

基于注意力机制的 干扰模式分类算法研究

Research on Interference Pattern Classification Algorithm Based on Attention Mechanism

秦怡童,陈宇宁,张剑书,柳 圣,王祝尧(南京工程学院,江苏 南京 210000)

Qin Yitong, Chen Yuning, Zhang Jianshu, Liu Sheng, Wang Zhuyao (Nanjing University of Technology, Nanjing 210000, China)

摘要:

随着无线通信技术的迅速发展,干扰模式的分类成为确保通信系统可靠性的关键因素。基于注意力机制的干扰模式分类算法通过将干扰信号转换为频谱瀑布图,直观地展示干扰信号在时间和频率上的变化规律,构建了包含多种干扰模式的数据集。该算法采用卷积神经网络结构,通过多层卷积和池化操作自动提取干扰信号的特征,并引入注意力机制聚焦关键特征,结合全连接层进行分类。实验结果表明,该算法在干扰模式分类任务中表现优异,分类精度达到94%,显著优于随机森林、支持向量机等传统机器学习方法。

关键词:

卷积神经网络;注意力机制;特征提取;干扰模式分类

doi:10.12045/j.issn.1007-3043.2026.03.006

文章编号:1007-3043(2026)03-0029-05

中图分类号:TN915

文献标识码:A

开放科学(资源服务)标识码(OSID):



Abstract:

With the rapid development of wireless communication technology, the classification of interference patterns has become a key factor in ensuring the reliability of communication systems. The interference pattern classification algorithm based on the attention mechanism converts interference signals into spectral waterfall diagrams, visually demonstrating the variations of interference signals in time and frequency. It constructs a dataset containing several interference patterns. This algorithm employs a convolutional neural network structure to automatically extract features of interference signals through multiple layers of convolution and pooling operations, introduces an attention mechanism to focus on key features, and combines with fully connected layers for classification. Experimental results show that this algorithm performs excellently in the task of interference pattern classification, achieving a classification accuracy of 94%, significantly outperforming traditional machine learning methods such as random forests and support vector machines.

Keywords:

Convolutional neural network; Attention mechanism; Feature extraction; Interference pattern classification

引用格式:秦怡童,陈宇宁,张剑书,等. 基于注意力机制的干扰模式分类算法研究[J]. 邮电设计技术,2026(3):29-33.

1 概述

近年来,随着无线设备数量的急剧增加和无线信号环境的日益复杂,无线通信系统面临着前所未有的挑战^[1]。高效、准确地识别和分类干扰信号,对于保障

通信质量和提高频谱利用率^[2]有重要意义。传统的无线通信干扰信号识别技术计算复杂度高且无法满足高精度识别的要求^[3]。而深度学习,特别是卷积神经网络,凭借其强大的特征提取^[4]和分类能力^[5],在图像识别^[6]、语音识别^[7]等领域取得了显著成果,也为干扰模式分类提供了新的思路。

国内外学者已经开展了基于深度学习的干扰识别和分类研究。文献[8]提出了一种基于高效信道注意力模块的干扰识别方法,通过引入注意力机制,同时采用多节点协同技术,进一步提升了干扰识别的准

基金项目:江苏省高等学校大学生创新创业训练计划项目(202411276105Y),南京工程学院校级科研基金项目(QKJ202301)

收稿日期:2026-02-10

确性。文献[9]通过引入全局自注意力机制,同时结合可变形注意力机制,有效提高了干扰识别模型的干扰特征全局建模能力和干扰区域鉴别能力。文献[10]提出了一种结合空间注意力机制与残差收缩神经网络的算法,有效解决了低干扰信噪比情景下干扰分类精度下降的问题。

尽管上述研究在干扰识别领域取得了显著进展,但现有方法大多针对特定类型的干扰信号,缺乏对复杂通信环境下多种干扰模式的通用分类能力^[11]。此外,传统机器学习方法如随机森林^[12-13]、支持向量机^[14-15]和多层感知机^[16]在处理高维、非线性干扰信号时,往往难以达到理想的分类精度。针对这些问题,本文提出了一种基于注意力机制的干扰模式分类算法,旨在实现对多种干扰模式的准确分类,进一步提升通信系统对复杂电磁环境的适应能力。

2 干扰频谱数据集构建

首先,考虑一个用户(发射器—接收器对)与一个或多个干扰机共存的通信场景。在通信系统中,用户和干扰机的信号在接收端混合。用户信号由发射机发送,频率为 $f_i \in [f_L, f_U]$,其功率谱密度(PSD)函数为 $U(f)$,带宽为 b_u 。干扰机 j 则选择频率 f_i^j 和基带PSD函数 $J_i^j(f)$ 生成干扰信号。接收端的信号混合模型可以表示为:

$$S_i(f) = g_u U(f - f_i) + \sum_{j=1}^J g_j J_i^j(f - f_i^j) + n(f) \quad (1)$$

其中, g_u 和 g_j 分别表示用户和干扰机到接收机的信道增益,由此模拟接收端接收到的信号与干扰的混合情况; $n(f)$ 是噪声的PSD函数。

接收机能够持续感知整个通信频带,并将接收到的混合信号进行离散化处理。离散频谱样本值定义为:

$$s_{i,t} = 10 \log \left[\int_{i\Delta f}^{(i+1)\Delta f} S_i(f + f_L) df \right] \quad (2)$$

其中, Δf 是频谱分析的分辨率。通过这种方式,得到一个频谱向量 $s_i = \{s_{i,1}, s_{i,2}, \dots, s_{i,N}\}$,其中 N 表示频谱样本的数量。

为了捕捉干扰信号的时频特性,定义一个矩阵 $S_i = \{s_i, s_{i-1}, \dots, s_{i-T+1}\}$,其中 T 表示回溯的历史状态数。 S_i 是一个大小为 $T \times N$ 的二维矩阵,该二维矩阵的热力图被称为频谱瀑布图。在频谱瀑布图中,横

轴表示频率 f ,纵轴表示时间 t ,每个像素点的颜色深浅对应特定时刻特定频点的信号功率 $s_{i,t}$ 。同时,图中也包含了频域和时域信息,能够直观地展示干扰信号在时间和频率上的变化规律。

为了训练干扰模式分类模型,将接收机处感知到的频谱瀑布图作为模型的输入,每张干扰图片对应一个特定的干扰模式。通过这种方式,构建一个包含6种干扰模式的干扰图片数据集,分别是:梳状干扰、动态干扰、跟随干扰、智能干扰、部分频带干扰以及扫频干扰。

6种干扰模式的频谱瀑布图如图1所示。其中,梳状干扰模式在特定频率点上产生持续干扰;动态干扰模式的频率和强度随时间随机变化;跟随干扰模式可动态调整干扰信号的频率,其频谱特征表现为频率跟随特性;智能干扰模式基于智能算法优化干扰信号的频率、强度和持续时间;部分频带干扰模式的干扰信号在频域上局部集中;扫频干扰模式的频谱特征表现为干扰频率在频域上连续变化。

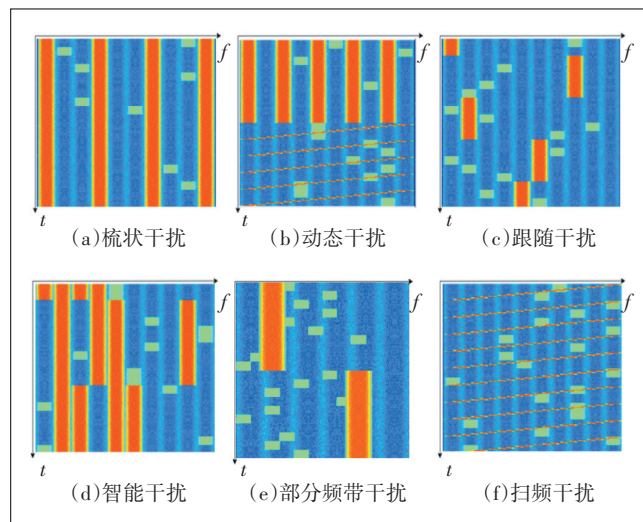


图1 6种干扰模式的频谱瀑布图

3 基于注意力机制的干扰模式分类算法的设计

本文提出的干扰模式分类算法基于卷积神经网络和注意力机制,旨在通过多层卷积和池化自动提取干扰特征,并利用注意力机制聚焦关键特征,最后使用全连接层进行分类。模型的输入为频谱瀑布图,输出为 n 种干扰模式的分类概率。分类模型函数可以表示为:

$$y = f_{\text{CNN}}(S; \theta) \quad (3)$$

其中, S 表示输入的频谱图片, θ 表示模型的参数, y 表示输出的分类概率向量。

卷积神经网络结构包括卷积层、SE(Squeeze-and-Excitation)模块、池化层、展平层、全连接层和随机丢弃,各层参数如表 1 所示。

表 1 卷积神经网络结构

层名称	输入尺寸	输出尺寸	配置
卷积层 1	1×200×200	32×200×200	卷积核 3×3,步幅为 1,填充 1,输出通道为 32
SE 模块 1	32×200×200	32×200×200	对 32 通道特征图进行通道注意力加权
池化层 1	32×200×200	32×100×100	最大池化,窗口 2×2,步幅为 2
卷积层 2	32×100×100	64×100×100	卷积核 3×3,步幅为 1,填充 1,输出通道为 64
SE 模块 2	64×100×100	64×100×100	对 64 通道特征图进行通道注意力加权
池化层 2	64×100×100	64×50×50	最大池化,窗口 2×2,步幅为 2
展平层	64×50×50	160 000	将三维特征图展平为一维向量
全连接层 1	160 000	128	输出维度为 128
随机丢弃	128	128	随机失活,丢弃概率 $p=0.5$
全连接层 2	128	6	全连接层,输出维度为 6

为了增强模型对重要特征的关注能力,本文在卷积层后引入了注意力机制,其中使用 SE 模块通过全局平均池化对特征图的通道进行压缩。然后,通过 2 个全连接层学习通道间的依赖关系。最后,通过 Sigmoid 函数生成通道注意力权重。

首先,在 Squeeze 操作中,对输入特征图 $S \in \mathbb{R}^{1 \times H \times W}$ 的每个通道进行全局平均池化,将特征图从 $1 \times H \times W$ 压缩为 $1 \times 1 \times 1$,得到通道描述向量 $z \in \mathbb{R}^{1 \times 1 \times 1}$,具体公式如下:

$$z = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W S(i, j) \quad (4)$$

其中, H 和 W 分别为特征图的高度和宽度, z 表示全局平均池化结果, $S(i, j)$ 表示在位置 (i, j) 的特征值。

其次,在 Excitation 操作中,直接对全局平均池化后的结果 z 使用激活函数 Sigmoid,生成通道注意力权重 $x \in \mathbb{R}^{1 \times 1 \times 1}$,具体如下:

$$x = \sigma(z) \quad (5)$$

其中, σ 表示 Sigmoid 函数,其作用是将全局平均池化后的结果 z 映射到 $[0, 1]$ 区间,表示通道的注意力权重。

最后,在特征重标定中,将学习到的通道注意力权重 x 与原始特征图 S 相乘,得到加权后的特征图。

$$\hat{S} = S \cdot x \quad (6)$$

其中, \hat{S} 表示加权后的特征图。

卷积层和池化层的输出特征图经过展平操作后,输入到 2 个全连接层中。第一全连接层包含 512 个神经元,激活函数为 ReLU;第二全连接层包含 256 个神经元,激活函数为 ReLU。输出层包含 n 个神经元,对应 n 种干扰模式,激活函数为 Soft max,输出为每种干扰模式的概率分布。

为了训练模型,本文采用交叉熵损失函数(Cross-Entropy Loss)作为优化目标。交叉熵损失函数的定义如下:

$$L(y, \hat{y}) = - \sum_{i=1}^n y_i \log \hat{y}_i \quad (7)$$

其中, y 表示真实的干扰模式标签, \hat{y} 表示模型预测的概率分布。

模型的参数通过反向传播算法和梯度下降法进行更新,逐步优化模型性能。本文使用 Adam 优化器更新模型参数,更新公式如下:

$$\theta_{i+1} = \theta_i - \eta \nabla_{\theta} L(y, \hat{y}) \quad (8)$$

其中, θ_i 表示第 i 次迭代的模型参数, η 为学习率。Adam 优化器结合了动量法和自适应学习率的优点,能够加速收敛并提高训练稳定性。

4 实验

4.1 仿真设置

每种干扰模式的实现和控制参数不同,可通过调整干扰数量、信号带宽、扫频速率等关键参数来生成不同的干扰数据,从而为后续的模式训练和测试提供丰富的数据样本。初步生成数据集的具体参数为:总频带带宽为 20 MHz,观测时长为 1 ms,发射信号功率 p_u 为 1 W,信号带宽 b_u 为 1 MHz,滚降系数为 0.5,信噪比为 10,扫频速率为 500 MHz/s 等。

梳状干扰的频谱特征表现为多个窄带信号在频域上均匀分布。在实验中,梳状干扰的带宽分别设置为 1 MHz、2 MHz 和 4 MHz 等。当干扰频带个数为 3 时,干扰频带位置分布为 1 MHz、10 MHz、19 MHz;当干扰频带个数为 4 时,干扰频带位置分布为 1 MHz、7 MHz、13 MHz、19 MHz;当干扰频带个数为 5 时,干扰频带位置分布为 1 MHz、5 MHz、9 MHz、13 MHz、17 MHz。

动态干扰的扫频速率分别设置为 300 MHz/s、500 MHz/s 和 800 MHz/s 等,干扰信号在不同频点之间随机切换,切换时间间隔为 1 ms。干扰频带的数量和位置的参数设置与梳状干扰相同,且频谱覆盖范围随时间

变化,使干扰信号呈现动态变化的特征。

跟随干扰的干扰信号频点切换间隔为 1 ms, 干扰信号会根据目标信号的频率变化实时调整, 确保干扰频率与目标信号频率保持高度相关性。

智能干扰通过自适应算法动态调整干扰策略, 干扰机每隔 100 ms 更新一次干扰频段, 并在 4 个频段上同时生成干扰信号。干扰机根据目标信号的历史频率分布优化干扰频段, 确保有效覆盖目标信号的频率范围。

通过改变干扰源的带宽, 生成不同强度的部分频带干扰数据集, 干扰带宽分别为 1 MHz、2 MHz 和 4 MHz 等。

扫频干扰的速率分别设置为 300 MHz/s、500 MHz/s 和 800 MHz/s 等, 干扰信号从低频到高频或从高频到低频连续切换, 覆盖整个通信频带。

据此, 每种干扰模式生成 100 张图片, 共 600 张图片, 构成实验所需的数据集, 并将数据集按 3:2 的比例划分为训练数据集和测试数据集。因此, 训练数据集包括 360 张干扰图片, 测试数据集包括 240 张干扰图片。

本文设计的卷积神经网络结构包括输入层、卷积层、池化层、全连接层和输出层。输入层接收尺寸为 200×200 的矩阵。在卷积层中, 第一卷积层使用 32 个卷积核, 第二卷积层使用 64 个卷积核, 第三卷积层使用 128 个的卷积核。每个卷积层后接一个最大池化层, 池化窗口大小为 2×2 , 步长为 2。然后, 使用 Adam 优化器进行参数更新, 学习率设置为 0.001。全连接层

的通道数压缩比例设置为 16, 用于优化模型的计算效率。输出层包含 6 个神经元, 对应 6 种干扰模式。

模型的训练过程包括数据预处理、批量训练和迭代训练。首先, 对输入的频谱图片进行归一化处理, 将像素值缩放到 $[0, 1]$ 内。每次训练从训练集中随机抽取 32 张图片作为一个批次, 进行前向传播、损失计算和参数更新。重复上述过程, 直到模型在验证集上的损失不再显著下降。模型共训练了 200 轮, 以确保充分收敛并达到最佳性能。

4.2 实验结果与分析

经过模型训练后, 获得了基于注意力机制的干扰模式分类的训练精度变化曲线和 6 种干扰模式的混淆矩阵, 如图 2 所示。从图 2(a) 可以看出, 尽管精度曲线有所波动, 但在 100 轮训练之后, 曲线趋于稳定且其最高训练精度能够达到 99%, 测试精度达到 94%, 这表明本文的干扰模式分类模型具有较好的性能和准确性。此外, 为了进一步分析模型在不同干扰模式下的分类性能, 本文构建了 6 种干扰模式下的混淆矩阵, 用于评估模型在各类干扰模式上的分类准确性和误分类情况。如图 2(b) 所示, 本文所提算法在大多数干扰类别上均表现出较高的分类准确率, 表明模型能够有效捕捉各类干扰信号的特征, 并具有较强的区分能力。

将本文所提出的基于注意力机制的干扰模式分类方法, 与多层感知机、支持向量机、随机森林等其他算法在 6 种干扰模式上的分类性能进行对比测试, 测试结果如图 3 所示。

从图 3 可以看出, 随着训练轮数的增加, 引入注意

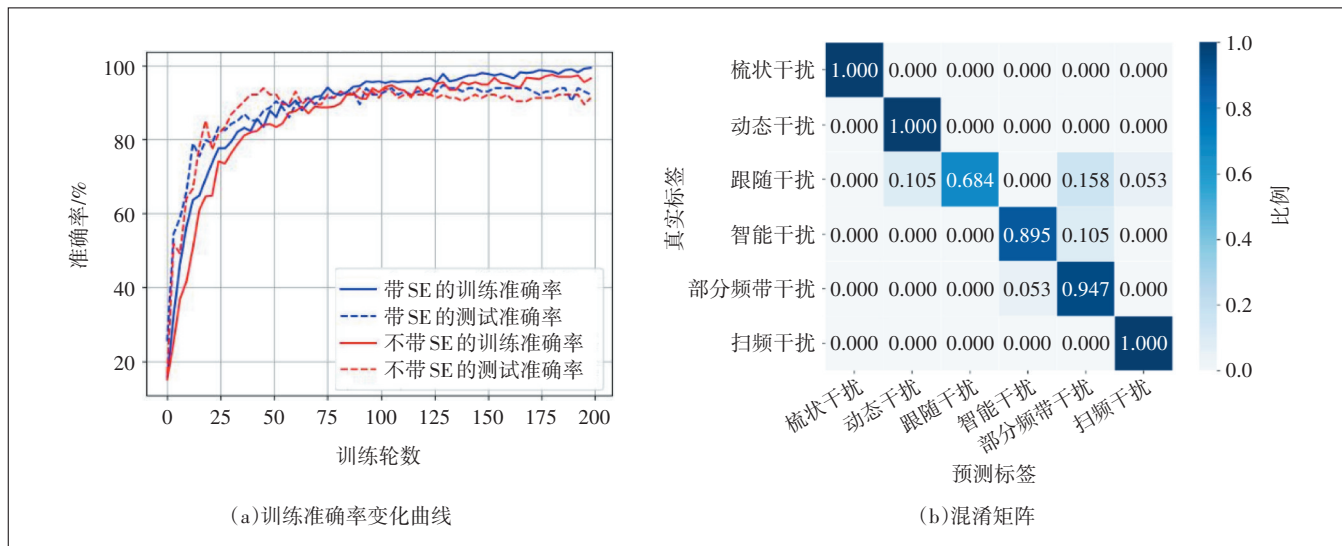


图 2 训练精度变化曲线及混淆矩阵

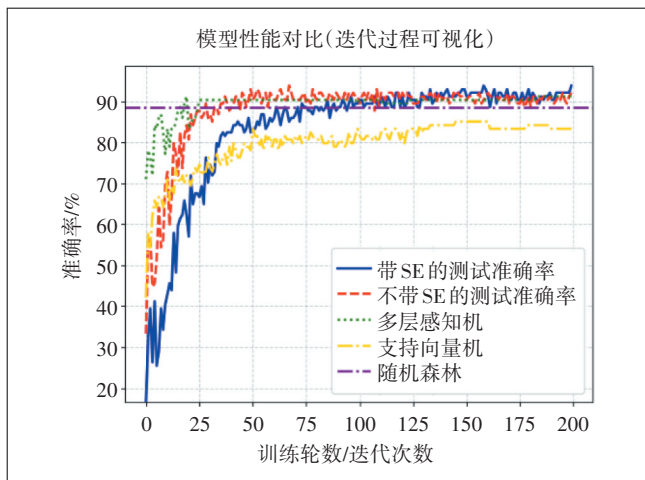


图3 各种算法的准确率变化曲线

力机制的模型分类准确率显著优于未引入注意力机制的模型及其他对比方法。实验结果表明,本文的方法最终达到了94%的分类准确率,与未引入注意力机制的模型相比提升了2%,验证了注意力机制在特征选择与增强方面的有效性。

与传统方法相比,本文方法的性能优势更为明显。其中,卷积神经网络的分类精度为92%,多层感知机为91%,随机森林为88%,支持向量机为83%。这一结果说明,基于注意力机制的模型能够更好地捕捉干扰模式中的关键特征,从而显著提升分类性能。综上所述,本文提出的基于注意力机制的干扰模式分类算法在分类精度和模型稳定性方面均优于传统方法,为干扰模式识别任务提供了更优的解决方案。

5 结束语

本文提出的基于注意力机制的干扰模式分类算法,为现代通信系统应对复杂多变的干扰环境提供了有效的解决方案,有助于提升通信系统的抗干扰能力和频谱利用效率。实验结果表明,所提算法在多种干扰模式分类任务中均表现出较高的准确率和鲁棒性,且相较于传统方法和其他机器学习模型具有显著优势,为通信领域的干扰分类技术提供了创新性解决方案。然而,本研究仍存在一定的局限性。未来研究可以进一步优化神经网络模型,提高识别准确率,同时考虑更多复杂多变的干扰环境因素。总之,基于注意力机制的干扰模式分类算法具有广阔的应用前景,为通信领域的发展提供了新的思路和方向。未来研究应继续关注这一领域的发展动态,为推动通信技术的

进步做出贡献。

参考文献:

- [1] 李庆博,王新宇,朱安琪,等. 深度学习的无线通信信号识别与分类技术研究[J]. 信息记录材料,2025,26(2):48-50.
- [2] 贾国庆. 中波广播频谱的高效利用与优化策略[J]. 电视技术,2024,48(11):135-138.
- [3] 王鹏宇. 基于深度学习的无线通信干扰识别技术研究[D]. 成都:电子科技大学,2023.
- [4] 戴瑞成,董翔,赵璧,等. 基于混合深度学习的变电站巡检机器人目标识别算法研究[J]. 智慧电力,2025,53(3):117-123.
- [5] CHEN J, XU S Y, CHEN Z P. Convolutional neural network for classifying space target of the same shape by using RCS time series [J]. IET Radar, Sonar & Navigation, 2018, 12(11):1268-1275.
- [6] 杨雪龙,李翰山. 改进YOLOv5-FireCAM网络的炸点图像识别处理算法[J]. 电光与控制,2025,32(7):105-111.
- [7] 刘琨,成李博,房庆龄,等. 一种基于深度学习及AI语音识别的工业软件大模型[J]. 中国信息界,2025(1):147-148.
- [8] ZHAO Q, HAN S C, GUO C J. The research of interference recognition method in multi-nodes cooperative frequency-hopping communication based on time-frequency image analysis and deep learning [J]. Physical Communication, 2024, 62: 102263.
- [9] 高飞,席睿达,邢相薇,等. SAR有源干扰分类识别图像数据集仿真构建[J]. 系统工程与电子技术,2025,47(10):3257-3269.
- [10] LIN Z J, ZHUANG X B, NIU B, et al. GNSS blanket jamming classification algorithm based on spatial attention mechanism and residual shrinkage neural network [J]. Measurement Science and Technology, 2024, 35(4):045120.
- [11] 覃思,金庆忍,周柯,等. 基于灰色理论的电磁环境中无线传感器网络通信评估[J]. 中国测试,2024,50(增刊2):69-73.
- [12] 许鸿奎,李鑫,邵星,等. 基于加权随机森林的FDD-LTE上行干扰分类研究[J]. 山东建筑大学学报,2020,35(6):23-29.
- [13] 邵正途,冷毅,葛代河,等. 基于小波包分解和随机森林特征选择的雷达有源干扰识别[J]. 现代雷达,2024,46(12):45-52.
- [14] HAO G C, BU L T, LU M Y, et al. Radar jamming signal recognition algorithm based on multi-feature fusion [J]. Digital Signal Processing, 2025, 158(3):104950.
- [15] 倪淑燕,付琦玮,陈世森,等. 基于支持向量机的GNSS欺骗式干扰多相关器检测方法[J]. 电子信息对抗技术,2025,40(2):24-31.
- [16] 闫晓伟,曲豫宾. 基于机器学习的导弹干扰试验效果评估实证研究[J]. 海军航空工程学院学报,2020,35(6):445-450,482.

作者简介:

秦怡童,南京工程学院本科在读,主要研究方向为计算机视觉;陈宇宁,南京工程学院本科在读,主要研究方向为信号处理;张剑书,高级实验师,博士,主要从事无线通信抗干扰理论与算法研究相关工作;柳圣,实验师,硕士,主要从事计算机软件理论相关工作;王祝尧,南京工程学院本科在读,主要研究方向为计算机软件实现。