

doi:10.19306/j.cnki.2095-8110.2020.04.015

# GNSS 干扰信号检测方法研究

王佳欣, 常青, 田原, 黄坚

(北京航空航天大学电子信息工程学院, 北京 100191)

**摘要:**研究了 GNSS 导航接收机在干扰源条件下的干扰检测和识别技术。除常见的卫星干扰如脉冲干扰、扫频干扰、BPSK 干扰、宽带高斯白噪声干扰外,还添加了 QPSK 和 8PSK 干扰进行建模分析,并提取了常见的特征参数,如信号 3dB 带宽和频谱峰度等。通过研究,高阶累积量被提取作为 MPSK 干扰类内识别的特征参数。研究了基于决策树和 BP 神经网络等分类器算法的干扰盲识别,并分析比较了这些分类算法的识别准确率,为抗干扰领域的研究提供了重要参考。

**关键词:**干扰检测与识别;特征提取;决策树;BP 神经网络

中图分类号:TN972

文献标志码:A

开放科学(资源服务)标识码(OSID):

文章编号:2095-8110(2020)04-0117-06



## Research on GNSS Interference Signal Detection Method

WANG Jia-xin, CHANG Qing, TIAN Yuan, HUANG Jian

(School of Electronic Information Engineering, Beihang University, Beijing 100191, China)

**Abstract:** This paper studies the interference detection and recognition technology of GNSS navigation receiver under interference source conditions. In addition to common satellite interferences such as pulse interference, sweep interference, BPSK interference and broadband gaussian white noise interference, QPSK and 8PSK interference are added for modeling analysis, and common characteristic parameters such as 3dB bandwidth and spectrum kurtosis of the signal are extracted. Through research, the high-order cumulant is extracted as the characteristic parameters recognized within MPSK interference. The decision tree algorithm and BP neural network algorithm are adopted for blind identification of interference, and the recognition accuracy of these classification algorithms are studied, analyzed and compared. The results show that the methods can provide important references in the research field of anti-interference.

**Key words:** Interference detection and identification; Feature extraction; Decision tree; BP neural network

## 0 引言

对全球导航卫星系统(Global Navigation Satellite System, GNSS)接收机干扰是战场电磁环境压制的主要手段,为提升接收机战场应用的可靠

性,不仅要提升其自身的干扰抑制能力,还要对干扰源信号进行检测和识别,为进一步实施对干扰源的精确摧毁提供依据<sup>[1-2]</sup>。

对于导航干扰源的检测,目前主要集中于检测干扰是否存在以及判断存在的干扰类型,几乎没有

收稿日期:2019-05-31;修订日期:2019-10-17

基金项目:装备预研领域基金(61405180203)

作者简介:王佳欣(1994-),女,硕士,主要从事卫星导航、干扰检测方面的研究。E-mail:cincinw@163.com

通信作者:常青(1962-),男,教授,主要从事卫星导航、空天地信息网络、移动通信方面的研究。E-mail:changq@263.net

考虑多干扰源复杂电磁环境下的识别问题。目前,干扰识别主要分为三大类:基于假设检验的最大似然调制识别<sup>[3]</sup>、基于特征提取的模式识别<sup>[4]</sup>和基于人工智能的识别方法<sup>[5]</sup>,主要应用在雷达信号识别方面。

1969年,Weaver C等最早开始了调制信号的识别。此后,基于极大似然准则的干扰检测识别的研究并不多,这种方法运用统计学原理,对先验信息进行处理,多依靠经验和观察,计算量相对较大,且不宜工程实现。基于特征提取的模式识别在实际中运用广泛,在雷达电子对抗中的研究较多。提取特征一般通过对时域、频域、变换域等进行分析处理,进而选取有效特征,再进行分类器的设计。常见的特征提取方法有信号回波谱相关法、中频信号处理和时域信号自相关法等<sup>[6]</sup>。其中时频分析应用广泛,主要包括短时傅里叶变换、Wigner变换和小波变换等。近年来,模式识别发展较快,梁金弟针对复杂电子环境的干扰识别问题,使用基于决策树和支持向量机两种识别器进行干扰性能仿真对比分析<sup>[7]</sup>;吴昊应用归一化高阶累积量作为特征参数,并应用神经网络对干扰进行识别,在低干信比下准确率较高<sup>[8]</sup>;金秋将深度学习运用到雷达辐射源分类中,实现智能化识别<sup>[9]</sup>;O'Shea T J成功将时域信号输入深度学习网络,实现了数字、模拟调制信号总计达二十八种信号的分类<sup>[10]</sup>。

综合以上情况,国内外对于GNSS接收机接收到的导航干扰信号识别研究成果较少,但可以借鉴雷达领域信号识别的成果,尤其是特征的选取方面。本文针对检测干扰是否存在提出了使用干扰存在因子这一特征量,并通过各种识别方法的研究比较,验证了提取特征的有效性。

## 1 卫星信号干扰模型

### 1.1 干扰建模

基于对GNSS阵列信号的干扰识别与测向,研究以北斗为代表的GNSS接收机接收到的干扰信号,对其他类型的GNSS信号有相似的作用。选择脉冲干扰、扫频干扰、BPSK调制干扰、宽带高斯白噪声、窄带高斯白噪声以及点频干扰六种干扰信号作为研究对象,进行数学建模。以下是它们的模型。

#### 1) 脉冲干扰

脉冲干扰(Pulse Interference, PI),一般为突发性、周期性的,特点是持续时间很短,频谱很宽<sup>[11]</sup>。

脉冲干扰可简单表示为

$$J(t) = \sum \delta(t - K) \quad (1)$$

其中,  $K$  为脉冲周期的整数倍。

#### 2) 扫频干扰

扫频干扰,以线性调频干扰为例,有一定带宽,其瞬时频率会随时间线性变化,数学表达式为

$$J_{\text{LFMI}}(t) = A(t) \text{rect}(t/T) \exp[j(2\pi f_0 t + \pi K t^2)] \quad (2)$$

式中,  $A(t)$  为扫频干扰信号的幅度,  $T$  为扫频的周期,  $f_0$  为扫频的中心频率,  $K$  为线性扫频频率。

#### 3) 宽带高斯白噪声

宽带高斯白噪声,为带通型高斯白噪声通过某一带通型滤波器,并且这个滤波器的通频带宽  $B$  满足大于其中心频率  $f_0$  (即  $B > f_0$ ) 时,滤波器输出端的高斯白噪声。

#### 4) 窄带高斯白噪声

窄带高斯白噪声,类似于宽带高斯白噪声,而当此滤波器的通频带宽  $B$  远小于其中心频率 (即  $B \ll f_0$ ) 时,滤波器输出即为窄带高斯白噪声。该噪声有如下表达式和统计特性

$$n(t) = n_c(t) \cos \omega_c t - n_s(t) \sin \omega_c t \quad (3)$$

$$E[n(t)] = E[n_c(t)] = E[n_s(t)] = 0 \quad (4)$$

$$\sigma_n^2 = \sigma_c^2 = \sigma_s^2 \quad (5)$$

其中,  $n(t)$  表示窄带高斯白噪声的平均功率,  $n_c(t)$  表示平均功率的同向分量,  $n_s(t)$  表示平均功率的正交分量,  $E[n(t)]$  表示幅度均值,  $\sigma_n^2$  表示幅度均值方差。

#### 5) 点频干扰

设点频干扰信号的频率与北斗 B1 中心调制频率相同,则该信号可以写成

$$J_{\text{cwj}}(t) = \sqrt{2P_{\text{cwj}}} \cos(2\pi f_{\text{L1}} t + \theta_{\text{cwj}}) \quad (6)$$

式中:  $P_{\text{cwj}}$  为干扰信号的功率;  $\theta_{\text{cwj}}$  为干扰的初始相位。经过 C/A 码调制及中频变换后,其表达式为

$$u_{\text{cwj}} = \sqrt{2P_{\text{cwj}}} C(t - \tau) \cos(2\pi f_1 t + \theta_{\text{cwj}}) \quad (7)$$

其自相关函数为

$$R_{\text{cwj}}(\tau) = E[u_{\text{cwj}}(t) u_{\text{cwj}}(t + \tau)] \quad (8)$$

$$= P_{\text{cwj}} R_{\text{C/A}}(\tau) \cos(2\pi \varphi_1 \tau)$$

#### 6) MPSK 调制干扰

实际的通信系统中,以  $0^\circ$  载波相位作为参考相位,以载波相位的  $M$  种不同取值分别表示数字信息。

$$e_{\text{MPSK}}(t) = \sum_n g(t - nT_s) \cos(\omega_c t + \varphi_n) \quad (9)$$

$M$  进制数字相位调制信号的正交形式为

$$e_{\text{MPSK}}(t) = I(t)\cos\omega_c t - Q(t)\sin\omega_c t \quad (10)$$

常用 I、Q 两路来调制多进制相移键控。

通过以上分析,对各个干扰进行建模,然后产生干扰信号数据库。

### 1.2 特征提取

通过对常见的卫星干扰进行分析,在归一化预处理后,研究了干扰信号的时域和频域等特点。选取下列特征进行提取。信号识别时对特征值个数并无绝对要求,只是可以采用如下特征参数在已知种类的干扰中识别不同干扰。

1) 干扰存在因子  $E$ : 检测干扰存在的方法众多,这里选取信号整体功率确定检测门限。

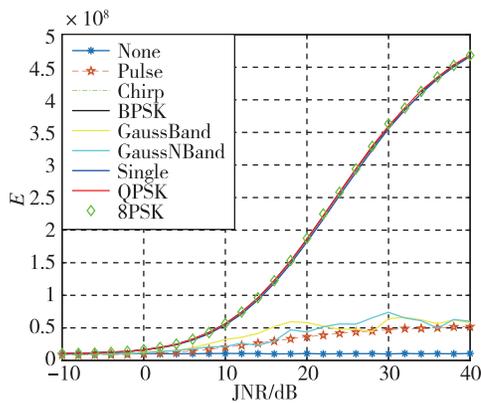


图 1 不同干扰比下  $E$

Fig. 1  $E$  under different JNRs

由图 1 可以看出,在干噪比为 0dB 以上时,干扰存在因子在无干扰时持续较低,可作为干扰是否存在的依据。

2) 干扰带宽  $B$ : 区分宽带和窄带干扰的重要特征。

由表 1 可知,宽带干扰和窄带干扰可通过门限值 0.03 区分。

表 1 干扰带宽

Tab. 1 Bandwidth of jammers

干扰类别	宽带干扰	窄带干扰
干扰带宽	>0.05	<0.01

3) 信号峰均比 PAR: 因为识别中有 PSK 调制的信号,其信号峰均比较大,可实现与其他信号的种类间识别。

4) 频谱峰度  $K$ : 脉冲干扰频谱峰度较大,可有效识别,并可区分扫频和宽带高斯白噪声。

5) 平均频谱平坦系数  $P$ : 点频干扰频谱峰值较高,可以与其他干扰区分。

6) 高阶累积量  $F_1$ 、 $F_2$ : 可采用该参数区分 MPSK 信号,实现类内识别。

由表 2 可知,不同进制 PSK 干扰信号可通过高和累积量  $F_1$ 、 $F_2$  进行区分。

表 2 高阶累积量

Tab. 2 High-order cumulant

干扰类别	BPSK	QPSK	8PSK
$F_1$	1	1	0
$F_2$	1	0	0

## 2 分类器设计

### 1) 决策树

决策树(Decision Tree)是一种常见的机器学习方法,可用于分类。常通过对相应参数进行估计,选取合适的阈值对不同类别进行分离。决策树方法最关键的是选取最优划分属性,一般选取信息增益、增益率或基尼指数来选择划分属性。这里采用 CART 决策树进行分类器设计,基于最小距离的基尼指数估计函数,将当前样本集分为 2 个子样本集。相对其他方法来说,具有在简化模型的同时不会丢失熵模型的优点<sup>[12]</sup>。

图 2 所示为决策树部分识别流程图。

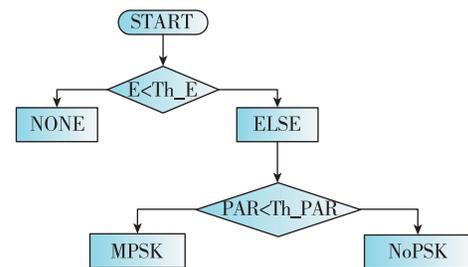


图 2 决策树基本构成示例

Fig. 2 Example of the decision tree basic composition

### 2) 支持向量机

支持向量机(Support Vector Machines, SVM)基于统计学习理论,在样本空间中构造超平面将样本分为两类。图 3 所示为训练样本分别为线性可分、线性近似可分、线性不可分时通过不同处理方式,学习不同类型支持向量机的基本模型<sup>[13]</sup>,实现了高效地从训练样本到预报样本的转导推理,但对大规模样本及多分类问题不大适用,需采用组合模

式进行训练。

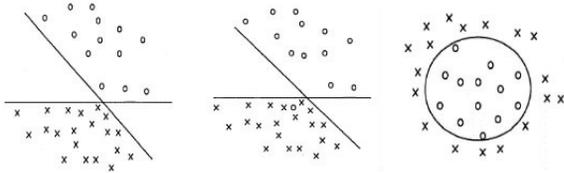


图3 SVM 常见分类模型

Fig. 3 Common classification models of SVM

3)神经网络

BP神经网络是常见的神经网络,是一种非线性分类器,通常包括前向传播和反向传播的过程,常用于分类识别和预测等,具有自学习和自适应能力,还具有一定的容错能力,较其他识别方式有突出优势,但是在层节点的选择上需要先验知识来决定。

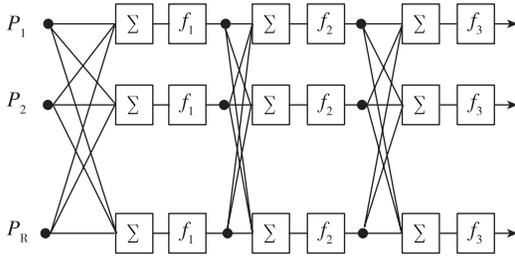


图4 简单神经网络

Fig. 4 Simple neural network

4)深度学习

深度学习基于数据挖掘,利用输入数据抽象提取数据特征,将低维度特征通过学习过程得到维度特征,是神经网络的扩展,具有更智能化的过程。但如果数据序列较长,则存在盲识别的准确性会极大降低的问题,因此一般为了可靠性考虑,在工程应用中鲜少直接使用。

实验使用决策树和BP神经网络对已有干扰进行识别率的比较,得出结论。

3 仿真实验

实验设置条件为GNSS接收机,选取北斗B1码进行仿真。信号及干扰设置条件如表3所示。这里认为当某种信号识别率达到98%及以上时,结果是相对可靠的。

表3 信号参数设置

Tab. 3 Signal parameter setting

参数类别	参数	值
基本参数	接收信号载波频率/MHz	1561.098
	发射信号载波频率/MHz	1561.098
	基准码率/MHz	2.046
	模拟中频/MHz	40.098
	采样率/MHz	62
	仿真时间/s	0.003
脉冲干扰	干噪比/dB	0/20
	占空比	0.1
扫频干扰	脉冲周期/s	0.001
	带宽/MHz	4.092
宽带高斯白噪声干扰	带宽/MHz	4.092
	带宽/MHz	0.4092

使用的干扰样本模型为无干扰及含有上述八种干扰的卫星信号,每种信号各100个,即900个带有标注的信号,同时生成相同条件下相同数量的另一组测试样本。

决策树及BP神经网络采用从信号中提取得到的特征值进行训练。决策树使用事先确定的各特征参数门限值进行分类,而BP神经网络经多次试验,采用的输入层、隐藏层、输出层节点数分别为7、25、1。下面比较两种分类器在干噪比为0dB和20dB下不同干扰类型的识别率。

1)仅有干扰存在因子E、干扰带宽B、频谱峰度K、平均频谱平坦系数P这4个特征的决策树和BP神经网络分类器识别情况。

仅有4个特征值时,由图5可以得出,干噪比为0dB时,九种信号识别率均在90%左右波动,说明特征参数过多,扰乱识别或缺少能够充分识别这些干扰的特征参数;而干噪比为20dB时,各种信号识别率有所提升,均达到95%以上,其中,扫频干扰、脉冲干扰、点频干扰识别率达到99%,说明随着干

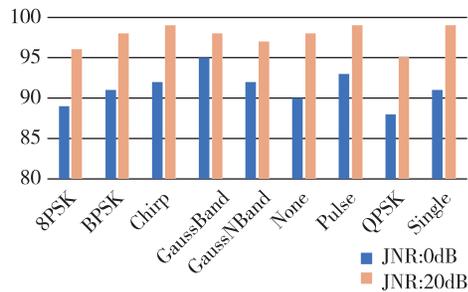


图5 4个特征参数-决策树识别率(%)

Fig. 5 Four characteristic parameters-recognition rate of decision tree(%)

噪比增加,信号识别效果有较大提升。

图 6 反映了 BP 神经网络作为干扰分类器,在干噪比为 0dB 时与决策树有相似的分类误差,进一步说明,低干噪比下所选取 4 个特征值的识别效果较差;当干噪比为 20dB 时,各个干扰识别率均在 95%~98%,略低于决策树分类器。

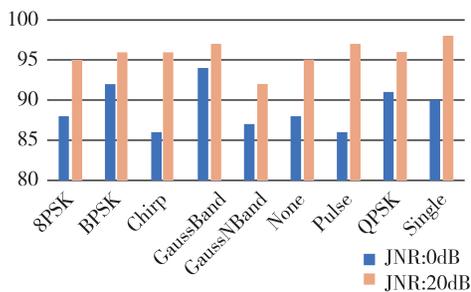


图 6 4 个特征参数-BP 神经网络识别率(%)  
Fig. 6 Four characteristic parameters -recognition rate of BP neural network(%)

也可以得出结论:在仅有 4 个特征值的条件下,干噪比为 0dB 时,两种分类方法的分类结果是不够可靠的。而当干噪比提升到 20dB 时,决策树方法对 8PSK 干扰、扫频干扰、宽带高斯白噪声干扰、无干扰、脉冲干扰及点频干扰识别率均达到 98% 及以上,可以认为 4 个特征参数的决策树分类器适用于这几种干扰;而 BP 神经网络识别的结果中,仅有点频干扰识别率达到 98%,因此 4 个特征参数的 BP 神经网络分类器适用于点频干扰的识别。

2)将 1)中提及的 7 个特征值作为特征参数,决策树和 BP 神经网络分类器识别情况。

由图 7 可知,使用决策树识别器识别设置的八种干扰及无干扰,干噪比为 20dB 时,识别率达到 99.8%,而 0dB 时识别效果也达到了 99.2%,可以验证特征提取的有效性。其中,MPSK 信号识别率达到 99.6%,说明高阶累积量足以区分不同进制的 PSK 干扰。

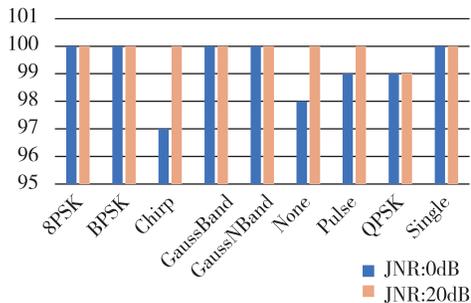


图 7 决策树识别率(%)  
Fig. 7 Recognition rate of decision tree(%)

其中,干噪比为 0dB 时,7 个特征值的决策树分类器不适用于扫频干扰,但其他干扰识别效果均达到 98% 以上;而当干噪比为 20dB 时,各个干扰识别率均达到 99% 及以上,因此 7 个特征值的决策树适用于此处设置的所有干扰。

由图 8 可知,使用 BP 神经网络,干噪比为 20dB 时,识别率达到 99.8%;干噪比为 0dB 时,无干扰、宽带高斯白噪声干扰、窄带高斯白噪声干扰存在 1%~2% 的干扰误分率,一定程度上反映了噪声的影响。同样 BP 神经网络也具有一定的分类稳定性。

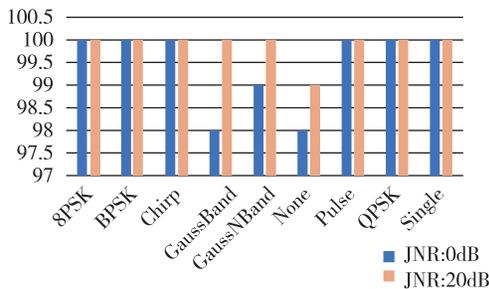


图 8 BP 神经网络识别率(%)  
Fig. 8 Recognition rate of BP neural network(%)

通过观察发现,虽然干噪比为 0dB 时个别干扰识别效果相对较差,但识别率也达到 98% 及以上,因此当干噪比为 0dB 及 20dB 时,7 个特征值的 BP 神经网络在识别所有干扰时均适用。

### 4 结论

本文针对 GNSS 导航接收机接收信号易受干扰的问题,对于干扰识别方面面临的一些问题进行了分析:

1)针对干扰识别时需要进行特征提取,选取常见的时域和频域等变换域特征进行研究,其中对于多进制 PSK 干扰采用了高阶累积量作为特征参数进行识别,有效提高了特征识别准确率。

2)对于常见的分类器,选取决策树及 BP 神经网络进行设计,对添加了高阶累积量作为特征参数的识别器,识别准确率有所提升,验证了特征提取的有效性。同时两种分类器在识别时均表现出了识别的稳定性,其中不同分类器对不同干扰的适用性已在文章中予以说明。

3)在特征识别过程中,仅对特定干噪比的信号进行仿真,对于干噪比低于 0dB 的情况识别效果相对较差,需要对特征参数加以研究;实验仅设定无干扰情况及八种常见干扰,对于其他类型的干扰并不适用。

## 参考文献

- [1] Perrone G, Vallan A. GNSS-Global Navigation Satellite Systems[M]. Springer, 2008.
- [2] Hewitson S, Wang J. GNSS receiver autonomous integrity monitoring (RAIM) performance analysis[J]. GPS Solutions, 2006, 10(3): 155-170.
- [3] Fang Y, Noel A, Yang N, et al. Symbol-by-symbol maximum likelihood detection for cooperative molecular communication[J]. arXiv: Information Theory, 2018.
- [4] Amin H U, Mumtaz W, Subhani A R, et al. Classification of EEG signals based on pattern recognition approach [J]. Frontiers in Computational Neuroscience, 2017, 11: 103.
- [5] Trentin E, Schwenker F, Gayar N E, et al. Off the mainstream: advances in neural networks and machine learning for pattern recognition[J]. Neural Processing Letters, 2018, 48(1): 1-6.
- [6] Lina W, Weining X, Yang L, et al. Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis [J]. Entropy, 2017, 19(6): 222.
- [7] 梁金弟, 程郁凡, 杜越, 等. 联合多维特征的干扰识别技术研究[J]. 信号处理, 2017, 33(12): 1609-1615.
- Liang Jindi, Cheng Yufan, Du Yue, et al. Research on interference identification technology combining multi-dimensional features [J]. Signal Processing, 2017, 33(12): 1609-1615(in Chinese).
- [8] 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.
- Wu Hao, Zhang Hang. Interference identification algorithm based on high-order cumulant and neural network [J]. Military Communication Technology, 2008, 29(1): 67-71(in Chinese).
- [9] 金秋, 王宏艳, 马方方. 雷达辐射源分类识别方法综述[J]. 电讯技术, 2019, 59(3): 360-368.
- Jin Qiu, Wang Hongyan, Ma Fangfang. Overview of radar radiation source classification and identification methods[J]. Telecommunications Technology, 2019, 59(3): 360-368(in Chinese).
- [10] O'Shea T J, Roy T, Clancy T C. Over the air deep learning based radio signal classification [J]. IEEE Journal of Selected Topics in Signal Processing, 2017, 12(1): 168-179.
- [11] Cai J, Xiao Y. Impulse interference processing for MT data based on a new adaptive wavelet threshold de-noising method[J]. Arabian Journal of Geosciences, 2017, 10(18): 407.
- [12] Bar-Hen A, Gey S, Poggi J M. Influence measures for CART classification trees[J]. Journal of Classification, 2015, 32(1): 21-45.
- [13] Wu J, Yang H. Linear regression-based efficient SVM learning for large-scale classification[J]. IEEE Transactions on Neural Networks & Learning Systems, 2017, 26(10): 2357-2369.