

基于深度学习的 MPSK 信号调制识别*

刘明骞^{1,2}, 郑诗斐^{1,2}, 李兵兵^{1,2}

(1. 西安电子科技大学 综合业务网理论与关键技术国家重点实验室, 陕西 西安 710071;

2. 西安电子科技大学 信息感知技术协同创新中心, 陕西 西安 710071)

摘要: 为了有效实现信号调制方式的智能识别, 提出基于深度学习的多进制相移键控 (Multiple Phase Shift Keying, MPSK) 信号调制识别方法。分析接收 MPSK 信号的循环谱, 并通过提取 MPSK 信号循环谱的等高图获得二维特征信息, 利用深度学习中的卷积神经网络对二维特征进行训练, 使用测试样本对所设计的调制识别方法的有效性进行验证。仿真结果表明, 所提方法具有良好的识别性能。

关键词: 调制识别; 循环谱; 深度学习; 卷积神经网络

中图分类号: PN911.7 **文献标志码:** A **文章编号:** 1001-2486(2019)05-153-06

Modulation recognition of MPSK signals based on deep learning

LIU Mingqian^{1,2}, ZHENG Shifei^{1,2}, LI Bingbing^{1,2}

(1. State Key Laboratory of Integrated Services Networks, Xidian University, Xi'an 710071, China;

2. Collaborative Innovation Center of Information Sensing and Understanding, Xidian University, Xi'an 710071, China)

Abstract: In order to realize the intelligent identification of signals modulation effectively, a novel modulation recognition method of MPSK (multiple phase shift keying) signals based on deep learning was proposed. The cycle spectrum of the MPSK signals were analyzed firstly, and the two-dimensional features information were obtained by extracting the contour map of the MPSK signals cyclic spectrum. Then, the two-dimensional features were trained by using the convolution neural network of deep learning. Finally, the effectiveness of the proposed modulation recognition method was verified by the test samples. The simulation results show that the proposed method has good recognition performance.

Keywords: modulation recognition; cyclic spectrum; deep learning; convolution neural network

信号的调制识别是通信侦察、认知无线电等领域的关键技术, 它在复杂环境和干扰噪声的情况下, 不需要其他的先验知识, 就能判断信号的调制方式, 并提取相应的调制参数, 为信号的进一步分析处理提供依据^[1]。按调制识别依据理论的不同, 可以分为依赖先验知识的判决论方法以及基于特征提取和分类器设计的统计模式识别方法。国内外众多学者在这方面做了大量的研究, 各种调制识别方法也不断涌现。其中, 一些学者利用循环谱对数字调制信号进行识别^[2]。但是, 在这些识别方法中, 针对多进制相移键控 (Multiple Phase Shift Keying, MPSK) 信号的识别效果不理想, 本文针对这一问题开展了进一步的研究。

近年来, 深度学习在模式识别等领域取得了突破性的进展, 也有部分学者将其应用于通信信

号的调制识别。文献[3]提出了一种利用信号循环谱特征和深度自动编码器进行通信信号自动识别的方法。文献[4]采用两个深度自动编码器和通信信号的循环谱特征和小波特征进行了调制识别, 当信噪比为 10 dB 时, 识别率可达到 95%。但是, 在低信噪比环境下, 识别性能欠佳。

本文从人工智能角度出发, 解决基于循环谱的高阶 MPSK ($M \geq 4$) 信号识别困难的问题, 提出基于深度学习的 MPSK 信号识别方法。

1 基于循环谱的特征参数

1.1 信号的循环谱

信号 $x(t)$ 是广义循环平稳过程, 自相关函数为

$$R_x(t; \tau) = E\{x(t)x^*(t - \tau)\} \quad (1)$$

* 收稿日期: 2018-05-08

基金项目: 国家自然科学基金资助项目(61501348, 61271299); 中央高校基本科研业务费专项资金资助项目(JB180106); 中国博士后科学基金资助项目(2017M611912); 江苏省博士后科研资助计划(1701059B); 陕西省自然科学基金基础研究计划资助项目(2016JQ6039); 高等学校学科创新引智计划资助项目(B08038)

作者简介: 刘明骞(1982—), 男, 河南平顶山人, 讲师, 博士, 硕士生导师, E-mail: mqliu@mail.xidian.edu.cn

式中, τ 为时间间隔。根据周期性可将 $R_x(t; \tau)$ 展开为 Fourier 级数的形式^[5]。

$$R_x(t; \tau) = \sum_{\alpha} R_x^{\alpha}(\tau) e^{j2\pi\alpha t} \quad (2)$$

式中, α 为循环周期频率, $R_x^{\alpha}(\tau)$ 为循环自相关函数。

$$R_x^{\alpha}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t)x^*(t - \tau) e^{-j2\pi\alpha t} dt \quad (3)$$

其中, T 为信号的持续时间。如果 $x(t)$ 是各态历经过程, 则

$$R_x^{\alpha}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x\left(t + \frac{\tau}{2}\right)x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\alpha t} dt \quad (4)$$

循环自相关函数的傅立叶变换被称为循环谱密度函数, 简称循环谱^[6], 其表达式为

$$S_x^{\alpha}(f) = \int_{-\infty}^{+\infty} R_x^{\alpha}(\tau) e^{-j2\pi f\tau} d\tau \quad (5)$$

式中, f 为信号频率。 $\alpha \neq 0$ 时, 平稳噪声的谱相关函数等于 0, 因此循环谱具有抗噪声性能。

二进制相移键控 (Binary Phase Shift Keying, BPSK) 信号可表示为

$$x(t) = \left[\sum_n a_n q(t - nT) \right] \cos(2\pi f_0 t) \quad (6)$$

式中, $q(t)$ 为脉宽是 T 的单个矩形脉冲, f_0 为载波频率, $a_n = \begin{cases} 1, & \text{概率为 } P \\ -1, & \text{概率为 } 1 - P \end{cases}$

则 BPSK 信号的循环谱为

$$S_x^{\alpha}(f) = \begin{cases} \frac{1}{4T} \left[Q\left(f - f_0 + \frac{\alpha}{2}\right) Q^*\left(f - f_0 - \frac{\alpha}{2}\right) + Q\left(f + f_0 + \frac{\alpha}{2}\right) Q^*\left(f + f_0 - \frac{\alpha}{2}\right) \right], & \alpha = \frac{n}{T} \\ \frac{1}{4T} \left[Q\left(f - f_0 + \frac{\alpha}{2}\right) Q^*\left(f + f_0 - \frac{\alpha}{2}\right) + Q\left(f + f_0 + \frac{\alpha}{2}\right) Q^*\left(f - f_0 - \frac{\alpha}{2}\right) \right], & \alpha = \pm 2f_0 + \frac{n}{T} \\ 0, & \text{其他} \end{cases} \quad (7)$$

其中, $Q(f)$ 为脉冲 $q(t)$ 的傅立叶变换, 且 $Q(f) = \frac{\sin(\pi f T)}{\pi f}$ 。

MPSK ($M \geq 4$) 信号可表示为

$$x(t) = \left[\sum_n a_n q(t - nT) \right] \cos(2\pi f_0 t + \varphi_k) \quad (8)$$

式中, φ_k 为被调相位, 有 M 种不同的取值。

则 MPSK ($M \geq 4$) 的循环谱为

$$S_x^{\alpha}(f) = \begin{cases} \frac{1}{4T} \left[Q\left(f - f_0 + \frac{\alpha}{2}\right) Q^*\left(f - f_0 - \frac{\alpha}{2}\right) + Q\left(f + f_0 + \frac{\alpha}{2}\right) Q^*\left(f + f_0 - \frac{\alpha}{2}\right) \right], & \alpha = \frac{n}{T} \\ 0, & \text{其他} \end{cases} \quad (9)$$

1.2 循环谱的等高图

目前, 国内外针对信号循环谱的估计算法进行了诸多研究, 其中, 应用较为广泛的有时域平滑算法中的快速傅立叶变换累加算法 (fast Fourier transform Accumulation Method, FAM)^[7] 和分段谱相关函数算法 (Strip Spectral Correlation Algorithm, SSCA) 以及频域平滑算法 (Frequency Smoothed Method, FSM)。为了减少计算量, 本文采用时域平滑算法估计 MPSK 信号的循环谱。

循环谱时域平滑算法估计表达式为

$$S_{xT}^{\alpha_0}(n, f_0)_{\Delta t} = \sum_r X_T\left(r, f_0 + \frac{\alpha_0}{2}\right) X_T^*\left(r, f_0 - \frac{\alpha_0}{2}\right) \cdot g(n - r) \quad (10)$$

式中, $X_T(r, f)$ 被称为复解调, 表示信号 $x(n)$ 加窗后的短时傅立叶变换, 其计算公式为

$$X_T(r, f) = \sum_{r=-N'/2}^{N'/2-1} a(n)x(r - n) e^{-j2\pi f(r-n)/T_s} \quad (11)$$

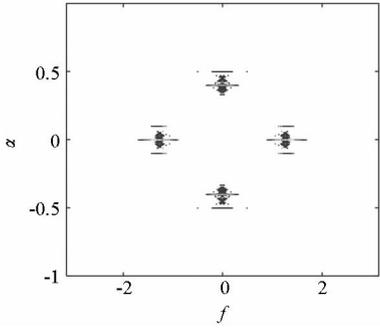
其中: $a(n)$ 为数据衰减窗; $g(n)$ 为平滑窗; Δt 为数据采集时间, $\Delta t = NT_s$, N 为样本数, T_s 为采样周期, N' 为傅立叶变换的长度, T 为复解调所需 N' 点离散傅立叶变换 (Discrete Fourier Transform, DFT) 数据时间。式 (10) 计算的是循环谱中点 (α_0, f_0) 处的幅度值。

选取常用的 MPSK 信号中 BPSK、正交相移键控 (Quadrature Phase Shift Keying, QPSK) 和八进制相移键控 (8 Phase Shift Keying, 8PSK) 为例, 图 1 给出 MPSK 信号的循环谱的等高图。从图 1 中可以直观地看出, 不同调制的 MPSK 信号, 它们的循环谱等高图是不相同的。因此, 将 MPSK 信号循环谱的等高图作为特征参数用于调制识别。

2 基于卷积神经网络的调制识别

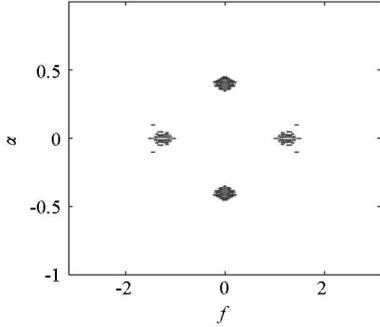
2.1 卷积神经网络

标准卷积神经网络 (Convolution Neural Network, CNN)^[8] 是一种特殊的前馈神经网络模型, 一般具有比较深的结构, 由输入层、卷积层、下采样层、全连接层、输出层组成。图 2 为标准卷积神经网络的整体结构。



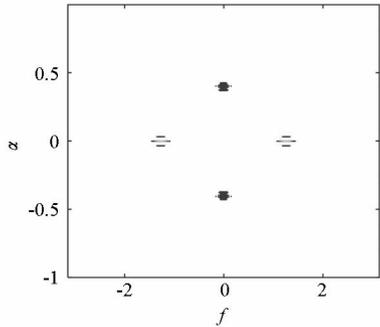
(a) BPSK 的循环谱等高图

(a) Cyclic spectrum contour maps of BPSK



(b) QPSK 的循环谱等高图

(b) Cyclic spectrum contour maps of QPSK



(c) 8PSK 的循环谱等高图

(c) Cyclic spectrum contour maps of 8PSK

图 1 MPSK 的循环谱等高图

Fig. 1 Cyclic spectrum contour maps of MPSK

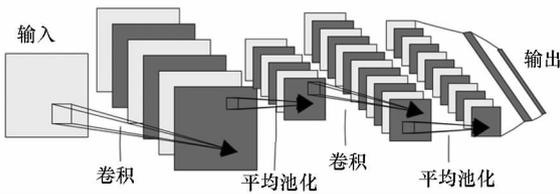


图 2 卷积神经网络结构模型

Fig. 2 Structure of convolution neural network

卷积阶段,设输入信号 x 是一个三维数组,这个数组由 n_1 个 $n_2 \times n_3$ 的二维特征图组成,每个特征图记为 x_i 。在卷积阶段对输入信号提取不同的特征,从而实现信号的观测。其观测模式被称为卷积核,对输入的二维特征图上的特定特征

进行检测,实现权值共享。同时为了获得特征图中的不同特征,可以采用不同的卷积核进行运算。假定有 N 个训练样本 $(\mathbf{x}^l, \mathbf{y}^l)$ ($1 \leq l \leq N$),输入是 $\mathbf{x}^l = (x_1^l, x_2^l, \dots, x_m^l)^T$,期望输出是 $\mathbf{y}^l = (y_1^l, y_2^l, \dots, y_c^l)^T$,实际输出是 $\mathbf{o}^l = (o_1^l, o_2^l, \dots, o_c^l)^T$,卷积层的计算如式(12)所示^[9]。

$$\mathbf{h}_{k,j}^l = f(\mathbf{u}_{k,j}^l) = f\left(\sum_i \mathbf{h}_{k-1,i}^l * \mathbf{w}_{i,j}^k + \mathbf{b}_j^k\right) \quad (12)$$

式中, $\mathbf{h}_{k,j}^l$ 表示第 k 层第 j 个输出面的输出矩阵, $\mathbf{u}_{k,j}^l$ 表示第 k 层第 j 个输出面的输入矩阵, $\mathbf{w}_{i,j}^k$ 表示第 k 层的第 i 个输入面到第 j 个输入面的权值矩阵, \mathbf{b}_j^k 表示第 k 层的第 j 个输出面的偏置矩阵, “*” 为二维离散卷积运算符。

下采样阶段,运用平均池化方法^[9]对每个特征图进行操作。下采样层的形式如式(13)所示。

$$\mathbf{h}_{k+1,j}^l = g[\beta_j^{k+1} \text{down}(\mathbf{h}_{k,j}^l) + \mathbf{b}_j^{k+1}] \quad (13)$$

式中, $\text{down}(\cdot)$ 表示下采样函数,权值 β_j 一般取值为 1,偏置 \mathbf{b}_j 一般取值为零矩阵, $f(\cdot)$ 一般取为恒等线性函数 $f(x) = x$ 。

在对网络进行训练时,通常使用反向传播法则和有监督训练方式^[9]。神经网络中输入特征通过前向传播得到输出特征,假设输入为 X ,经过多层网络传播后得到输出特征图 O 。然后将得到的输出特征图 O 与给输入图像所加的标签 G 进行对比,根据一定的运算公式得到误差 E 。根据反向传播路径,将误差 E 层层传播,并通过权值更新公式对卷积层的权值 $\mathbf{w}_{i,j}$ 进行调整。随着迭代次数的不断增加,网络误差逐渐降低,并最终收敛到稳定的权值集合。在训练过程中,网络中权值的初始化通常随机,而偏置的初始化往往全置为零。

反向传播过程中优化的目标函数为

$$L_N = \frac{1}{2} \sum_{l=1}^N \sum_{j=1}^c (o_j^l - y_j^l)^2 \quad (14)$$

当 L 层是网络的最后一层时,输出层误差为

$$\delta_L^l = (\mathbf{o}^l - \mathbf{y}^l) \cdot \sigma'(\mathbf{u}_L^l) \quad (15)$$

式中: $\sigma(x)$ 是一个向量值函数,在非线性情况下通常取为逐元 sigmoid 函数,或者逐元 tanh 函数, $\sigma'(x)$ 为其导数; “ \cdot ” 代表两个向量的哈达马积。

当 L 层为卷积层时,

$$\delta_{k,j}^l = \beta_j^{k+1} [f'(\mathbf{u}_{k,j}^l) \circ \text{up}(\delta_{k+1}^l)] \quad (16)$$

通过求和来计算偏差的梯度。

$$\frac{\partial L_N}{\partial \mathbf{b}_j^k} = \sum_{l=1}^N \delta_{k,j}^l \quad (17)$$

计算对权值的偏导数。

$$\frac{\partial L_N}{\partial \mathbf{w}_{ij}^k} = \sum_{l=1}^N \delta_{k,j}^l * \mathbf{h}_{k-1,i}^l \quad (18)$$

当 L 为下采样层时,

$$\delta_{k,j}^l = g'(\mathbf{u}_{k+1,j}^l) \circ [\delta_{k+1,j}^l * \text{rot}180(\mathbf{w}_j^{k+1})] \quad (19)$$

式中, $\text{rot}180(\cdot)$ 表示把一个矩阵水平翻转一次再垂直翻转一次。

误差计算出来后,便可以用式(20)~(21)更新所有的网络参数。

$$\mathbf{w}^k \leftarrow \mathbf{w}^k - \eta \frac{\partial L_N}{\partial \mathbf{w}^k} \quad (20)$$

$$\mathbf{b}^k \leftarrow \mathbf{b}^k - \eta \frac{\partial L_N}{\partial \mathbf{b}^k} \quad (21)$$

2.2 调制识别方法的步骤

综上所述,所提基于深度学习的 MPSK 信号调制识别方法的具体步骤如下。

步骤 1: 利用时域平滑算法估计接收到的 MPSK 信号的循环谱,并提取信号循环谱的等高图转换为二维图像信息。

步骤 2: 对二维图像进行预处理,同时为了减少运算量,提取大小为 81×81 的像素块,并按照分类器所需的格式进行处理。

步骤 3: 确定卷积神经网络分类器的网络参数,并利用数据样本进行训练。

步骤 4: 在完成卷积神经网络的训练后,输入测试样本进行 MPSK 信号的调制方式识别。

3 仿真结果及分析

为了验证所提方法的有效行,基于 MATLAB 软件平台进行仿真实验。仿真实验的参数设置为:待识别的信号为 BPSK、QPSK、8PSK,载波频率为 4 kHz,码元速率为 2 kBd,采样频率为 20 kHz,各个信噪比下产生的每种信号的训练样本和测试样本分别为 5000 个和 1000 个,卷积神经网络的参数见表 1。

在信噪比范围为 0 ~ 10 dB 的条件下,对 BPSK、QPSK、8PSK 信号进行调制识别。其中,训练样本的信噪比分别为 0 dB、5 dB、10 dB,从而得到 0 dB、5 dB、10 dB 的测试样本的正确识别率见表 2。从表 2 可以看出,在不同的信噪比下,该方法具有较好的识别结果,当测试样本信噪比为 0 dB、5 dB、10 dB 时,单个信号的正确识别率可达 85% 以上,信号的平均识别率高于 90%。由此可见,所提基于深度学习的 MPSK 信号识别方法在不同的信噪比下具有良好的识别性能。

表 1 卷积神经网络中的参数设置

Tab. 1 Parameter settings of convolution neural network

名称	释义	缺省值
outputmaps	输出映射面的个数	6 或 12
kernelsize	卷积核的边的长度	6 或 7
scale	滑动窗口的边的长度	2
opts. alpha	学习率	0.1
opts. batchsize	迷你块包含的样本数	50
opts. numepochs	迭代次数	50

表 2 单信噪比信号训练样本的识别结果

Tab. 2 Recognition results of training samples with

调制方式	测试样本的 SNR		
	single SNR signals	%	
	0 dB	5 dB	10 dB
BPSK	98.5	99	100
QPSK	86.5	100	100
8PSK	85.5	94.5	99
平均识别率	90.17	97.83	99.67

为了提高训练样本集的完备性,将 0 dB、5 dB、10 dB 三种不同信噪比的信号同时进行训练,即构建这三种混合信噪比下 MPSK ($M = 2, 4, 8$) 信号的训练样本集合。对信噪比为 0 dB、5 dB 和 10 dB 三种情况下单个信号的测试样本分别进行识别,其识别结果见表 3。从表 3 可以看出,该方法在低信噪比下能够对 MPSK ($M = 2, 4, 8$) 信号进行有效的识别。另外,在混合信噪比信号训练样本下信号的正确识别率高于单信噪比信号训练样本下的正确识别率。从而可以看出,训练样本数量的增多能够有效地提高信号的识别性能。

表 3 混合信噪比信号训练样本的识别结果

Tab. 3 Recognition results of training samples with

调制方式	测试样本的信噪比		
	mixed SNR signals	%	
	0 dB	5 dB	10 dB
BPSK	99	99.5	100
QPSK	85.5	98.5	100
8PSK	90.5	100	100
平均识别率	91.66	99.33	100

在相同的仿真实验环境和相同的码元速率、载波频率、采样频率、采样点数等信号参数的设置

下,信噪比分别在 0 dB、5 dB 和 10 dB 情况下,本文方法与文献[10]基于高阶累积量的方法和文献[11]基于循环谱的方法进行对比实验,对比结果见表4。从表4可以看出,在信噪比为 0 dB 和 5 dB 时,本文方法的平均识别率较文献[10]方法有了明显的提高;在信噪比为 5 dB 和 10 dB 时,本文方法的平均识别率比文献[11]方法高。并且在信噪比为 0 dB、5 dB 和 10 dB 的情况下,对于 BPSK 信号,本文方法的识别率优于文献[11]方法。本文方法的计算复杂度为 $O(N^2 \log_2 N)$,文献[10]方法的计算复杂度为 $O(N)$,文献[11]方法的计算复杂度为 $O(N^3 \log_2 N)$ 。由此可以看出,本文方法的计算复杂度高于文献[10]方法,但在低信噪比条件下,本文方法的平均识别效果优于文献[10]方法;本文方法的计算复杂度低于文献[11]方法,并且本文方法能够解决文献[11]方法不能识别 8PSK 信号的问题。

该实验使用了带有两个 Intel 酷睿 i3 3110M

CPU 的 PC,并且神经网络的运行效率良好。每个信噪比下每种信号的训练样本数为 5000 个,离线训练时间为 20 539.87 s;每个信噪比下产生的每种信号的测试样本数为 1000 个,在线测试时间为 165.247 591 s。相比而言,文献[10]方法中每种信号的测试样本数为 1000 个,每个信噪比下每种信号识别时间为 0.764 339 6 s;文献[11]方法中每种信号的测试样本数为 1000 个,每个信噪比下每种信号识别时间为 170.611 929 s。可见,所提方法的在线时间复杂度低于文献[11]方法,而高于文献[10]方法。

4 结论

本文提出了一种基于深度学习的 MPSK 信号调制识别方法。仿真结果表明,在不同的信噪比下所提方法具有良好的识别性能,并且针对高阶 MPSK 信号,所提方法比现有的基于循环谱的识别方法的识别性能更优。

表4 三种不同方法的识别率对比

Tab.4 Comparison of the recognition rates of three different methods

调制方式	本文方法			文献[10]方法			文献[11]方法		
	0 dB	5 dB	10 dB	0 dB	5 dB	10 dB	0 dB	5 dB	10 dB
BPSK	98.5	99	100	89	96	100	97.35	98.2	99.65
QPSK	86.5	100	100	76	85	100	91.9	97.35	98.3
8PSK	85.5	94.5	99	81	89	100			
平均识别率	90.17	97.83	99.67	82	90	100	94.63	97.77	98.97

参考文献 (References)

[1] 刘明骞,李兵兵,曹超凤,等. 认知无线电中非高斯噪声下数字调制信号识别方法[J]. 通信学报, 2014, 35(1): 82-88.
LIU Mingqian, LI Bingbing, CAO Chaofeng, et al. Recognition method of digital modulation signals over non-Gaussian noise in cognitive radio [J]. Journal on Communications, 2014, 35(1): 82-88. (in Chinese)

[2] Spooner C M, Mody A N, Chuang J, et al. Modulation recognition using second and higher-order cyclostationarity [C]//Proceedings of IEEE International Symposium on Dynamic Spectrum Access Networks, 2017.

[3] Li J C, Qi L, Lin Y. Research on modulation identification of digital signals based on deep learning [C]//Proceedings of IEEE International Conference on Electronic Information and Communication Technology, 2016.

[4] Ya T, Lin Y, Wang H. Modulation recognition of digital signal based on deep auto-encoder network [C]//Proceedings of IEEE International Conference on Software Quality,

Reliability and Security, 2017.

[5] Napolitano A. Cyclic statistic estimators with uncertain cycle frequencies [J]. IEEE Transactions on Information Theory, 2017, 63(1): 649-675.

[6] Cohen D, Eldar Y C. Sub-Nyquist cyclostationary detection for cognitive radio [J]. IEEE Transactions on Signal Processing, 2017, 65(11): 3004-3019.

[7] 何继爱,裴承全,郑玉峰. 稳定分布下基于FAM的低阶循环谱算法研究[J]. 电子学报, 2013, 41(7): 1297-1304.
HE Jiai, PEI Chengquan, ZHENG Yufeng. The realization of low order FAM method under α stable distribution [J]. Acta Electronica Sinica, 2013, 41(7): 1297-1304. (in Chinese)

[8] Kong S H, Kim M, Hoang L M, et al. Automatic LPI radar waveform recognition using CNN [J]. IEEE Access, 2018, 6: 4207-4219.

[9] Wang Q C, Zheng Y J, Yang G P, et al. Multi-scale rotation-invariant convolutional neural networks for lung texture classification [J]. IEEE Journal of Biomedical and Health Informatics, 2018, 22(1): 184-195.

- [10] 陆风波, 黄知涛, 易辉荣, 等. 一种基于高阶累积量的数字调相信号识别方法[J]. 系统工程与电子技术, 2008, 30(9): 1611 - 1615.
LU Fengbo, HUANG Zhitao, YI Huirong, et al. Recognition algorithm of phase shift keying signals by higher-order cumulants[J]. Systems Engineering and Electronics, 2008, 30(9): 1611 - 1615. (in Chinese)
- [11] 魏阳杰. 基于循环谱的调制样式识别与参数估计[D]. 成都: 电子科技大学, 2015.
WEI Yangjie. Modulation recognition and parameter estimation based on cyclic spectral density[D]. Chengdu: University of Electronic Science and Technology of China, 2015. (in Chinese)
-
- (上接第 152 页)
- [8] Comon P, Jutten C, Hérault J. Blind separation of sources, part II: problems statement[J]. Signal Processing, 1991, 24(1): 11 - 20.
- [9] 朱万华, 底青云, 刘雷松. 基于磁通负反馈结构的高灵敏度感应式磁场传感器研制[J]. 地球物理学报, 2013, 56(11): 3683 - 3689.
ZHU Wanhua, DI Qingyun, LIU Leisong. Development of search coil magnetometer based on magnetic flux negative feedback structure[J]. Chinese Journal of Geophysics, 2013, 56(11): 3683 - 3689. (in Chinese)
- [10] Griffiths L, Jim C. An alternative approach to linearly constrained adaptive beamforming[J]. IEEE Transactions on Antennas and Propagation, 1982, 30(1): 27 - 34.
- [11] 方民权, 周海芳, 张卫民, 等. GPU 上高光谱快速 ICA 降维并行算法[J]. 国防科技大学学报, 2015, 37(4): 65 - 70.
FANG Minquan, ZHOU Haifang, ZHANG Weimin, et al. A parallel algorithm of FastICA dimensionality reduction for hyperspectral image on GPU [J]. Journal of National University of Defense Technology, 2015, 37(4): 65 - 70. (in Chinese)
- [12] Benesty J, Paleologu C, Ciochina S. Regularization of RLS algorithm [J]. IEICE Transactions on Fundamentals of Electronics Communications and Computer Sciences, 2011, E94 - A(8): 1628 - 1629.