm structure

该算法主要由 3 部分组成。首先是通过属性选择找出对最终分类结果有较大大利影响的属性;其次是间距值特征提取,即对第 1 部分筛选之后的属性进行处理,提取雷达点迹之间的间距值,从而得到雷达数据的时空特性;最后构建递归神经网络模型,综合考虑雷达点迹之间的时间先后关系及点迹间距值对航迹识别的影响,进行航迹的分类识别。

2.1 属性选择

属性选择用于确定对航迹识别分类结果更具影响力的属性。由于方位、距离、时间等属性在数量值上差别很大,因此需要对数据进行预处理。本文采用正态标准化的方式对数据进行预处理。设 μ_k 是第 k 个属性的均值, σ_k 是第 k 个属性的标准差。对于属性 k 的第 n 个数据,其正太标准化的预处理如下:

$$x'_{k,n} = \frac{x_{k,n} - \mu_{k,n}}{\sigma_k} \tag{1}$$

对已经标签化的航迹数据,首先分析各属性对航迹识别的影响程度。多元线性回归^[14]可以通过建模,对所有的因素进行综合回归分析,得到各因素对结果的影响程度。本文采用多元线性回归进行分析。设因变量为 y ,自变量为 x ,有 p 个自变量,回归方程为:

$$y = b_0 + b_1x_1 + b_2x_2 + \cdots + b_px_p \tag{2}$$

n 组观测值^[14]下的多元线性回归的线性方程组:

$$\begin{pmatrix} 1 & x_{11} & \cdots & x_{1p} \\ 1 & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{np} \end{pmatrix} \begin{bmatrix} b_0 \\ \vdots \\ b_p \end{bmatrix} = \begin{bmatrix} y_1 \\ \vdots \\ y_p \end{bmatrix} \tag{3}$$

式(3)中 3 个矩阵分别记为系数矩阵 A , 参数向量 B , 观测值 y_i 记为 Y 。

采用最小二乘法解出最优解:

$$B = (A^T A)^{-1} A^T Y \tag{4}$$

本文提出采用重合率 R_i 作为属性筛选的指标,以进行属性筛选。重合率 R_i 定义为:

$$R_i = \frac{a_{i,n1}}{a_{i,N}} \tag{5}$$

式中: $a_{i,n1}$ 为删除变量集中归属于属性 a_i 的变量数目; $a_{i,N}$ 为属性 a_i 中所包含的变量总数。如果筛选的变量集合占 1 个属性所包含的变量集合大多数时,则该属性不是重要影响因素,因此不选择该属性。

本文提出属性选择算法挑选对航迹识别分类结果更具影响力的属性。该算法的输入包括 n 组标签化航迹数据、航迹数据的属性集合 $G = \{a_1, a_2, a_3, \cdots, a_k\}$ 和属性个数 k 、变量集合 $U = \{v_1, v_2, v_3, \cdots, v_p\}$ 、删除的变量集合 DC , 其中 DC 初始值为空。该算法的输出为新的属性集合。属性选择算法的步骤如下。

- 1) 采用式(8)对 n 组航迹数据进行正态标准化。
- 2) 采用式(2)建立多元线性回归方程。

3)对步骤2)得到的多元线性方程,采用式(3)计算回归系数矩阵 $\mathbf{B}$,并计算出判定系数 r^2 , F -检验值, p 值,方差的估计量 s^2 。

4)如果 $r^2 \geq \Delta r$ 且 F -检验值 $> F_{\alpha}(p, n - p - 1)$ 且 $p < \Delta p$ 且 $s^2 < \Delta S$, 转步骤5);否则,转步骤9)。

5)对回归系数取绝对值,得到 $|b_1|, |b_2|, \dots, |b_p|$, 并把这些绝对值按照从小到大排序;将相关性特别小或明显小于其他变量相关性的变量加入 DC 中。

6)对每一个变量 $v_i \in U$, 将 DC 中的变量按照归属属性分类。

7)对每一个属性 $a_i \in U$, 根据式(5)计算重合率 R_i 。

8)如果 $R_i \geq \Delta R$, 则删除该属性 a_i 并更新属性集合;否则,保留该属性;转至步骤10)。

9)认为回归方程不显著,不删除属性。

10)返回新的属性集合。

假设1条航迹由10个点组成, $N = 10$ 。每个点有3

个属性值。方位为属性1,记为 a_1 ;距离为属性2,记为 a_2 ;时间为属性3,记为 a_3 。1条航迹是按照时间的先后顺序排列的10个雷达数据点,每条航迹有1个标签,对应该航迹数据记录的类型。所以,自变量的个数是30个,即 p 为30。因变量 y 为标签值,取值范围为 $\{1, 2, 3, 4, 5, 6\}$ 。故多元线性回归函数为:

$$y = b_0 + b_1x_1 + b_2x_2 + \dots b_{30}x_{30} \tag{6}$$

数据集中有21 000条数据。从数据集里随机选择1 000条数据,即取1 000条数据进行多元线性回归。 $n = 1\,000, p = 30, n - p - 1 = 1\,000 - 30 - 1 = 769, \alpha = 0.05$ 为参数设置。根据属性选择算法,计算出的参数如表3和4所示。

表3 显著性指标

Table 3 Significance indicators

r^2	F -检验值	p 值	s^2
0.418 9	32.014 7	0.000	0.594 1

表4 回归系数参数表

Table 4 Regression coefficient parameters

b_1	b_2	b_3	b_4	b_5	b_6	b_7	b_8	b_9	b_{10}	b_{11}	b_{12}	b_{13}	b_{14}	b_{15}
0.18	-1.2	0	0.37	3.23	0	-0.22	-6.90	53.4	-0.11	11.73	0	0.017	-8.18	0
b_{16}	b_{17}	b_{18}	b_{19}	b_{20}	b_{21}	b_{22}	b_{23}	b_{24}	b_{25}	b_{26}	b_{27}	b_{28}	b_{29}	b_{30}
0.108	1.96	0	-0.04	-10.5	0	0.118	24.18	0	-0.09	19.52	0	-0.2	5.72	-53

变量 v_3 对应的相关系数为0,符合删除条件,加入删除变量集合,依次类推。最终得到的删除变量集合为 $\{v_6, v_{12}, v_{15}, v_{18}, v_{21}, v_{24}, v_{27}\}$ 。这些变量归属于时间属性,计算时间属性的 $R_3 = 8/10 = 0.8 > 0.6$,故删除属性时间。属性距离的 $R_2 = 0/10 = 0 < 0.6$,保留;方位的 $R_1 = 0/10 < 0.6$,保留,故经过属性选择算法,选择属性距离和方位。

2.2 数据点空间特征提取

1个航迹点的方位和距离成对出现表示1个点迹数据,雷达数据的多个点并不独立,因此可利用航迹点迹数据之间的空间关系特征,进行航迹的识别。本文将数据点之间的距离值作为一种新的特征,即间距值特征,用于目标航迹识别,航迹点 $p_i(x_i, y_i, z_i)$ 和航迹点 $p_j(x_j, y_j, z_j)$ 之间的间距值定义为:

$$|D_{i,j}| = \sqrt{x_i^2 + x_j^2 - 2x_ix_j\cos(y_i - y_j)}, 1 \leq i \leq N - 1 \tag{7}$$

其中, $j - i = 1$ 或 $j - i = 2$;即观测相邻两点或间隔1个点的两点之间的距离值。

空间特征提取算法:首先对每一条标签化的数据进行属性提取,将第1个点到第 N 个点的3个属性分别提取出来并存储在不同的矩阵中。根据所得到的矩阵,采用式(7)对每条航迹数据进行间距值特征提取,从而计算出每条航迹的间距值。

空间特征提取算法的输入:标签化航迹数据、矩阵

$\mathbf{M}_X, \mathbf{M}_Y, \mathbf{M}_Z, \mathbf{M}_F$ 。空间特征提取算法的输出:特征值 $\mathbf{D}$ 的矩阵。算法步骤如下:

- 1)读取输入数据的行数和列数,记为 k_1 和 k_2 ;
- 2)对每一条标签化的数据进行提取,将第1个点到第 N 个点的3个属性分别提取出来并存储在 $\mathbf{M}_X, \mathbf{M}_Y, \mathbf{M}_Z$ 矩阵中;
- 3)针对矩阵 $\mathbf{M}_X, \mathbf{M}_Y, \mathbf{M}_Z$,按照行数从1到 k_1 ,根据式(7)对每一行进行间距值特征提取,计算出每一行(每条轨迹)的间距值,并存储在 $\mathbf{M}_F$ 对应的行中;
- 4)返回 $\mathbf{M}_F$ 的值,即输出 $\mathbf{M}_F$ 。

2.3 RNN 模型构建和分类识别

RNN 是一种节点定向连接成环的,主要用于处理序列数据的神经网络^[15],其展开结构如图2所示。其中, x^t 是 t 时刻的输入层的输入, h^t 是 t 时刻隐藏层神经元的输出, y^t 是 t 时刻的输出层的输出。

由图2可知,在RNN结构中,一个序列的当前输出不仅与当前时刻的输入有关,还与前一时刻输出有关。因此,隐藏层的神经元之间不再是无连接而是有连接的。各层之间的计算如式(8)~(11)。

$$h^t = f(w_{hx}x^t + w_{hh}h^{t-1} + c) \tag{8}$$

$$y^t = g(w_{yh}h^t) \tag{9}$$

$$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{10}$$




图 2 递归神经网络
Fig. 2 Recurrent neural network

$$\text{softmax}(x^t) = \frac{e^{x^t}}{\sum_{k=1}^K e^{x^k}} \quad (11)$$

式中: c 是偏置量; $f(x)$ 为 $\tanh$; $g(x)$ 为 softmax 函数。
神经元数量太少,则无法学习到较为完整的特征信息,导致分类识别准确率较差。神经元数量过多,则会增加复杂性且模型容易过拟合。经多次测试,本文构建的递归神经网络的输入层、隐藏层、输出层神经元数量分别为 128、50、128。采用式(8)计算隐藏层的神经元的输出,采用式(9)计算输出层的输出。本文采用的激活函数 $f(x)$ 为式(10)所示的 $\tanh$ 函数,优化函数 $g(x)$ 为式(11)所示的 softmax 函数。

表 5 目标航迹示例表
Table 5 Example of target track

$x_1/(^{\circ})$	y_1/m	z_1/ms	$x_2/(^{\circ})$	y_2/m	z_2/ms	L
135.148 13	26 380.602 67	16 639 000	126.892 10	23 421.677 13	16 741 000	...
325.341 81	53 430.822 37	12 978 000	325.258 58	53 571.025 63	13 078 000	...
69.508 92	10 136.493 83	16 303 000	69.076 40	11 268.614 76	16 407 000	...

表 6 用例表
Table 6 Case table

用例	1	2	3	4	5	6	7
训练集/%	70	73	75	78	80	83	85
测试集/%	30	27	25	28	20	17	15

表 6 的百分数为数据量占数据集大小的百分比。为了使实验结果更准确,对每一个用例,本文随机生成 10 组训练集和测试集。
本文将 10 组数据的平均值作为实验的最终结果,如表 7 所示。

表 7 分组表
Table 7 Group table

组号	1	2	3	4	5	...	9	10
训练集	701	702	703	704	705	...	709	710
测试集	301	302	303	304	305	...	309	310

3 实验

3.1 实验设置

本文参照文献[16]模拟雷达目标航迹方法,使用 MATLAB 仿真模拟单雷达收集到的多个飞行物的航迹数据。
1) 3 个目标飞行物。
2) 目标飞行物的航迹如表 2 所示,包括直线型、圆弧型、圆周型、椭圆型、抛物线型和 S 型 6 种航迹。
3) 航迹周期为 100 ms、航迹点时间间隔为 10 ms,也即每条目标航迹由 10 个连续航迹点组成。
4) 每个航迹点包含 3 个属性,时间、距离和方位。时间属性取值范为[10 000 000, 20 000 000]ms。空间属性距离的取值范围为[0, 100 000]m,方位范围为[0°, 360°]。
本文仿真模拟的目标航迹数据示例如表 5 所示。本文的数据集数量大小为 21 000,采用分层抽样^[17]的方式划分数据集。以数据集的 70% 作为训练集,30% 作为测试集,以随机抽取的方式从每种类别中选取 70% 的数据,汇总成为训练集,剩余的 30% 汇总为测试集。测试集和训练集用例总数为 7,每组重复 10 次实验。实验中,共划分了 7 个训练集和测试集用例,划分如表 6 所示。

算法的其他参数设置如下: $\Delta r = 0.3$, $\Delta p = 0.05$, $\Delta S = 10$, $\Delta R = 60\%$ ^[18]。本文按特征值对比了如下 4 种情况:

- 1) 原始数据雷达目标航迹数据(origin);
- 2) $D1, j - i = 1$ 时,提取到的间距值特征 1;
- 3) $D2, j - i = 2$ 时,提取到的间距值特征 2;
- 4) $D3, D3 = D1D2, D1$ 和 $D2$ 顺序排列得到间距值特征 3。

本文采用机器学习分类任务常用的 4 个评价指标评估所提算法 TRST 的性能,准确率(accuracy)、精确率(precision)、召回率(recall)、F1-Score。

准确率是分类问题中最常见的评价指标。准确率是被正确分类的样本占总样本的比值,其值的范围是[0, 1]。准确率代表模型整体的预测程度,数值越大,预测越准确。计算公式为:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

式中: TP 是真正例的数量,即模型预测为正且真实标签

为正的样本数量; FP 是假正例的数量, 即被模型预测为正且真实标签为负的样本; FN 是假负例的数量, 即被模型预测为负且真实标签为正的样本; TN 是真负例的数量, 即被模型预测为负且真实标签为负的样本。

精准率是在所有被预测为正的样本中实际为正的样本的比例, 其取值范围为 $[0, 1]$, 数值越大, 预测越精准。精准率的计算公式为:

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

召回率是在实际为正的样本中被预测为正样本的比例, 其范围为 $[0, 1]$, 数值越大, 分类效果越好。召回率的计算公式为:

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

精准率和召回率指标常常呈现出此消彼长的关系; 即精确率提高了, 召回率下降, 而召回率提高了, 精确率降低了。 $F1-Score$ 是精确率和召回率加权调和平均, 兼顾精确率和召回率。 $F1-Score$ 范围为 $[0, 1]$, 数值越大, 分类效果越好。 $F1-Score$ 的计算公式为:

$$F1-Score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (15)$$

3.2 实验结果与分析

1) 不同特征对算法性能的影响

为了验证本文所提取的特征值是否有利于目标航迹分类, 本文采用不同的特征值作为 RNN 分类器的输入, 进行航迹识别的对比实验。准确率、精确率、召回率和 $F1-Score$ 的实验结果分别如图 3~6 所示。




图3 不同输入特征的准确率

Fig. 3 Accuracy with different input features

图3所示为当输入数据是原始雷达目标点迹数据时, 识别的准确率为 50%; 当输入数据是间距值特征时 ($D1$ 、 $D2$ 或 $D3$), 目标航迹识别的准确率稳定在 97% 以上。从而说明了本文所挖掘的目标航迹的间距值特征值可有效提高雷达目标航迹的识别准确率。

图4所示为当输入数据是原始雷达目标航迹时, 精准率在 44% 左右; 当输入数据是间距值特征时, 精准率稳定在 98% 以上。从而说明了间距值特征是有效的, 可提




图4 不同输入特征的精准率

Fig. 4 Precision with different input features




图5 不同输入特征的召回率

Fig. 5 Recall with different input features




图6 不同输入特征的 $F1-Score$

Fig. 6 $F1-Score$ with different input features

升模型的精准率。图5所示为输入数据是间距值的时候, 召回率远远高于输入数据是原始雷达目标航迹数据时, 说明本文所提取的间距值特征有利于分类。图6所示为输入数据是间距值特征时, $F1-Score$ 远远高于输入数据是原始雷达目标点迹数据时, 说明本文所提取的间距值特征有利于分类。

综上所述, 本文所提取的目标航迹的间距值特征有利于目标航迹分类。图3~6表明当输入数据参数是特征 $D1$ 时, 目标航迹识别的准确率、精准率、召回率和 $F1-Score$ 都是最高的, 说明了间距值特征 $D1$ 最有利于雷达目标航迹分类识别。相比 $D2$ 、 $D3$, 间距值特征 $D1$ 是相邻两点间的间距值特征, 其空间距离比 $D2$ 和 $D3$ 短; 此外, 间距值特征 $D1$ 的时间间隔比 $D2$ 和 $D3$ 短。所以, 间距值特征 $D1$ 比 $D2$ 、 $D3$ 更有利于目标航迹分类。本文的后续实验 TRST 都采用 $D1$ 作为 RNN 的输入。

2) TRST 算法对每一类航迹的识别性能

TRST 算法对航迹识别的准确率、精确率、召回率和 $F1-Score$ 的实验结果分别如图 7~10 所示。




图 7 TRST 对不同航迹类型识别的准确率
Fig. 7 Accuracy vs. different track types




图 8 TRST 对不同航迹类型识别的精确率
Fig. 8 Precision vs. different track types




图 9 TRST 对不同航迹类型识别的召回率
Fig. 9 Recall vs. different track types




图 10 TRST 对不同航迹类型识别的 $F1-Score$
Fig. 10 $F1-Score$ vs. different track types

图 7 表明,抛物线型、弧型、椭圆型、S 型和圆周型 5

种目标航迹识别准确率达到 99% 及其以上,直线型目标识别准确率>96%。这一结果充分证明,TRST 算法可准确识别目标航迹。图 8 表明 TRST 在所有 6 类目标航迹识别的精准率均>97%,表明 TRST 算法对所有类型航迹的正样本的识别正确率都较高。图 9 表明,抛物线型、S 型和圆周型 3 种目标航迹识别的召回率为 100%,椭圆型>99%,直线型和弧型在 98% 左右,表明 TRST 算法对所有类型航迹的识别效果都很好。图 10 中 TRST 算法的 $F1-Score$ 均在 98% 以上,表明 TRST 算法在所有类型的目标航迹上都很好的完成了识别任务。

综上所述,所提算法 TRST 在每一类目标航迹上都具有优异的识别效果,从而表明了 TRST 在目标航迹识别上的有效性。

3) TRST 和其他算法的性能对比

为了验证所提算法 TRST 的性能,本文将 TRST 和其他 7 个分类算法做对比,包括 RNN、CNN、决策树 (decision tree, DecTree)、随机森林 (random forest, RF)、高斯朴素贝叶斯 (Gaussian Naïve Bayes, GauNB)、伯努利朴素贝叶斯 (Bernouli Naïve Bayes, BerNB) 和 SVM。不同算法在识别性能准确率、精确率、召回率和 $F1-Score$ 上实验结果分别如图 11~14 所示。




图 11 不同算法识别的准确率
Fig. 11 Accuracy of different algorithm recognition

图 11 表明伯努利朴素贝叶斯和 SVM 识别准确率较差,高斯贝叶斯、CNN 和 RNN 识别准确率效果一般,决策树和随机森林识别准确率较好,而本文所提算法 TRST 识别准确率最高,从而说明了 TRST 算法可有效识别目标航迹且大幅度提升准确率。图 12 中,本文所提算法 TRST 的识别精准率达到 99% 之外,远远高于其他的算法。图 13 表明 TRST 算法召回率>99%;与其他算法相比,TRST 算法大幅度提升了召回率。图 14 表明本文所提 TRST 算法的 $F1-Score$ 为 99% 左右,明显高于其他的分类算法,从而验证了本文所提算法 TRST 在目标航迹




图 12 不同算法识别的精准率

Fig. 12 Precision of different algorithm recognition




图 13 不同算法识别的召回率

Fig. 13 Recall of different algorithm recognition




图 14 不同算法识别的 F1-Score

Fig. 14 F1-Score of different algorithm recognition

识别上的良好效果。

综上所述,本文所提算法 TRST 的航迹识别性能明

显高于其他的对比算法,大幅度提高了雷达目标航迹识别的准确率、精准率、召回率和 $F1-Score$ 。雷达航迹分类是多分类问题, SVM 用于多分类问题分类效果一般较差。高斯朴素贝叶斯、伯努利朴素贝叶斯分类器,均建立在样本属性独立性假设上,而雷达目标航迹数据的各属性之间不一定独立,故采用贝叶斯分类效果较差。CNN 未考虑航迹数据的时序性和点迹数据之间的关系特征,故其识别效果不理想。虽然 RNN 考虑了航迹数据的时序特征,但未考虑点迹数据之间的关系特征,因此其识别效果仍有提高空间。决策树通常是递归选择最优属性,并根据该特征对训练数据进行分割,故取得了较好的航迹识别效果。随机森林由多个决策树组成,所以随机森林的分类识别准确率比决策树高。但是,决策树和随机森林都没有综合考虑航迹数据的时序性和点迹数据之间的关系特征,因此其航迹识别性能低于本文所提的算法 TRST。

TRST 算法在进行分类识别之前,首先对点迹数据进行正态标准化,解决了原始点迹数据的量纲差异导致分类效果较差的问题;其次,TRST 算法选择出了最有利于分类的属性,并构造了间距值特征 $D1$,以挖掘点迹数据之间的关系;此外,间距值特征是按照时间序列提取的,保留了雷达数据的时序性;最后,TRST 算法采用了适用于处理时序数据的分类器 RNN。因此,TRST 算法识别目标航迹性能良好。

4 结 论

本文针对战场雷达大数据背景下目标航迹识别问题,提出了一种基于雷达点迹数据时空关系的目标航迹识别算法。该算法首先对雷达点迹数据进行属性选择,然后挖掘点迹数据在空间关系上的间距值特征,最后构建递归神经网络进一步捕捉点迹数据的时空关系特征,实现对目标航迹的分类识别。仿真实验结果表明,本文所提算法 TRST 能有效提高目标航迹识别的准确率、精准率、召回率和 $F1-Score$ 性能。

参考文献

- [1] LEE K C. Radar target recognition by frequency-diversity RCS together with kernel scatter difference discrimination[J]. Progress in Electromagnetics Research, 2019, 87: 137-145.
- [2] 蔡德饶,张婷. 联合多分辨表示的 SAR 图像目标识别方法[J]. 电子测量与仪器学报, 2018, 32(12): 76-82.
- CAI D R, ZHANG T. Target recognition method of SAR image based on joint multi-resolution representation [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(12): 76-82.

- [3] 谢晴,张洪. SAR 图像多层次正则化增强及在目标识别中的应用[J]. 电子测量与仪器学报, 2018,32(9): 157-162.
- XIE Q, ZHANG H. Multi-level regularization enhancement of SAR images and its application in target recognition [J]. Journal of Electronic Measurement and Instrument, 2018, 32(9): 157-162.
- [4] JOU N Y. Radar target recognition using compressive backscatter[C]. 2017 IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting, 2017: 421-422.
- [5] ZHANG R, ZHANG L, WANG Y, et al. Radar target recognition based on polarization invariant[C]. 2018 12th International Symposium on Antennas, Propagation and EM Theory (ISAPE), IEEE, 2018: 1-4.
- [6] 王彩云,黄盼盼,李晓飞,等. 基于 AEPSO-SVM 算法的雷达 HRRP 目标识别[J]. 系统工程与电子技术, 2019,41(9): 1984-1989.
- WANG C Y, HUANG P P, LI X F, et al. Radar HRRP target recognition based on AEPSO-SVM algorithm [J]. System Engineering and Electronics, 2019, 41 (9): 1984-1989.
- [7] GUO Y, XIAO H, FU Q. Least square support vector data description for HRRP-based radar target recognition [J]. Applied Intelligence, 2017, 46(2): 365-372.
- [8] 袁家雯,刘文波,杨孟交,等. 基于希尔伯特黄变换的雷达 HRRP 目标识别[J]. 电子测量技术, 2018, 41(14): 78-82.
- YUAN J W, LIU W B, YANG M J, et al. Radar HRRP target recognition based on Hilbert Yellow transform [J]. Electronic Measurement Technology, 2018, 41 (14): 78-82.
- [9] CHEN J, DU L, HE H, et al. Convolutional factor analysis model with application to radar automatic target recognition[J]. Pattern Recognition, 2019, 87: 140-156.
- [10] PAN M, JIANG J, KONG Q, et al. Radar HRRP target recognition based on t-SNE segmentation and discriminant deep belief network [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(9): 1609-1613.
- [11] XU B, CHEN B, WAN J, et al. Target-aware recurrent attentional network for radar HRRP target recognition[J]. Signal Processing, 2019, 155: 268-280.
- [12] 樊玉琦,温鹏飞,许雄,等. 基于卷积神经网络的雷达目标航迹识别研究[J]. 强激光与粒子束, 2019, 31(9): 93203-1.
- FAN Y Q, WEN P F, XU X, et al. Research on radar target track recognition based on convolutional neural network [J]. High Power Laser and Particle Beams, 2019, 31 (9): 93203-1.
- [13] WENKE S, FLEMING J. Contextual recurrent neural networks[J]. Machine Learning, 2019, arXiv:1902. 03455.
- [14] 杨凤波,程然,赵丹玲. 基于多元线性回归分析和 Chan 算法的三维精确定位研究[J]. 数学的实践与认识, 2017, 47(14): 173-182.
- YANG F B, CHENG R, ZHAO D L. Research on 3D precise positioning based on multiple linear regression analysis and chan algorithm [J]. Mathematics in Practice and Theory, 2017, 47(14): 173-182.
- [15] BANERJEE I, LING Y, CHEN M C, et al. Comparative effectiveness of convolutional neural network (CNN) and recurrent neural network (RNN) architectures for radiology text report classification [J]. Artificial Intelligence in Medicine, 2019, 97: 79-88.
- [16] 李洁. 雷达原始回波数据的模拟与处理[D]. 西安:西安电子科技大学, 2014.
- LI J. Simulation and processing of radar raw echo data [D]. Xi'an: Xi'an University of Electronic Technology, 2014.
- [17] 张灵,徐章韬. 微言要义之抽样方法[J]. 数学通报, 2018(5): 27-29, 33.
- ZHANG L, XU ZH T. Sampling method for essentials of weak words [J]. Bulletin of Mathematics, 2018 (5): 27-29, 33.
- [18] 张福旺,苑会娟. 基于多元线性回归的空腹血糖影响因素分析方法[J]. 计算机科学, 2018, 45 (S2): 555-557.
- ZHANG F W, YUAN H J. Analysis of factors affecting fasting blood glucose based on multiple linear regression [J]. Computer Science, 2018, 45 (S2): 555-557.

作者简介



E-mail: yuqi.fan@hfut.edu.cn

樊玉琦, 分别在 1999 年和 2003 年于合肥工业大学获得学士学位和硕士学位, 2009 年于美国莱特州立大学获得博士学位, 现为合肥工业大学副教授, 主要研究方向为人工智能、数据资源分配及优化、云计算、物联网等。

Fan Yuqi received his B. Sc. and M. Sc. degrees from Hefei University of Technology in 1999 and 2003, Ph. D. degree from Wright State University in 2019, respectively. He is currently an associate professor at Hefei University of Technology. His main research interests include artificial intelligence, computer networks, cloud computing, IoT, etc.