

## 基于时频图学习的北斗卫星导航系统干扰类型识别

刘瑞华<sup>a</sup>, 张艳婷<sup>a</sup>, 马赞<sup>b</sup>

(中国民航大学 a. 电子信息与自动化学院; b. 安全科学与工程学院, 天津 300300)

**摘要:** 针对当前干扰识别算法依赖特征工程提取特征存在提取繁琐、识别准确率受干信比取值影响较大的问题, 本文提出在不同干信比情况下基于时频图学习的北斗卫星导航系统(BDS, Beidou navigation satellite system)干扰类型识别方法。以航空机载北斗卫星导航系统 B1I 信号为对象, 对原始 B1I 信号、包含干扰的 B1I 信号进行短时傅里叶变换, 将变换后获取的时频图作为支持向量机和卷积神经网络模型的输入向量, 完成干扰类型的检测与识别。仿真结果表明, 两种机器学习识别算法的平均识别率均达到了 99% 以上, 识别结果比传统决策树识别算法提升了 30% 以上, 解决了现有干扰识别算法需要严重依赖人工设计的特征工程手动提取干扰信号特征以及识别率较低的问题。该研究结果可为后续的干扰抑制工作提供先验信息, 提高航空领域中北斗卫星导航系统的安全性。

**关键词:** 干扰识别; 短时傅里叶变换; 时频图; 支持向量机; 卷积神经网络

中图分类号: TN911.4

文献标志码: A

文章编号: 1674-5590(2024)05-0045-07

### Identification of interference type of Beidou navigation satellite system based on learning from time-frequency graph

LIU Ruihua<sup>a</sup>, ZHANG Yanting<sup>a</sup>, MA Zan<sup>b</sup>

(a. College of Electronic Information and Automation; b. College of Safety Science and Engineering, CAUC, Tianjin 300300, China)

**Abstract:** Aiming at the problem that existing interference identification algorithms rely on feature engineering to extract features, which is cumbersome and the identification accuracy is greatly affected by the value of signal-to-noise ratio, the interference type identification method of Beidou navigation satellite system (BDS) based on learning from time-frequency graph under different signal-to-noise ratio is proposed in this paper. Taking the B1I signal of the airborne BDS as the object, the original B1I signal and the B1I signal containing interference are subjected to short-time Fourier transform. The time-frequency graph obtained after the transform is used as the input vector of the support vector machine and convolutional neural network model to complete the detection and identification of interference types. The simulation results show that the average identification accuracy of both machine learning identification algorithms has reached over 99%, which is about 30% higher than that of traditional decision tree identification algorithms, solving the problem of existing interference identification algorithms that heavily rely on manually designed feature engineering to extract interference signal features and have low accuracy. The research results can provide prior information for subsequent interference suppression work and improve the safety of BDS in the aviation field.

**Key words:** interference identification; short-term Fourier transform; time-frequency graph; support vector machine; convolutional neural network

北斗卫星导航系统(BDS, Beidou navigation satellite system)空间信号落地功率微弱, 易受到各种信号的干扰, 威胁机载导航系统的准确性和可靠性。预先识别出环境中的干扰信号类型, 并采取具体的抗干扰措施, 可

最大程度地抑制干扰信号<sup>[1-2]</sup>, 降低事故发生率。

国内外众多学者对干扰类型的检测和识别进行了大量研究, 以提高算法准确率。在传统干扰信号识别方面: 孙殿星等<sup>[3]</sup>提出基于均值-方差联合检测的干扰

识别技术,利用似然比统计检测,实现了90%左右的识别率;田晓等<sup>[4]</sup>针对拖引过程的干扰识别,提出利用小波变换获取的归一化能量值作为特征参数,提高了识别算法的有效性和实用性;李果等<sup>[5]</sup>提出前向连续方差去除干扰检测算法,该方法重新定义干扰检测门限,提高了经典前向连续均值去除算法的干扰检测性能。

随着机器学习(ML, machine learning)的深入发展,大量学者开始利用ML对信号进行处理。在干扰信号类型识别方面的研究主要分为以下2个方面:一是干扰信号的特征提取,主要使用的技术有小波分析<sup>[6]</sup>、几何参数法等;二是分类和识别算法,常使用的ML算法有决策树(DT, decision tree)<sup>[7]</sup>、反向传播神经网络(BPNN, back propagation neural network)<sup>[8]</sup>和卷积神经网络(CNN, convolutional neural network)等。张婧等<sup>[9]</sup>提取干信比(JSR, jamming to signal ratio)值下的特征参数作为输入特征,使用支持向量机(SVM, support vector machine)和CNN对典型的全球定位系统(GPS, global positioning system)干扰信号进行识别,平均识别率达到了94%左右;Yang等<sup>[10]</sup>使用Lib-SVM对两种卫星干扰信号进行检测与识别,准确率约为95%;王亚<sup>[11]</sup>提取时域包络起伏度、频谱峰度等有关叠加信号在时域和频域的特征参数,并对决策树网络进行优化,在低干信比情况下对混叠干扰类型的识别率达到了70%。上述方法具有计算复杂度较低、易于实现的优点,但对于干扰特征的提取过度依赖人工设计的特征工程,致使特征参数显著性较差,无法高效区分干扰信号类型,致使准确率下降。

以上提到的干扰信号识别算法经过多年的研究和应用,具有相对成熟稳定的技术基础,且计算复杂度较低、易于实现。但是算法本身通常基于特定场景和特定类型的干扰进行设计和优化,特征因子的提取严重依赖于领域专业知识和经验<sup>[12]</sup>,存在特征选择和提取的主观性,且在低干信比下提取的特征因子不具有显著性特征,以上原因致使算法干扰分类准确率相对较低。以往使用的基于特定参数值的ML识别算法在选取具体特征变量时也需要依赖人工设计的特征工程来提取,具有一定的主观性。此外,现有识别算法在低干信比情况下的特征参数显著性较差,无法高效区分干扰信号类型,致使准确率下降。

时频图<sup>[13]</sup>兼顾了信号在时域和频域的信息,无须依赖人工设计的特征工程,识别算法可以从大量原始数据中自动提取有价值的特征,包括隐含的复杂和抽象特征,即使在低干信比情况下也能够从图像中学习

特征表示和捕捉数据中的复杂关联性和非线性关系,完成干扰信号的有效识别。因此,本文提出基于SVM与CNN的北斗卫星导航系统干扰识别方法,即把时频图作为SVM和CNN学习对象,实现对单一干扰信号以及混合干扰信号的识别。

## 1 干扰信号建模

本文对北斗B1I信号造成较大影响的典型压制式干扰进行建模。

假设北斗接收机接收的北斗信号表示为 $y(t)$ ,有用信号为 $s(t)$ ,干扰信号为 $J(t)$ ,高斯白噪声为 $n(t)$ ,则接收信号模型可表示为

$$y(t) = s(t) + J(t) + n(t) \quad (1)$$

对其进行短时傅里叶变换(STFT, short-time Fourier transform),即可得本文供ML分类使用的时频图,即

$$\text{STFT}(n, \omega) = \sum_{m=-\infty}^{\infty} y(m)g(n-m)e^{-j\omega m} \quad (2)$$

式中: $y(m)$ 为输入信号,这里代表的是无干扰信号影响的北斗离散信号,也可以是北斗信号与干扰信号混叠而成的离散混合信号; $g(\cdot)$ 为进行傅里叶变换时选取的窗函数; $m$ 为窗函数的中心位置; $n$ 为窗函数的当前滑动位置; $\omega$ 为傅里叶变换频率; $j$ 为虚数单位。

### 1.1 单音干扰

单音干扰(CWI, continuous wave interference)信号为连续波干扰中定频干扰的一种,其结构简单、频域单一、能量较为集中,其数学模型表示为

$$J_{\text{CWI}}(t) = \sqrt{2P_j} \cos(2\pi f_{j, \text{CWI}} t + \theta_j) \quad (3)$$

式中: $P_j$ 为干扰功率; $f_{j, \text{CWI}}$ 为单音干扰信号频率; $\theta_j$ 为随机相位。

### 1.2 多音干扰

多音干扰(SCWI, surplus continuous wave interference)的频率分布在导航信号频段的不同频点,且在每个频点都表现出单音干扰的特性,弥补了单音信号频点单一的缺陷,其数学模型表示为

$$J_{\text{SCWI}}(t) = \sum_{i=1}^M \sqrt{2P_j} \cos(2\pi f_i t + \theta_{j,i}) \quad (4)$$

式中: $f_i$ 为第 $i$ 个干扰分量的频率; $M$ 表示单音干扰的个数; $\theta_{j,i}$ 表示第 $i$ 个干扰分量的随机相位。

### 1.3 线性扫频干扰

线性扫频(LFM, linear frequency interference)信号是一种动态非平稳信号,对通信过程有较大影响,频率在干扰用户感兴趣的频段范围内随着时间呈线性变

化,故又称为线性调频信号,其数学模型表示为

$$J_{\text{LFM}}(t) = \sqrt{2P_j} \cos(\pi kt^2 + 2\pi f_0 t + \theta_j) \quad (5)$$

式中: $k = B/T$  为扫频速率; $B$  为信号带宽; $T$  为扫频持续时间;当扫频速率为  $k = 0$  Hz/s 时,LFM 相当于 CWI; $f_0$  为起始频率。

#### 1.4 混合干扰

当今电磁环境错综复杂,几种干扰同时存在,并对工作频段造成阻塞的情况较为普遍<sup>[14]</sup>,本文讨论的混叠干扰包括多音干扰和线性扫频干扰,其数学模型表示为

$$J(t) = J_{\text{SCWI}}(t) + J_{\text{LFM}}(t) = \sum_{i=1}^M \sqrt{2P_j} \cos(2\pi f_i t + \theta_{j,i}) + \sqrt{2P_j} \cos(\pi kt^2 + 2\pi f_0 t + \theta_j) \quad (6)$$

## 2 时频图及机器学习网络模型

STFT 变换得到的时频图将信号时域和频域信息相结合,通过时频图可以同时提取信号在两域的特征,提取过程较为高效。

ML 算法众多,其中 SVM 在解决多类别样本、非线性和高维模式识别问题时具有准确率高、适用性强等显著特点。CNN 在基于图像的基准测试<sup>[15-16]</sup>中也取得了较好的分类效果。故本文把信号时频图作为 SVM 和 CNN 的学习对象,时频图及两种分类模型的建立如下。

### 2.1 时频图创建

SVM 和 CNN 算法通常有 2 个阶段:第 1 阶段完成特征提取,获取用于分类的重要输入特征向量,在本文中信号时频图是特征提取的对象;第 2 阶段为决策阶段,所建立模型为每个输入图像分配一个类。通过在信号进行傅里叶变换之前乘以一个窗函数,并在时间轴上不断移动,完成对信号的逐段分析和获取。具体步骤如下。

(1)确定北斗信号和各种干扰信号的主要参数,比如干扰功率、干扰信号频率等,然后将上述 2 种信号叠加得到混合信号。

(2)确定式(2)涉及的相关参数。主要使用的是接收信号、窗函数、重叠点数、采样频率、傅里叶点数等。其中,窗函数长度对时间和频率分辨率有较大影响。长窗口提供良好的频率分辨率,短窗口提供较高的时间分辨率,为了同时兼顾频率分辨率和时间分辨率,本文采取 512 的窗口长度。

(3)得到步骤(2)涉及的参数数值后,按照式(2)

对混合信号进行 STFT 变换获取相应时频图。

### 2.2 支持向量机模型

SVM 最初由 Cortes 等<sup>[17]</sup>提出,Mathur 等<sup>[18]</sup>使用 SVM 进行多分类和二分类研究,现被广泛用于图像识别以及文本分类等研究中<sup>[19]</sup>,其目的是寻找一个可以将不同类型样本分开且与支持向量保持最大距离的超平面。本文要实现的是线性不可分的多分类任务,最优分类超平面可利用核函数  $K(\mathbf{x}_i, \mathbf{x}_j)$  获取。

假设样本数据集由信号时频图  $D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$  组成,其中输入数据样本  $\mathbf{x}_i$  使用的特征由特征包 (BoF, bag of features) 生成; $y_i$  代表本文提到的 5 种信号类型的标签,即  $y_i \in \{1, 2, 3, 4, 5\}$ ,数字分别表示单音干扰、混合干扰、扫频干扰、无干扰(北斗信号)和多音干扰。

为了找到最优超平面,可以定义一个线性超平面为

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (7)$$

式中: $\mathbf{w}$  是超平面的法向量; $b$  为偏差常数。

若超平面可以将所有数据点正确分类,那么每一个样本点都应满足

$$\begin{cases} \mathbf{w}^T \mathbf{x}_i + b \geq 1 & y_i = 1 \\ \mathbf{w}^T \mathbf{x}_i + b \leq -1 & y_i = -1 \end{cases} \quad (8)$$

对式(8)进行优化即可得到 SVM 最优分类超平面,即

$$\begin{cases} \max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s.t.} \sum_{i=1}^n \alpha_i y_i = 0 \quad \alpha_i \geq 0 \end{cases} \quad (9)$$

式中, $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle^2$ ;  $\alpha$  为拉格朗日因子。

本文 SVM 整体工作流程如图 1 所示。

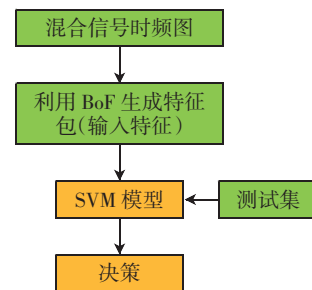


图 1 SVM 分类流程图

Fig.1 Flowchart of SVM classification

流程图中 BoF 把每幅图像描述为一个局部区域特征的无序集合,然后使用拥有 500 个聚类中心的 k-means 聚类算法将局部特征进行聚类,每个聚类中心被看作是一个视觉词汇,图像中的特征都将被映射

到视觉词典的某个词上,通过统计每个视觉词的出现次数或频率将图像描述为一个维数相同的直方图向量,然后把 BoF 术语向量作为 SVM 分类器的输入特征。

### 2.3 卷积神经网络

CNN 经常被用作图像分类,当数据集较大时尤其有效<sup>[20]</sup>。构建 CNN 架构需要重点关注卷积层、池化层和全连接层。图 2 为本文使用的 CNN 可视化模型。

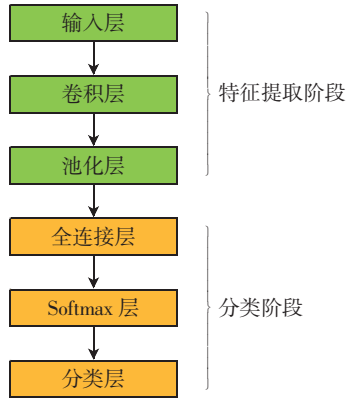


图 2 CNN 模型层架构

Fig.2 Layer architecture of CNN model

## 3 实验仿真

### 3.1 时频图数据库的创建

表 1 和表 2 分别为信号参数和短时傅里叶变换参数的设置。其中: $P_{DBS}$  为北斗信号的功率; $f_{j,cwi}$ 、 $f_i$ 、 $f_0$  分别为单音、多音、线性扫频干扰信号的频率; $U(,)$  表示参数值在给定范围内均匀变化;JSR 为干信比,表示干扰信号功率与北斗信号功率的比值;SNR 表示北斗信号功率与高斯白噪声功率的比值。

表 1 信号参数设置

Tab.1 Parameter settings of signal

参数	设置	参数	设置
$P_{DBS}/dBW$	-160	$f_0/MHz$	$U(4.1,4.5)$
$f_{j,cwi}/MHz$	$U(3.8,4.2)$	JSR/dB	$U(-5,50)$
$f_i/MHz$	$U(3.8,4.5)$	SNR/dB	45

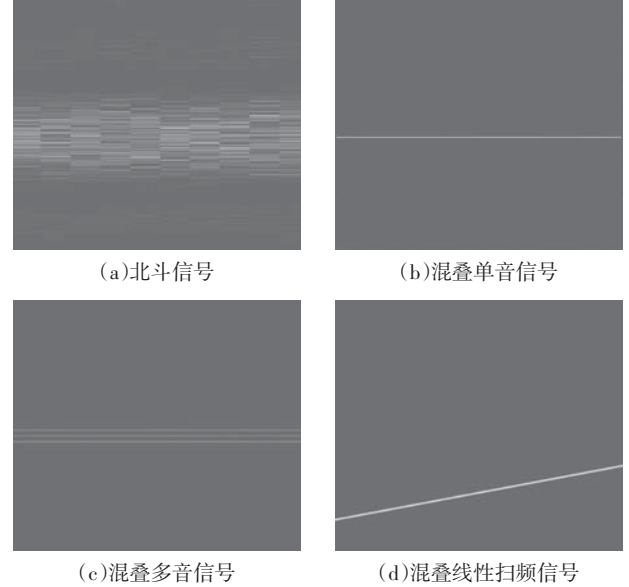
表 2 短时傅里叶变换参数设置

Tab.2 Parameter settings of short-term Fourier transform

参数	设置	参数	设置
窗口长度	512	重叠点数	250
傅里叶点数	2 000	采样频率/(10 <sup>6</sup> Hz)	1.841 4

图 3 为根据所设参数获取的信号灰度时频图。由图 3 可知:单音干扰时频图中存在一条特定频率处的水平直线;多音干扰时频图包含多个特定频率处的水

平直线;线性扫频干扰的频率呈现出随时间连续线性变换的动态特性;混合干扰表现出所叠加干扰的特征。干扰识别算法根据时频图数据库提取不同干扰的特征供网络模型进行学习。



(e) 混合信号

图 3 北斗信号及多种信号时频图

Fig.3 Time-frequency diagram of Beidou signal and multiple signal

### 3.2 网络模型训练

北斗信号与干扰信号的干信比在给定范围内变化,干扰信号频率在给定范围内取值,根据以上 2 种参数以及式(2)创建包含 50 000 个混合信号时频图的数据集,其中,30 000 个图像(每种干扰类型 6 000 个图像)用于训练,20 000 个图像(每种干扰类型 4 000 个图像)用于测试,创建时频图数据库的参数如表 1 和表 2 所示。

#### 3.2.1 传统识别算法——决策树模型设置

决策树识别算法依赖特征工程,选取的干扰特征因子以及对应的门限阈值如表 3 所示,为保证实验的可对比性,使用决策树识别算法进行信号分类时,采用的北斗信号和压制式干扰信号参数设置如表 1 所示,与 ML 算法仿真的北斗信号和干扰信号参数一致。整体识别率仿真结果如图 4 所示。

从图 4 中可以看出,随着干信比的增加,整体干

表 3 干扰识别仿真参数

Tab.3 Interference identification simulation parameters

干扰特征因子	门限阈值	干扰特征因子	门限阈值
频域峰度系数 $R_f$	30	时域峰度系数 $R_{tm}$	4
音频干扰系数 $C$	15	频域 $R$	0

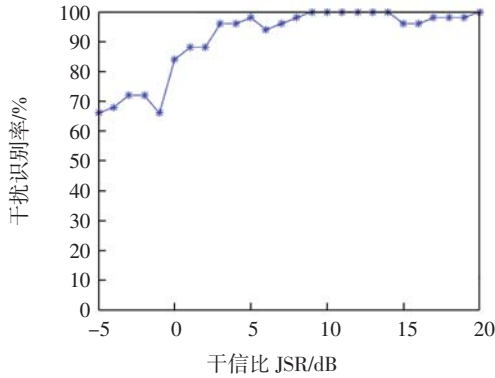


图 4 决策树整体干扰识别率

Fig.4 Overall interference identification rate of decision tree

干扰识别率也逐渐增加,当干信比为-5 dB 时,整体干扰识别率达到 65%左右,识别率较低,影响接收机定位性能;当干信比大于 5 dB 时,总体识别率在 90% 左右。综上可知,决策树识别算法在干扰信号功率较大,即低干信比情况下的识别效率明显不满足实际需求。针对传统识别算法需人工设计的特征工程提取特征因子以及低干信比情况下干扰识别率较低的问题,本文提出基于时频图学习的 SVM 和 CNN 算法。以下是两种 ML 算法的模型设置。

### 3.2.2 SVM 模型设置

使用 SVM 算法进行分类时的网络参数设置如下。

(1)输入: k-means 聚类中心为 500,每幅图像特征都将被归类为 500 个视觉码字,然后使用 BoF 对图像 70% 的特征进行量化,即根据视觉码字对每幅图像建立特征直方图,得到总特征数为 3 087 000 的图像术语向量,将其作为 SVM 的输入特征向量。

(2)核函数:在内核选择方面,从实际运行情况是否良好以及参数调优难易 2 个角度出发,选择使用高斯核函数。

(3)优化算法:基于拉格朗日乘子的迭代算法——序列最小优化算法寻找最优的超平面。

(4)输出:通过迭代训练,SVM 根据分类模型输出数据集所属的某一个干扰类型。

### 3.2.3 CNN 模型设置

本文使用拥有 1 个卷积层、1 个池化层、1 个全连接层和 Adam 算法<sup>[21]</sup>的 CNN 网络。在实验过程中尝试多种不同尺寸的时频图、卷积核和池化窗口进行网络

训练,从识别率和识别时间 2 个角度考虑,最终选取像素为 228 px × 228 px 的信号时频图进行 2 次迭代训练,每轮以最小训练批次尺寸 100 进行 300 次训练,一共可进行 600 次迭代循环。各层的具体参数设置如下。

(1)输入层:输入图像高度、宽度、深度为 228 px × 228 px × 1 px 数据集。

(2)卷积层:卷积神经网络的核心,使用 16 个大小为 13 × 13 × 1、步长为 1 的二维卷积核,卷积层的输出为 16 × 228 × 228。

(3)池化层:在本文的体系结构中使用最大池化,这意味着如果卷积层返回值  $\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix}$ ,那么池化层的输出为 4,池化窗口为 2 × 2,则池化层的输出为 16 × 108 × 108。

(4)输出层:一共有 5 种类型的信号,因此,卷积神经网络设有 5 个输出神经元。

2 种网络的参数设置如表 4—表 5 所示。

表 4 SVM 网络参数设置

Tab.4 Parameter settings of SVM network

网络参数	设置	网络参数	设置
优化算法	SMO	保留特征	0.7
聚类方法	k-means( $k=500$ )	损失函数	交叉熵损失函数
核函数	Gaussian		

表 5 CNN 网络参数设置

Tab.5 Parameter settings of CNN network

网络参数	设置	网络参数	设置
卷积层	13×13×1	激活层	ReLU 激活函数
池化层	最大池化	优化算法	Adam

### 3.3 仿真结果

使用创建的图像数据库分别对 SVM 和 CNN 进行训练,使用测试精度和混淆矩阵研究、量化机器学习算法。

图 5 显示了 CNN 算法的混淆矩阵和干扰识别率以及损失误差。图 5(a)中数字 1、2、3、4、5 分别代表单音干扰、混合干扰、扫频干扰、无干扰(北斗信号)和多音干扰,横坐标表示模型预测干扰类型,纵坐标表示实际干扰类型。图 6 为 SVM 算法的混淆矩阵。图 5 和图 6 的混淆矩阵右侧颜色渐变进度条表示数字大小,颜色越深数字越大。

由图 5 中的干扰识别率和损失误差曲线图可知,无论干信比的取值情况如何,随着网络模型的迭代优化,分类器最终的干扰识别率向 1 无限接近,与之对应,损失误差向 0 逐渐靠拢。



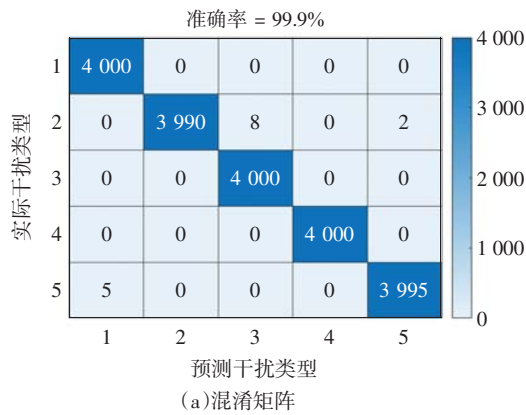


图 5 CNN 算法实验结果

Fig.5 Experiment results of CNN




图 6 SVM 算法的混淆矩阵  
Fig.6 Confusion matrix of the SVM algorithm

对比图 4 传统干扰识别率, CNN 和 SVM 网络在训练时已经遍历给定干信比范围下干扰信号时频图的特征因子, 在低干信比情况下依然有较高的干扰识别率, 前文提到的决策树识别率仅有 65% 左右, ML 算法则达到了 99% 以上, 与之相比识别率提高了 30% 以上, 本文提出的算法有较大优势。

由图 5 和图 6 混淆矩阵可以看出, 两种算法在同类干扰信号的具体识别率有不同之处, 经分析可能是

在自动提取时频图特征时采用的提取方法不同而导致, SVM 是采用 BoF 提取干扰特征, CNN 是通过卷积层和池化层提取。但是无论是在低干信比还是高干信比数值下, CNN 和 SVM 的平均识别率皆达到了 99% 以上, 结果相差不大。针对 LFM、北斗信号和 CWI 这 3 种信号, CNN 的识别率达到了 100%, 对 SCWI 和混合干扰的识别也都达到了 99% 左右; SVM 对 CWI 和北斗信号的识别率达到了 100%, 对其他干扰类型的识别率达到了 99% 以上。

以上实验结果验证了信号时频图作为 ML 输入特征情况下, 无论是 SVM 还是深度学习 CNN 识别算法, 在整体识别率上均比传统识别算法表现出更高数值且不受干信比影响的优势。

### 4 结语

现有干扰信号算法严重依赖人工设计的特征工程, 这种提取特征的方式受干信比影响较大且通用性较差。本文提出将混合信号时频图作为 SVM 和 CNN 学习对象的 BDS 干扰识别方法, 即用图像代替数字特征进行 ML 训练, 使其捕获更多干扰特征因子。实验结果表明, SVM 与 CNN 网络的干扰信号识别率在低干信比情况下识别率比决策树模型提高 30% 以上, 解决了现有算法存在的问题, 为后续抗干扰技术提供先验信息, 最大程度地避免和抑制干扰, 保证北斗卫星导航系统的安全性和可靠性。

### 参考文献:

- [1] FANG F, LI Y, NIU Y T, et al. Jamming signal recognition based on decision tree algorithm[J]. Communications Technology, 2019, 52(11): 2617-2623.
- [2] SHAN L, ZHANG J Y, SUN L. Deception jamming identification based on original echo information[J]. Electronic Information Warfare Technology, 2016: 55-58.
- [3] 孙殿星, 王国宏, 盛丹. 基于均值-方差联合检验的航迹欺骗干扰识别[J]. 航空学报, 2016, 37(4): 1292-1304.
- [4] 田晓, 唐斌. 基于归一化小波分解能量比的雷达有源欺骗干扰识别[J]. 数据采集与处理, 2013, 28(4): 416-420.
- [5] 李果, 文妮, 宫丰奎, 等. 部分频带干扰下的 OFDM 系统干扰检测与分集抑制算法[J]. 通信学报, 2021, 42(9): 194-204.
- [6] LI Y Q, LI P, YAN X P, et al. Application of wavelet transform to radio fuze jamming identification[C]//2008 4th International Conference on Wireless Communications, Networking and Mobile Computing, October 12-14, 2008, Dalian, China. IEEE, 2008: 1-4.
- [7] CUI Y, WANG J F. Wideband LFM interference suppression based on fractional Fourier transform and projection techniques[J]. Circuits, Systems, and Signal Processing, 2014, 33(2): 613-627.

- [8] FUR R. Compound jamming signal recognition based on neural networks[C]//2016 6th International Conference on Instrumentation & Measurement, Computer, Communication and Control(IMCCC), July 21-23, 2016, Harbin, China. IEEE, 2016: 737-740.
- [9] 张婧,冯振明.基于神经网络和SVM的GPS干扰类型识别[J].信息与电子工程,2009,7(5):386-389.
- [10] YANG Y, ZHU L D. An efficient way for satellite interference signal recognition via incremental learning[C]//2019 International Symposium on Networks, Computers and Communications(ISNCC), June 18-20, 2019, Istanbul, Turkey. IEEE, 2019: 1-5.
- [11] 王亚.基于特征提取的多干扰检测与识别方法研究[D].成都:电子科技大学,2022:39-40.
- [12] 葛红娟.卫星干扰信号的检测与识别[D].杭州:杭州电子科技大学,2022:48-50.
- [13] 陈起磊,蒋亦悦,唐瑶,等.基于时频图与改进图卷积神经网络的异步电机故障诊断方法[J].振动与冲击,2022,41(24):241-248.
- [14] WANG Y X, HUANG Y, CHEN Z Y, et al. Complicated interference identification via machine learning methods[C]//2021 IEEE 4th International Conference on Electronic Information and Communication Technology (ICEICT), August 18-20, 2021, Xi'an, China. IEEE, 2021: 400-405.
- [15] HOTFILTER T, HOEFER J, MERZ P, et al. Leveraging mixed-precision CNN inference for increased robustness and energy efficiency[C]//2023 IEEE 36th International System-on-Chip Conference (SOCC), September 5-8, 2023, Santa Clara, CA, USA. IEEE, 2023: 1-6.
- [16] PANE S F, RAMDAN J, PUTRADA A G, et al. A hybrid CNN-LSTM model with word-emoji embedding for improving the twitter sentiment analysis on Indonesia's PPKM policy[C]//2022 6th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE), December 13-14, 2022, Yogyakarta, Indonesia. IEEE, 2022: 51-56.
- [17] CORTES C, VAPNIK V. Support vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [18] MATHUR A, FOODY G M. Multiclass and binary SVM classification: implications for training and classification users[J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(2): 241-245.
- [19] 朱鹏程. GNSS 干扰检测与识别技术研究[D]. 重庆: 重庆大学, 2018.
- [20] DUVVURI K, KANISSETYPALLI H, JAYAN S. Detection of brain tumor using CNN and CNN-SVM[C]//2022 3rd International Conference for Emerging Technology (INCET), May 27-29, 2022, Belgaum, India. IEEE, 2022: 1-7.
- [21] LLUGSI R, YACOUBI S E, FONTAINE A, et al. Comparison between adam, adamax and adam w optimizers to implement a weather forecast based on neural networks for the Andean city of Quito[C]//2021 IEEE Fifth Ecuador Technical Chapters Meeting (ETCM), October 12-15, 2021, Cuenca, Ecuador. IEEE, 2021: 1-6.

(责任编辑:孟欣)

(上接第 35 页)

- [C]//The AIAA AVIATION 2021 FORUM, Reston, Virginia: AIAA, 2021: AIAA2021-2848.
- [14] 宋文萍,吴猛猛,朱震,等.面向层流减阻设计的转捩预测方法研究[J].空气动力学学报,2018,36(2):213-228.
- [15] 徐国亮,等.三维边界层流动失稳与Bypass转捩模式研究[D].北京:清华大学,2011.
- [16] MALIK M, ORSZAG S. Efficient computation of the stability of three dimensional compressible boundary layers[C]//The 14th Fluid and Plasma Dynamics Conference, Palo Alto, CA, USA. Reston, Virginia: AIAA, 1981: AIAA1981-1277.
- [17] SMITH A M O. Transition, pressure gradient and stability theory: report ES 26388[R]. City of Saint Louis: Douglas Aircraft Co., 1956.
- [18] 于高通.高超声速三维边界层 $e^n$ 方法的应用及扰动演化的预测[D].天津:天津大学,2016.
- [19] BALAKUMAR P, KING R. Receptivity and transition of supersonic boundary layers over swept wings[C]//The 48th AIAA Aerospace Sciences Meeting Including the New Horizons Forum and Aerospace Exposition, Orlando, Florida. Reston, Virginia: AIAA, 2010: AIAA2010-1454.

(责任编辑:刘智勇)