

基于 HOG-SVM 的跳频信号检测识别算法

张 萌^{1,2}, 王 文¹, 任俊星¹, 魏 冬^{1,2}, 黄伟庆^{1,2}, 杨召阳^{1,2}, 吕志强^{1,2}

¹中国科学院信息工程研究所 北京 中国 100093

²中国科学院大学网络空间安全学院 北京 中国 100049

摘要 针对非合作通信场景下的跳频信号自动化检测识别问题, 本文提出了一种基于方向梯度直方图与支持向量机的跳频信号检测识别算法。该算法将无线通信信号转化为包含时间、频率和幅度的时频瀑布图, 采用方向梯度直方图特征提取算法将不同跳频序列在瀑布图上产生的独特结构特征提取出来。然后利用支持向量机将特征序列映射到高维空间, 通过寻找最大间隔分离超平面, 实现跳频信号的检测与多种跳频序列的识别, 并依此建立跳频信号检测识别原型系统。最后在室内多径信道环境下进行了测试验证, 该算法能够完全自动化的精确检测到开放电磁环境下的跳频信号并且能够实现对多种跳频序列的识别。在信干噪比不超过 20dB 时, 针对不同跳频序列的平均识别正确率能够达到 98.01%。

关键词 跳频信号; 检测识别; 方向梯度直方图; 支持向量机

中图分类号 TN914.41 DOI 号 10.19363/j.cnki.cn10-1380/tn.2020.05.06

Detection and Recognition Algorithm for Frequency Hopping Signals Based on HOG-SVM

ZHANG Meng^{1,2}, WANG Wen¹, REN Junxing¹, WEI Dong^{1,2}, HUANG Weiqing^{1,2}, YANG Zhaoyang^{1,2}
LV Zhiqiang^{1,2}

¹Institute of Information Engineering, Chinese Academy of Sciences, Beijing 100093, China

²School of Cyber Security, University of Chinese Academy of Sciences Beijing 100049, China

Abstract In this paper, an algorithm based on Histogram of Oriented Gradient (HOG) and Support Vector Machine (SVM) is proposed to detect and recognize the frequency hopping signals in non-cooperative communication environment. The algorithm transforms wireless communication signals into time-frequency waterfall graph which include time, frequency and amplitude information. The algorithm of HOG is used to extract the special structure features on the waterfall graphs of different frequency-hopping sequences. Then the feature sequences are mapped to high dimensional space based on SVM to find the maximum margin hyperplane, thus the detection of frequency hopping signal and the recognition of different frequency-hopping sequences are realized, and the prototype system of frequency hopping signal detection and recognition is established. In the indoor multipath channel environment, the algorithm can automatically detect the frequency hopping signal accurately in open electromagnetic environment and can recognize many kinds of frequency-hopping sequences. Under the circumstance that the signal interference noise ratio is not above 20dB, the accuracy rate of recognizing different frequency hopping sequences can reach 98.01%.

Key words frequency hopping signal; detection and recognition; histogram of oriented gradient; support vector machine

1 引言

跳频通信技术可通过在宽频段内随机快速改变其载波频率实现抗干扰及抗截获^[1]。因此, 跳频通信技术被广泛应用于现代军事通信和保密通信领域。同时, 跳频通信信号的检测识别也成为信息安全领域的研究热点及难点问题。针对跳频信号的检测识

别, 主要面临如下难点: 1) 跳频信号难以有效接收, 受限于跳频通信技术的抗截获特点, 往往只能接收到部分信道的跳频信号, 从而影响后续的检测及识别; 2) 跳频信号接收面临电磁干扰, 由于电磁环境的复杂性, 跳频信号各信道间存在着大量且多样的其他通信信号, 这些通信信号的存在为跳频通信发挥抗截获性能提供了空间, 但同时跳频信号的检测及识别形成了干扰; 3) 跳频信号先验信息缺乏,

通讯作者: 王文, 博士, 高级工程师, Email: wwen@iie.ac.cn。

本课题得到中国科学院战略性先导 C 类(No.XDC02000000)专项资助。

收稿日期: 2018-12-28; 修改日期: 2019-04-01; 定稿日期: 2020-04-27

先验信息的缺失导致无法对高速随机变化的跳频信号建立稳定的检测识别特征, 从而影响检测及识别的精度; 4) 跳频信号难以自动检测识别, 当前针对跳频信号的判决还主要依赖于人工, 然而随着电磁空间的持续扩展及日益复杂化, 在实时产生的海量监测数据中实现对跳频信号的快速捕获及检测识别无法依赖人工, 因此迫切需要跳频信号的自动化检测识别方法。

针对上述难点问题, 当前针对跳频信号检测识别的研究主要分为: 自相关检测识别、时频分析及图像去干扰方法。

自相关检测识别方法主要解决噪声干扰下的跳频信号检测问题, 通过分析跳频信号自相关函数和噪声信号自相关函数, 构建检验统计量, 利用判决门限对跳频信号进行检测。Sultan 等人^[2]提出了基于线性调频 z 变换的跳频信号自相关检测方法, 分析了在加性高斯白噪声和窄带干扰情况下的跳频信号检测性能。Polydoros 等人^[3]提出了强宽带加性高斯白噪声和宽频带干扰环境下的跳频信号自相关检测理论模型, 并对此模型进行了深入的分析。Polydoros 等人^[4]进一步优化了宽带加性高斯白噪声环境下的跳频信号自相关检测模型, 降低了模型计算复杂度。Fanji Meng 等人^[5]使用自适应滤波器提升信号信噪比, 并提出分段自相关方法实现了在较低信噪比环境下的跳频信号检测。钱博等人^[6]利用差分跳频信号的自相关特性和高跳速特征在特定噪声环境下实现了跳频信号的高效检测。董占奇等人^[7]使用基于 ρ 判决的信噪比无关的自相关检测方法, 避免了基于功率信号采样的信号干扰问题。基于自相关函数的跳频信号检测方法计算复杂度高, 实时监测性能较差, 并且需要人工设置判决阈值, 自动化检测能力有所欠缺。同时, 该类方法对噪声信号模型依赖较强, 无法适应多变的噪声环境, 因此无法在实际复杂电磁环境中被广泛应用。

时频分析方法是分析非平稳信号的重要工具, 可以提取信号在时域和频域上的特征, 形成跳频信号时频图案, 再通过人工识别等方法辨别跳频信号。时频分析方法的应用使得跳频信号检测完全不需要任何电磁环境及跳频信号本身有关的先验知识及假设, 实现了跳频信号全场景下的盲检测。其算法主要包括短时傅里叶变换(short-time Fourier transform, STFT), 小波变换, Wigner-Ville 类变换。基于短时傅里叶变换的跳频信号检测方法^[8]不存在交叉项干扰, 但是对时频信号聚焦性不强, 不易权衡频率分辨率和时间分辨率。基于小波变换的跳频信号盲

检测方法由于引入小波函数, 小波函数的频率特性和时间特性可以有效提升跳频信号检测的时频分辨率^[9,10], 基于 Wigner-Ville 类变换的盲检测方法同样是对跳频信号检测中时频分辨率进行平衡, 改善了跳频信号时频局部聚集性, 但是引入了交叉干扰项, 计算复杂, 实时性差^[11,12]。跳频信号盲检测的时频分析方法需要对时频分辨率做出权衡并且依然受到跳频频域跨度内噪声信号和干扰信号的影响, 同样无法适应实际复杂电磁环境中多变的噪声环境。

随着图像处理技术的发展及其在信号处理方面的不断深入应用, 由于跳频信号固有的时域和频域二维特征与图像二维平面特征有着高度的相似性, 图像处理技术被引入跳频信号检测领域, 与时频分析方法相结合^[13], 不断提升跳频信号检测能力。跳频信号可以通过短时傅里叶变换和小波变换等时频分析方法得到时频图进行分析^[14], 再通过图像处理中的二值形态学滤波方法加强信号强度, 应用膨胀、腐蚀方法^[15,16]提升时频图中跳频信号清晰度。文献[17]通过边缘检测算法, 使用抗噪声强的 Sobel 边缘算子对时频图进行卷积操作, 去除跳频信号复杂背景噪声和定频干扰。

现有时频分析和图像处理相结合的跳频信号盲检测方法, 更多的应用在了对跳频信号时频图进行信号强度增强和去除干扰噪声方面, 能够实现简单跳频信号盲检测。而且, 形态学中的膨胀、腐蚀操作在复杂环境下组合难以选定, 需要依赖较多人工经验。同时, 基于 Sobel 算子的边缘检测算法需要设置边缘检测阈值, 阈值选择的好坏对时频图恢复效果有决定性影响。此外, 现有时频分析结合图像处理的方法缺少对跳频信号自动化检测方法的研究。总的来说, 目前对于跳频信号的盲检测技术还存在识别准确率不高, 检测自动化不足, 抗外界噪声、干扰能力不足等问题。

上述方法在一定程度上解决了噪声和定频干扰对跳频信号检测带来的困难, 并且实现了在电磁环境和跳频信号本身先验知识未知情况下的盲检测。但是, 上述方法的前提均为在完整接收信号的情况下, 并且对于噪声和干扰的去除缺乏自适应方法, 其中最为关键的检测步骤需要人工参与。

然而, 在实际电磁环境中, 电磁空间情况复杂多变, 各种噪声、干扰可能剧烈变化, 并且跳频信号是否存在, 以及何时、何频段出现是不可预知的, 需要通过长时监测和宽频带监测来捕捉随时可能出现的跳频信号。在情况多变的电磁空间中, 实现对跳频信号的实时预警, 自动化检测识别至关重要。

本文提出一种基于方向梯度直方图(Histogram of Oriented Gradient, HOG)及支持向量机(Support Vector Machine, SVM)的跳频信号识别算法, 该算法通过时频分析的方法将跳频信号转化为包含信号强度、信号带宽、信号驻留时间的三维信息瀑布图, 通过对跳频信号瀑布图所独具的 HOG 特征的描述, 可基于信号强度、信号带宽、跳频间隔、信号驻留时间多个维度对不同类型的跳频信号进行描述。跳频信号瀑布图的 HOG 特征具有很高的稳定性, 即使截取的跳频序列不完整, 其瀑布图仍具有 HOG 特征, 并且能够体现不同类型跳频序列间的差异。在对信号瀑布图的 HOG 特征进行分析后, 利用 SVM 算法实现复杂电磁环境下的跳频信号检测及多种跳频序列的识别。该算法在进行信号时频分析及 HOG 特征提取时分别对数据进行了大量压缩, 从而降低了计算量, 有效提高了实时检测性能。此外, 本文基于该算法建立了跳频信号检测识别原型系统, 并在实际的电磁环境及室内多径无线信道下, 针对无人机、蓝牙及 Wifi 等不同类型跳频信号的检测识别进行了仿真及测试验证。

本文后续章节安排如下: 第二部分提出跳频信号检测识别模型, 第三部分详细介绍基于方向梯度直方图和支持向量机的跳频信号检测识别算法, 第四部分基于跳频信号检测识别模型建立原型系统, 在开放电磁环境下, 对原型系统进行测试验证并对系统性能进行深入分析; 第五部分对论文内容进行总结并展望后期工作。

2 跳频信号检测识别模型

为实现对跳频信号检测识别算法的仿真及测试验证, 本文首先针对实际的电磁环境建立跳频信号检测识别模型, 如图 1 所示, 该模型主要包括跳频信

号采集模块、时频转换模块、特征提取模块、以及跳频检测识别模块四个部分组成。




图 1 跳频信号检测模型

Figure 1 Frequency hopping signal detection model

2.1 信号采集模块

本小节建立无线信号的采集模型。如图 2 所示, 首先利用接收天线接收目标无线信号 $s(t)$

$$s(t) = a(t)e^{j[2\pi(f_c + n\Delta f)t + \phi(t)]} \quad (1)$$

其中, 载波频率 f_c 随时间变化。

然后通过低噪放大器、本机振荡器及模拟低通滤波器将射频信号的频率降至中频, 得到

$$s_0(t) = a(t)e^{j[2\pi(f_L + n\Delta f)t + \phi(t)]} \quad (2)$$

之后, 利用模数转换对中频模拟信号进行数字采样, 并利用数字震荡器分别产生中频正弦载波

$$\sin(\omega_0 n) \quad (3)$$

及中频余弦载波

$$\cos(\omega_0 n) \quad (4)$$

与中频数字信号进行混频, 并通过数字低通滤波器获得数字基带调制信号

$$x_0(n) = x_I(n)\cos(2\pi n\Delta f n) - x_Q(n)\sin(2\pi n\Delta f n) \quad (5)$$

其中

$$x_I(n) = a(n)\cos\phi(n) \quad (6)$$

$$x_Q(n) = a(n)\sin\phi(n) \quad (7)$$

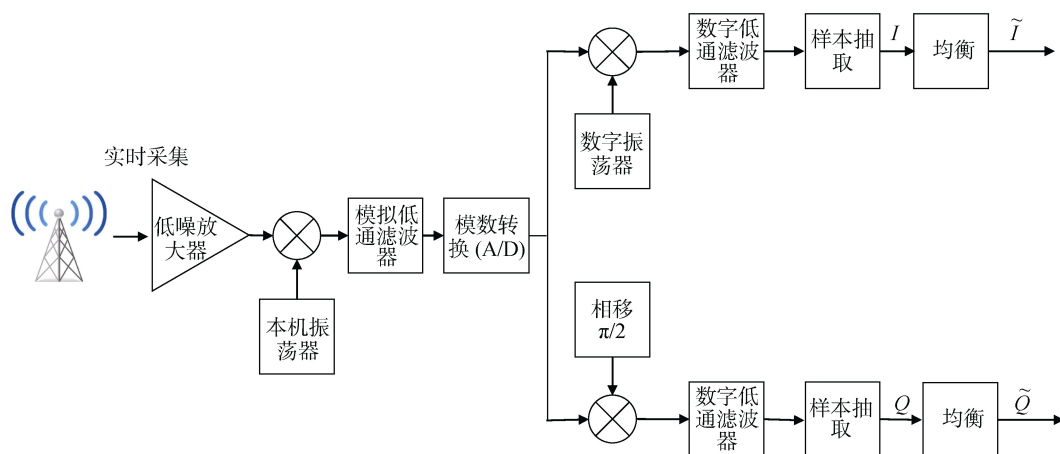


图 2 无线信号采集模型

Figure 2 Wireless signal acquisition model

分别为无线调制信号的数字基带正交分量及数字基带同相分量, 分别记为 \tilde{I} 路信号和 \tilde{Q} 路信号。

2.2 时频转换模块

时频转换模块实现对待检测信号的时频分析, 获得跳频信号的时频瀑布图。跳频信号是典型的非平稳信号, 具有较宽的频域跨度, 并且每一跳信号频点随时间快速变化, 而常规的全局变换算法不适用于非平稳信号。为了确定跳频信号在某一时间上的频率分布情况, 本文采用短时傅里叶变换方法实现对待检测信号的时频分析。将采集到的数字基带信号 $x_0(n)$ 进行离散短时傅里叶变换^[18], 得到

$$STFT[m, n] = \sum_{k=0}^{N-1} x(k) g^*[kT - mT] e^{-j2\pi(nF)k} \quad (8)$$

其中 $g(t)$ 为窗函数, m 表示窗函数长度, $g^*(t)$ 表示复数共轭, T 表示时间变量的采样周期, F 表示频率变量的采样周期, 其中, $T > 0$, $F > 0$, m, n 为整数。

短时傅里叶变换得到待检测信号的时间和频率信息。待检测信号能量信息 $SPEC(t, \omega)$ 表示为

$$SPEC(t, \omega) = |STFT[m, n]|^2 \quad (9)$$

将待检测信号的时间信息 t , 频率信息 f , 信号强度信息 $SPEC$ 转化为频谱瀑布图 G

$$G(t_i, f_j) = SPEC_{t_i, f_j} \quad (10)$$

如图 3 所示瀑布图 G 中横向表示信号频率, 纵向表示信号出现时间, 颜色等级表示对应时间点和频率点上的信号电平强度, 其信号强度越高颜色越接近红色。瀑布图完整表示了信号在时域、频域、信号强度三个维度上信息。同时, 跳频信号具有跳频速率、跳频带宽、跳频频率数、跳频增益多种性能指标, 指标值的不同使得信号具有不同的跳频图案。通过时频转换模块得到的瀑布图, 包含了跳频信号的完整信息。




图 3 瀑布图示意

Figure 3 Waterfall schematic diagram

2.3 特征提取模块

特征提取模块实现对待检测信号瀑布图的特征提取, 同时实现数据降维。经过时频转换的跳频信号瀑

布图包含了信号的全部信息, 同时也包含了大量的冗余数据, 特征提取模块用于提取不同跳频信号的本质属性, 并去除冗余数据。

经过时频转换后, 跳频信号的瀑布图具有类似时空域图像的边缘特征, 使用 HOG 特征提取的改进算法提取跳频信号在时频域的边缘分布特征。通过计算跳频信号与背景噪声能量变化的梯度, 并统计一定区域内梯度变化方向和该方向上的梯度变化强度来得到时频域空间上的跳频信号特征。同时, HOG 特征对时空域图像的几何形变具有容忍能力, 相对应的, 在瀑布图中表现为对时间分辨率和频率分辨率的容忍能力。另外, HOG 特征在时空域内具有光学不变特性^[19], 允许图像有一定程度的明暗变化, 该特征在瀑布图中可以类比为宽频带内底部噪声不变性。总的来说, HOG 特征可以在时频分辨率较低、底部噪声变化的环境下实现对跳频信号的时频特征提取。

从跳频信号瀑布图 G 提取信号特征, 并表示为特征向量 \mathbf{v}

$$\mathbf{v} = HOG[1, 2, \dots, N] \quad (11)$$

其中, N 为特征向量维度。

2.4 跳频检测识别模块

特征提取完成之后需要将跳频信号的特征向量映射为跳频信号的存在性及其信号类别, 以完成跳频信号检测识别模型的最终功能。

跳频检测模块核心为支持向量机算法, 该算法将特征向量映射到高维空间以解决数据特征线性不可分问题, 并通过计算最大分隔平面在数据集上获得最优的分隔平面获得良好的检测性能。

支持向量机算法通过学习不同干扰和噪声环境下的跳频信号特征, 得到高精度的跳频信号检测模型。在实际检测过程中, 将跳频信号的时频域 HOG 特征, 输入已训练好的支持向量机模型中, 可实现对跳频信号存在性的检测及其信号类型的识别。

3 基于 HOG-SVM 的跳频信号检测识别算法

3.1 基于 HOG 的跳频序列特征提取

跳频信号在时频域的分布特征本质上由其跳频速率、跳频带宽、跳频频率数等性能指标决定, 受其性能指标的约束, 跳频信号在时频域二维空间上具有频域跨度大、跳频点随机出现、单跳驻留时间极短的特点。这些特点反映在跳频信号瀑布图上, 每一跳表现为一条横向延伸的短线段。加之多跳在频域的随机

性形成了瀑布图上疏密程度的不同, 使其整体上呈现为长短不一的时频域线条所组成的独特图案。

由此, 对跳频信号的检测可以等价于对时频域瀑布图在二维平面上线条分布规律的检测。跳频信号与背景噪声存在信号强度上的差异, 这种差异可以使用信号与背景过渡所带来的梯度变化程度来衡量。图像处理中边缘检测技术正是用于检测图像中线条与周边图案的梯度变化情况^[20]。所以跳频信号的特征可以被理解为时频域的一种边缘特征, 可以使用边缘特征对跳频信号进行描述。

本文提出基于方向梯度直方图对跳频信号的时频域特征进行描述。

方向梯度直方图在图像处理中用于对检测物体进行特征描述。在一幅图像中, 局部目标可以由其边缘梯度和方向密度描述, HOG 即用于表征这样的特征。由于其良好的局部几何不变性和光学不变性, HOG 特征被广泛用于行人检测领域, 并取得了良好的应用效果。

跳频信号瀑布图中存在多种形态的代表信号频率宽度和持续时间的短线段, 信号所在时频位置四周的梯度变化明显, 具备丰富的时频域局部梯度变化特征。又由于背景噪声的存在会影响频带内跳频信号的信噪比, 这可以等价于时空域内光照对图像明暗程度的影响。使用方向梯度直方图特征可以在一定程度上忽略跳频信号的背景噪声。

如图 4 所示, HOG 通过灰度化跳频图像、计算像素梯度、构建 HOG 特征及梯度强度归一化共四个步骤实现特征提取, 形成对跳频信号时频域的完整特征表示, 具体流程如下。




图 4 特征提取流程

Figure 4 Feature extraction process

(1) 灰度化跳频图像

如图 5 所示灰度化处理是将 RGB 三通道彩色跳频信号瀑布图转化为单通道灰度图像, 并用二维矩阵 A 表示

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{mn} \end{pmatrix} \quad (12)$$

矩阵上元素的数值表示信号的强度, 取值范围为 $[0, 255]$ 。灰度化处理不仅便于后续像素梯度计算, 而且可以去除颜色对图像边缘特征的影响, 提升信号识别的鲁棒性。

本文使用加权平均法实现对 RGB 三通道彩色跳频信号瀑布图的灰度化处理, 灰度化处理后的像素值 $a(i, j)$ 为

$$a(i, j) = \alpha R(i, j) + \beta G(i, j) + \gamma B(i, j) \quad (13)$$

其中 α, β, γ 分别表示 R, G, B 三个颜色通道上的权值, $R(i, j), G(i, j), B(i, j)$ 表示彩色图像像素点在 R, G, B 三个通道上的像素值。




图 5 灰度化示意

Figure 5 Grayscale schematic diagram

(2) 计算图像中每个像素的梯度

灰度化瀑布图中像素点用 $a(i, j)$ 表示, 分别计算其水平方向梯度 $H_G(i, j)$ 、垂直方向梯度 $V_G(i, j)$ 、梯度幅值 $A_G(i, j)$ 、梯度方向角 $\beta(i, j)$

$$H_G(i, j) = P(i+1, j) - P(i-1, j) \quad (14)$$

$$V_G(i, j) = P(i, j+1) - P(i, j-1) \quad (15)$$

$$A_G(i, j) = \sqrt{H_G(i, j)^2 + V_G(i, j)^2} \quad (16)$$

$$\beta(i, j) = \arctan(V_G(i, j) / H_G(i, j)) \quad (17)$$

(3) 构建方向梯度直方图特征

首先进行图像分割, 以输入为 1024×128 像素大小的跳频瀑布图为例, 使用 128×128 像素大小的滑动窗口对图像进行分割(图 6), 滑动窗口从图像左侧向右每次滑动 128 个像素的距离, 将图像分割为

128×128 像素大小的 8 个像素块。




图 6 滑动窗口对图像进行分割

Figure 6 The sliding window divides the image

其次对像素块进一步分割, 将其分割为 16 个 32×32 像素大小的胞元, 考虑到跳频信号在频域内的水平分布特征及其在时域内的垂直分布特性, 同时注意到单个跳频信号时频边缘位置上, 在水平方向和垂直方向附近的角度的范围内存在更丰富的时频梯度变化, 所以在划分胞元区间时, 考虑统计水平方向和垂直方向及其附近角度的梯度变化, 故将胞元内像素梯度方向角度平均分为 4 个统计区间, $(-45^\circ, 45^\circ]$ 、 $(45^\circ, 135^\circ]$ 、 $(135^\circ, 225^\circ]$ 、 $(225^\circ, 315^\circ]$, 如图 7 所示。




图 7 胞元内梯度方向统计区间划分

Figure 7 Statistical interval division of intracellular gradient direction

胞元内每个像素均存在梯度强度和梯度方向, 如图 8 所示, 箭头方向表示梯度强度, 箭头长度表示




图 8 胞元内梯度强度及方向示意

Figure 8 Intensity and direction of intracellular gradient

梯度强度。统计图 7 所示的 4 个方向上的梯度强度加和值形成胞元内的方向梯度直方图(图 9)。




图 9 方向梯度直方图示意

Figure 9 Histogram of direction gradient

最后将每个像素块中的胞元直方图组合在一起, 得到整体的 HOG 特征, 共 $8 \times 16 \times 4 = 512$ 个特征点, 表示为

$$v = HOG[1, 2, \dots, 512] \quad (18)$$

(4) 梯度强度归一化

为了降低图像背景噪声与图像噪声对比度变化对梯度幅值的影响采用 $L2$ 范数对特征向量做归一化处理。

$$v = \frac{v}{\sqrt{\|v\|_2^2 + e}} \quad (19)$$

其中, v 表示 HOG 特征向量, $0 < e \ll 1$ 为防止除 0 错误而设置。

3.2 基于 SVM 的跳频信号检测识别

支持向量机是一种具有坚实的统计学理论基础的有监督分类判别算法, 通过最大间隔超平面对数据进行划分。它在线性分类器的基础上结合了 VC 维概念、结构风险最小化理论以及核函数方法, 能很好的解决复杂分类模型的线性不可分问题。

VC 维是分类学习算法对函数空间学习能力的度量^[21], 如果存在 N 个样本的数据集 D 能被具有参数向量 θ 的分类模型 f 按所有可能中的 2^N 种可能分开, 则用分类模型 f 把数据集 D 打散, 分类模型的 VC 维定义为分类模型 f 能打散的最大样本数 N 。一般来说分类算法的 VC 维越大, 其学习能力越强, 同时模型也更加复杂。

统计学习理论提出了结构风险最小化原则^[22], 即把函数集构造成为一个嵌套子集序列, 使得所有函数子集按照 VC 维从小到大排列, 同一个函数子集中的置信范围相同, 在每一个子集中寻找最小经验风险, 选择最小经验风险与置信范围之和最小的子集, 得到的期望风险最小, 这个子集就是最优函数, 这种求解最优函数的方法称为结构风险最小化。

本文基于上述理论, 构建最大间隔分离超平面。

对于给定数据集 D 和超平面 (w, b) , 超平面 (w, b) 关于样本点 (x_i, y_i) 的函数间隔为

$$\hat{\gamma}_i = y_i(w \cdot x_i + b) \quad (20)$$

其中, w 表示分离超平面的法向量, b 表示截距。

数据集 D 到超平面 (w, b) 的函数间隔为 D 中样本点 (x_i, y_i) 到超平面 (w, b) 的函数间隔最小值, 即

$$\hat{\gamma} = \min_{i=1,2,\dots,N} \hat{\gamma}_i \quad (21)$$

对于给定数据集 D 和超平面 (w, b) , 超平面 (w, b) 关于样本点 (x_i, y_i) 的几何间隔为

$$\gamma_i = y_i \left(\frac{w}{\|w\|} \cdot x_i + \frac{b}{\|w\|} \right) \quad (22)$$

数据集 D 到超平面 (w, b) 的几何间隔为 D 中所有样本点 (x_i, y_i) 到超平面 (w, b) 的几何间隔最小值

$$\gamma = \min_{i=1,2,\dots,N} \gamma_i \quad (23)$$

最大间隔超平面即为, 在能够正确划分数据集的前提下, 能唯一确定的几何间隔最大的超平面, 满足

$$\max_{w,b} \gamma \quad (24)$$

$$\text{s.t. } y_i(w \cdot x_i + b) \geq \gamma \\ i = 1, 2, \dots, N$$

上式可以等价于

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (25)$$

$$\text{s.t. } y_i(w \cdot x_i + b) \geq \gamma \\ i = 1, 2, \dots, N$$

特征数据中往往存在噪声点和异常点, 不同类别间往往线性不可分, 在线性 SVM 中引入松弛变量 ξ_i 惩罚参数 C , 并用软间隔最大化学习策略确定唯一分离超平面。SVM 目标函数可以表示为

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (26)$$

SVM 学习机制可以表示为如下凸优化问题

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (27)$$

$$\text{s.t. } y_i(w \cdot x_i + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \quad i = 1, 2, \dots, N$$

如上学习机制的对偶问题表示为

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \quad (28)$$

$$\text{s.t. } \sum_{i=1}^N \alpha_i y_i = 0$$

$$0 \leq \alpha \leq C \quad i = 1, 2, \dots, N$$

对于训练集

$$D_T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \quad (29)$$

$$y_i \in \{-1, +1\} \quad i = 1, 2, \dots, N$$

SVM 训练过程表示为:

求解式(28)所表示的凸二次规划问题, 得出最优解

$$\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T \quad (30)$$

计算最大分隔超平面权重

$$w = \sum_{i=1}^N \alpha_i^* y_i x_i \quad (31)$$

选取 α^* 分量 α_j^* , 满足 $0 \leq \alpha_j^* \leq C$, 计算最大分隔超平面偏置

$$b^* = y_i - \sum_{i=1}^N y_i \alpha_i^* (x_i \cdot y_i) \quad (32)$$

得到分隔超平面为

$$w^* \cdot x + b^* = 0 \quad (33)$$

分类决策函数为

$$f(x) = \text{sign}(w^* \cdot x + b^*) \quad (34)$$

其中, 解向量

$$\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T \quad (35)$$

$$\text{中对应 } \alpha_i^* > 0 \quad (36)$$

的样本点 (x_i, y_i) 称为支持向量。

对于更复杂的非线性分类问题, 可以使用核方法^[23]将输入特征空间映射到高维特征空间, 此时非线性分类问题转化为线性分类问题。

设 \mathcal{X} 为欧式输入空间, 设 \mathcal{H} 为希尔伯特空间, 如果存在一个从 \mathcal{X} 到 \mathcal{H} 的映射

$$\phi(x): \mathcal{X} \rightarrow \mathcal{H} \quad (37)$$

使得所有 $x, z \in \mathcal{X}$, 函数 $K(x, z)$ 满足

$$K(x, z) = \phi(x) \cdot \phi(z) \quad (38)$$

则称 $K(x, z)$ 为核函数, $\phi(x)$ 为映射函数。

应用核方法的 SVM 目标函数可以表示为:

$$W(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \quad (39)$$

分类决策函数可以表示为

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i K(x_i, x) + b^* \right) \quad (40)$$

实际应用中, 由于分类超平面无法预知, 需要通过搜索方法筛选出最适合当前问题的核函数及其参数, 常用核函数包括线性核、多项式核及高斯核。其中, 线性核为

$$K(x, z) = x \cdot z + c \quad (41)$$

对应的决策函数为

$$f(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i^* y_i (x_i \cdot x + c) + b^*\right) \quad (42)$$

利用线性核得到的分割超平面如图 10 所示。

多项式核为

$$K(x, z) = (x \cdot z + c)^p \quad (43)$$

其中 p 为多项式系数。

对应的决策函数为

$$f(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i^* y_i (x_i \cdot x + c)^p + b^*\right) \quad (44)$$

高斯核为

$$K(x, z) = \exp\left(-\frac{\|x - z\|^2}{2\sigma^2}\right) \quad (45)$$

对应的决策函数为

$$f(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i^* y_i \exp\left(-\frac{\|x - z\|^2}{2\sigma^2}\right) + b^*\right) \quad (46)$$

利用高斯核得到的分隔超平面如图 11 所示。




图 10 线性分隔超平面

Figure 10 Linearly separated hyperplanes




图 11 高斯核方法分隔超平面

Figure 11 The gaussian kernel method separates the hyperplane

选择合适的核函数及 SVM 算法参数, 训练得到跳频信号检测识别模型。使用该模型最终实现跳频信号的检测与识别。

4 实验测试与分析

结合信号采集模块以及多种型号手机、无线键盘、无线鼠标、联想笔记本电脑、无人机并利用 OpenCV 机器视觉库、scikit-learn 机器学习库和 C# 编程语言, 本文基于上文所提出的跳频信号检测识别模型搭建原型系统, 并在室内开放环境中进行了测试与分析。

4.1 跳频信号检测识别原型系统

本系统的信号采集模块由天线、信号采集终端及笔记本电脑组成, 如图 12 所示。天线与信号采集终端连接, 信号采集终端与笔记本电脑连接, 将采集到的无线信号迹线数据存储在笔记本电脑中。




图 12 跳频信号检测识别原型系统

Figure 12 Frequency hopping signal detection and identification prototype system

时频转换模块使用 C# 编程语言对采集到的无线信号迹线数据进行时频转换, 得到瀑布图图像数据, 同时保存在笔记本电脑中。

特征提取模块使用 openCV 机器视觉库, 提取瀑布图的 HOG 特征, 将特征向量构成的数据集存储为 csv 格式。

跳频信号检测识别模块使用 scikit-learn 机器学习库, 实现基于高斯核的 SVM 算法学习 HOG 特征数据, 形成检测识别模型。同时完成对跳频信号的检测识别功能。

4.2 实验测试场景

本文所做实验在实际办公环境下进行, 如图 13 所示。环境中存在不可预知的外部电磁干扰, 同时还存在打印机、计算机等办公设备及手机、平板等各种无线设备产生的干扰, 电磁环境开放且较为复杂。

本节测试在实验场景中模拟产生了实际工作、生活中开放电磁环境下常见的多种跳频信号和非跳频信号。

本测试共包括工作在 2.4~2.483GHz 带宽内的蓝牙传输信号、蓝牙扫频信号、无人机信号、Wifi 信号 4 种跳频信号。跳频信号一部分由手机、无线键




图 13 实验场景示意
Figure 13 Schematic diagram of experimental scene

盘、无线鼠标的蓝牙模块产生, 包括它们在扫描周边设备时发出的蓝牙扫描信号和在传输数据的过程中发出的蓝牙传输信号, 另一部分跳频信号为无人机信号及办公环境中的 Wifi 信号, 其中无人机信号为大疆精灵 3 无人机与其遥控器之间通信产生控制信号。测试用蓝牙设备及无人机设备如图 14 及 15 所示, 跳频信号类型及其发射设备, 如表 1 所示。



图 14 蓝牙设备
Figure 14 Bluetooth devices



图 15 大疆精灵 3 无人机及遥控器
Figure 15 Dji spirit 3 drone and remote control

非跳频信号包括实验场景中的突发信号、定频信号及背景噪声等, 将在测试结果中统一标记为负例信号。

表 1 跳频信号设备		
Table 1 Frequency hopping signal equipment		
信号类型	设备	型号
蓝牙传输	手机	小米 5s
		华为荣耀 7
	无线鼠标	罗技 M185
蓝牙扫描	无线键盘	罗技 M185
	手机	小米 5s
	手机	华为荣耀 7
无人机	无线鼠标	罗技 M185
	无线键盘	罗技 M185
Wifi	无人机	大疆精灵 3
	无线路由器	-

实验区域覆盖跳频信号检测识别原型系统周边半径 20 米范围内。实验过程中正常使用无线鼠标、无线键盘工作, 持续采集无线鼠标和无线键盘在工作过程中发出的蓝牙扫描和蓝牙传输信号, 并将信号存储在笔记本电脑中。

使用两个手机互相传输图片、视频数据, 持续采集数据传输过程中手机产生的蓝牙扫描和蓝牙传输信号, 并将信号存储在笔记本电脑中。

使用遥控器遥控无人机在实验环境中飞行, 持续采集遥控器和无人机之间的通信信号, 标记为无人机信号, 并将信号存储在笔记本电脑中。

实验环境中存在多个无线路由器, 关闭其他信号发射设备, 持续采集无线路由器发出的 Wifi 信号, 并将信号存储在笔记本电脑中。

使用信号发生器产生定频信号、突发信号, 同时采集实验场景内的背景噪声, 通过原型系统中的信号接收设备采集之后, 统一标记为负例信号, 并将信号存储在笔记本电脑中。

由于实验场景内存在一定程度的干扰, 经测试采集到信号的信噪比 0.2~20dB 范围内。

通过时频转换将采集到的无线信号转化为瀑布图数据, 得到包括蓝牙传输信号(图 16)、蓝牙扫频信号(图 17)、无人机信号(图 18)、Wifi 信号(图 19)、负例信号(图 20)在内的无线信号瀑布图共 16959 张, 其中训练集 12128 张, 测试集包括上述五类信号的瀑布图 703 张及带有不同程度干扰的五类信号瀑布图 4128 张。




图 16 蓝牙传输信号

Figure 16 Bluetooth transmission signal




图 17 蓝牙扫频信号

Figure 17 Bluetooth sweep signal



图 18 无人机信号

Figure 18 Drone signal




图 19 Wifi 信号

Figure 19 Wifi signal



图 20 负例信号

Figure 20 Negative cases of signal

4.3 实验测试分析

4.3.1 跳频信号检测识别能力分析

本节使用基于 HOG-SVM 算法的跳频信号检测

识别原型系统测试了在正常工作区域内的检测识别性能。

使用混淆矩阵对基于 HOG-SVM 的跳频信号检测识别原型系统的检测能力和识别能力进行评估。对于混淆矩阵 C

$$C = \begin{pmatrix} c_{11} & \cdots & c_{1n} \\ \vdots & \ddots & \vdots \\ c_{n1} & \cdots & c_{nn} \end{pmatrix} \quad (47)$$

其中, 横坐标表示信号被检测识别到的类别, 纵坐标表示信号的真实类别, c_{ij} 表示模型将测试数据中第 i 类信号检测识别为第 j 类信号的数量。同时, 统计 HOG-SVM 模型对跳频和非跳频信号的检测结果(图 21)和对各类跳频信号不同序列特征的识别结果(图 22)。




图 21 用混淆矩阵表示检测结果

Figure 21 The obfuscation matrix of the detection results




图 22 用混淆矩阵表示识别结果

Figure 22 The obfuscation matrix of the identify results

从图 21 可以看出, HOG-SVM 模型能够将测试集内的跳频和非跳频信号进行正确的检测和分类。

将图 22 的测试数据转换为图 23 的识别正确率, 可以看出, 本测试对无人机信号、Wifi 信号具有优异的识别性能, 实现了对测试集内无人机信号、Wifi 信号的全部识别, 没有与其他信号发生混淆。




图 23 跳频信号识别正确率

Figure 23 Frequency hopping signal recognition accuracy

可见 HOG 特征正确捕捉到了上述两种信号经时频变换后的跳频瀑布图特征, 能够很好的表征上述两种跳频信号的不同跳频序列, 并且特征之间存在较大差异, 结合 SVM 算法实现了优异的识别性能。

与此同时, 本测试针对蓝牙传输和蓝牙扫频所采用的跳频序列, 识别性能略有不足, 有很少一部分的蓝牙传输信号和蓝牙扫频信号得到了错误的识别结果, 经统计, 蓝牙传输跳频序列的识别正确率为 98.5%, 蓝牙扫频跳频序列的识别正确率为 94.48%。

总体上, 经统计, 本模型针对不同跳频序列的识别正确率能够达到 98.01%。

由上述测试结果可见, HOG 特征能很好的表征跳频信号在瀑布图上的特点, 特征经 SVM 算法分类后能有效检测到跳频信号并且区分不同跳频信号序列。从而可以得出结论, 基于 HOG-SVM 的跳频信号检测模型实现了在开放电磁环境下对跳频信号优异的检测识别能力。

4.3.2 定频信号干扰情况下的检测识别能力分析

定频信号是在通信环境中使用极为广泛的一种信号, 对讲机信号、广播通信信号普遍使用定频信号进行传输, 是在跳频信号检测中一类主要的干扰信号。由于定频信号具有频率稳定、持续时间长、传输带宽内能量强的特点, 而跳频信号每一跳能量较小, 且持续时间短, 如果在跳频带宽内出现定频信号干扰(图 24), 则导致跳频带宽内信干噪比显著下降, 给跳频信号检测带来极大困难。

如图 25 所示, 若跳频通信环境下存在多个定频信号干扰, 多个定频信号带宽总和达到 4MHz, 跳频信号带宽内的信干噪比则会迅速下降至 20dB 以下(图 26), 电磁环境发生显著变化。



图 24 定频信号

Figure 24 Fixed frequency signal




图 25 定频干扰下的无人机跳频信号

Figure 25 Frequency hopping signal of uav under Fixed frequency signal interference




图 26 定频信号对跳频信号信干噪比的影响

Figure 26 Effect of fixed frequency signal on signal-to-noise ratio of frequency hopping signal

本节在同样的测试场景下, 即信干噪比不超过 20dB 的环境下, 利用本原型系统对带有定频信号干扰的数据集进行了测试, 得到了定频干扰在直接影响信干噪比后, 对不同跳频信号检测识别正确率的影响, 如图 27 所示。

从图 27 可见电磁空间中存在的定频干扰尤其对蓝牙扫频信号的检测识别存在显著的影响, 同时对 Wifi 协议的识别一直保持着 100.00% 的高正确率。

通过对 Wifi 协议及其时频特征分析可知, Wifi 协议同时采用跳频方式和直接序列扩频方式发送信号。直接序列扩频方式直接在发送端扩展信号频谱, 在时频域形成较宽的线段组合特征。同时, 信号在高速传输数据过程中, 跳变的 Wifi 信号跳与跳之间时间间隔极短, 所接收到的信号转化为时频图时, 跳间间隔不明显, 形成了特有的较宽的实体柱状时频形态特征, 规则的柱状形态相比于无规则的跳频点




图 27 定频信号对跳频识别的影响

Figure 27 The influence of fixed frequency signal on frequency hopping recognition

分布形态更加简单,也就更容易于表示为稳定的信号特征,所以 Wifi 信号在定频干扰环境下能保持稳定的时频特征,识别正确率受定频干扰的影响很小。

与此同时,蓝牙扫频信号受到定频干扰信号的影响最大。在信干噪比为 20dB 的环境下,原型系统对蓝牙扫频信号识别正确率为 94.48%,随着信干噪比的降低,当降低到 0.2dB 时,识别正确率急速下降为 42.33%。从图 17 所示的蓝牙扫频信号和图 24 所示的定频信号可以看出,两种信号在瀑布图上均存在明显的窄柱状特征。HOG 特征将 1024×128 大小的瀑布图被映射为长度为 256 的序列,压缩比例达到 0.195%,压缩后的数据虽然提取到了信号的本质特征,但是也存在一定程度的信息缺失。由于蓝牙扫频信号在传输频带宽度、相邻信号频域间距上与定频信号具有一定的相似性,都具有传输频带宽度小,相邻信号频域间距小的特点。在蓝牙扫频信号和密集定频信号同时出现时,如图 28 所示, HOG 特征提取过程中对数据的压缩对更细微特征信息存在不足,从而使得在识别过程中定频信号和蓝牙扫频信号发生混淆。




图 28 密集定频信号干扰下的蓝牙扫频信号

Figure 28 Bluetooth sweep signal under dense fixed frequency signal interference

此外,在信干噪比为 0.2dB 的情况下,原型系统对蓝牙传输信号识别正确率为 94.5%,对无人机信号识别正确率为 95.33%,可见当存在一定的定频干扰时,原型系统对蓝牙传输信号和无人机信号仍然有着良好的识别性能。

4.3.3 信号不完整情况下的检测识别能力分析

本小节针对信号存在频带和时间上不完整的情况,对跳频信号检测识别系统进行了测试。

由于信号接收机采集无线信号时频带范围设置与实际跳频信号工作频带不一致,会使得接收到的信号缺失一部分频率范围,如图 29 所示,导致接收到的信号不完整,从而造成跳频信号瀑布图中信号微观结构发生改变、信号特征缺失,从而对模型检测识别能力产生影响。




图 29 信号频带缺失示意图

Figure 29 Schematic diagram of signal band loss

本小节使用存在不同频带不完整程度的跳频信号及非跳频信号作为测试数据,对原型系统的性能进行了检验。经测试,本系统对分辨跳频信号和非跳频信号的检测正确率如图 30 所示,针对不同跳频序列的识别正确率如图 31 所示。

从图 30 可以看出,随着信号频带缺失比例的增加,在缺失比例达到 12% 时,系统对区分跳频和非跳频信号的检测正确率出现小幅下降。在信号频带缺失比例为 12%、13%、14% 时,检测正确率分别为 96.73%、96.16%、96.16%,在频带缺失情况下,系统




图 30 信号频带缺失情况下的检测正确率

Figure 30 Detection accuracy of missing signal band




图 31 信号频带缺失情况下的识别正确率

Figure 31 Recognition accuracy of missing signal band

对跳频信号的检测正确率始终保持在 95%以上, 具有一定的抗信号缺失的能力。可以得出结论, 由频带缺失导致的信号不完整不会影响系统区分跳频和非跳频信号的能力。

结合图 31, 可以看出, 针对蓝牙传输信号, 在信号频带缺失比例为 8% 时, 系统对蓝牙传输信号的识别正确率急速下跌, 缺失比例达到 14% 时, 系统对蓝牙传输信号的识别正确率为 55%, 已经失去实际可用的识别效果。针对蓝牙扫频信号, 当信号频带缺失比例为 12% 时, 系统对蓝牙扫频信号的识别正确率出现显著下降, 并且在缺失比例为 14% 时, 识别正确率下降为 32%, 已经不具备有效的跳频信号识别能力。与此同时, 系统对无人机信号和 WiFi 信号的识别均具有稳定并且极高的正确率, 当信号频带缺失比例小于 13% 时, 系统针对 WiFi 和无人机信号数据集的识别正确率均为 100%, 保持了极其优异的识别性能。

WiFi 信号在时频瀑布图中的表现为明显的柱状特征, 并且信号能量高度集中, 在使用 WiFi 协议传输数据时, 只在特定的较窄的频带上有能量, 所以只要不是破坏 WiFi 信号的主要信号传输频段, 则原型系统对于 WiFi 信号的识别能力不会有显著的下降, 这也符合实验结果中识别正确率始终保持在 100% 的结果。

蓝牙传输信号和无人机信号在发射频点上具有相似的随机特征, 但是原型系统在对这两种信号的识别性能上具有显著差异, 对无人机信号的识别效果远远好于对蓝牙传输信号的识别效果, 这可能是蓝牙传输信号具有极高的跳速, 并且使用的频点更多, 在时频瀑布图上具有更加密集的特征。但是, 无人机信号在时频瀑布图上分布更加稀疏, 相同程度

的信号缺失, 使得无人机信号的特征缺失比例更低, 从而造成了识别性能上的差别。

对于蓝牙扫频信号, 该信号在时频瀑布图上具有明显的柱状特征(如图 17 所示), 并且在瀑布图上表现为多个时频域柱体, 能量高度集中, 其余空间保持空白, 随着信号缺失程度的增加, 在缺失比例较低时, 信号的缺失只是没有信号能量的空白区域, 不会对实际信号产生影响, 但是随着缺失比例的增大, 在缺失比例达到 12% 时, 实际信号出现缺失, 导致了原型系统对该信号识别能力的大幅下降。

本小节同样对信号在时间维度上的缺失进行了测试。在对信号进行采集时, 采集时间越长, 信号包含的信息量越大, 本小节后半部分将对信号时间信息不充足的情况进行分析。

信号采集的基准时间以 4.3.1 节中的信号采集时间为基准, 信号采集时间不足基准时间的情况为信号时间信息的缺失, 该种情况的信号瀑布图如图 32 所示。




图 32 信号时间信息缺失示意图

Figure 32 Schematic diagram of signal time information missing

本小节针对信号存在不同程度时间信息缺失的情况, 测试了原型系统对跳频信号检测识别的性能, 分辨跳频信号和非跳频信号的检测正确率如图 33 所示, 针对不同跳频序列的识别正确率如图 34 所示。

从图 33 可以得出, 随着信号时间缺失比例的增大, 系统对区分跳频信号和非跳频信号的能力呈下




图 33 信号时间信息缺失情况下的检测正确率

Figure 33 The detection accuracy of missing signal time information




图 34 信号时间信息缺失情况下的识别正确率

Figure 34 The recognition accuracy of missing signal time information

降趋势, 信号在时间维度上缺失 40% 时, 原型系统对跳频信号检测的正确率为 78.81%, 仍具有较高的正确率。与频带范围缺失情况相比, 系统对时间信息的缺失具有较好的抵抗能力, 即使大比例的时间信息缺失, 也能基本保证对跳频信号的检测性能。

结合图 34 可以得出, 信号时间维度信息的缺失均会使得系统对蓝牙扫频信号、Wifi 信号、蓝牙传输信号、无人机信号的跳频序列识别产生影响, 并且影响程度依次增大。

时间维度上的信息缺失使得系统对蓝牙扫频信号的识别正确率下降最快, 蓝牙扫频信号相较于其他三种信号对时间缺失更加敏感。在时间信息缺失比例为 20% 时, 其他三种跳频序列的识别正确率仍然保持在 99% 以上, 而对于蓝牙扫频信号的识别正确率已不足 40%。

综上所述, 在本小节的实验中, 原型系统在对不同跳频序列进行识别时, 蓝牙扫频信号对于频率信息和时间信息具有极高的敏感性, 而无人机信号对信息的缺失最不敏感, 这使得原型系统对无人机信号具有极高的识别正确率, 对蓝牙扫频信号具有较低的识别正确率。

5 总结与下一步工作

本文针对跳频信号时频域二维特征, 提出了一种基于 HOG 特征和 SVM 算法对真实电磁环境中跳频信号进行自动化实时检测识别的模型。模型主要由跳频信号采集模块、时频转换模块、特征提取模块、以及跳频检测识别模块四个部分组成。本文基于此模型构建原型系统, 对真实电磁环境中存在不同程度定频干扰情况下蓝牙传输、蓝牙扫频、无人机、wifi 共四类跳频信号进行检测识别, 并对测试结

果进行了分析。该模型对跳频信号具有优异的检测能力, 并且能够区分不同跳频序列, 在信干噪比不超过 20dB 时, 针对不同跳频序列的平均识别正确率能够达到 98.01%。此外, 该模型在低信干噪比情况下也具有较好的性能, 在信干噪比为 0.2dB 的情况下, 原型系统对蓝牙传输信号识别正确率为 94.5%, 对无人机信号识别正确率为 95.33%。

为了实现对跳频信号更精确的检测识别, 下一步工作主要有(1)研究去噪算法, 在时频转换前端滤除噪声。检测环境中存在的噪声信号会造成待检测信号功率下降, 并造成信号时频形态畸变, 从而造成信号特征发生改变, 影响最终的检测识别。使用去噪算法能提高信号强度, 同时提高信号的时频分辨率, 从而得到更加稳定的信号特征, 使得检测识别性能得到加强。(2)应用神经网络实现信号特征提取与检测识别。现有的人工提取特征的方法, 依赖特征工程方法, 对像素级细微特征理解不够深入。神经网络方法已被证明能够很好理解二维数据, 深入理解二维数据细微特征。而且, 卷积神经网络已经在图像识别、目标检测领域被广泛应用, 并取得了良好的效果。神经网络方法在跳频信号检测识别领域存在广阔的应用前景。

参考文献

- [1] R. L. Peterson and R. E. Ziemer. Digital Communications and Spread Spectrum System[M]. Macmillan Pub. Co, 1985.
- [2] Mahmood S, Ziemer R. Correlation Detection of an FTH - Signal Using a CCD/CZT Implementation[C]. ICASSP '79. IEEE International Conference on Acoustics, Speech, and Signal Processing, Washington, DC, USA. Institute of Electrical and Electronics Engineers, 1979: 853-856.
- [3] Polydoros A, Holmes J K. Autocorrelation Techniques for Wideband Detection of FH Waveforms in White Noise[C]. MILCOM 1983 - IEEE Military Communications Conference, October 31-November 2, 1983. Washington, DC, USA. Piscataway, NJ: IEEE, 1983: 776-780.
- [4] Polydoros A, Woo K. LPI Detection of Frequency-Hopping Signals Using Autocorrelation Techniques[J]. IEEE Journal on Selected Areas in Communications, 1985, 3(5): 714-726.
- [5] Meng F J, Zhang L, Wang Y W. Detection of DS & FH Hybrid Spread Spectrum Signal in TT & C Communication[C]. 2013 IEEE Third International Conference on Information Science and Technology (ICIST), March 23-25, 2013. Yangzhou, Jiangsu, China. Piscataway, NJ: IEEE, 2013: 1242-1245.
- [6] Qian B, Feng Y X, Pan C S, et al. A Method of Detecting Differential Frequency Hopping Signal Based on Multiple-hop Autocorre-

- lation[J]. *Acta Aeronautica et Astronautica Sinica*, 2011, 32(12): 2268-2276.
(钱博, 冯永新, 潘成胜, 等. 一种基于多跳自相关的差分跳频信号检测方法[J]. *航空学报*, 2011, 32(12): 2268-2276.)
- [7] Dong Z Q, Hu H Y. Multi-hop Autocorrelation Detection of Frequency Hopping Signals Based on ρ Decision[J]. *Modern Electronics Technique*, 2007, 30(7): 25-27.
(董占奇, 胡捍英. 基于 ρ 判决的跳频信号多跳自相关检测[J]. *现代电子技术*, 2007, 30(7): 25-27.)
- [8] Zhang D, Wu Y. Application of STFT in Analysis of Frequency Hopping Signal[J]. *Modern Electronic Technique*, 2005, 28(10): 60-61.
(张丹, 吴瑛. STFT 在跳频信号分析中的应用[J]. *现代电子技术*, 2005, 28(10): 60-61.)
- [9] M. P. Fargues, H. F. Overdyk, R. Hippenstiel. Wavelet-based detection of frequency hopping signals[C]. *Asilomar Conference on Signals, Systems, and Computers (ACSSC)* 1997: 515-519.
- [10] Sirotiya M, Banerjee A. Detection and Estimation of Frequency Hopping Signals Using Wavelet Transform[C]. *2010 Second UK-India-IDRC International Workshop on Cognitive Wireless Systems (UKIWCWS)*, December 13-14, 2010. New Delhi, India. Piscataway, NJ: IEEE, 2010: 1-5.
- [11] Du J, Liu J, Qian F. A Novel Method of Time-frequency Analysis for Frequency Hopping Signal[J]. *Journal of China Academy of Electronics and Information Technology*, 2009, 4(6): 576-579.
(杜娟, 刘静, 钱锋. 跳频信号时频分析的一种新方法[J]. *中国电子科学研究院学报*, 2009, 4(6): 576-579.)
- [12] Zhao H W, Li Y. The Research of FH Signal Detection Based on Time-Frequency Distribution[J]. *China Information Security*, 2006, 4(6): 98-99, 102.
(赵宏伟, 李勇. 一种基于时频分布的跳频信号检测方法的研究[J]. *信息安全与通信保密*, 2006, 4(6): 98-99, 102.)
- [13] Luan H Y, Jiang H. Blind Detection of Frequency Hopping Signal Using Time-Frequency Analysis[C]. *2010 International Conference on Computational Intelligence and Software Engineering*, September 23-25, 2010. Chengdu City, China. Piscataway, NJ: IEEE, 2010: 1-4.
- [14] Luo S E, Luo L Y. Detection of an Unknown Frequency Hopping Signal Based on Image Features[C]. *2009 2nd International Congress on Image and Signal Processing*, October 17-19, 2009. Tianjin, China. Piscataway, NJ: IEEE, 2009: 1-4.
- [15] Wang H, Wang B. A Frequency-Hopping Detection Algorithm Based on the Direction Image of Partitioned and Projected[J]. *Signal Processing*, 2012, 28(12): 1729-1736.
(王辉, 王斌. 基于示向图分割投影的短波跳频信号检测算法[J]. *信号处理*, 2012, 28(12): 1729-1736.)
- [16] Q. I. Chang, B. Wang, X. Q. Yan. Detection of Short-Wave Frequency Hopping Signals[C]. *Radar Science & Technology*, 2011: 125-130.
- [17] S. Chen, L. I. Tian-Yun, G. E. Lin-Dong. Study on Frequency-Hopping Detection Algorithm Based on Edge Detection[J]. *Journal of Information Engineering University*, 2006, 7(3): 264-266.
- [18] Zhang S Q, Yu D S, Sheng S M. A Discrete STFT Processor for Real-time Spectrum Analysis[C]. *APCCAS 2006 - 2006 IEEE Asia Pacific Conference on Circuits and Systems*, December 4-7, 2006. Singapore. Piscataway, NJ: IEEE, 2006: 1943-1946.
- [19] Dalal N, Triggs B. Histograms of Oriented Gradients for Human Detection[C]. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, CA, USA. Piscataway, NJ: IEEE, 2005: 886-893.
- [20] Kanopoulos N, Vasanthavada N, Baker R L. Design of an Image Edge Detection Filter Using the Sobel Operator[J]. *IEEE Journal of Solid-State Circuits*, 1988, 23(2): 358-367.
- [21] Blumer A, Ehrenfeucht A, Haussler D, et al. Learnability and the Vapnik-Chervonenkis Dimension[J]. *Journal of the ACM (JACM)*, 1989, 36(4): 929-965.
- [22] Shawe-Taylor J, Bartlett P L, Williamson R C, et al. Structural Risk Minimization over Data-dependent Hierarchies[J]. *IEEE Transactions on Information Theory*, 1998, 44(5): 1926-1940.
- [23] Shawe-Taylor J, Cristianini N. Kernel Methods for Pattern Analysis[M]. Cambridge University Press, 2004.



张萌 于 2013 年在北京航空航天大学通信与信息系统专业获得硕士学位, 现在工作于中国科学院信息工程研究所第四研究室, 研究领域为电磁信息安全, 研究方向包括: 电磁泄漏发射检测防护技术、无线通信安全技术等。Email: zhangmeng@iie.ac.cn



王文 于 2015 年在北京理工大学电子科学与技术专业获得博士学位。现工作于中国科学院信息工程研究所第四研究室, 研究领域为场所电磁安全, 研究方向包括: 电磁环境感知、信号特征提取建模。Email: wwen@iie.ac.cn



任俊星 于 2014 年在北京航空航天大学通信与信息系统专业获得硕士学位。现任中国科学院信息工程研究所工程师。研究方向为: 电磁空间安全。Email: renjunxing@iie.ac.cn



魏冬 于 2013 年在北京邮电大学通信与信息系统专业获得博士学位。现任中国科学院信息工程研究所, 第四研究室副研究员。研究方向为无线通信物理层安全、调制识别、信号处理。Email: weidong@iie.ac.cn



黄伟庆 现任中国科学院信息工程研究所第四研究室主任、全国信息安全标准化技术委员会 WG2 组副组长、中国计算机学会信息保密专委会副秘书长。研究方向为: 无线通信安全、电磁信号处理、网络安全保密技术、物联网安全、云计算安全技术等。Email: huangweiqing@iie.ac.cn



杨昭阳 于 2011 年在同济大学物理专业获得硕士学位。现在中国科学院信息工程研究所计算机专业攻读博士学位。研究领域为无线通信物理层安全、调制识别、信号处理。Email: yangzhaoyang@iie.ac.cn



吕志强 博士, 副研究员, 研究生导师, 现在工作于中国科学院信息工程研究所第四研究室, 主要研究方向为信号收发与分析、射频系统集成。Email: lvzhiqiang@iie.ac.cn