

基于时频分析和神经网络的水声通信信号识别技术

陆 扬, 王雪松, 赵鹏远, 周 华

中国人民解放军 91439 部队, 辽宁大连 116041

摘要 水声通信信号识别具有重要的现实意义。传统的识别器是每种调制模式分别设计的检测器, 因而运算量随调制模式数量的增加而增加。随着通信技术手段日益更新, 调制模式不断翻新, 传统识别器已经不能满足快速检测和识别信号的要求, 设计统一的特征提取方法以减少检测器的数量非常迫切。从侦收信号的时频分布中提取特征向量, 利用人工神经网络对特征向量进行分类, 基于此提出了一种新的识别方法。对本文提出的识别器, 在使用前增加新的调制模式的样本并重新训练神经网络, 使用过程中能实现更多调制模式的识别而不增加运算量。对特征向量的提取方法进行了详细描述, 并通过计算机仿真实验, 得出了低信噪比时的正确识别概率。

关键词 水声通信信号识别; 时频分析; 人工神经网络

中图分类号 TB567

文献标识码 A

doi 10.3981/j.issn.1000-7857.2011.28.004

Identifications of Underwater Acoustic Communication Signals Classification Based on Time-frequency Analysis and Neural Network

LU Yang, WANG Xuesong, ZHAO Pengyuan, ZHOU Hua

No. 91439 Troop of PLA, Dalian 116041, Liaoning Province, China

Abstract The fast detection of communication signals and the exact identification of their modulation types are of importance in practice. Traditional designs use detectors for each modulation type separately thus the computation time would increase as the number of modulation types increases. It is necessary to work out a standard feature vector extraction method to reduce the number of detectors. A novel identification scheme is proposed, with feature vectors being extracted from the time-frequency distribution and identified by an artificial neural network. By adding signal samples of new modulation types and by retraining the neural network, this identification scheme can recognize more modulation types without increase of computation burden. The detail of this feature vector extraction approach is described, the probability of the correct identification of the communication signals in low signal-to-noise conditions is obtained through computer simulations.

Keywords underwater acoustic communication signal classification; time-frequency analysis; artificial neural network

0 引言

在水声通信中, 海洋信道的干扰和恶意施放的干扰使得常规通信调制模式如频移键控、相移键控调制等方式不能满足数据可靠传输的要求。扩展频谱通信(包括跳频和直序扩频通信)和多载波通信(如正交频分复用, 正交频分复用技术(Orthogonal Frequency Division Multiplexing, OFDM))具有抗多径干扰和抗人为干扰的能力^[1], 是水声通信中广泛采用的调制模式。在信号形式已知的情况下, 已有多成熟技术用

于检测特定的信号; 跳频信号的检测采取基于能量检测的宽带多通道检测器、单跳自相关法和多跳自相关法等^[2-3]; 直扩信号的检测方法有能量法、相关法、高阶谱分析、倒谱分析、循环谱分析和各种时频法^[4]; OFDM 信号的检测包括循环谱等方法^[5]。实际情况下, 截获水声通信信号时并没有信号形式的先验知识, 因而使用一组检测器, 为每种调制模式设计一种检测器, 并采取“轮询”的方法识别调制样式^[6], 如图 1 所示。

图 1 中 H_1 表示满足特定的判决条件, H_0 表示不满足特

收稿日期: 2011-09-06; 修回日期: 2011-09-17

作者简介: 陆扬, 高级工程师, 研究方向为水声工程, 电子信箱: cg300@sina.com




图1 采用“轮询”方式的水声通信信号识别技术

Fig. 1 Identification of underwater acoustic communication signal modulations using polling scheme

定的判决条件。这种基于“轮询”的识别器实现复杂,而且能识别的调制类型数量取决于检测器的数量,运算量也随调制类型的增加而增加。随着通信技术的进步,通信体制、信号样式不断翻新,这样的识别器难以满足实际需求,研究一种基于标准检测器(即统一的特征提取方法)的数字调制自动识别器非常迫切。

在调制模式识别中,对侦收信号特征的选取和处理,是模式识别的首要任务。不同类型通信信号频谱随时间变化的情况存在差别,因而可以采取时频分析作为信号特征提取的手段^[7]。在调制模式的识别环节,则可以采用神经网络方法。神经网络在模式识别领域得到了广泛应用是因为其具有新的信息表达方式、高度平行分布处理、联想、自学习和自组织能力及极强的非线性映射能力^[8]。

基于时频分析和神经网络,本文提出了一种检测和识别水声通信信号的联合方法,如图2所示。




图2 水声通信信号检测、识别和估计联合方法流程图

Fig. 2 Combination method of detection, identification and estimation

对侦收数据进行时频分析,从时频分析得到的二维向量中提取特征向量,将特征向量输入训练好的神经网络,输出结果给出了“有无通信信号”与“通信信号类型”的信息,达到了检测和识别的目的。新的方法基于标准检测器,可扩展性好,在使用前增加新的调制类型的样本并重新训练神经网络,使用过程中能实现更多调制类型的识别而不增加运算量。在复杂的信号环境下,比基于多个检测器的传统识别器

具有显著的优势。

1 特征向量提取

时频分析理论和方法为侦收信号处理提供了有效的工具,Cohen类双线性时频分布构成了时频分析理论的基础和核心。Wigner-Ville分布(WVD)及衍生类型“伪WVD”和“平滑伪WVD”,作为典型的Cohen类时频分布,具有良好的时频聚集性,是时频分析中应用最多的时频表示,本文即采用了WVD对侦收信号进行分析。

图3为侦收信号特征向量提取流程图。




图3 特征向量提取流程图

Fig. 3 Flow chart of feature vector extraction algorithm

侦收信号特征向量提取具体步骤:(1)求信号的WVD;(2)对WVD进行时间积分,得到信号的边缘频率分布,对其进行平滑和归一化处理;(3)对平滑和归一化处理后的边缘频率分布进行门限处理,得到信号存在的频带范围;(4)根据信号频带信息,从原始时频图中截取出包含信号的部分;(5)按照规定的尺寸调整分离出的时频图的大小,调整大小后的时频图二维矩阵转化为一维向量,即为所求的特征向量。

设直扩信号采样率为50kHz,载波频率为50000/8=6250Hz,切普长度为31,切普时间宽度为2个载波周期,伪随机码周期等于码元周期,信噪比为-4dB。图4是仿真信号的边缘频率分布图。边缘频率分布中能量较高的区间代表信号存在的频带。精确地将信号存在的部分从时频图中截取出来是特征向量提取的首要步骤,这可以通过将不同频率的能量与预设门限值进行比较来完成。对同一信号,在不同的信噪比下,基于该方法得到的信号频带位置变动很大,需要对边缘频率分布进行平滑操作。

平滑操作分为两步:首先采用自适应滤波器来降低噪声,然后采用平均滑动滤波器来抑制边缘效应和极大值点。

自适应滤波器根据输入信号的统计特性改变信号参数,本文采取维纳滤波器^[9],根据边缘频率分布向量当前元素相邻的 $2m+1$ 个元素来估计局部均值 $\mu(n)$ 和局部方差 $\sigma^2(n)$ 。即

$$\mu(n)=\frac{1}{2m+1}\sum_{k=n-m}^{k=n+m}A(k) \quad (1)$$

$$\sigma^2(n) = \frac{1}{2m+1} \sum_{k=n-m}^{k=n+m} A^2(k) - \mu^2(k) \quad (2)$$

其中, $A(k)$ 是频率边缘分布向量。

根据计算出的局部均值和局部方差, 维纳滤波器将输入的边缘频率分布向量转换成新的向量 $A'(n)$, 见式 (3)

$$A'(n) = \mu(n) + \frac{\sigma^2(n) - V^2}{\sigma^2(n)} (A(n) - \mu(n)) \quad (3)$$

其中, V^2 是所有局部方差的平均值。当 σ^2 的值大时, 滤波器进行了较小的平滑; 当 σ^2 的值小时, 滤波器进行了较大的平滑。图 5 是边缘频率分布经过维纳滤波器后得到的结果, 其中 $m=5$ 。




图 4 仿真信号的边缘频率分布

Fig. 4 Marginal frequency distribution of received signal




图 5 经过维纳滤波器后的边缘频率分布

Fig. 5 Marginal frequency distribution after Wiener filtering

由图 5 可知, 经维纳滤波器作用后, 噪声大大减少。

维纳滤波器大幅度减少了噪声, 将维纳滤波器的输出结果再经过一个滑动平均滤波器, 如式 (4), 可以降低噪声的局部脉冲干扰。

$$\tilde{A}_{\text{avg}} = \frac{1}{N+M+1} \sum_{k=-N}^M A'(n-k) \quad (4)$$

图 6 是滑动平均滤波器的输出信号的波形图。其中 $N+M+1=15$ 。

对滑动平均滤波器的输出结果进行归一化处理:

$$\bar{A} = \frac{\tilde{A}_{\text{avg}}}{\max(\tilde{A}_{\text{avg}})} \quad (5)$$

对归一化以后的 $\bar{A}$ 做门限处理。门限值由仿真确定: 如果根据由某一门限得到的所有测试样本的平均正确识别概率最大, 则该门限为所选门限。门限确定以后, $\bar{A}$ 中低于门限的值被设为 0。由此可以确定信号存在的最高频率和最低频率, 如图 7 所示。依据最高频率和最低频率, 可以从图像中提取出调制能量, 如图 8 所示。再对提取出的图像进行压缩或拉伸处理, 得到统一大小的标准图像。依照逐行排列的顺序, 将二维矩阵转换为一维向量, 即为所求的特征向量。

2 仿真及结果分析

假设接收信号的采样率为 50kHz, 取 2048 个采样点进行频分析。对经过截取得到的调制信号的二维图像 (图 8(b))




图 6 经过滑动平均滤波器的边缘频率分布

Fig. 6 Marginal frequency distribution after average filtering




图 7 经过门限处理后的边缘频率分布

Fig. 7 Marginal frequency distribution after threshold processing




图 8 根据最高频率和最低频率提取出调制能量

Fig. 8 Modulation energy cropping based on start and end frequencies

进行图像插值或降采样, 使其大小为 64×256 , 依照逐行排列的顺序, 将二维矩阵转换为一维向量, 则转换后的特征向量大小为 16384×1 。样本类型包括直扩、跳频、OFDM 和噪声。直扩信号参数包括载波频率、码元周期、切普宽度、伪随机码长度、信噪比, 跳频信号参数包括 m 序列长度、本原多项式、跳频频率间隔、码元周期、调制频率间隔、信噪比, OFDM 信号参数包括 IFFT 点数、载波个数、每码元比特数、信噪比, 噪声参数包括幅度方差。对每一类型信号, 通过改变其参数可以得到丰富的样本; 若两个相同类型的样本信号参数相同, 由于仿真中噪声是随机产生的, 仍可视为不同样本。仿真中训练样本集信噪比取 -3dB 和 ∞ , 测试样本集信噪比取值从 -9dB 到 6dB 。训练样本集和测试样本集中相同类型的信号, 至少有 1 个信号参数存在差异, 如此可以考查神经网络对信噪比和其他信号参数的泛化能力。

神经网络采用单隐层 BP 网络, 如图 9 所示。输入层维数为 16384, 隐层包含 135 个神经元, 输出层维数为 4 (分别对应 4 种信号类型)。隐层和输出层传输函数都为 logsig 函数。输入向量为依照第 1 节所述方法得到的特征向量, 对信号类别 1, 目标向量为 $[1, 0, 0, 0]$, 对信号类别 2, 目标向量为 $[0, 1, 0, 0]$, 依此类推; 对某一测试样本, 如果其输出向量的最大值出现在第 m 列, 则判为第 m 类。




图 9 神经网络结构图

Fig. 9 Structure of the artificial neural network

在特征向量提取过程中, 门限需要通过仿真计算得到。在 0 和 1 之间取 10 个间隔相等的门限值, 在不同门限值下, 计算测试样本集的所有样本的平均正确识别概率, 得到平均正确识别概率随门限值变化的曲线, 如图 10 所示。




图 10 不同门限下测试样本集的平均正确识别概率

Fig. 10 Average probabilities of correct identification versus different SNR levels

由图 10 可得到门限 0.1 时, 平均正确识别概率最大。其中 4 种不同类型信号各自的正确识别概率如表 1 所示, 行标题代表识别结果, 数据标题代表正确识别概率, 列标题代表原信号调制模式。黑体数字表示信号调制模式识别结果与原信号调制模式一致时的正确识别概率, 非黑体数字表示信号调制模式识别结果为其他调制模式时的概率。在该门限下, 可以计算不同信噪比时测试样本集的平均正确识别概率, 如图 11 所示。由图 11 可知, 信噪比为-4dB 时, 仍可得到较高的正确识别概率。

表 1 门限为 0.1 时不同类型信号的正确识别概率

Table 1 Probabilities of test signals of each type at threshold value of 0.1

正确识别 概率	直扩	跳频	OFDM	噪声
直扩	0.857	0.003	0.122	0.018
跳频	0.123	0.765	0.046	0.066
OFDM	0	0	0.933	0.067
噪声	0.340	0.063	0.028	0.569

3 结论

基于时频分析和人工神经网络的水声通信信号识别技术, 采用标准检测器, 简化了流程。通过仿真信号或预先录制




图 11 门限为 0.1 时, 不同信噪比下测试样本集的平均正确识别概率

Fig. 11 Average probabilities of correct identification versus different SNR levels for threshold value of 0.1

的信号对神经网络进行训练, 并将该神经网络的参数储存, 实际使用时只需将采集的信号经过特征向量提取, 特征向量输入该神经网络, 即可实现信号的识别。因此运算量较采用多个检测器的通信信号识别器大大减少, 有利于实时截获。

经过仿真比较, 选取了 0.1 作为特征向量提取过程的门限值, 在该门限值下, 信噪比为-4dB 时, 正确识别概率为 84.3%。

参考文献 (References)

- [1] Poisel R A. 现代通信干扰原理与技术 [M]. 陈鼎鼎, 等译. 北京: 电子工业出版社, 2005.
Poisel R A. Modern communications jamming principles and techniques [M]. Chen Dingding, et al. Trans. Beijing: Publishing House of Electronics Industry, 2005.
- [2] Polydoros A, Woo K T. LPI detection of frequency hopping signal using autocorrelation techniques [J]. *IEEE Journal on Selected Areas in Communications*, 1985, 3(5): 714-726.
- [3] 钱俭, 武传华. 跳频信号检测和参数估计技术研究 [J]. *空间电子技术*, 2007, 4(2): 14-18.
Qian Yi, Wu Chuanhua. *Space Electronic Technology*, 2007, 4(2): 14-18.
- [4] 赵睿. 直接序列扩频信号检测方法研究[D]. 大连: 大连理工大学, 2008.
Zhao Rui. Research on detection method of direct-sequence spread spectrum signals[D]. Dalian: Dalian University of Technology, 2008.
- [5] 刘献玲. 基于累量的 OFDM 信号调制识别 [D]. 西安: 西安电子科技大学, 2007.
Liu Xianling. Modulation identification based on cumulants for OFDM signal[D]. Xi'an: Xidian University, 2007.
- [6] 陶海平. 通信信号调制样式的识别研究[D]. 哈尔滨: 哈尔滨工程大学, 2005.
Tao Haiping. Research on communication signal modulations classification [D]. Harbin: Harbin Engineering University, 2005.
- [7] 周琳, 杨绍全. 时-频分析算法在通信信号调制识别中的应用[J]. *航天电子对抗*, 2002(5): 40-45.
Zhou Lin, Yang Shaoquan. *Aerospace Electronic Warfare*, 2002(5): 40-45.
- [8] Nandi A K, Azzouz E E. Modulation recognition using artificial neural networks[J]. *Signal Processing*, 1997, 56(2): 165-175.
- [9] 陈乃金, 周鸣争, 潘冬冬. 一种新的维纳滤波图像去高斯噪声算法[J]. *计算机系统应用*, 2010, 19(3): 111-114.
Chen Naijin, Zhou Mingzheng, Pan Dongdong. *Computer systems and Applications*, 2010, 19(3): 111-114.

(责任编辑 岳臣)