

基于改进 OpenMax 的开集干扰识别方法

刘佳楠, 宋志群, 李 勇

(中国电子科技集团公司第 54 研究所 先进通信网全国重点实验室, 石家庄 050081)

摘要: 目前的无线通信干扰识别研究主要针对闭集场景, 为了面对日益复杂的电磁环境, 对无线通信开集场景下未知干扰信号识别问题进行了研究, 提出了一种基于改进 OpenMax 的开集干扰识别算法; 该算法通过将干扰信号从时频空间映射至特征空间进行聚类, 并采用基于距离的损失函数进行网络训练; 通过计算样本映射至特征空间的点与中心锚点之间的欧几里得距离, 判断信号属于已知干扰类别还是未知干扰; 引入 OpenMax 算法对样本边界进行拟合, 从而实现阈值的自适应调节; 实验结果表明, 该算法对干扰信号的聚类效果优秀, 可以在对已知干扰识别准确率超过 90% 的同时识别出未知干扰, 更加适合动态环境下的干扰识别。

关键词: 干扰识别; 未知干扰信号; 开集识别; 深度学习; 度量学习

Open Set Interference Recognition Method Based on Improved OpenMax

LIU Jia'nan, SONG Zhiquan, LI Yong

(National Key Laboratory of Advanced Communication Networks, the 54th Research Institute of China

Electronics Technology Group Corporation, Shijiazhuang 050081, China)

Abstract: The current wireless communication interference identification research mainly focuses on closed set scenarios, in order to face the increasingly complex electromagnetic environment, the problem of unknown interference signal identification in wireless communication open set scenarios is studied, and an open set interference identification algorithm based on improved OpenMax is proposed; The algorithm is trained by mapping interference signals from time-frequency space to feature space for clustering, and adopts a distance-based loss function for network training; The Euclidean distance between the points mapped to feature space and central anchor point is calculated to determine whether a signal belongs to a known category or an unknown interference category; The OpenMax algorithm is introduced to fit the boundary of samples, thus realizing adaptive adjustment of the threshold; Experimental results show that the algorithm has excellent clustering effect on interference signals and can recognize the unknown interference with an accuracy of more than 90% in the known interference recognition, which is more suitable for interference recognition in dynamic environment.

Keywords: interference detection; unknown interference signal; open set recognition; deep learning; metric learning

0 引言

由于无线信道的开放性, 无线通信容易受到有意或无意的物理层干扰, 其中高功率的恶意压制式干扰会严重影响降低通信系统的误码率, 导致其无法正常通信。干扰识别是无线通信抗干扰的重要环节, 准确识别出干扰信号的干扰模式对保障无线通信系统的正常运行有非常关键的作用。

传统无线通信干扰识别算法主要从提取干扰信号的特征展开。在传统干扰识别研究方面, 文献 [1] 提出

了一种基于接收信号 LZ 复杂度和盒维数的干扰识别方法。该算法提取复杂度特征来分类单音干扰、多音干扰、窄带干扰等六种干扰和 QPSK 通信信号。在干扰样本训练后, 计算每种干扰模式的复杂度特征的均值和方差, 然后使用指数模糊隶属度函数来确定测试样本的隶属度值, 并采用最大隶属度原理识别干扰模式; 文献 [2] 使用脉宽、调频斜率和带宽比 3 个分类特征对 5 种干扰进行识别, 干噪比大于 3dB 时, 识别准确率可以达到 90%; 文献 [3] 提出了一种基于高阶累积量和机器学习的干扰识别算法, 将归一化的高阶累积量作为特征

收稿日期:2025-03-24; 修回日期:2025-04-08。

基金项目:先进通信网全国重点实验室基金资助课题(FFX23641X021)。

作者简介:刘佳楠(2000-),男,硕士研究生。

引用格式:刘佳楠,宋志群,李 勇. 基于改进 OpenMax 的开集干扰识别方法[J]. 计算机测量与控制, 2025, 33(5): 306-312, 321.

参数,输入到神经网络中进行分类,该算法可以在低干扰比下保持较高的准确性;文献[4]提出了一种全球导航卫星系统干扰信号的盲识别方法,提取了信号时频域以及统计域的特征,在6种干扰信号上干扰识别准确率大于97%。文献[5]提出了一种基于脉冲内特征和非故意信号调制的辐射源识别方法,所提脉冲内特征可以实现超过98%的正确识别率,相对传统特征有较大提升。文献[6]提出了一种基于Zernike矩特征的干扰识别算法,实现了对3种雷达欺骗式干扰信号的识别。上述算法都是在对数据库中已知的干扰类别的研究基础上设计特征,无法处理不在数据库中的未知干扰信号。

深度学习对数据的强大处理能力为干扰识别技术研究提供了新的方向,文献[7]通过倒残差网络对8种干扰信号的时频图进行识别,其提出的通道、时域、频域三重注意力模块可以提高算法的识别准确率。文献[8]使用卷积神经网络从不同的干扰信号中提取特征,然后使用多维缩放降低特征的维度。最后将特征输入到支持向量分类器中以获得分类结果。文献[9]将干扰信号的I路和Q路数据直接输入所设计的一维卷积网络中进行识别,针对可能存在的干扰样本较少的问题,作者提出了一种孪生CNN网络,结果表明其所提算法可以在足够和有限的样本下有效地对雷达干扰信号进行分类。文献[10]提出了一种改进Transformer的模型Multidomain-former,用Transformer架构对切割划分后的序列进行处理,设计了逆傅里叶变换—傅里叶变换编码模块提取时域和频域特征,在其通过通用仪器和收发天线搭建的无线信道环境中,相对于传统Transformer模型得到了提升。文献[11]通过双向网络的注意力机制提取二维时频图的有效特征,对干扰信号进行分类。从上述相关研究工作可以看出将深度学习算法和信号处理算法结合起来是干扰信号识别研究的重要方向,但是目前基于深度学习的干扰识别算法大多没有有在特征空间中为未知干扰留出空间,在遇到未知干扰时会将其归类为已知干扰,无法面对愈发复杂的电磁干扰环境。

随着无线通信领域的不断发展,通信环境日益复杂多变,干扰信号的种类也在不断增加,针对闭集干扰识别的算法在遇到未知类别时会将其归类为某一已知类别,无法正确处理开集环境下的干扰信号识别工作。为了保障通信的安全性和可靠性,必须采用有效的开集识别技术应对各种已知干扰和未知干扰,使得通信系统可以发现并应对潜在的干扰源。为干扰识别系统增加识别未知干扰的能力对于提升抗干扰系统的鲁棒性,保障无线通信系统在强干扰环境下的稳定性与可靠性有十分重要的意义。

当前干扰识别研究方面对未知干扰研究相对较少,文献[12]提出了基于条件高斯编码器的通信干扰信号开集识别网络,使用条件高斯编码器对含噪干扰进行编码,实现了在复杂电磁环境下的闭集和开集识别;王小豪通过增加置信估计分支对神经网络识别的置信度进行打分,判断信号是否属于未知类^[13];李佳浩提出了一种基于对抗互易点学习的无人机通信干扰开集识别方法,从I/Q数据中提取信号特征,并设计了联合自适应阈值开集分类器,实现了对无人机通信干扰的开集识别^[14]。文献[15]将零次学习的思想应用到干扰模式的开集识别中,使用编码器对干扰信号时频图的语义特征进行提取,使用语义特征对模型进行训练。从而实现对干扰信号的开集识别。文献[16]提出了一种生成式开放集干扰模式识别框架,即干扰分类器生成对抗网络,该网络通过生成有效的伪未知干扰数据,将开集识别问题转化成闭集识别问题;文献[17]提出了基于孪生神经网络的开集干扰识别方法,实现了未知干扰的检测和无监督聚类;文献[18]提出了基于置信度得分的开集干扰识别和基于OpenMax的开集干扰识别算法,可以在小样本条件下对已知干扰进行分类并区分未知干扰。

本文在总结上述开集干扰识别方法的基础上,针对OpenMax算法识别精度不够的问题,提出了一种基于改进OpenMax的开集干扰识别算法。该算法通过将干扰信号从时频空间映射到特征空间对开集干扰信号进行识别,采用基于距离的损失函数提升了网络的聚类能力,然后通过Weibull分布实现了阈值的自适应调节,并对特征空间中样本分布进行了可视化,进一步证实了该方法的可行性。

1 无线通信中的开集干扰

1.1 开集干扰场景

考虑如图1所示的无线通信干扰场景,包含发射机、接收机和干扰机,接收机接收到的信号不仅有合法通信信号,还有可能存在干扰机发射的压制式干扰信号。若接收机配备干扰检测模块,则可以在静默状态下监测无线信道,环境中存在强干扰时,识别出干扰模式为抗干扰提供先验知识。

随着干扰技术的不断发展,压制式干扰种类更加多样,复杂动态环境下通信可能会受到未知干扰攻击,因此需要对算法增加检测未知干扰的功能。开集场景下的干扰识别工作与闭集识别的区别如图2所示,其中干扰类别1,2,3,4为数据集中的已知干扰,干扰类别5为数据集中不存在的未知干扰。闭集识别会将未知干扰归类到已知干扰中,而开集识别会给未知干扰预留空间。




图 1 无线通信干扰场景




图 2 开集与闭集识别区别

本文设计了一种未知干扰识别算法，可以对未知干扰进行拒绝，算法流程图如图 3 所示。未知干扰识别算法通过训练集中的已知类样本对模型权重进行更新，提高模型的聚类能力和识别能力，然后用存在未知干扰的测试集模拟实际电磁环境，对训练后的模型性能进行验证。模型会判断输入信号是否为已知干扰，若干扰信号为已经记录的已知干扰，则输出干扰类型，进行下一步抗干扰措施；若干扰信号为未曾记录的未知干扰，则输出干扰未知，为后续的干扰信号处理提供先验信息。




图 3 未知干扰识别流程

1.2 干扰信号模型

在通信场景中，接收机接收的信号如式 (1) 所示，其中 $y(n)$ 表示接收信号序列， $s(n)$ 表示合法传输的有用通信信号， $j(n)$ 表示强干扰环境下的压制式干扰信号

序列， $\epsilon(n)$ 表示环境中的白噪声序列：

$$y(n) = s(n) + j(n) + \epsilon(n) \quad (1)$$

为方便对干扰信进行识别，本文选择在静默状态下对信道环境进行监测，静默状态下不进行有用信号传输，可以表示为

$$y(n) = j(n) + \epsilon(n) \quad (2)$$

在实际通信场景中，接收机无法事先获知所有的干扰模式，对于接收机来说，除了已知的 C 类干扰外，环境中可能存在未知干扰，本文希望在对已知干扰模式识别的同时能够对未知干扰进行检测，从而为后续的未知干扰模式识别工作以及抗干扰工作提供先验信息。

本文选择线性扫频干扰、单音干扰、多音干扰、部分带干扰、梳状谱干扰、跳频干扰、余弦扫频干扰、噪声调制脉冲干扰作为干扰信号，每次选择其中一种作为未知干扰信号，其余七种干扰信号作为已知干扰信号进行闭集模型训练，八种干扰信号进行开集测试。干扰信号的数学表达式如表 1 所示。

表 1 干扰信号数学表达式

干扰种类	数学描述	补充说明
线性扫频干扰	$j(t) = Ae^{j(2f_0 n/f_s + \pi k t^2/n^2 + \varphi)}$ $0 < n \leq N$	k 决定了频率随时间变化的速度， f_0 为干扰起始频率
单音干扰	$j(t) = Ae^{j(2\pi f_j n/f_s + \varphi)}$	f_j 为干扰频率
多音干扰	$j(t) = \sum_{j=1}^M Ae^{j(2\pi f_j n/f_s + \varphi)}$	M 表示干扰频点数， f_j 为干扰频率
部分带干扰	$j(n) = v(n) * h(n)$	$v(n)$ 为高斯噪声， $h(n)$ 为带通滤波器
梳状谱干扰	$j(n) = \sum_{k=0}^{N-1} g_k \cos\left(2\pi f_k \frac{n}{f_s} + \varphi\right)$	$g_k \sim N(0, \sigma^2)$ 为窄带高斯分布
跳频干扰	$j(n) = A \cos\left[2\pi f_j(n) \frac{n}{f_s} + \varphi\right]$	$f_j(n)$ 为随跳频图案变化的干扰频率
余弦扫频干扰	$j(n) = A \cos\left\{2\pi \left[f_0 t + \frac{\Delta f}{\omega} \sin\left(\omega \frac{n}{f_s}\right) \right] + \varphi \right\}$	f_0 表示干扰中心频率， ω 表示频率变化的角频率， Δf 表示最大频率偏移
噪声调制脉冲干扰	$j(n) = v(n) \cdot p(n)$	$v(n)$ 为高斯噪声， $p(n)$ 为矩形脉冲信号

表 1 中 A 为干扰信号幅度， φ 为干扰信号初始相位，通过对干扰信号进行仿真采样得到干扰信号采样序列，得到干扰信号后，我们选择将其功率归一化预处理然后将其映射到时频域，以方便 CNN 网络对其进行特征提取，对干扰信号进行预处理以及短时傅里叶变换的数学表达式分别如式 (3) 和式 (4) 所示：

$$\bar{y} = \frac{y(n)}{\sqrt{\frac{1}{N} \sum_{n=1}^N |y(n)|^2}} \quad (3)$$

$$Y(n,m) = \sum_{k=0}^{N-1} y(k)r^*(k-n)e^{-j2\pi nk/N} \quad (4)$$

其中: N 表示采样点数, $r(n)$ 表示短时傅里叶变换的窗函数。图 4 展示了短时傅里叶变换后得到的干扰时频图, 窗函数为汉明窗, 干噪比为 10 dB, 干扰依次为线性扫频干扰、单音干扰、多音干扰、部分带干扰、梳状谱干扰、跳频干扰、余弦扫频干扰、噪声调制高斯脉冲干扰。




图 4 干扰信号时频图

2 基于改进 OpenMax 的开集识别模型

2.1 网络结构

在上一节得到干扰信号的时频图后, 本文通过深度卷积网络对时频图特征进行提取。深度卷积网络可以提取图片特征, 起到对图片的矩阵数据降维的作用。主干网络借鉴了 ResNet18^[19], 是残差卷积网络的一种, 共有 18 层, 是 ResNet 系列中较小的模型之一, 但仍保留了足够的深度捕捉数据的复杂特征。残差卷积网络的核心在于使用的跳跃连接的残差模块允许输入直接加到输出端, 有助于缓解梯度消失问题, 可以在训练更深网络的同时性能不下降。采用残差卷积网络对输入的时频图进行特征提取并将其映射到特征空间中, 网络结构如 5 所示, 其中下采样模块如图 6 所示, 网络使用卷积层对

输入为 $512 \times 512 \times 3$ 的时频图进行特征提取, 先通过一个长度为 7×7 的大卷积核和最大池化层提取数据特征, 然后通过 4 个残差模块进一步提取数据特征, 在此期间特征图的大小减小而特征图的数量增加, 最后通过最大池化层和全连接层得到干扰信号时频图在特征空间的映射, 得到长度为 7 的特征向量。由于残差结构在数据处理方面的优越性, 本文在使用 ResNet18 作为骨干网络的前提下对网络训练的损失函数和对未知干扰的判定方式进行了优化, 使得模型更加适用于未知环境下的干扰识别工作。

2.2 基于距离的损失函数

训练的损失函数并不采用分类任务中常用的交叉熵损失函数, 而是采用基于度量的损失函数, 与交叉熵损失函数相比, 距离损失函数对样本的聚类效果更好, 其表达式如下:

$$L_1(x,y) = \log(1 + \sum_{j \neq y}^K e^{d_j - d_i}) \quad (5)$$

$$L_2(x,y) = \|x - c_y\|_2 \quad (6)$$

$$L(x,y) = L_1(x,y) + \lambda L_2(x,y) \quad (7)$$

其中: $L_1(x,y)$ 表示样本距离其他样本中心的距离, $L_2(x,y)$ 表示样本距离该类中心的距离, x 表示样本在特征空间中的特征向量, y 表示样本实际标签, K 表示已知干扰类别数, d_j 表示样本在特征空间的映射点距离第 j 个样本中心的距离, c_y 表示该类样本中心的坐标, λ 是一个常数, 设为 0.1。在训练过程中中心点的位置坐标同样作为需要优化的参数通过反向梯度传播进行更新。

对于经过模型映射后的特征空间, 我们将其可视化, 如图 7 所示, 图片中依次为线性扫频干扰、单音干扰、多音干扰、部分带干扰、梳状谱干扰、跳频干扰、余弦扫频干扰、高斯调制脉冲干扰作为干扰时的聚类情况, 其中未知干扰已经在图中标出。可以看到该算法对同类样本的聚类效果很好, 可以将样本聚集在样本中心周围, 同时可以将未知干扰映射在未知干扰的聚类簇外。

从图 7 中可以看出在特征空间中特征向量会牢牢聚




图 5 网络结构图




图 6 下采样模块

集在样本中心的周围,当测试样本距离某一样本中心较近时,我们将其归类为该样本中心代表的类别,当距离每个样本中心都较远时,我们认为该测试样本为未知类,从而实现对未知类别样本的拒绝。




图 7 聚类效果可视化

文献 [20] 中提出一种手动设置阈值的方法,假设测试样本在特征空间的投影为 $x = (x_1, x_2 \dots x_N)$, 按照式 (8) 对特征向量进行校正,当校正后的分数小于阈值时,将样本归类到该类中:

$$\text{scores} = d_i \times \{1 - \text{softmax}[-\text{abs}(x_i)]\} \quad (8)$$

2.3 基于 OpenMax 的自适应阈值算法

在深度学习识别领域,模型识别范围一般局限于训练集的种类范围,设定在闭集状态下工作。但是在复杂的电磁环境中,不仅存在训练集中存在的干扰种类,也可能存在新的干扰种类。

本文在设计算法时借鉴了 Openmax 算法中拒绝未知类的方法,利用已知类别的统计特性来对已知类边缘拟合,从而拒绝未知干扰种类。

极值分布定理是概率论中的一个重要定理,可以描述随机变量极端值的统计特性,其常用于极端事件分析。其一般定义如下:

考虑一组独立且同分布的随机变量序列 $\{X_n\} =$

$(x_1, x_2, x_3, \dots, x_n)$, 其最大值的分布函数 $M_{(n)} = \max\{x_1, x_2, x_3, \dots, x_n\}$ 。若存在一组实数 $\{a_n, b_n\}$, 使得 $a_n > 0$ 时满足:

$$\lim_{n \rightarrow \infty} P\left(\frac{M_{(n)} - b_n}{a_n} \leq x\right) = F(x) \quad (9)$$

若 $F(x)$ 为非退化的分布函数,则该分布属于极值分布^[21]。对于通信干扰识别问题,我们可以合理地认为训练样本之间满足独立同分布,如果对该分布的尾部进行建模,根据极值分布定理,可以认为其尾部的分布会收敛到某种极值分布类型。

极值分布可以用一个统一的广义极值分布函数来表示:

$$F(x) = \begin{cases} \exp[-(1 + kx - a/\lambda)^{-1/k}], & k \neq 0 \\ \exp(-e^{-x/\lambda}), & k = 0 \end{cases} \quad (10)$$

其中表示位置参数,表示尺度参数,表示形状参数。当时为 Gumbel 分布;时为 Fréchet 分布;时为 Weibull 分布。

Weibull 分布的概率密度函数为:

$$f(x; \lambda, k) = \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-(x/\lambda)^k} \quad (11)$$

其中: λ 和 k 分别是控制尺度和形状的参数。

Weibull 分布的累计分布函数为:

$$F(x; \lambda, k) = 1 - e^{-(x/\lambda)^k} \quad (12)$$

我们可以通过利用特征空间中最外侧的样本求得 Weibull 分布中的参数,对该类干扰在特征空间的边界进行拟合。在处理新样本时,我们通过已知类的 Weibull 分布对归一化后的干扰信号特征向量进行矫正,并引入新的一维来表示属于未知干扰的概率,数学表达式如下:

$$S(x_i) = \text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{k=1}^K e^{x_k}} \quad (13)$$

$$S'(x_i) = S(x_i) - S(x_i) \times F(d_x; \lambda, k) \quad (14)$$

$$S_{\text{unknown}} = \sum_{i=1}^C S(x_i) - S'(x_i) \quad (15)$$

在得到干扰种类在特征空间的映射后,通过每一个类的特征点到锚点的距离我们可以拟合该类的异常值的 Weibull 分布, Weibull 分布可以刻画特征空间中该类边界的概率分布,通过对距离集合中的极端值可以得到将该类判定为未知类的概率。若测试样本中属于未知类别的概率最高或概率分布最大值小于某个阈值时,我们将其判定为未知干扰,否则根据最大值的索引进行分类。

综上所述,我们的算法流程如下。

基于聚类和 Openmax 的开集干扰检测算法:

1) 通过基于聚类的损失函数对模型进行训练,使其在特征空间中同类别干扰聚集在中心点附近,不同类

干扰的欧几里得距离尽可能大；

2) 通过训练样本在特征空间的分布对 Weibull 分布进行拟合，得到每个类别的边界；

3) 测试样本网络得到其在特征空间的投影点并计算其与各个中心点的距离；

4) 通过 2 中得到的 Weibull 模型对归一化后的特征向量进行矫正，得到其属于各个类别的概率；

5) 通过 4 中得到的概率分布判断干扰种类。

2.4 算法仿真结果

根据上述理论分析进行实验验证，数据集由 Matlab 仿真得到，训练集和测试集的数据比例为 4 : 1。数据集中的干扰信号为干扰信号和环境噪声的混合信号，为了使实验能够验证高干噪比和低干噪比下模型的表现，干噪比范围选择 -10 dB 至 10 dB，间隔为 1 dB。每 dB 训练集 80 有个样本，测试集有 20 个样本，每个种类干扰信号共 2 100 个样本。

干扰信号参数信息如表 2 所示。

表 2 干扰信号参数信息

干扰种类	参数信息
线性扫频干扰	初始频率:0.1 MHz~0.2 MHz 截至频率 :0.3 MHz~0.5 MHz
单音干扰	频率:0.1 MHz~0.45 MHz
多音干扰	频率:0.1 MHz~0.45 MHz 干扰频率个数:3
部分带干扰	窗函数:凯撒窗 中心频率:0.1 MHz~0.38 MHz 波器带宽:0.1 MHz~0.18 MHz 进入滤波器前白噪声功率:15 dB
梳状谱干扰	窗函数:凯撒窗 梳状个数:3,4,5 梳状谱间隔:0.03 MHz 梳状宽度:0.03 MHz 起始频率:0.05 MHz~0.12 MHz
跳频干扰	最高频率:1 MHz 跳频次数:5
余弦扫频干扰	初始频率:0.1 MHz~0.4 MHz 带宽:0.04 MHz~0.1 MHz
高斯脉冲干扰	脉冲带宽:0.1 MHz 脉冲周期:0.01 秒

实验所使用显卡为 RTX3090，用 Pytorch 作为深度学习框架，cuda 版本为 11.1，训练迭代次数为 100，优化器为 Adam，模型权重参数初始化方式为随机初始化。在八种干扰信号依次作为未知干扰信号，不同阈值下得到的已知干扰和未知干扰的识别准确率如表 3~6 所示。

表 3 干扰识别准确率(尾部长度为 25)

未知干扰种类	线性扫频干扰	单音干扰	多音干扰	部分带干扰	梳状谱干扰	跳频干扰	余弦扫频干扰	高斯脉冲干扰
已知类准确率/%	90.31	90.31	93.1	90.1	90.5	95.65	93.54	90
未知类准确率/%	100	100	100	100	100	100	100	100

表 4 干扰识别准确率(尾部长度为 20)

未知干扰种类	线性扫频干扰	单音干扰	多音干扰	部分带干扰	梳状谱干扰	跳频干扰	余弦扫频干扰	高斯脉冲干扰
已知类准确率/%	91.7	91.63	91.63	95.99	91.9	96.26	94.69	91.8
未知类准确率/%	100	100	100	100	100	100	100	100

表 5 干扰识别准确率(尾部长度为 15)

未知干扰种类	线性扫频干扰	单音干扰	多音干扰	部分带干扰	梳状谱干扰	跳频干扰	余弦扫频干扰	高斯脉冲干扰
已知类准确率/%	92.89	97.56	92.82	95.99	93.27	97.18	95.18	93.1
未知类准确率/%	100	100	100	100	99.76	100	100	100

表 6 干扰识别准确率(尾部长度为 5)

未知干扰种类	线性扫频干扰	单音干扰	多音干扰	部分带干扰	梳状谱干扰	跳频干扰	余弦扫频干扰	高斯脉冲干扰
已知类准确率/%	95.48	98.95	97.86	95.99	96.67	98.67	98.57	97.04
未知类准确率/%	100	100	100	100	98.57	100	100	100

从实验结果我们可以看到，使用 Weibull 分布对类别边缘拟合的算法准确率可以达到 90% 以上，这是因为模型的聚类效果非常较好，用最外侧的少量样本对边界的刻画是合理的，与理论相符。

为了进一步证明算法有效性，我们将所提算法与 OpenMax 算法进行对比研究，与本文不同的是，OpenMax 算法的损失函数为交叉熵损失函数。

实验结果分析主要关注两个评价指标：已知干扰的识别准确率以及未知干扰的识别准确率。图 8 为不同干扰作为未知干扰时已知干扰的识别准确率，从图中可以看到本文所提算法在已知干扰识别方面相对于 OpenMax 算法有明显提升，本文所提算法的已知类干扰识别率可以达到 95% 以上，而 OpenMax 算法对已知干扰识别准确率最高达到 91.4%；图 9 为不同干扰作为未知干扰时未知干扰的识别准确率，从图中可以看到在未知干扰识别方面本文所提算法识别准确率提升较大，尤其是部分带干扰作为未知干扰时所提算法优势更加明

显, 由于改进算法的聚类能力更加优秀, 在未知干扰识别方面, 本文所提算法几乎可以识别出所有未知干扰, 而 OpenMax 算法在部分带干扰作为未知干扰时效果较差, 只有在余弦扫频干扰作为未知干扰时对未知干扰的识别效果较好, 可以达到 96.4%。




图 8 已知干扰识别率对比




图 9 未知干扰识别率对比

3 结束语

针对开放环境下的无线通信干扰识别问题, 本文提出了一种基于深度学习的开集干扰识别算法。该算法针对复杂干扰环境进行设计, 通过将干扰信号时频图投影到特征空间中对干扰信号进行聚类, 从而实现开放环境

下的干扰信号识别; 在此基础上引入 Weibull 分布对归一化的特征向量进行矫正, 同时计算属于未知类的概率。实验结果表明, 所提算法可以实现 90% 以上的已知类干扰识别准确率的同时准确识别出未知干扰, 可以较好地复杂的开集环境下对干扰信号进行识别, 具有较强的应用价值。下一步将在信号建模时考虑不同信道环境以及在通信状态下研究干扰信号的识别工作, 为抗干扰工作提供先验信息。

参考文献:

- [1] NIU Y, CHENG Y, CHEN J. Jamming pattern recognition based on complexity measure [C] //2010 3rd International Congress on Image and Signal Processing. IEEE, 2010, 8: 3596 - 3600.
- [2] 李 建, 王飞雪, 李柏渝, 等. 一种卫星导航信号干扰类型自动识别方法. 第五届中国卫星导航学术年会 [C] // 2014: 72 - 76.
- [3] 吴 昊, 张 杭. 基于高阶累积量与神经网络的干扰识别算法 [J]. 军事通信技术, 2008, 29 (1): 67 - 71.
- [4] 杨燕梅, 郎荣玲, 叶万洋. 软件无线电的 GNSS 干扰盲识别系统 [J]. 导航定位学报, 2019, 7 (2): 103 - 111.
- [5] KAWALEC A, OWCZAREK R. Radar emitter recognition using intrapulse data [C] //15th International Conference on Microwaves, Radar and Wireless Communications (IEEE Cat. No. 04EX824). IEEE, 2004, 2: 435 - 438.
- [6] YANG X, RUAN H, FENG H. A recognition algorithm of deception jamming based on image of time-frequency distribution [C] //2017 7th IEEE International Conference on Electronics Information and Emergency Communication (ICEIEC). IEEE, 2017: 275 - 278.
- [7] 靳增源, 张晓瀛, 谭思源, 等. 基于集成时频通道注意力的倒残差神经网络干扰识别 [J]. 信号处理, 2023, 39 (2): 343 - 355.
- [8] YU H, ZHANG R, DING R. Interference recognition based on machine learning for satellite communications [C] //ICMLT'18: Proceedings of the 2018 International Conference on Machine Learning Technologies, 2018.
- [9] SHAO G Q, CHEN Y S, WEI Y S. Convolutional neural Network-Based radar jamming signal classification with sufficient and limited samples [J]. IEEE Access, 2020, 8: 80588 - 80598.
- [10] 阳鹏飞, 何 玲, 王 茜, 等. 基于混合信号多域特征和 Transformer 的干扰识别 [J]. 系统工程与电子技术, 2024, 46 (6): 2138 - 2145.
- [11] XIAO Y, ZHOU J, YU Y, et al. Active jamming recognition based on bilinear EfficientNet and attention mechanism [J]. Iet Radar Sonar and Navigation, 2021, 15 (9): 957 - 968.

(下转第 321 页)