

DOI:10. 20079/j. issn. 1001-893x. 230814003

“电磁信号智能感知”专题

引用格式:任江飞,许魁,刘洋,等. 一种基于改进残差神经网络的直扩信号感知方法[J]. 电讯技术,2023,63(12):1862-1868. [REN J F,XU K,LIU Y,et al. A DSSS signal sensing method based on improved residual neural networks[J]. Telecommunication Engineering,2023,63(12):1862-1868.]

一种基于改进残差神经网络的直扩信号感知方法^{*}

任江飞,许 魁,刘 洋,陆 瑞,张 咪,叶子绿

(陆军工程大学 通信工程学院,南京 210007)

摘 要:非合作条件下直扩信号感知问题一直是通信对抗领域研究的热点,传统的感知方法在低信噪比条件下性能下降严重。为有效提升直扩信号感知的性能,提出了一种基于改进残差神经网络的直扩信号感知方法。首先,通过广义互相关算法,快速提取直扩信号的相关峰特性;然后,以残差神经网络为基础,融合注意力机制,建立网络模型,分析识别抽象特征;最后,在仿真的数据集中进行实验验证。结果表明,相较于时域自相关法、卷积神经网络法等,所提方法具备更好的感知效果,能够在信噪比为-16 dB 的情形下有效地感知直扩信号。

关键词:直扩信号感知;广义互相关;残差神经网络;注意力机制

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN971 文献标志码:A 文章编号:1001-893X(2023)12-1862-07

A DSSS Signal Sensing Method Based on Improved Residual Neural Networks

REN Jiangfei,XU Kui,LIU Yang,LU Rui,ZHANG Mi,YE Zilu

(College of Communications Engineering, Army Engineering University of PLA, Nanjing 210007, China)

Abstract: The problem of direct sequence spreading spectrum (DSSS) signal sensing under non-cooperative conditions has always been a hot research topic in the field of communication countermeasures, and the performance of traditional sensing methods is seriously degraded under low signal to noise ratio (SNR) conditions. In order to effectively improve the performance of DSSS signal sensing, a DSSS signal sensing method based on an improved residual neural network (ResNet) is proposed. Firstly, the correlation peak characteristics of the DSSS signal are quickly extracted by the Generalized Cross Correlation (GCC) algorithm. Then, based on the ResNet, the attention mechanism is introduced to build a network model to analyze and identify the abstract features. Finally, experimental validation is carried out in the simulated dataset. The results show that, compared with the time-domain autocorrelation method and the convolutional neural network method, the proposed method has a better sensing effect and can effectively sense the DSSS signals with -16 dB SNR.

Key words: DSSS signal sensing; generalized cross correlation; residual neural network; attention mechanism

^{*} 收稿日期:2023-08-14;修回日期:2023-10-12
通信作者:许魁

0 引 言

直接序列扩频 (Direct Sequence Spreading Spectrum, DSSS) 是一种调制技术,通过降低通信传输速率的方式,实现固定带宽内的频谱扩展。相对于传统的通信手段,直扩通信能够有效抵抗复杂电磁环境,具有保密性高、截获概率低、抗干扰性能强等诸多特性,被广泛应用于军用通信、卫星导航、雷达等领域。

在非合作条件下,因信号参数未知,且直扩信号一般工作在低信噪比条件下,使其难以被有效感知。传统的直扩信号感知方法主要是利用直扩信号和背景噪声在时域、相关域、功率谱域、谱相关域等方面的不同,采取相应的运算,获取特征统计量,进而与设定的门限进行比较来实现信号感知,具体包括时域自相关法^[1]、循环谱法^[2]、倒谱法^[3]以及高阶累计量法^[4]等。基于特征提取的统计感知方法,普遍存在运算复杂度高、感知效果受噪声影响大、门限难以确定等问题。

近年来,深度学习发展迅速,在信号处理领域取得了巨大成就,为研究直扩信号感知提供了新的思路。Gu 等人^[5]提出了一种基于卷积神经网络 (Convolutional Neural Network, CNN) 的直扩信号感知方法,利用卷积神经网络自动学习直扩信号和噪声的特征,仿真结果表明该方法能够在信噪比不低于 -8 dB 的高斯噪声条件下实现直扩信号的有效感知。王晓蓉等人^[6]提出了一种基于循环平稳特征的分阶段直扩超宽带信号感知算法,将直扩超宽带信号的循环谱归一化为二维灰度图,使信号感知问题转换为图像分类问题,有效解决了传统感知方法中的门限设置困难问题。刘锋等人^[7]提出了一种基于融合压缩采样与深度神经网络的直扩信号参数估计方法,将压缩采样技术和深度神经网络有效配合,进而实现以较低采样率对直扩信号参数的准确估计。王源等人^[8]提出了一种基于稀疏滤波和卷积神经网络的直扩信号感知算法,将直扩信号转换为循环谱图进行特征提取,利用直扩信号循环谱图的稀疏特性,有效提升了信号感知的准确率。深度学习在直扩信号感知方面已取得一定进展,但研究者大多是将直扩信号的特征数据转换为图像进行处理,在转换过程中难免会破坏数据中的其他细节特征^[9],同时在感知网络模型方面仍可进一步改进

优化。

针对上述文献研究存在的问题,本文提出了一种基于改进残差神经网络 (Residual Neural Network, ResNet) 的直扩信号感知方法,将一维序列数据作为输入,同时利用卷积核提取更多的数据特征,以提升低信噪比条件下直扩信号感知的准确率。具体工作如下:首先,对直扩信号的信号模型进行分析,确定信号感知的评价指标;其次,使用广义互相关 (Generalized Cross Correlation, GCC) 算法进行直扩信号特征分析和提取;然后,以残差神经网络模型为主干,融合注意力机制,并进行适当优化,设计适用于直扩信号感知的网络模型;最后,在仿真生成的数据集进行测试验证,分析评估所提方法的有效性和鲁棒性。

1 系统模型

直扩信号的基本特点就是使用高速率的扩频序列对信息序列进行扩展,使原来的窄带信号变成类似于白噪声的宽带信号。本文以 BPSK 调制的直扩信号为例,其信号 $s(t)$ 可表示为

$$s(t)=\sqrt{2P_s}d(t)c(t)\cos(2\pi f_s t+\varphi_s)。(1)$$

式中: P_s 为信号发射功率; $d(t)$ 为需要传输的信息; f_s 为载波频率; φ_s 为初始相位; $c(t)$ 为特定长度扩频序列的周期信号,可表示为

$$c(t)=\sum_{i=0}^{\infty}p_i g(t-iT_c)。(2)$$

式中: T_c 为码片宽度; p_i 为扩频序列符号,满足 $\{p_i \in (-1,1), i=1,2,3\cdots\}$; $g(t)$ 为矩形窗函数。

在非合作条件下,接收信号 $r(t)$ 可表示为

$$r(t)=\begin{cases} v(t)+j(t), & H_0 \\ s(t)+v(t)+j(t), & H_1 \end{cases}。(3)$$

式中: $v(t)$ 为信道噪声; $j(t)$ 为无线信道中的干扰信号。从分类的角度,可以将直扩信号感知假设为二元分类问题,其中 H_0 表示接收信号中不存在直扩信号, H_1 则表示接收信号中存在直扩信号。

通常情况下,直扩信号 $s(t)$ 、信道噪声 $v(t)$ 和干扰信号 $j(t)$ 之间相互独立,相关性很低。根据自相关原理,接收信号 $r(t)$ 的自相关函数 $R_r(\tau)$ 可表示为

$$R_r(\tau)=R_s(\tau)+R_v(\tau)+R_j(\tau)=2P_sR_d(\tau)R_c(\tau)\cos(2\pi\omega\tau)+$$

$R_v(\tau)+R_j(\tau)。$ (4)

式中: $R_v(\tau)$ 为 $v(t)$ 的自相关函数; $R_j(\tau)$ 为 $j(t)$ 的自相关函数; $R_d(\tau)$ 为 $d(t)$ 的自相关函数; $R_c(\tau)$ 为 $c(t)$ 的自相关函数。假设 M 为扩频序列长度,则 $R_c(\tau)$ 在一个周期内可表示为

$$R_c(\tau)=\begin{cases} 1-\frac{\tau(1+M)}{MT_c}, & |\tau|\leq T_c \\ -\frac{1}{M}, & |\tau|>T_c \end{cases}。$$
 (5)

由式(4)可知,接收信号 $r(t)$ 的自相关函数主要由扩频序列自相关函数 $R_c(\tau)$ 决定。由扩频序列特性可知, $R_c(\tau)$ 在扩频周期处存在周期性峰值。因此,接收信号 $r(t)$ 的自相关函数 $R_r(\tau)$ 在扩频序列周期处同样也存在周期性峰值,该特性可用于直扩信号感知。直扩码分多址信号同属于时域扩频信号,也可使用相关法进行信号感知和参数估计^[10]。

在实际信号感知过程中,存在 4 种结果,如图 1 所示。通常用准确率 P_D 和虚警率 P_{FA} 两个指标来综合评价信号感知方法的性能。准确率反映对正确正样本判断正确的能力,其数值越大,感知性能越好。虚警率则反映正确预测正样本纯度的能力,其数值越小,感知性能越好。准确率 P_D 和虚警率 P_{FA} 可分别表示为

$$P_D=\frac{TD}{TD+FD},$$
 (6)

$$P_{FA}=\frac{FN}{TN+FN}。$$
 (7)

		预测	
		直扩信号	噪声
真实	直扩信号	TD (正确的正样本)	FD (漏警)
	噪声	FN (虚警)	TN (正确的负样本)

图 1 直扩信号感知结果示意

2 基于改进 ResNet 的直扩信号感知

基于改进 ResNet 的直扩信号感知方法整体架

构如图 2 所示,具体描述如下:首先,对直扩信号进行分帧、加窗、归一化等预处理;其次,通过广义互相关和二阶矩进行特征提取,生成数据集;然后,将数据集输入网络模型进行训练与评估;最后,当模型满足需求后将网络模型发布,用于实现直扩信号感知。




图 2 直扩信号感知方法整体架构

2.1 基于广义互相关的直扩信号特征提取

2.1.1 广义互相关算法原理

广义互相关的概念最早来自于时延估计,是对基本相关算法的改进,通过频域加权函数对两个信号的互功率谱进行前置滤波,能够适当消除噪声和干扰的影响^[11]。根据广义互相关的原理,信号 $x(t)$ 与 $y(t)$ 的广义互相关函数 $R_{xy}(\tau)$ 可表示为

$$R_{xy}(\tau)=\frac{1}{\pi}\int_0^\pi\psi(f)\cdot X_{xy}(f)\cdot e^{i2\pi f\tau}df。$$
 (8)


式中: $X_{xy}(f)$ 为信号 $x(t)$ 与信号 $y(t)$ 的互功率谱密度函数; $\psi(f)$ 为频域加权函数。

频域加权函数的意义在于能够使两个信号的相关峰得到锐化,不同的频域加权函数能够抑制不同类型的干扰^[12]。常用的频域加权函数有平滑相干变换(Smoothed Coherence Transform, SCOT)加权、相位变换(Phase Transform, PTAH)加权、最大似然(Maximum Likelihood, ML)加权等,其中 SCOT 加权函数兼顾了两路信号的影响,且对噪声引起误判的抑制效果良好^[13]。因此,本文选取 SCOT 加权函数为频域加权函数进行研究,其表示式为


$$\psi(f)=\frac{1}{\sqrt{X_{xx}(f)\cdot X_{yy}(f)}}。$$
 (9)

图 3 展示了直扩信号信噪比为 -10 dB 时,广义互相关算法和时域自相关算法在特征提取方面的能

力。可以看出,时域自相关算法的特征提取能力明显弱于广义互相关算法,时域自相关算法的相关峰大部分已被淹没在噪声中,而广义互相关算法能清晰看出相关峰,也能估算出扩频周期为 1.27 ms。



(a) 广义互相关算法



(b) 时域自相关算法

图 3 特征提取性能对比

2.1.2 特征提取流程

利用广义互相关算法对直扩信号进行特征提取,包括信号分帧、加窗、离散傅里叶变换、频域加权、逆傅里叶变换、累积平均二阶矩等步骤,主要流程如图 4 所示。




图 4 广义互相关特征提取流程

Step 1 将采集的直扩信号 $s(n)$ 分成 K 段,每段数据长度为 M ,同时为保证信号信息的完整性,采用 Hamming 窗对信号数据进行加窗处理,得到

$x_1(n), x_2(n), \dots, x_K(n)$, 即

$$x_i(n) = \left[0.54 - 0.46 \cos\left(\frac{2\pi n}{M-1}\right) \right] \cdot s_i(n) \quad (10)$$

Step 2 对分段后的信号进行离散傅里叶变换,得到 $X_i(f)$:

$$X_i(f) = \frac{1}{M} \sum_{n=0}^{M-1} x_i(n) e^{-j2\pi n f / M} \quad (11)$$

Step 3 对 $X_i(f)$ 求共轭,得到 $X_i^*(f)$ 。

Step 4 将相邻段的 $X_i^*(f)$ 和 $X_{i+1}(f)$ 相乘,得到互功率谱密度函数 $X_{i,i+1}(f)$:

$$X_{i,i+1}(f) = X_i^*(f) \cdot X_{i+1}(f) \quad (12)$$

Step 5 再对互功率谱密度函数 $X_{i,i+1}(f)$ 进行 SCOT 函数加权,并进行逆傅里叶变换,得到分段直扩信号的广义互相关函数 $R_{i,i+1}(\tau)$:

$$R_{i,i+1}(\tau) = \text{IFFT}(\psi(f) \cdot X_{i,i+1}(f)) \quad (13)$$

Step 6 为进一步降低噪声影响,对广义互相关函数 $R_{i,i+1}(\tau)$ 进行 N 次二阶矩累积处理,得到特征数据 $\rho(\tau)$:

$$\rho(\tau) = \frac{1}{N-1} \sum_{i=1}^{N-1} |R_{i,i+1}(\tau)|^2 \quad (14)$$

2.2 基于改进 ResNet 的感知器

上一节通过广义互相关算法将直扩信号感知问题转换成周期性相关峰的识别问题。针对此类问题,残差神经网络具有显著优势,可以通过强大的特征识别能力,将低信噪比条件下难以识别的相关峰通过机器自动、准确地进行感知判断。

2.2.1 残差神经网络模型

残差神经网络由 He 等人^[14]于 2016 年提出,通过引入残差块的形式,有效缓解了神经网络训练过程中的梯度消失和梯度爆炸问题。残差块由直连部分和残差映射部分组成,输入输出关系可以表示为

$$y = F(x; W) + x \quad (15)$$

式中: x 为残差块的输入; y 为输出; W 为卷积层参数; $F(x; W)$ 表示要学习的残差映射。

2.2.2 挤压-激励注意力机制

挤压-激励 (Squeeze-Excitation, SE) 注意力机制^[15]的核心思想是解决在卷积池化过程中因不同通道的占比程度不同所导致的特征损失问题。具体来说,就是让网络能够以学习的方式自动获取每个特征通道的重要程度,然后依照这个重要程度去增

强有用的特征。SE 注意力机制的结构如图 5 所示,包括 Squeeze 和 Excitation 两个过程。Squeeze 操作是将卷积池化后的特征 U 进行全局平均池化 (Global Average Pooling, GAP), 输出维度为 $C \times 1 \times 1$ 的全局平均特征。Excitation 操作是将全局平均特征送入全连接层 (Full Connection, FC)、ReLU 函数和 Sigmoid 函数中,输出维度为 $C \times 1 \times 1$ 的通道权重向量。最后将通道权重与特征 U 相乘,得到特征 Z 。




图 5 SE 注意力机制示意

2.2.3 网络模型设计

本文以 ResNet18 模型为基础,将内部参数、网络层等进行了优化完善,具体包括:①在残差块中加入 SE 注意力,增强特征通道的相关性,解决低信噪比条件下特征提取不足的问题;②去除最大池化层,最大池化层包含下采样操作,会导致部分特征的消失;③引入随机丢弃节点 (Dropout),防止模型出现过拟合问题,提升模型泛化能力。

改进后的网络模型结构如图 6 所示,包括改进残差块、平均池化层、全连接层和 Softmax 函数等。在每个改进残差块中,通过 2 个卷积层来提取数据特征,在卷积层后加入批归一化层 (Batch Normalization, BN) 防止模型过拟合,并利用 ReLU 函数对前一层的输出值进行非线性决策,同时还通过 SE 注意力进一步强化特征提取能力。卷积层中的卷积核数量决定网络模型的特征提取能力,本模型设置残差块中卷积层的卷积核数量依次为 64, 64, 128, 128, 256, 256, 512, 512, 为保证卷积运算后的数据尺寸保持不变,将步长设置为 1,填充模式设置为相同。网络模型的末端是平均池化层和全连接层,主要是将获得的局部数据特征进行组合得到全局特征。最后使用 Softmax 函数进行二元分类输出。




图 6 网络模型结构

3 实验仿真分析

实验均在 Windows11 操作系统下实现,基于 Matlab R2022b 深度学习工具箱环境进行网络模型的设计、训练和验证,使用 NVIDIA GeForce RTX3060 显卡加速, CPU 型号为 Intel Core i9 - 12900H@2.5 GHz,内存大小为 64 GB。

3.1 数据集及训练参数设置

实验数据是由 Matlab 生成的仿真数据集。仿真数据集分为正负两种样本,共包含 4 种信号,分别为 BPSK 调制直扩信号、BPSK 信号、QPSK 信号、高斯白噪声,信道模型设置为高斯信道,每个样本包含 8 000 个样本点。正样本为 BPSK 调制直扩信号,载波频率为 400 MHz;信噪比在 -20~0 dB 的范围内进行选择;二阶矩累积次数为 10 次;扩频序列采用 m 序列,长度分别为 31, 63, 127, 255, 每种扩频序列长度的直扩信号间隔 1 dB 产生 100 个信号样本,共 8 400 个样本。负样本由 BPSK 信号、QPSK 信号、高斯白噪声等 3 类信号随机产生,样本数量与正样本一致。仿真数据集共有 16 800 个样本,其中 80% 用于训练,10% 用于验证,10% 用于测试。

网络模型训练参数设置学习率从 0.02 开始,每 50 个迭代降低 10 倍,总共 100 个迭代,呈阶梯式降低;最大运行 Epochs 数为 12;最小批量大小设置为

128;优化器采用 Adam 优化器,动量为 0.9。

3.2 感知性能对比实验

为充分验证所提感知方法的性能,本文选取了 4 种不同的感知方法进行性能比较:方法 1 为本文所提方法,简称 GCC-SE-ResNet 法;方法 2 为文献[1]中的时域自相关法,简称 CORR 法;方法 3 为文献[13]中的广义互相关法,简称 GCC 法;方法 4 为文献[5]中的基于原始时序同相正交(In-phase and Quadrature-phase, IQ)数据的卷积神经网络法,即直接将直扩信号 IQ 数据输入卷积神经网络进行感知,简称 IQ-CNN 法。采用相同的实验数据集,并限定虚警率 P_{FA} 小于 0.01,以准确率 P_D 作为评价指标进行仿真实验,4 种感知方法准确率 P_D 随直扩信号信噪比的变化曲线如图 7 所示。




图 7 4 种感知方法准确率与信噪比的关系

从图 7 可以看出,时域自相关法感知性能最弱,当直扩信号信噪比低于 -6 dB 时,准确率则低于 100%。将直扩信号 IQ 数据不经处理直接输入卷积神经网络进行感知,效果不佳,当信噪比低于 -8 dB 时,感知性能急剧下降。广义互相关法能够在一定程度上抵抗噪声的干扰,当信噪比为 -12 dB 时,依然能保持较高的准确率。而本文所提的方法明显优于其他 3 种方法,当信噪比为 -16 dB 时仍能对直扩信号进行有效感知,与广义互相关法相比感知容限提高了 4 dB,而与时域自相关法相比感知容限则提高了 10 dB。

除了准确率 P_D ,虚警率 P_{FA} 也是评估感知方法性能的重要指标。在直扩信号信噪比为 -12 dB 时,通过不同的虚警率 P_{FA} 设置相应的门限,通过多次实验统计准确率 P_D ,计算 4 种感知方法的受试者工作特征(Receiver Operating Characteristic, ROC)曲线,如图 8 所示。




图 8 4 种感知方法的 ROC 曲线

由图 8 可知,本文所提直扩信号感知方法具有更优的感知性能。在虚警率 $P_{FA} = 0.05$ 时, CORR、IQ-CNN、GCC 和 GCC-SE-ResNet 等 4 种方法的感知准确率分别为 0.16, 0.38, 0.95 和 1。在相同虚警率的情况下,所提方法能够通过残差神经网络和 SE 注意力机制有效提高感知性能。

3.3 网络模型对感知性能的影响

不同结构的网络模型会对直扩信号感知的准确率产生一定的影响。为验证所构建网络模型的性能,本文选取了残差神经网络、引入 SE 注意力的残差神经网络、卷积神经网络等 3 种不同的网络模型对直扩信号感知性能进行仿真实验。特征提取方法统一选用广义互相关算法,并保持训练数据和网络参数基本一致。在 3 种网络模型下,直扩信号感知准确率 P_D 随信号信噪比的变化曲线如图 9 所示。




图 9 3 种网络模型感知准确率与信噪比的关系

实验表明,3 种网络模型均能有效完成直扩信号感知任务。总体来说,采用残差神经网络的感知性能明显优于传统的卷积神经网络,同时引入 SE 注意力能够在一定程度上提高感知性能。

3.4 复杂电磁环境对感知性能的影响

之前的仿真主要集中在高斯信道下,而在实际通信中,直扩信号会经常受到有色噪声、干扰等影

响,会使得噪声模型并不服从高斯分布。为验证所提感知方法对复杂电磁环境的鲁棒性,本文对测试数据集进行了增广,将直扩信号的信道模型设置为莱斯信道,并随机添加多普勒频偏、粉红噪声、冲击噪声、部分频带干扰等。通过多次实验,对不同信噪比下的直扩信号感知准确率 P_D 和虚警率 P_{FA} 进行统计,结果如表 1 所示。

表 1 复杂电磁环境下直扩信号感知准确率		
信噪比/dB	准确率/%	虚警率/%
-8	100.00	0.00
-10	100.00	0.17
-12	100.00	0.84
-14	91.81	5.83
-16	62.37	22.71

实验表明,复杂电磁环境会对本文所提方法的感知性能产生一定影响,但影响相对较小。当直扩信号信噪比为-14 dB 时,直扩信号感知准确率已达 91.81%,但此时虚警率为 5.83%,有些偏高;而当直扩信号信噪比大于-12 dB 时,感知准确率则保持在 100%,且虚警率较低。因此,本文所提方法具有较好的鲁棒性,在复杂电磁环境下依然能保持较好的感知性能。

4 结束语

本文提出了一种基于改进残差神经网络的直扩信号感知方法。实验结果表明,所提方法在信噪比为-16 dB 的高斯白噪声条件下对直扩信号依然具有良好的感知效果,且与现有感知方法相比具有更好的低信噪比和复杂电磁环境适应能力,在直扩信号实时感知方面具有较高的工程应用价值。

但是,本文所提出的直扩信号感知网络模型并未达到最佳状态。由于深度学习的可解释性较弱,网络模型的性能只能通过不断试验来进行评估,如何从理论角度设计可解释性和鲁棒性更强的网络模型将是后续研究的重点。

参考文献:

[1] 李思佳. 低信噪比下直扩信号检测与参数估计技术研究[D]. 哈尔滨:哈尔滨工程大学,2019.

[2] 郭小芳,李懿,李锋. 基于改进循环谱的直扩信号检测方法研究[J]. 科学技术与工程, 2010, 10(32): 7937-7941.

[3] 张刚强,董阳泽,刘平香. 基于功率谱平均的水声直扩信号倒谱检测方法[J]. 哈尔滨工程大学学报, 2010, 31(7): 863-867.

[4] 石穗,张天骐,徐昕,等. UQPSK 直扩信号的四阶累积量的检测研究[J]. 科学技术与工程, 2014, 14(20): 257-262.

[5] GU H Q, LIU X X, XU L, et al. DSSS signal detection based on CNN[J]. Sensors, 2023, 23(15): 6691-6706.

[6] 王晓蓉,宋晓鸥. 基于循环平稳特征的分阶段直扩超宽带信号检测[J]. 电讯技术, 2020, 60(9): 1075-1079.

[7] 刘锋,张爽,黄渝昂. 融合压缩采样与深度神经网络的直接序列扩频参数估计[J]. 电讯技术, 2022, 62(9): 1248-1253.

[8] 王源,冯永新,钱博. 一种循环谱特征提取的直扩信号智能识别方法[J]. 沈阳理工大学学报, 2023, 42(4): 31-39.

[9] 徐雅楠,刘宁波,丁昊,等. 利用 CNN 的海上目标探测背景分类方法[J]. 电子学报, 2019, 47(12): 2505-2514.

[10] 张天骐,杨凯,赵亮,等. 多径衰落信道下 MC-CDMA 信号扩频序列周期盲估计[J]. 系统工程与电子技术, 2017, 39(12): 2803-2809.

[11] KNAPP C, CARTER G. The generalized correlation method for estimation of time delay [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1976, 24(4): 320-327.

[12] 张伟,董阳泽,张刚强,等. 一种基于广义互相关的水声直扩信号检测方法[J]. 声学技术, 2021, 40(1): 44-48.

[13] 邢毓华,郑琦. 广义互相关在混沌扩频时延估计中的研究与应用[J]. 激光与光电子学进展, 2021, 58(23): 43-49.

[14] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.

[15] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42(8): 2011-2023.

作者简介:

任江飞 男, 1991 年生于江苏镇江, 2013 年获学士学位, 现为硕士研究生、工程师, 主要研究方向为移动通信、通信信号处理。

许 魁 男, 1982 年生于安徽蚌埠, 2009 年获博士学位, 现为教授、博士生导师, 主要研究方向为无线通信、移动通信。

刘 洋 女, 1996 年生于吉林延边, 2017 年获学士学位, 现为硕士研究生, 主要研究方向为通信抗干扰、强化学习。

陆 瑞 男, 1991 年生于江苏南京, 2014 年获学士学位, 现为硕士研究生、工程师, 主要研究方向为移动通信、通信信号处理。

张 咪 女, 1999 年生于江苏镇江, 2021 年获学士学位, 现为硕士研究生, 主要研究方向为信号处理。

叶子绿 女, 2001 年生于江西萍乡, 2023 年获学士学位, 现为硕士研究生, 主要研究方向为无线通信。