

1-13-2022

Radar Emitter Signal Identification Via Distance Features

Yingkun Huang

1. College of Electrical Engineering, Southwest Jiao tong University, Chengdu 610031, China; ;

Weidong Jin

1. College of Electrical Engineering, Southwest Jiao tong University, Chengdu 610031, China; ;2. Science and Technology on Electronic Information Control Laboratory, Chengdu 610031, China;

Yan Kang

1. College of Electrical Engineering, Southwest Jiao tong University, Chengdu 610031, China; ;

Jiehao Zhu

2. Science and Technology on Electronic Information Control Laboratory, Chengdu 610031, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Radar Emitter Signal Identification Via Distance Features

Abstract

Abstract: Aiming at the problem that traditional recognition methods of radar emitter signal have low accuracy in low signal to noise ratio (SNR) environment, and are usually suitable for only several specific radar signals, *an identification approach of radar signal based on distance features is proposed. Several cluster centers are extracted via the k-means algorithm, and the Dynamic Time Warping (DTW) values between the radar signal and the cluster center are calculated respectively, which are combined as the input features of k-Nearest Neighbor (k-NN) algorithm.* The simulation results show that when the SNR is 3 dB, the identification rate of the 6 classes of radar signals is 91%. Compared to the method based on wavelet ridge-frequency cascade-feature, the proposed method also shows better recognition performance.

Keywords

radar emitter signals identification, cluster center, Dynamic Time Warping (DTW) method, k-nearest neighbor algorithm, distance features

Recommended Citation

Huang Yingkun, Jin Weidong, Yan Kang, Zhu Jiehao. Radar Emitter Signal Identification Via Distance Features[J]. Journal of System Simulation, 2021, 33(12): 2959-2966.

基于距离特征的雷达辐射源信号识别方法

黄颖坤¹, 金炜东^{1,2*}, 颜康¹, 朱劼昊²

(1. 西南交通大学 电气工程学院, 四川 成都 610031; 2. 电子信息控制重点实验室, 四川 成都 610031)

摘要: 针对传统的雷达辐射源信号识别方法在低信噪比环境下的正确率较低, 且通常只适用几种特定的雷达信号的问题, 提出一种基于距离特征的辐射源信号识别方法。使用 k -means 算法提取若干个聚类中心, 分别计算雷达信号脉冲与聚类中心之间的 DTW (Dynamic Time Warping) 度量值, 联合这些度量值作为 k 邻近算法的输入进行识别。仿真结果表明, 在信噪比为 3 dB 时, 所提方法对 6 类雷达信号的识别率达到 91%。与基于小波脊频级联特征的方法相比, 所提方法也表现出更好的识别效果。

关键词: 雷达辐射源信号识别; 聚类中心; DTW (Dynamic Time Warping) 度量方法; k 邻近算法; 距离特征

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X (2021) 12-2959-08

DOI: 10.16182/j.issn1004731x.joss.21-FZ0808

Radar Emitter Signal Identification Via Distance Features

Huang Yingkun¹, Jin Weidong^{1,2*}, Yan Kang¹, Zhu Jiehao²

(1. College of Electrical Engineering, Southwest Jiao tong University, Chengdu 610031, China;
2. Science and Technology on Electronic Information Control Laboratory, Chengdu 610031, China)

Abstract: Aiming at the problem that traditional recognition methods of radar emitter signal have low accuracy in low signal to noise ratio (SNR) environment, and are usually suitable for only several specific radar signals, an identification approach of radar signal based on distance features is proposed. Several cluster centers are extracted via the k -means algorithm, and the Dynamic Time Warping (DTW) values between the radar signal and the cluster center are calculated respectively, which are combined as the input features of k -Nearest Neighbor (k -NN) algorithm. The simulation results show that when the SNR is 3 dB, the identification rate of the 6 classes of radar signals is 91%. Compared to the method based on wavelet ridge-frequency cascade-feature, the proposed method also shows better recognition performance.

Keywords: radar emitter signals identification; cluster center; Dynamic Time Warping (DTW) method; k -nearest neighbor algorithm; distance features

引言

雷达辐射源信号(Radar Emitter Signal, RES)识别是雷达情报侦察(ELectronic INTelligence, ELINT)系统中的重要一环, 是雷达对抗首先要解决的关键性问题^[1]。其中, RES 的脉内调制方式识

别是 RES 识别的重要内容, 它可以分为有意调制(Intentional Modulation on Pulse, IMOP)识别和无意调制(Unintentional Modulation on Pulse, UMOP)识别。IMOP 是为减少拦截概率、提高抗干扰和检测能力等特殊目标而设计的, 本文的内容是提出一种

收稿日期: 2021-03-15 修回日期: 2021-08-11

基金项目: 电子信息控制重点实验室开放基金(6142105190312)

第一作者: 黄颖坤(1989-), 男, 博士生, 研究方向为雷达信号处理。E-mail: huangchen@my.swjtu.edu.cn

通讯作者: 金炜东(1959-), 男, 博士, 教授, 研究方向为智能信息处理、系统仿真与优化方法。E-mail: wdjin@home.swjtu.edu.cn

基于监督学习的 IMOP 识别方法。

大多数关于 RES 脉内调制识别地研究中^[2-7], 基于特征提取+机器学习的方法由于设计简单而受到广泛关注。该方法构建特征的方法几乎都是遵循同样的思路, 即从信号的产生机理出发, 来寻找可以表征不同调制类型的参数。这种基于信号模型的方法, 提取的参数具有明确的物理意义, 但是存在以下 2 个问题: ①过程往往需要耗费大量的时间和人力; ②融合专家经验的特征参数通常只适合几种特定的雷达信号。基于数据的自动表示学习可以很好地解决上面的问题。表示学习有各种形式, 对于深度学习而言, 表示学习指通过模型的参数矩阵来表述输入的数据。这种表示学习方法已经在许多模型识别领域获得了很好的效果。同样的, 许多被用于 RES 调制识别的深度学习模型也相继提出^[8-12]。这些方法被设计为端到端的模型, 包括深层神经网络, 如卷积神经网络(Convolutional Neural Networks, CNN)、栈式自编码器(Stack AutoEncoder, SAE)、深度置信网络(Deep Belief Network, DBN), 通过自动学习数据的表示进行决策。这些方法通常比经典的特征提取+机器学习方法获得更好的识别精度。但是, 深度学习具有“黑盒子”属性, 学习的特征难理解, 而这个特性对于雷达信号识别而言相当重要。

为了获得高精度的辐射源信号识别结果, 本文提出一种 DTW(Dynamic Time Warping)^[13-14]的距离特征(DTW-based distance Feature, DTWF)用于 RES 调制识别方法。该方法包括以下 3 个步骤: ①雷达信号重构。将每一个 RES 脉冲从时域变换到频率域, 用幅度谱重构雷达信号并且进行消噪和能量归一化处理; ②RES 特征提取。对重构后的雷达信号用 k -means 算法进行聚类, 提取每个簇的聚类中心, 计算每一个雷达信号脉冲与所有聚类中心的 DTW 距离构建特征向量; ③使用分类器进行识别。本文选择 k -NN 作为最后的决策算法, 该方法提取特征表示样本与不同类别之间的相关性。

1 雷达信号重构

1.1 消噪处理

由于不同调制类型的雷达辐射源信号存在唯一可分辨的频谱特征^[15], 所以首先对 RES 脉冲进行傅里叶变换, 以变换后的幅度谱序列作为特征提取的对象。考虑到侦察接收机接收信号不可避免受到噪声干扰, 当 SNR 过低时, 信号的波形形状严重失真。因此有必要对信号进行噪声弱化处理。在本文中, 采用一种频率域的简单消噪方法, 这里称为频率域中值消噪。

假设信号 s 经过离散傅里叶变换后为 $\{x_i, i=1, 2, \dots, n\}$, n 为信号的采样点数。由于在频率域中有效信息的能量集中在较窄的频带范围, 而噪声能量均匀分布在整个频带上, 所以可以按式(1)对信号序列进行消噪处理。假设处理后的信号序列为 $f = \{\bar{y}_i, i=1, 2, \dots, n\}$, 所以:

$$\bar{y}_i = \begin{cases} x_i - \mu, & x(i) > \mu \\ 0, & x(i) \leq \mu \end{cases} \quad (1)$$

式中: μ 为 $\{x_i, i=1, 2, \dots, n\}$ 的中值。需要注意的是, 式(1)只能抑制有效频带外的噪声。因此还需利用移动平均滤波算法抑制有效带宽内的噪声, 可以实现:

$$y_i = (\bar{y}_i + \bar{y}_{i+1} + \dots + \bar{y}_{i+n}) / n \quad (2)$$

式中: n 为滑动窗口的大小。移动平均滤波算法对序列进行平滑处理, 以达到消噪作用。

1.2 能量归一化

进行距离度量时需要先对数据进行归一化操作, 保留数据相对关系的同时, 将特征值大小限定在一个范围内。假设 $s = \{y_i, i=1, 2, \dots, n\}$ 是 RES 脉冲经过消噪处理后的表示序列, 并令 $\bar{s} = \{\bar{y}_i, i=1, 2, \dots, n\}$ 是归一化后的序列, 则 \bar{y}_i 可以通过式(3)求解:

$$\bar{y}_i = \sqrt{y_j^2 / \sum_{k=1}^n y_k^2} \quad (3)$$

式(3)将特征值限定在[0,1]范围内, 保证了距离

度量过程中可以有效的排除大特征值对真实距离的影响。图 1 是 LFM 和 BPSK 经过消噪和能量归一化后的结果,可以看出按照式(1)处理后的信号降噪效果明显。




图 1 LFM 和 BPSK 消噪前后对比
Fig. 1 Comparison of LFM and BPSK before and after denoising

2 提取 RES 特征向量

2.1 聚类中心提取

本文中,采用 k -means 算法需要先对数据进行聚类, k -means 算法是一种被广泛使用的无监督聚类方法,它具有简单、低时间复杂性的优点。这里假设将 RES 数据集 D 分为训练集 $D_{\text{train}} = \{s_i, i=1,2,\dots,N\} \in \mathbb{R}^{N \times m}$ 和测试集 $D_{\text{test}} = \{\hat{s}_i, i=1,2,\dots,M\} \in \mathbb{R}^{M \times m}$, 其中 N 为训练集的大小; M 为测试集的大小; m 为样本的特征维数。假设训练集 D_{train} 有 c 个已知的类,使用 c -means ($k=c$)对 D_{train} 进行聚类,然后提取 c 个聚类中心, k -means 的算法流程可以描述如下:

step 1: 从 D_{train} 中随机选取 c 个信号样本作为初始的聚类中心,记为 $\{\hat{t}_j, j=1,2,\dots,c\}$;

step 2: 对每一个样本 s_i , 首先计算 $\text{dis}(s_i, \hat{t}_j)$, $j=1,2,\dots,c$, 然后将 s_i 分配到距离最小的聚类中心对应的类中;

step 3: 对 c 个不同的簇类,通过 $\frac{1}{N} \sum_{s_k \in \hat{t}_i} s_k$ 重新计算聚类中心。其中, N 为分配到聚类中心 \hat{t}_j 中的信号样本个数;

step 4: 重复 step2, 3, 直至聚类中心不再变化;

step 5: 输出 c 个聚类中心 $\{t_i, i=1,2,\dots,c\}$, 替代初始的聚类中心。

其中, $\text{dis}(s_i, \hat{t}_j)$ 表示信号样本 s_i 与 \hat{t}_j 之间的距离,通常采用欧式距离来度量。另外,通过上面的 5 个步骤,可以得到 c 个聚类中心。

2.2 DTW 距离特征的构造

在许多模式分类和数据挖掘领域中,已经有大量基于数据库的特征提取研究^[16-22], 这些方法都是扩展并利用基于“质心”的方法。但是这些方法或是提取的特征之间有较高的相关性,可能无法获得最好的效果,或是面临着时间复杂度高的问题。

本文提出一种简单且有效的 RES 距离特征构建方法,并采用 DTW 作为样本相似度的度量方法。DTW 算法的求解思路是,求 2 个序列所有可能的对齐方式中最小的对齐距离。这是一个典型的动态处理问题,需要定义一个 DTW 矩阵 M 来求解。同样考虑 2 个时间序列 $Q = \{q_i, i=1,2,\dots,n\}$ 和 $C = \{c_j, j=1,2,\dots,n\}$, 则 DTW 矩阵 M 中可以通过式(4)求得

$$M(i, j) = \delta(q_i, c_j) + \min\{M(i, j-1), M(i-1, j-1), M(i-1, j)\} \quad (4)$$

式中: $\delta(q_i, c_j) = (q_i - c_j)^2$ 。得到累积矩阵 M 后,序列之间的 DTW 距离为

$$\text{DTW}(Q, C) = M(n, n) \quad (5)$$

值得注意的是,DTW 距离不要求序列 Q 和序列 C 的长度一致,这和其他大多数距离度量方法不同。基于此,本文的距离特征可以计算为

$$\text{DTWF}(s) = [\text{DTW}(s, c_1), \text{DTW}(s, c_2), \dots, \text{DTW}(s, c_k)]^T \quad (6)$$

式中: $s \in D$, 是消噪和能量归一化后的 RES 脉冲;

$\{c_1, c_2, \dots, c_k\}$ 是 k -means 算法在 D_{train} 上提取的 k 个聚类中心。如图 2 所示, 样本 p 的 DTWF 为 $[\text{DTW}(p, c_1), \text{DTW}(p, c_2), \text{DTW}(p, c_3)]^T$ 。综合上述的分析, RES 信号的距离特征提取方法总结为:

step 1: 通过规则采样获取离散信号 s 。

step 2: 对信号 s 进行重采样, 以消除信号长度对距离特征的影响。

step 3: 将重采样后的信号从时域变换到频率域, 用 1.1 节的算法对变换后的信号进行消噪处理(滑动窗口大小设置为 2)和归一化处理。值得注意的是, 由于信号的幅度谱是对称的, 因而只考虑左边的幅度谱。

step 4: 根据 k -means 算法求出训练集的若干个聚类中心(和已知类别数相同)。

step 5: 根据式(5)求出所有信号样本的距离特征矢量。





图 2 DTW 距离特征的计算例子
Fig. 2 Example of computing the DTWF


2.3 欧式距离和 DTW

当前, 最常见的距离度量方法是欧式距离, 但是欧式距离是按照时间轴进行点对点的依次计算, 对序列的移位、错位等较为敏感。如图 3 所示, 图 3(a), (b) 是四相编码信号的幅度谱, 2 个幅度谱表现出移位现象; 图 3(c) 是二相编码的幅度谱。如果按照欧式度量方法, 图 3(a), (b) 的欧式距离为 1.292 4; 而图 3(a), (c) 的欧式距离为 0.407 0, 这是典型的由于序列移位产生的度量错误的例子。


DTW 度量可以处理时间序列出现错位、移位等问题, 并且不要求序列的长度相同。同样考虑图 3 的例子, 采用 DTW 度量方法可以算出图 3(a), (b) 的 DTW 距离为 0.008 6; 而图 3(a), (c) 的 DTW 距离为 0.050 5, 比欧式度量方法获得更准确的距离值。



(a) QPSK 信号(1)



(b) QPSK 信号(2)



(c) BPSK 信号

图 3 QPSK 信号和 BPSK 信号
Fig. 3 Signal type of QPSK and BPSK

2.4 时间复杂度分析

RES 的距离特征提取方法是一种集成无监督

聚类、数据重构和相似性度量的一种自动特征提取方法。因此算法的总时间消耗可以通过分析这些机器学习技术时间复杂度得到。本文采用 k -means 算法作为算法用来提取聚类中心, k -means 算法的时间复杂度为 $\Theta(t \cdot c \cdot m \cdot N)$, 其中 t 为算法的迭代次数; c 为类别个数; m 为 RES 的采样点数(特征维数); N 为训练的大小。数据重构(采用快速傅里叶变换)的时间复杂度为 $\Theta(N \cdot m \cdot \lg m)$ 。对于本文提出的消噪和归一化处理, 它的时间复杂度是线性的, 即为 $\Theta(N \cdot m)$ 。最后对预处理后的 RES 提取距离特征, 由于 DTW 算法的时间复杂度是线性的, 即 $\Theta(N \cdot m^2)$ 。基于此, 距离特征提取方法的时间复杂度为

$$\Theta(\text{DTWF}) = \Theta(t \cdot c \cdot m \cdot N) + \Theta(N \cdot m \cdot \lg m) + \Theta(N \cdot m) + \Theta(N \cdot m^2)$$

实际中, m^2 会远大于 $t \cdot c$, 所以:

$$\Theta(\text{DTWF}) = \Theta(N \cdot m^2)$$

可见, 本文算法的时间消耗集中在相似性度量阶段。如果使用欧式距离作为度量方法, 算法的时间复杂度将变为

$$\Theta(\text{EF}) = (t \cdot c \cdot m \cdot N)$$

也即, 聚类中心的提取效率决定了特征提取消耗的时间。后续的实验与分析章节表明, 使用 DTW 可以在损失一定算法效率情况下, 可以获得比基于欧式距离度量方法更好的辐射源信号识别正确率。

对比于经典的特征提取方法, 譬如小波脊频级联特征(WRFCCF), 其算法时间复杂度由小波脊线提取算法决定。文献[7]提取的小波脊线算法时间复杂度为

$$\Theta(\text{WRFCCF}) = (t \cdot m^2 \cdot \lg m \cdot N)$$

显然, WRFCCF 的执行效率低于本文方法。

3 实验与分析

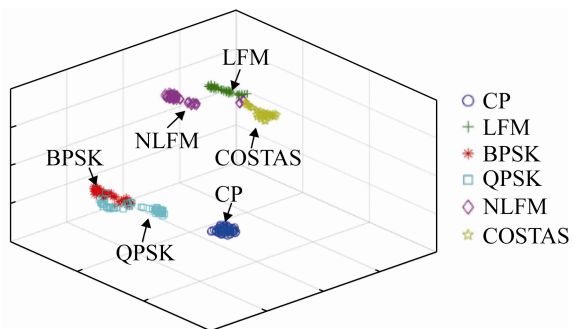
为了与文献[7]提出的小波脊频级联特征向量(WRFCCF)进行对比。仿真 6 种相同调制类型的信

号, 包括具有恒定频率的常规信号(CW)、线性调频信号(LFM)、二相编码信号(BPSK)、四相编码信号(QPSK)、二进制频率编码信号(BFSK)、非线性调频信号(NLFM)。其中, BPSK 和 BFSK 采用 13 位 Barker 码; QPSK 采用 16 位 Frank 码。LFM 的频率变化范围是 10~15 MHz; NLFM 采用正弦波调制; BFSK 信号的 2 个频点分别为 10 MHz 和 2 MHz, 其他信号样式的载频为 10 MHz。考虑实际存在的测量误差, 将载频的均方根误差设置为 1 MHz。各辐射源信号的脉宽都为 10 μ s, 采样频率为 60 MHz。本文的实验都在 Matlab R2015b 平台下完成的。


本实验构造这样一组仿真数据: 在 10~15 dB 的信噪比范围内, 每种信号随机产生 20 个脉冲, 总计 120 个脉冲信号作为分类器的训练样本。同时, 分别在 3, 6, 9, 12, 15 dB 信噪比下各仿真 360 个脉冲信号作为测试样本, 其中, 每一种信号各 60 个脉冲作为测试样本。图 4 是在信噪比为 9 dB 时, 基于 DTW 距离特征和基于 WRFCCF 的数据分布图(本文使用 t -SNE 方法^[23]将 6 维的数据映射到 3 维的向量空间中进行可视化)。

从图 4 可以看出, 除了 BPSK 信号和 QPSK 信号出现部分重叠无法分开外, DTW 距离特征的类内聚集性和类间分离性都较好, 并且是优于 WRFCCF。所以, WRFCCF 的类别可分性较 DTW 距离特征要差。

为了测试 DTW 特征的识别性能, 本文选用 k -NN 分类器进行测试。 k -NN 分类器的基本思想是: 输入一个待分类新数据, 首先与训练集中的每一个数据进行比较, 然后提取 k 个最相似的数据对应的类标签, 统计这 k 个最相似数据中出现次数最多的类别, 将其作为新数据的类别。在许多时间序列分类的问题上, 使用 k -NN 分类器通常能得到较好的效果。在接下来的所有仿真实验中, 设置 $k=1$ 。表 1 是基于 DTW 特征的 6 类雷达信号在信噪比 3~15 dB 的识别效果。



(a) 基于 DTW 距离特征的数据分布



(b) 基于 WRFCCF 的数据分布

图 4 信噪比为 9 dB 时 6 类信号的三维数据分布图
Fig. 4 Three-dimensional data distribution of 6 classes of signals when SNR=9 dB

表 1 基于 DTW 距离特征的识别结果

信号类型	信噪比 SNR/dB				
	3	6	9	12	15
LFM	98.33	100	100	100	100
CW	100	100	100	100	100
BPSK	80	90	98.33	100	100
QPSK	81.67	76.67	85	95	96.67
BFSK	98.33	98.33	96.67	98.33	100
NLFM	90	98.33	100	100	100
识别率	91.39	93.89	96.67	98.89	99.44

从表 1 中可以看出 LFM 信号、CP 信号、BFSK 信号和 NLFM 信号在低信噪比下仍然表现出良好的识别性能，而 BPSK 信号和 QPSK 信号在低信噪比下识别率较差。这是因为在频率域中，BPSK 信号和 QPSK 信号的幅度谱非常相似，在受到噪声的影响下，DTW 方法也是难以得到正确的距离值。表 2 是基于 WRFCCF 的识别正确率。

表 2 基于 WRFCCF 的识别结果

信号类型	信噪比 SNR/dB				
	3	6	9	12	15
LFM	88.33	86.67	96.67	98.33	96.67
CW	81.67	63.33	71.67	88.33	95
BPSK	60	85	85	85	95
QPSK	71.67	73.33	76.67	96.67	95
BFSK	70	78.33	78.33	90	88.33
NLFM	73.33	68.33	95	98.33	100
识别率	74.17	75.83	83.89	92.27	95

通过对比表 1, 2 的识别结果，可以明显看出，基于 DTW 距离特征的识别性能优于基于 WRFCCF 的识别性能。

进一步的，本文对比文献[14]中提出的距离特征(Distance Sum-based)，该方法被应用在时间序列分类问题上。为了便于描述，将该特征表述为“DSF”。考虑一个数据样本 s ，则它的 DSF 特征定义为：

$$DSF(s) = \sum_{i=1}^k ED(s, c_i) - ED(s, c_i)$$

表 3 是 DSF 和 DTW 距离特征在 6 类仿真信号(测试集包含信噪比在 3~15 dB 之间的所有样本，总计 1 800 个样本)上的总体识别率对比。从表 3 可以很明显地看出，本文提出的基于 DTW 距离特征的雷达信号识别方法获得了更好的性能。

表 3 DSF 和 DTW 距离特征的识别结果对比

分类方法	平均识别率
DTWF+1NN	96.06
DSF+1NN	84.72

4 结论

本文提出了一种基于 DTW 距离特征的雷达信号识别方法，并通过仿真 6 种典型雷达信号进行实验，结果显示：本文方法所得到的特征在类内聚集性和类间分离性两方面都好于文献[7]中提出的特

征,并且在雷达信号识别正确率上也要优于文献[7]的方法。进一步的,本文还对比了文献[14]提出的距离特征在雷达信号识别上的性能,并获得了更好的性能。实验结果表明,本文的方法在仿真数据集上获得更好的识别性能。因此,本文的方法具有较好的参考价值。本方法要计算序列的 DTW 距离,所以在高维数据集上有较高的时间复杂度。因此,进一步研究高效率的距离度量方法代替 DTW 是一个值得研究的方向。

参考文献:

- [1] 候印鸣. 综合电子战[M]. 北京: 国防工业出版社, 2000: 1-32.
Hou Yinming. Synthetic EW[M]. Beijing: National Defense Industry Press, 2000: 1-32.
- [2] Pang J, Lin Y, Xu X. The Improved Radial Source Recognition Algorithm Based on Fractal Theory and Neural Network Theory[J]. International Journal of Hybrid Information Technology (S2511-2104), 2014, 7(2): 397-402.
- [3] Zhang X L, You W T, Guo Q, et al. Recognition Method Studies for Radar and Communication Signals based on Spectral Correlation[C]// International Symposium on Systems and Control in Aeronautics and Astronautics. Piscataway, USA: IEEE Press, 2010: 363-366.
- [4] Guo Q, Nan P, Zhang X, et al. Recognition of Radar Emitter Signals Based on SVD and AF Main Ridge Slice[J]. Journal of Communications and Networks (S1229-2370), 2015, 17(5): 491-498.
- [5] Li Y, Wang Y, Lin Y. Recognition of Radar Signals Modulation Based on Short Time Fourier Transform and Reduced Fractional Fourier Transform[J]. Journal of Information and Computational Science (S1548-7741), 2013, 10(16): 5171-5178.
- [6] Konopko K, Grishin Y P, Jańczak D. Radar Signal Recognition based on Time-frequency Representations and Multidimensional Probability Density Function Estimator[C]// Signal Processing Symposium. Debe, Poland: IEEE Press, 2015: 1-6.
- [7] 余志斌, 金炜东, 陈春霞. 基于小波脊频级联特征的雷达辐射源信号识别[J]. 西南交通大学学报, 2010, 45(2): 290-295.
Yu Zhibin, Jin Weidong, Chen Chunxia. Radar Emitter Signal Recognition based on WRFCCF[J]. Journal of Southwest Jiaotong University, 2010, 45(2): 290-295.
- [8] Wang C, Wang J, Zhang X. Automatic Radar Waveform Recognition based on Time-frequency Analysis and Convolutional Neural Network[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. New Orleans, USA: IEEE Press, 2017: 2437-2441.
- [9] Zhang M, Diao M, Guo L. Convolutional Neural Networks for Automatic Cognitive Radio Waveform Recognition[J]. IEEE Access (S2169-3536), 2017, 5(6): 11074-11082.
- [10] Zhou Z, Huang G, Chen H, et al. Automatic Radar Waveform Recognition Based on Deep Convolutional Denoising Auto-encoders[J]. Circuits Systems and Signal Processing (S0278-081X), 2018, 37(1): 1-15.
- [11] 周志文, 黄高明, 高俊, 等. 一种深度学习的雷达辐射源识别算法[J]. 西安电子科技大学学报, 2017, 44(3): 85-90.
Zhou Zhiwen, Huang Gaoming, Gao Jun, et al. Radar Emitter Identification Algorithm based on Deep Learning[J]. Journal of Xidian University, 2017, 44(3): 85-90.
- [12] Zhang M, Diao M, Gao L, et al. Neural Networks for Radar Waveform Recognition[J]. Symmetry (S2073-8994), 2017, 9(5): 75.
- [13] Wan Y, Chen X L, Shi Y. Adaptive Cost Dynamic Time Warping Distance in Time Series Analysis for Classification[J]. Journal of Computational and Applied Mathematics (S0101-8205), 2017, 319(8): 514-520.
- [14] Zhang Z, Tavenard R, Bailly A, et al. Dynamic Time Warping Under Limited Warping Path Length[J]. Information Sciences (S0020-0255), 2017, 393(7): 91-107.
- [15] 余志斌. 基于脉内特征的雷达辐射源信号识别研究[D]. 成都: 西南交通大学, 2010.
Yu Zhibin. Study on Radar Emitter Signal Identification based on Intra-pulse Features[D]. Chengdu: Southwest Jiaotong University, 2010.
- [16] Tsai C F, Lin W Y, Hong Z F, et al. Distance-based Features in Pattern Classification[J]. Eurasip Journal on Advances in Signal Processing (S1687-6172), 2011(1): 1-11.
- [17] Guo C, Zhou Y, Ping Y, et al. A Distance Sum-based Hybrid Method for Intrusion Detection[J]. Applied Intelligence (S0924-669X), 2014, 40(1): 178-188.
- [18] Lin W C, Ke S W, Tsai C F. CANN: An Intrusion Detection System Based on Combining Cluster Centers and Nearest Neighbors[J]. Knowledge-Based Systems

- (S0950-7051), 2015, 78(1): 13-21.
- [19] Kate R J. Using Dynamic Time Warping Distances as Features for Improved Time Series Classification[J]. Data Mining and Knowledge Discovery (S1384-5810), 2015, 30(2): 1-30.
- [20] Hall P, Pham T. Optimal Properties of Centroid-based Classifiers for Very High-dimensional Data[J]. Annals of Statistics (S0090-5364), 2010, 38(2): 1071-1093.
- [21] Mori U, Mendiburu A, Keogh E, et al. Reliable Early Classification of Time Series Based on Discriminating the Classes Over Time[J]. Data Mining and Knowledge Discovery (S1384-5810), 2016, 31(1): 1-31.
- [22] Mei J, Liu M, Wang Y F, et al. Learning a Mahalanobis Distance-based Dynamic Time Warping Measure for Multivariate Time Series Classification[J]. IEEE Transactions on Cybernetics (S2168-2267), 2016, 46(6): 1363-1374.
- [23] Pérezgonzález A, Vergara M, Sanchobru J L, et al. Visualizing Data Using t-SNE[J]. Journal of Machine Learning Research (S1532-4435), 2008, 9: 2579-2605.