

引用格式:胡苏,马,上,林迪,等.基于射频指纹技术的卫星信号个体识别方法[J].信息对抗技术,2022,1(1):55-61. [HU Su, MA Shang, LIN Di, et al. Identification of individual satellite signal based on radio frequency fingerprint technology[J]. Information Countermeasure Technology, 2022, 1(1):55-61. (in Chinese)]

基于射频指纹技术的卫星信号个体识别方法

胡苏*,马,上,林迪,吴薇薇

(电子科技大学通信抗干扰技术国家级重点实验室,四川成都 611731)

摘要 现有射频指纹识别研究主要集中于射频指纹产生及提取的通信机理,忽略了实际应用中信号采集数据的清洗筛分、识别算法模型的效率等工程性问题。为此,分析了卫星通信信号的载波信息提取的原理与方法,并针对现有射频指纹方法的不足,围绕卫星信号识别领域,利用海量采集的射频指纹数据,深入研究基于自组织神经网络的射频指纹识别算法,提出了对应的算法模型,并与现有常见的无监督算法进行了比较。结果表明,所提方法可以取得更优的算法聚类效果和时间开销,可作为设计实现卫星频谱管理系统的基础。

关键词 射频指纹;卫星通信;信号识别;聚类算法

中图分类号 TP 919 **文献标志码** A **文章编号** 2097-163X(2022)01-0055-7

DOI 10.12399/j.issn.2097-163x.2022.01.005

Identification of individual satellite signal based on radio frequency fingerprint technology

HU Su*, MA Shang, LIN Di, WU Weiwei

(National Key Lab on Communications University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract Current research on radio frequency(RF) fingerprint recognition mainly focuses on the communication mechanism of RF fingerprint generation and extraction, but ignores engineering problems such as the efficiency of data cleaning and recognition models in practical applications. Aiming at these shortcomings, this paper analyzed the principles and methods for extracting carrier signal information of satellite communication signals. Focusing on the field of satellite signal recognition, This paper used the massively collected RF fingerprint data, deeply studied the RF fingerprinting algorithm based on self-organizing neural networks, and proposed the corresponding algorithm model. In comparison with unsupervised algorithms, our proposed algorithm can achieve a higher clustering accuracy and lower time cost, and could be used as the basis for the design and implementation of a satellite spectrum management system.

Keywords RF fingerprint; satellite communication; signal identification; clustering algorithm

收稿日期:2022-03-13

修回日期:2022-04-10

通信作者:胡苏, E-mail: husu@uestc.edu.cn

作者简介:胡苏(1983—),男,博士,教授,博士研究生导师,教育部青年长江学者,研究方向为无线通信与信号处理;马,上(1978—),男,博士,研究员,博士研究生导师,研究方向为通信与信号处理;林迪(1985—),男,博士,副教授,研究方向为人工智能与大数据;吴薇薇(1984—),女,博士研究生,研究方向为射频指纹识别

基金项目:国家自然科学基金资助项目(61971092);四川省杰出青年科技人才基金资助项目(2020JDJQ0023)

0 引言

随着现代科学技术的进步,电子系统在战场敌我态势监视、控制指挥、武器协调、信息通信等环节发挥了越来越重要的作用。作战平台或武器系统与其使用的电磁信号辐射设备存在着映射对应关系,通过对其使用的电磁信号辐射设备的个体特征进行辨识,既可以确定辐射设备个体,也可以据此有效地辨识作战平台或武器系统目标个体^[1]。基于射频指纹的个体识别,由于不需要掌握对方着力保护的通信协议和加密方式就能够进行目标个体识别,因此有着广泛的战场应用前景。

20世纪80年代中期,美国工程师 Phil Ferrell 为了对抗非法信号,提出通过和已知身份用户的信号进行比较来识别非法信号的方法,利用对讲机系统特有的静噪功能的输出作为信号起始点,采集 VHF/UHF(very high frequency/ultra high frequency),FM(frequency modulation)信号起始阶段 200 ms 区间内的 2 048 个瞬时频率样点(即开机瞬态信号),然后进行平均和滤波,最终显示和记录 64 个超级采样点作为发射机指纹^[2]。该方法于 1987 年申请了专利,对应产品被联邦通信委员会(federal communications commission,FCC)用于空口监测。该系统可以工作在一125 dBm 的接收信号强度下,且幅度和多径对于系统性能影响不大,即使是同一个型号的对讲机也存在显著的差异。

此外,在 20 世纪 90 年代,由美国 AT&T 开发的第一代蜂窝电话系统标准——高级移动电话系统(advanced multi-physics simulation, AMPS)面临着严峻的“蜂窝电话克隆”问题。攻击者采用特制的设备可以截取 AMPS 设备的电子序列号(electronic serial number,ESN)和移动标识码(mobile identification number,MIN),然后复制和克隆到一个不同的手持电话,从而进行免费通信呼叫^[3]。为此,海盗船通信公司(corsair communications)建立了名为 PhonePrint 的射频指纹识别系统^[4],它可以识别一部电话和另一部电话信号(包括开启瞬态、稳态和关闭瞬态部分)的细微区别,从而切断一些克隆者的电话,并且对于如何解决符号间干扰、深衰落、低信噪比等一系列实际系统中会遇到的问题也做了大量的研究。另外,蜂窝技术服务公司等也研究了一些结合呼叫

号码、基于模糊分类器等的指纹识别技术。

经过多年的研究,基于射频指纹的辐射源个体识别技术的发展主要分为 3 个阶段:基于统计学、基于机器学习和基于深度学习,如图 1 所示^[5]。与前 2 个阶段相比,因为深度学习识别技术可以突破专家经验限制,使机器从原始数据中自动提取特征,所以当前识别技术正在向第三阶段发展。

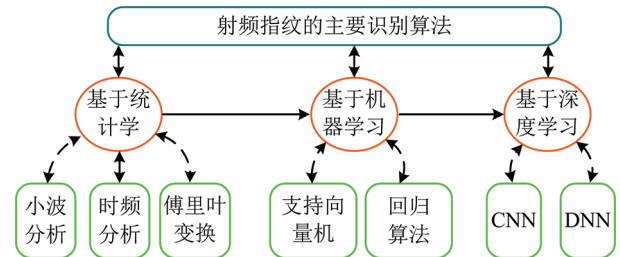


图 1 射频指纹识别算法框架

Fig. 1 RF fingerprinting algorithm framework

近年来,随着深度学习方法的兴起,利用深度神经网络模型从原始信号样本中直接提取数据的深层特征成为可能。在综合考虑通信信号局部和时序特征的情况下,现有研究提出了将 CNN(convolutional neural networks)和 LSTM(long short-term memory)网络进行异构融合,成为卷积长短时记忆全连接深度网络(convolutional long short-term memory fully connected deep neural networks,CLDNN)的方法,提升了信号识别分类的性能。可见,深度学习模型的应用一定程度上使得信号识别领域研究进入第三阶段。

尽管射频指纹识别在国内外学术领域有广泛研究,但在工程实践上还没有推出实际应用产品。本文着重从工程化应用角度,考虑信号宽带实时采集、射频指纹的快速识别等实际要求,对射频指纹的个体智能识别原型系统进行设计。

1 卫星信号宽带采集

结合现有卫星转发器、地面接收天线和变频器技术状态,为了实时获取卫星大数据,设计了宽带实时采集分析设备。通过实时宽带采集和分析,提取带宽范围内所有载波特征,形成数据库,供后续离线卫星大数据分析,其基本原理和系统构成如图 2 所示。

接收天线与变频单元和实时采集与信号特征提取单元部署在采集对象波束覆盖范围内,通

过长时间的信号采集并实时提取目标频段内所有载波特征信息,将海量的采样数据压缩形成数据库,累积一定时长后通过离线卫星大数据分析单元进一步分析数据特征及规律。为了实现高动态范围和较好的信号接收质量,目前大量装备的电磁频谱空间监测、信号侦察和分析设备均基于窄带扫频方式实现,系统实时带宽通常在 100 MHz 以下。这种分时扫描获取宽带频谱数据的方法对短猝发、时分多址等信号的检测较为困难,而这类卫星通信信号往往具有高价值特征。因此,宽带化的信号采集设备在卫星通信信号监测、卫星大数据获取中具有重要作用。

2 载波信息提取原理与方法

2.1 载波信息提取总体原理

传感器通过宽带数据的采集,实时提取宽带内的所有载波信息,包括 4 大类数据:实时提取的载波引导信息、载波精细参数、载波指纹特征和频谱快照。其基本原理如图 3 所示。除天线、射频及高速采样外,载波信息提取系统用于信号分析的单元主要包括了 2 个部分:(1) 基于大规模现场可编程逻辑门阵列(field programmable gate array, FPGA)的高速信号处理单元;(2) 基于高性能计算机的信号处理、控制、显示及存储单元。




图 2 宽带采集与卫星大数据分析原理框图

Fig. 2 Block diagram of broadband acquisition and satellite big data analysis

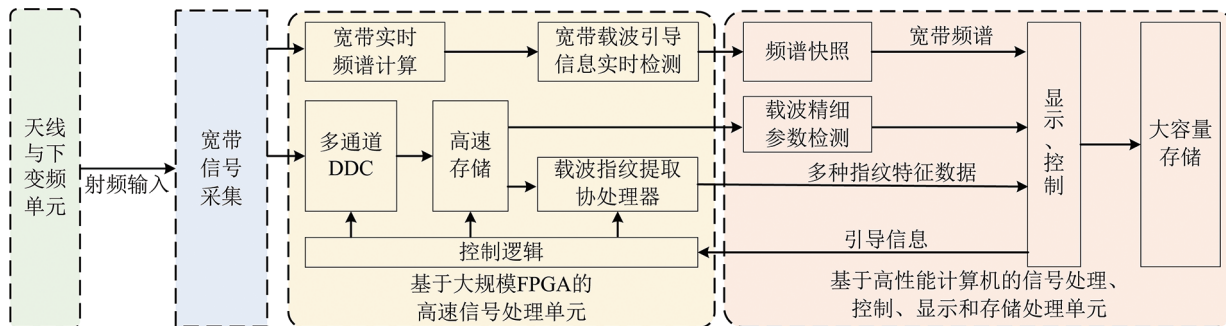


图 3 载波信息提取原理总体框图

Fig. 3 Overall block diagram of carrier information extraction principle

宽带实时频谱实时输出带宽范围内的频谱,通过宽带载波引导信息实时检测单元输出中心频率、带宽、时分多址(time division multiple access, TDMA)、载噪比等信息及一定时长内的频谱累积结果,并发送到计算机系统。计算机系统根据接收到的快速载波引导信息,控制高速信号处理单元中的多通道直接数字控制器(direct digital control, DDC)、存储单元、载波指纹特征提取协处理器、调试识别协处理器等模块,根据设定规则完成载波特征信息的快速提取。同时,更为精确的载波参数测量,包括精确频点、带宽、调制方式、符号率、编码方式、交织方式、扰码方式等信息的提取,则由计算机系统完成。最后,将所有检测单元的检测结果数据以及按一定时间间隔抽样的频谱快照数据存入到大容量存储系统中,供后续的离线大数据分析。

2.2 载波引导参数提取

传感器载波引导参数的测量在大规模 FPGA 实时信号处理模块中实现,目的是对全带宽内的载波实时监测,避免传统扫频方式带来突发或 TDMA 信号漏检的问题。引导参数检测结果被报送至计算机系统,计算机系统完成复杂的调度算法,对设定载波重点监控以及控制全部载波的信息分时提取。

载波的准确检测依赖于 2 个关键技术,一是检测算法,二是基于 FPGA 的实时监测架构。本文提出了基于形态学的噪底展平双门限低载噪比检测算法以及基于 FPGA 的可变参数并行检测实现结构,检测算法取得了良好的检测效果,在 3 和 5 dB 载噪比测试中分别获得了 98% 和 100% 准确率,而灵活的并行检测实现架构可以匹配任意射频结构和信号交叠方案。待检测的

原始频谱如图4所示,经噪底展平后的检测结果如图5所示,可见传感器具有优秀的载波检测能力(图中A表示Power/frequency)。

2.3 载波精细参数提取

精确的载波参数更有利于大数据分析中不同维度的聚类、识别、判证等分析。载波引导参数的目的是实现载波精细测量的引导,其精度相对较低,而载波精细参数的测量则可以准确获取载波的中心频率、带宽、调制方式、符号率、编码方式、交织方式、扰码方式等一系列参数,其基本原理如图6所示。计算机系统通过引导参数,按照设定策略对重点载波或全部载波进行轮询,控制采集设备多通道数字下变频模块,获得需要测量的载波数据,并存入宽带高速存储器中。然后将存储器中的DDC数据读取到计算机系统,完成信号和信息级的载波信息提取,形成数据记录并存入数据库中。在信号级处理中,主要由载波的高阶累积量和频谱形状特征来实现调制识别、频偏估计和符号率估计,为后续信息级处理奠定基础。信息级处理首先进行载波解调,包括同步、定时等流程,然后解调出载波承载的信息比特,并完成信道编码、扰码、帧格式、交织方式等识别。所有信号和信息级的处理结果按照一定格式生成原始数据记录并存入大容量存储单元中。




图4 待检测的原始频谱

Fig. 4 Original spectrum to be detected




图5 检测结果

Fig. 5 Test results




图6 载波参数精细测量原理框图

Fig. 6 Block diagram of fine measurement of carrier parameters

2.4 载波指纹特征提取

载波的指纹特征可以对目标个体进行区分,从而实现更高层次出联信息的获取,在现代信号侦察中具有越来越重要的地位^[6]。为了提高指纹特征信息提取的实时性,传感器基于硬件方式实现了20种指纹特征的提取,取得了较好的识别效果。指纹特征提取原理如图7所示。提取得到的信号射频指纹特质包括:引导中心频率、3 dB带宽、幅度均值、幅度方差、三阶中心矩、四阶中心矩、幅度对称度、盒维数因子、信息维数、功率谱均值、功率谱方差、功率谱三阶中心矩、功率谱四

阶中心矩、幅度偏度、幅度峰度、高阶矩 R 、高阶矩 J 、盒维数、功率谱偏度、功率谱峰度等。




图7 载波指纹特征提取原理框图

Fig. 7 Block diagram of carrier fingerprint feature extraction

由计算机模块根据引导参数,将载波数据存储在高速存储器中,完成数据获取。然后在硬件中实现载波的时域幅度、频谱、统计特征和分形维数特征的提取,形成数据记录并存入数据库中。

3 基于自组织神经网络的射频指纹聚类算法

针对数据库中的射频指纹高维特征,本文采用自组织神经网络(self-organizing network, SOM)对指纹特征进行聚类,以获取重点信号发射设备的身份识别^[7]。相较于 K-means 等聚类算法,该模型无需提前确定 K 值,故不用迭代搜索参数 K 的值。当训练数据量非常大时,自组织神经网络可以有效地节约聚类算法的时间成本。

由于传统自组织神经网络的结构是固定的,因此在训练过程中无法动态改变竞争层的神经元数量,只有通过设置网络规格的初始值为某一固定的经验值。如果神经元数量过多,则会影响网络收敛性^[8];如果速度太小,则无法完全表征数据分布规律。基于主观评价标准生成的 SOM 网络规模不适合处理实时数据和非固定数据集,不能满足电台源设备识别功能的实时性要求^[9]。为解决此问题,本文提出通过一种自适应的方式,在网络训练时动态确定网络的形状和大小,即动态自组织映射模型(growing self-organizing map, GSOM)。通过对 GSOM 网络的训练,实现关键信号特征动态增长,确保当前关键信号中心频率上通信的射频发射器数量的自适应变化。此外,GSOM 算法通过对相邻集合中节点数量的抑制,修正达到相邻阈值的竞争神经元,避免网络过度生长。

3.1 GSOM 生长阶段

在 GSOM 网络生长期间,神经元的权重值会进行迭代。计算输入向量 \mathbf{x}_i 和竞争神经元权重向量 $\mathbf{w}_j(t)$ 间的欧氏距离 $d_j(t)$,得到最接近输入向量的权重向量 $\hat{\mathbf{w}}_j$,将 $\hat{\mathbf{w}}_j$ 与 \mathbf{x}_i 间的欧氏距离叠加到 $T_{TE_j}(t)$ 上,

$$T_{TE_j}(t+1) \leftarrow T_{TE_j}(t) + \sqrt{\sum_{k=1}^N (\mathbf{X}_{ik} - \hat{\mathbf{w}}_{jk}(t))^2} \quad (1)$$

在每轮次神经元权重更新结束后进行判定:

(1) 当 $T_{TE_j}(t)$ 超过阈值 $G_T(t)$ 时,表明神经网络的神经元较少,需要将网络边缘的神经元向量分散到新增的神经元中,权值为当前所有神经

元权重的均值。

(2) 当 $T_{TE_j}(t)$ 低于阈值 $G_T(t)$ 时,网络对最接近输入向量的权重向量进行更新,更新的公式如下:

$$\mathbf{w}_j(t+1) = \begin{cases} \mathbf{w}_j(t), & j \notin N_{t+1} \\ \mathbf{w}_j(t) + \alpha(t)d_j(t), & j \in N_{t+1} \end{cases} \quad (2)$$

式中, $\alpha(t)$ 为学习率,取值为 $(0, 1]$, 当 $t \rightarrow \infty$ 时, $\alpha(t) = 0$ 。 N_{t+1} 为第 $t+1$ 轮中神经元 $\hat{\mathbf{w}}_j$ 的领域神经元。

阈值 $G_T(t)$ 决定了何时启动新神经元增长,同时也决定要生成的映射网络的扩展量。当 $G_T(t)$ 较大时,收敛速度变快,但只能实现较为粗糙的聚类效果;当 $G_T(t)$ 较小时,网络生长量增加,收敛速度变慢的同时也提高了聚类的精度。阈值 $G_T(t)$ 可使用时间衰变的方法进行更新如下:

$$G_T(t+1) = \frac{N(1 - S_{SF})^2}{1 + 1/t} \quad (3)$$

式中, N 表示向量 \mathbf{x}_i 的维度, t 表示迭代轮次; S_{SF} 为扩展因子,可衡量生长阈值 $G_T(t)$ 动态变化的尺度, S_{SF} 的取值为 $(0, 1]$ 。此方法可保证 $G_T(t)$ 取值随 S_{SF} 增大而减小。同时, $1 + 1/t$ 使得 $G_T(t)$ 的初始值较小,可保证网络快速生长。

3.2 GSOM 平滑修正阶段

GSOM 平滑修正阶段发生在网络训练的新神经元增长阶段之后,当新神经元增长饱和时增长阶段停止,这可以通过设置神经元增长频率阈值来识别^[10]。一旦神经元点生长阶段完成,网络训练进入平滑修正阶段,神经元权重更新将以较低的学习率继续进行,在此阶段不会添加新节点。该阶段目的是平滑任何现有的量化误差,尤其是在生长阶段后期生长的节点中。在平滑阶段,网络的输入与增长阶段的输入类似,但平滑阶段的起始学习率小于生长阶段且学习率的衰减率较小,因为权重值不应该在不收敛的情况下波动太大。同时将胜出神经元邻域宽度 $\sigma(t)$ 设置为 1(即胜出神经元的直接邻域),避免神经元权重值更新范围过大。输入数据被反复输入网络直到实现收敛,当竞争层与输入数据集之间的误差值变得非常小时,平滑阶段停止。

当网络训练的新神经元生长饱和时,即刻进入平滑生长校正阶段,神经元权重更新将以较低的学习率继续。此阶段的目的是在后期生长的

节点中消除量化误差。在网络平滑阶段,其输入与成长阶段类似,但初始学习率远小于成长阶段,且学习率的衰减率较小。在没有收敛的情况下,权重值不应波动太大。同时,将神经元的直接邻域设置为1,以避免神经元权重值的更新范围过大。当竞争层和输入数据集之间的误差较小时,平滑阶段停止。

4 基于射频指纹的信号识别与活动规律分析

卫星信号中,同一中心频率和同一带宽的信号,可能由多个用频设备发射得到。仅使用频谱图中的中心频率和带宽,难以识别不同信号发射设备间微小的差异,故需要采用射频指纹参数识别不同设备间的差异。通过提取检测信号数据的相关特征,得到包括幅度均值、幅度方差、二阶矩、四阶矩等共计20个特征维度,这些特征之间存在共线性,直接代入模型会存在过拟合等情况,导致模型的聚类准确度降低。因此,首先对20个特征进行主成分分析,将20维特征降低到5~10维,并根据主成分变量的信息熵比例,选取信息熵比例最高的主成分变量带入模型。

对于主成分变量,采用GSOM方法进行聚类分析。将同一中心频率和带宽信号对应的所有记录带入到模型中,从而得到聚类结果分布于 K 簇中。 K 的取值为某信号的用频设备数量,簇内记录为对应设备的使用情况。例如,当 $K=3$ 时,某中心频率和带宽的信号,对应3个用频设备。

4.1 目标信号的射频指纹分析

4.1.1 目标信号1的射频指纹分析

采用主成分分析(principal component analysis, PCA),提取出信号1的2个主要成分变量,记为特征1和特征2,均为20个原始特征的线性组合。基于特征1和特征2,通过聚类,将信号记录分到3簇之中,如图8所示。

4.1.2 目标信号2的射频指纹分析

采用PCA,提取出信号2的2个主要成分变量,记为特征1和特征2,均为20个原始特征的线性组合。基于特征1和特征2,通过聚类,将信号记录分到5簇之中,如图9所示。

4.2 基于GSOM算法的信号识别实验结果

本实验通过对特征聚类分析,形成相应的簇来标注不同射频信号发射端,以此构建设备射频指纹识别的数据集。对于原始信号中指纹特征

的20个字段,采用PCA进行特征降维,减少GSOM网络的输入维度以降低计算资源消耗。PCA算法重构特征后,需要选择保留的新特征维数 K 。为了评估 K 值聚类的影响,使用戴维森堡丁指数进行评估^[11],其定义如下:

$$D_{DBI} = \frac{1}{N} \sum_{i=1}^N \max_{j \neq i} \left(\frac{\bar{S}_i - \bar{S}_j}{\omega_i - \omega_{j_2}} \right) \quad (4)$$

式中, \bar{S}_i, \bar{S}_j 表示簇内数据到质心的平均距离, $\omega_i - \omega_{j_2}$ 表示簇间欧式距离。从式(4)可以看出DBI度量每个簇类最大相似度的均值。将 K -means和自编码器算法作为基准算法,衡量GSOM的聚类表现效果,实验结果如表1所示。

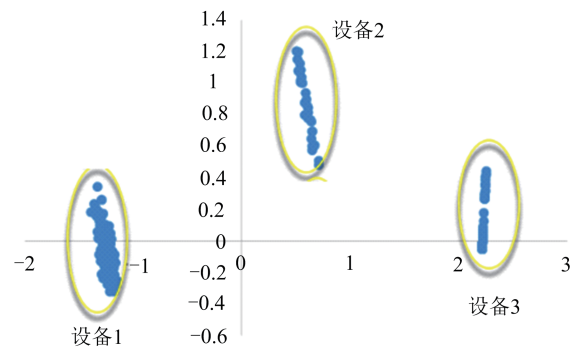


图8 目标信号1的射频指纹分簇

Fig. 8 RF fingerprint clustering of target signal 1

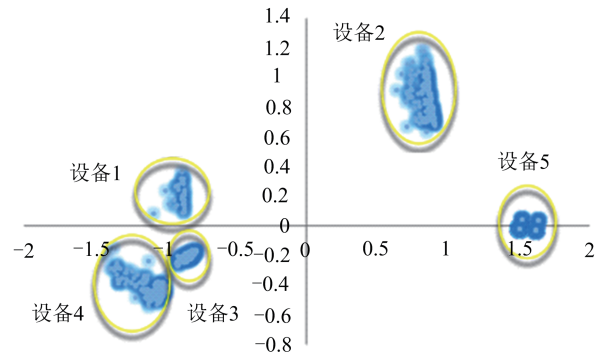


图9 目标信号2的射频指纹分簇

Fig. 9 RF fingerprint clustering of target signal 2

实验结果表明,PCA保留的特征维数过多时,聚类效果变差,这是由于过于冗余的特征维数会增加GSOM竞争层获胜的难度。当 $K=4$ 时,GSOM的聚类效果最佳,故PCA算法保留的信号指纹特征维数设置为4。为衡量GSOM算法聚类效果和时间开销,对比GSOM算法和常见无监督算法的聚类表现,如 K -means、DBSCAN(density based spatial clustering of applications with noise)、自编码器、原始SOM等,实验结果如表2所示。

表 1 PCA 降维保留维数对比验证结果 (DBI)

Tab. 1 Results of PCA dimensionality reduction (DBI)

K	$K=2$	$K=3$	$K=4$	$K=5$	$K=6$	$K=7$	$K=8$	$K=9$	$K=10$
K -means	0.4278	0.5243	0.2680	0.3496	0.4528	0.5154	0.5436	0.5548	0.5673
自编码器	0.4877	0.3007	0.2678	0.4845	0.5654	0.6001	0.5662	0.8771	0.5512
GSOM	0.4993	0.2707	0.2644	0.5058	0.6545	0.6602	0.4924	0.7118	0.5234

表 2 GSOM 算法和常见无监督算法对比结果

Tab. 2 Comparison results of GSOM algorithm and unsupervised algorithms

算法	D_{DBI}	时间开销/s
K -means	0.2680 (-1.36%)	8.55 (+260.7%)
DBSCAN	0.3736 (-41.3%)	5.28 (+122.8%)
自编码器	0.2678 (-11.06%)	3.28 (+26.5%)
原始 SOM	0.3127 (-18.2%)	1.46 (-38.4%)
GSOM	0.2644 (+0%)	2.37 (+0%)

综上所述,GSOM 算法在聚类效果和时间开销两方面综合表现相对最佳。

5 结束语

本文围绕卫星信号识别领域,通过实时宽带采集和分析,提取带宽范围内所有载波特征,形成数据库。并利用射频指纹提取技术,构建了 20 维卫星信号指纹库。此外,提出了基于动态自组织神经网络(GSOM)的射频指纹识别算法,通过与 K -means、DBSCAN、自编码器、原始 SOM 等常见无监督算法的比较,证明了 GSOM 算法在聚类效果和时间开销两方面综合表现相对最佳。

参 考 文 献

- [1] Li S, Li D X, Zhao S. 5G Internet of things: a survey [J]. Journal of Industrial Information Integration, 2018(10):1-9.
- [2] DE R F, POTRINO G, TROPEA M, et al. Energy-aware dynamic Internet of things security system based on elliptic curve cryptography and message queue telemetry transport protocol for mitigating replay attacks[J]. Pervasive and Mobile Computing, 2020, 61: 101105.
- [3] ZHAO F, JIN Y. An optimized radio frequency fingerprint extraction method applied to low-end receivers [C]//Proceedings of the 11th International Conference on Communication Software and Networks (ICCSN). Chongqing, China: [s. n.], 2019.
- [4] DING G, HUANG Z, WANG X. Radio frequency fingerprint extraction based on singular values and singular vectors of time-frequency spectrum [C]//Proceedings of 2018 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Qingdao, China: [s. n.], 2018.
- [5] 崔天舒. 面向天基电磁信号识别的深度学习[D]. 北京:中国科学院大学,2021.
- [6] CUI Tianshu. Deep learning method for space-based electromagnetic signal recognition[D]. Beijing:Chinese Academy of Sciences University, 2021. (in Chinese)
- [7] YU J, HU A, LI G, et al. A robust RF fingerprinting approach using multisampling convolutional neural network[J]. IEEE Internet of Things Journal, 2019, 6(4): 6786-6799.
- [8] YU J, HU A, ZHOU F, et al. Radio frequency fingerprint identification based on denoising autoencoders [C]//Proceedings of 2019 International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob). Barcelona, Spain: IEEE, 2019: 1-6.
- [9] LARA-BENÍTEZ P, GALLEGÓ-LEDESMA L, CARRANZA-GARCÍA M, et al. Evaluation of the transformer architecture for univariate time series forecasting[C]//Proceedings of the Spanish Association for Artificial Intelligence. [S. l.]: Springer, 2021: 106-115.
- [10] LI X, WANG W, HU X, et al. Selective kernel networks[C]//Proceedings of 2019 IEEE Conference on Computer Vision and Pattern Recognition. Long Beach, USA: [s. n.], 2019: 510-519.
- [11] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//Proceedings of 2020 IEEE Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2020.
- [12] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2019, 16(7): 4681-4690.