

doi:10.3969/j.issn.1001-893x.2014.07.006

引用格式:王鑫,王峰,孙军,等.联合循环平稳特征 PCA 与 RVM 的频谱感知[J].电讯技术,2014,54(7):893-898. [WANG Xin,WANG Feng,SUN Jun,et al.Spectrum Sensing by Combining Cyclostationary PCA with RVM[J].Telecommunication Engineering,2014,54(7):893-898.]

联合循环平稳特征 PCA 与 RVM 的频谱感知*

王鑫^{1,**},王峰²,孙军²,杜恺²,陈景川²

(1. 沈阳建筑大学 信息与控制工程学院,沈阳 110168;2. 解放军 93115 部队,沈阳 110031)

摘要:针对无线信道环境中低信噪比情况下主用户信号检测率较低的问题,提出了一种基于循环平稳特征主成分分析(PCA)与相关向量机(RVM)的认知网络频谱感知算法。该算法结合了主成分分析算法与相关向量机分类方法,应用于解决认知网络频谱感知问题。首先对信号循环平稳特征参数进行特征提取,通过主成分分析进行降维提取信号主成分,生成训练样本和待测样本,并完成对相关向量机的训练,再采用训练完成的相关向量机算法分别对有无主用户情况下的信号进行分类检测,最后获得主用户信号存在性的感知判断。仿真实验表明,与人工神经网络、支持向量机和最大最小特征值算法相比较,所提算法在低信噪比情况下具有较高的分类检测性能,检测率最大可提高 61.6%,有效地实现了对主用户信号的感知。

关键词:认知网络;频谱感知;主成分分析;相关向量机

中图分类号:TN92;TN911 **文献标志码:**A **文章编号:**1001-893X(2014)07-0893-06

Spectrum Sensing by Combining Cyclostationary PCA with RVM

WANG Xin¹,WANG Feng²,SUN Jun²,DU Kai²,CHEN Jing-chuan²

(1. School of Information & Control Engineering,Shenyang Jianzhu University,Shenyang 110168,China;
2. Unit 93115 of PLA,Shenyang 110031,China)

Abstract:For the low accuracy rate of the primary user detection in the wireless channel environment,this paper proposes a method based on cyclostationary principal component analysis(PCA) and relevant vector machine(RVM) for spectrum sensing under the low signal to noise ratio(SNR) environment in cognitive radio. This method combines PCA with the RVM classification algorithm to solve spectrum sensing problem in cognitive network. A set of cyclic spectrum features are first calculated,and the PCA is applied to extract the most discriminate feature vector as training samples and testing samples for classification. The RVM is trained by training samples. Finally,the trained RVM is utilized to detect and decide the existence of the primary user. It is observed that the maximum increase of the detection probability of the proposed algorithm can be increased about 61.6% in comparison with artificial neural network(ANN),support vector machine(SVM) and maximum-minimum eigenvalue(MME). Simulation results show the proposed algorithm can effectively detect primary user signals.

Key words:cognitive network;spectrum sensing;principal component analysis;relevant vector machine

* 收稿日期:2014-01-28;修回日期:2014-04-29 Received date:2014-01-28;Revised date:2014-04-29
基金项目:国家自然科学基金青年基金项目(61305125);河北省自然科学基金资助项目(F2014501082);沈阳建筑大学青年基金项目(2013160)
Foundation Item: The National Natural Science Foundation of China (No. 61305125); The Natural Science Fund of Hebei Province (F2014501082);The Foundation of Shenyang Jianzhu University(No. 2013160)
** 通讯作者:wangxin7988@163.com Corresponding author:wangxin7988@163.com

1 引言

频谱感知作为认知网络 (Cognitive Network, CN) 技术的基础与核心,能够快速、有效、准确地对主用户进行感知检测的,成为人们在探索如何高效利用频谱资源、减少频谱浪费问题时的研究热点^[1-4]。目前,常见的频谱感知算法包括能量检测、循环平稳特征检测和匹配滤波器检测等算法^[5]。能量检测算法具有无需主用户信号的先验信息、实现灵活、可适用于不同中心频率和带宽的感知等优点,但该算法在低信噪比情况下感知性能并不理想。匹配滤波检测法具有较好的匹配滤波特性,但需要获取主用户信号的先验信息,否则不能对主用户进行有效感知。循环平稳特征检测法具有较强的抗噪声性能,但该算法运算量大,感知时间长^[6-7]。

在此基础上,人们针对低信噪比条件下主用户信号频谱感知问题展开进一步研究。文献[8]和文献[9]利用接收信号矩阵的特征值提出了最大-最小特征值法 (Maximum - minimum Eigen - value, MME),用以研究不同信噪比情况下主用户信号检测问题;文献[10]采用机器学习方法来解决一定信噪比环境下频谱感知问题;文献[11]将支持向量机 (Support Vector Machine, SVM) 算法应用于认知网络环境中,提出了采用 SVM 对高斯白噪声环境下的主用户信号进行分类感知的方法。上述算法针对主用户信号的频谱感知取得了一定的研究成果,但对低信噪比环境下频谱感知效果并不显著。

鉴于上述原因,本文提出一种基于循环平稳特征主成分分析 (Principal Component Analysis, PCA) 与相关向量机 (Relevant Vector Machine, RVM) 的认知网络频谱感知算法。本文算法将主成分分析算法的降维思想与相关向量机分类方法相结合,并应用于认知网络频谱感知中。目前国内外已开展了对机器学习的思想方法应用于频谱感知中的研究,但关于主成分分析与相关向量机相结合的频谱感知研究尚未发现。仿真结果表明,在各信噪比环境下,本文算法与 MME、人工神经网络 (Artificial Neural Network, ANN) 和 SVM 算法相比较,具有较高的感知精度和良好的稳健性。

2 系统模型

针对认知网络环境中主用户信号的频谱感知特点,设存在 W 个主用户和 G 个次用户,且各主用户

信号互不干扰。各路径具有不同时延,并分别进入后续感知系统。对任何一个次用户,系统模型可归纳为二元模型:

$$\begin{cases} H_0: y(t) = n(t) \\ H_1: y(t) = \sum_{w=1}^W s_w(t) + n(t) \end{cases} \quad (1)$$

其中, H_0 为无主用户出现情况, H_1 为主用户出现情况, $0 \leq t \leq T$, T 为接收信号的采样时间, $s_w(t)$ 为均值为零的循环平稳信号 (主用户信号) ($w = 1, 2, \dots, W$), $n(t)$ 为均值为零、方差为 σ_n^2 的加性高斯白噪声。如图 1 所示,对任意主用户信号,该系统模型具有普适性。




图 1 系统模型
Fig. 1 The system model

3 基于联合循环平稳特征 PCA 和 RVM 的频谱感知算法

基于循环平稳特征 PCA 和 RVM 的认知网络频谱感知方法基本思想是:在低信噪比环境下,结合主成分分析和相关向量机算法思想,通过对信号循环谱参数进行 PCA 降维提取信号主成分,并生成训练样本和待测样本,之后利用生成的训练样本完成对 RVM 的训练,最后利用训练完成的 RVM 分别对有无主用户情况下的信号进行分类检测。

3.1 接收信号循环谱特征提取

若均值为 0 的循环平稳随机信号 $y(t)$, 其循环自相关函数为

$$R^{\alpha}(\tau) = \frac{1}{T_0} \int_0^{T_0} R(t, \tau) \exp(-2\pi\alpha t j) dt \quad (2)$$

其中, α 为循环频率, T_0 为循环周期, $R(t, \tau)$ 为 $y(t)$ 的自相关函数。

其循环谱为

$$S^{\alpha}(f)=\int_{-\infty}^{\infty} R^{\alpha}(\tau) \exp (-2 \pi \alpha t j) d t \quad (3)$$

实际中,由于信号长度有限,式(3)可变为

$$\tilde{S}^{\alpha}(f)=\frac{1}{N T} \sum_{n=1}^N Y\left(t_n, f+\alpha / 2\right) Y^{*}\left(t_n, f-\alpha / 2\right) \quad (4)$$

式中,将次用户接收信号 $y(t)$ 分成 N 段,每段采 T 点, $Y\left(t_n, f\right)$ 为信号 $y(t)$ 每段的 DFT,“ $*$ ”表示共轭。

由于若提取各 $\alpha \neq 0$ 时的 $\tilde{S}^{\alpha}(f)$ 值维数过高,无法应用相关向量机进行分类检测,因此,可以利用 PCA 算法对各 $\alpha \neq 0$ 时的 $\tilde{S}^{\alpha}(f)$ 值进行降维处理。

3.2 PCA 算法

主成分分析^[12]是在统计学中分析数据的一种有效的方法,其主要目标是在大输入空间中寻找一定的特征向量,并在所有的特征中提取其主要特征,即降维。在认知网络系统模型下,利用 PCA 进行数据降维与特征提取的步骤如下:

设 $h_{l 1}, h_{l 2}, \cdots, h_{l M}$ 表示 M 个 $\alpha \neq 0$ 时的 $\tilde{S}^{\alpha}(f)$ 值,并构成原始样本参数矩阵 $H=\left(h_{l m}\right)_{M \times L}, l=1,2, \cdots, L, m=1,2, \cdots, M$,其中, l 为样本数, m 为维数。

步骤 1:原始样本参数标准化

设 $x_{l m}$ 表示原始样本参数标准化结果,则有

$$x_{l m}=\frac{h_{l m}-\overline{h_m}}{S_m} \quad (5)$$

式中, $\overline{h_m}=\frac{1}{L} \sum_{l=1}^L h_{l m}, S_m=\sqrt{\frac{\sum_{l=1}^L\left(h_{l m}-\overline{h_m}\right)^2}{L-1}}$ 分别表示原始样本参数的均值和标准差,则构成标准化样本参数集为

$$X=\left[X_1, X_2, \cdots X_L\right], X_l=\left[x_{l 1}, x_{l 2}, \cdots, x_{l M}\right]^T \in R^M, \\ l=1,2, \cdots, L$$

步骤 2:计算标准化样本参数集 X 的协方差矩阵

$$C=E\left[X X^T\right] \quad (6)$$

矩阵 $X X^T$ 可表示为

$$X X^T=\left[\begin{array}{cccc} x_{11} & x_{21} & \cdots & x_{L 1} \\ x_{12} & x_{22} & \cdots & x_{L 2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1 M} & x_{2 M} & \cdots & x_{L M} \end{array}\right]\left[\begin{array}{cccc} x_{11} & x_{12} & \cdots & x_{1 M} \\ x_{21} & x_{22} & \cdots & x_{2 M} \\ \vdots & \vdots & \ddots & \vdots \\ x_{L 1} & x_{L 2} & \cdots & x_{L M} \end{array}\right]= \\ \left[\begin{array}{cccc} c_{11} & c_{12} & \cdots & c_{1 M} \\ c_{21} & c_{22} & \cdots & c_{2 M} \\ \vdots & \vdots & \ddots & \vdots \\ c_{M 1} & c_{M 2} & \cdots & c_{M M} \end{array}\right] \quad (7)$$

式中

$$c_{11}=x_{11}^2+x_{21}^2+\cdots+x_{L 1}^2 \\ c_{12}=x_{11}^2 x_{21}+x_{21}^2 x_{12}+\cdots+x_{L M}^2 \\ \vdots \\ c_{M M}=x_{1 M}^2+x_{2 M}^2+\cdots+x_{L M}^2$$

步骤 3:计算协方差矩阵 C 的特征值 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_M$ 及其对应的特征向量 $U_1, U_2, \cdots, U_M$ 。

$$C U_l=\lambda_m U_l, \quad m=1,2, \cdots, M \quad (8)$$

步骤 4:计算方差贡献率,选取主成分

$$\varphi(K)=\frac{\sum_{k=1}^K \lambda_k}{\sum_{m=1}^M \lambda_m}>threshold \quad (9)$$

式中, $\varphi(K)$ 表示方差贡献率, $threshold \geq 0.85, k=1, 2, \cdots, K, K < M$,由公式(9)可得 K 的值:

设 $y_{l k}$ 是降维后特征向量 Y_l 的第 k 个主成分,由公式(10)可获得各 $y_{l k}$ 值:

$$Y_l=X_l^T U=\left[y_{l 1}, y_{l 2}, \cdots, y_{l K}\right] \quad (10)$$

式中, $U=\left[U_1, U_2, \cdots, U_K\right]$ 。

3.3 相关向量机

相关向量机(RVM)是 Michael E. Tipping 所提出与 SVM 相似的稀疏概率模型^[13],它是在贝叶斯框架下进行训练,并用于回归估计预测,从而获得预测值的分布。对同一个训练样本集而言,核函数的函数形式不像在 SVM 中受到限制,RVM 所需的支持向量数目比 SVM 少得多。

设 RVM 的模型输出为

$$y(x)=\sum_{j=1}^M \omega_j \varphi_j(x)+\omega_0 \quad (11)$$

式中, $\{\varphi_j\}$ 表示非线性基函数, $\{\omega_j\}$ 表示模型权值。

这里我们选用以每个训练样本为中心的高斯函数作为基函数,在贝叶斯框架下采用最大似然法对权值 $\{\omega_j\}$ 进行训练。

定义每个权值的先验概率分布为

$$p\left(\omega_j \mid a_j\right)=\left(\frac{a_j}{2 \pi}\right)^{\frac{1}{2}} \exp \left(-\frac{a_j \omega_j^2}{2}\right) \quad (12)$$

式中, a_j 表示决定权值 ω_j 先验分布的超参数。

对于训练样本集 $\left\{x_i, t_i\right\}_{i=1}^N$,假设目标值 t_i 是独立的,则相应训练样本集的似然函数为

$$p\left(t \mid \omega, \sigma^2\right)=\left(2 \pi \sigma^2\right)^{-N / 2} \exp \left(-\frac{1}{2 \sigma^2}\left\|t-\phi \omega\right\|^2\right) \quad (13)$$

式中, $t=\left(t_1, t_2, \cdots, t_N\right)^T ; \omega=\left(\omega_1, \omega_2, \cdots, \omega_N\right)^T ; \phi$ 表示矩阵,其行包含所有基函数对输入 x_i 的相应 $\phi_i=$

$[1, \phi_1(x_i), \dots, \phi_N(x_i)]$ 。

根据先验概率分布和似然分布,采用贝叶斯公式计算权值的后验概率分布,即

$$p(\omega | t, a, \sigma^2) = \frac{p(t | \omega, \sigma^2) p(\omega | a)}{p(t | a, \sigma^2)} \quad (14)$$

该权值的后验分布属于多变量高斯分布,即

$$p(\omega | t, a, \sigma^2) = N(\mu, \Sigma) \quad (15)$$

式中, $\Sigma = (\sigma^{-2} \phi^T \phi + A)^{-1}$ 表示协方差, A 为 $(a_0, a_1, \dots, a_N)$ 的对角阵, $\mu = \sigma^{-2} \Sigma \phi^T t$ 表示均值。

训练目标值的似然分布通过对权值变量进行积分,即

$$p(\omega | t, a, \sigma^2) = \int p(t | \omega, \sigma^2) p(\omega | a) d\omega \quad (16)$$

从而求得超参数的边缘似然分布表示式

$$p(t | a, \sigma^2) = N(0, C) \quad (17)$$

式中,协方差 $C = \sigma^2 I + \phi A^{-1} \phi^T$ 。

在 RVM 方法中模型权值的估计值可由后验分布的均值给出,同时它又是权值的最大后验 (MAP) 估计。权值的 MAP 估计取决于超参数 a 和噪声方差 σ^2 ,其估计值 $\hat{a}$ 和 $\hat{\sigma}^2$ 可以通过最大化边缘似然分布获得。后验分布反映出权值最优值的不确定性,表示模型预测的不确定性。若给定输入值为 x^* ,相应输出的概率分布为

$$p(t^* | x^*, \hat{a}, \hat{\sigma}^2) = \int p(t^* | x^*, \omega, \hat{\sigma}^2) \cdot p(\omega | t, \hat{a}, \hat{\sigma}^2) d\omega \quad (18)$$

服从高斯分布,即

$$p(t^* | x^*, \hat{a}, \hat{\sigma}^2) = N(y^*, \sigma^{*2}) \quad (19)$$

其中预测均值及方差 (不确定性) 分别为

$$y^* = \mu^T \phi(x^*)$$

$$\sigma^{*2} = \hat{\sigma}^2 + \phi^T(x^*) \Sigma \phi(x^*) \quad (20)$$

RVM 解决了模型的参数选取问题,具有较好的适用性。

3.4 算法步骤

基于循环平稳特征 PCA 与 RVM 的主用户信号频谱感知算法实现步骤如下:

步骤 1: 针对接收信号,提取其循环谱特征参数,构成原始样本集;

步骤 2: 利用 PCA 进行数据降维,之后采集 Q_1 个主用户存在时的特征向量作为训练的正样本,其中,任意一个特征向量为 $Y_l^1 = [y_{l1}^1, y_{l2}^1, \dots, y_{lK}^1]^T$; 采集 Q_0 个主用户不存在时的特征向量作为训练的负样本,其中,任意一个特征向量为 $Y_l^0 = [y_{l1}^0, y_{l2}^0, \dots, y_{lK}^0]^T$;

步骤 3: 将采集到的 Q_1 个正样本和 Q_0 个负样本构成训练集 G ,并利用训练集 G 中的样本对 RVM 进行训练;

步骤 4: 重复步骤 1、步骤 2,所得正负样本作为待测样本,利用训练完成的 RVM 对测试样本进行分类,由分类结果判断主用户信号的存在性,进而达到主用户信号感知的目的。

4 仿真与分析

为了验证本文算法在认知网络中低信噪比条件下的主用户信号感知效果,分别以 AM 和 OFDM 信号作为主用户信号,使用 Matlab7.0 进行仿真实验。设 AM 信号的仿真参数设定:载波频率 $f_c = 4$ kHz,采样点数 $N = 1\ 024$,采样频率 $f_s = 500$ Hz,样本信号的频率为 51 ~ 100 Hz;OFDM 信号的仿真参数设定:含 64 个子载波,采样率 $f_s = f_b \times 64 = 4\ 096$ Hz,符号率 $f_b = 256$ Hz,载频 $f_c = f_b \times 16 = 1\ 024$ Hz,频率间隔为 256 Hz。两种信号均采用单级 RVM 分类器结构,采用 RBF 核函数,其宽度值为 2;信道噪声为均值为 0、方差为 σ_n^2 的加性高斯白噪声。两种信号时间延迟为 150 ns。

在真实环境中,由于受到实际信号环境和实验设备等综合因素的影响,检测效果与仿真实验结果将产生一定误差,在后续研究中,将结合仿真实验,在真实环境中完成对主用户信号的频谱感知性能的检测。

实验一、实验二仿真统计次数均为 10^4 数量级。

4.1 实验一:两种信号检测率比较

根据以上参数,在 H_1 情况下,平均单次实验训练样本数为 4 000,测试样本数为 400,利用本文算法分别对 OFDM 和 AM 两种信号进行样本参数计算,并将生成的样本代入训练完成的 RVM 进行分类,依据 3.3 节和 3.4 节算法原理及步骤,完成对主用户信号存在性的检测,与 ANN、SVM 和 MME 算法比较结果如图 2 和图 3 所示。

图 2 表明:在 OFDM 信号下,SNR 为 -15 dB 时,本文算法检测率为 0.751,ANN 算法检测率为 0.491,SVM 算法检测率为 0.510,MME 算法检测率为 0.135,本文算法检测率与 ANN、SVM 和 MME 算法检测率相比分别提高了 26%、24.1% 和 61.6%;在 SNR 为 -5 dB 时,本文算法检测率为 0.987,ANN 算法检测率为 0.832,SVM 算法检测率为 0.841,

MME 算法检测率为0.912;本文算法检测率与 ANN、SVM 和 MME 算法检测率相比分别提高了 15.5%、14.6%和7.5%。图 3 表明:随着信噪比的增大,各算法的检测性能均有所增加,但本算法检测率仍显著高于其他 3 种算法,这是因为本文算法基于循环平稳 PCA 特征参数提取。与 RVM 的感知算法相比,其优势在于将循环平稳特征 PCA 参数提取与 RVM 分类相结合,很大程度上减少了训练样本特征参数及样本数量,获取更精确的样本参数,有效克服了 ANN 由于局部优化不能获得最优解、SVM 算法由于样本数过大而产生过拟合现象及能量检测算法在低信噪比情况下检测性能低下等弊端。




图2 OFDM 信号下本文算法与 ANN、SVM 和 MME 算法检测率比较

Fig. 2 The detection rate of the proposed algorithm versus ANN,SVM and MME for OFDM signal




图3 AM 信号下本文算法与 ANN、SVM 和 MME 算法检测率比较

Fig. 3 The detection rate of the proposed algorithm versus ANN,SVM and MME for AM signal

4.2 实验二:两种信号虚警率比较

在 H_1 情况下,分别对不同噪声功率下两种信号的虚警率进行仿真试验,仿真结果如图 4 和图 5 所示。




图4 OFDM 信号下本文算法与 ANN、SVM 和 MME 算法虚警率比较

Fig. 4 The false alarm rate of the proposed algorithm versus ANN,SVM and MME for OFDM signal




图5 AM 信号下本文算法与 ANN、SVM 和 MME 算法虚警率比较

Fig. 5 The false alarm rate of the proposed algorithm versus ANN,SVM and MME for AM signal

如图 4 和图 5 表明:针对不同噪声功率,MME 算法的虚警率在 10^{-3} 数量级,而 ANN、SVM 与本文算法虚警率在 10^{-4} 数量级,本文算法的虚警率明显低于两种对比算法,进而更加证明了算法的有效性。

5 结 论

本文提出了一种基于循环平稳主成分分析与 RVM 的频谱感知算法,并具体研究了低信噪比情况下主用户信号检测问题。仿真表明该算法在低信噪比情况下具有良好的检测性能,在一定程度上减少了训练样本特征参数及样本数量,获取更精确的样本参数,有效克服了 ANN 由于局部优化不能获得最优解、SVM 算法由于样本数过大而产生过拟合现象及能量检测算法在低信噪比情况下检测性能低下等弊端,具有较高的识别精度和良好的稳健性,且对任意主用户信号,本文算法具有普适性,对于频谱感知技术的进一步研究具有较好的理论和实际研究价值。

在未来的研究中,将针对更多非线性降维方法


与机器学习方法在认知网络频谱感知中的应用展开,进一步对信号中所存在的非线性成分进行有效提取,结合更强大的分类器进行主用户信号的感知,以实现更为精确的频谱感知目的。

参考文献:

- [1] Sun H, Nallanathan A, Wang C X, et al. Wideband spectrum sensing for cognitive radio networks: a survey [J]. IEEE Journal of Wireless Communications, 2013, 20(2): 74-81.
- [2] Wang B, Liu K J R. Advances in cognitive radio networks: A survey [J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(1): 5-23.
- [3] Liang Y C, Chen K C, Li G Y, et al. Cognitive Radio Networking and Communications: An Overview [J]. IEEE Transactions on Vehicular Technology, 2011, 60(7): 3386-3407.
- [4] 何继爱, 陈峰. 一种认知无线电的二次频谱感知算法 [J]. 科学技术与工程, 2011, 11(36): 8993-8997.
HE Ji-ai, CHEN Feng. A Kind of Cognitive Radio Secondary Spectrum Sensing Algorithms [J]. Science Technology and Engineering, 2011, 11(36): 8993-8997. (in Chinese)
- [5] 王鑫, 汪晋宽, 刘志刚, 等. 基于随机森林的认知网络频谱感知算法 [J]. 仪器仪表学报, 2013, 34(11): 35-41.
WANG Xin, WANG Jin-kuan, LIU Zhi-gang, et al. Spectrum sensing algorithm based on random forest in cognitive network [J]. Journal of Scientific Instrument, 2013, 34(11): 35-41. (in Chinese)
- [6] Zhao Q, Geirhofer S, Tong L, et al. Opportunistic spectrum access via periodic channel sensing [J]. IEEE Transactions on Signal Processing, 2008, 56(2): 785-796.
- [7] 陆阳. 认知无线电差分协作压缩频谱估计算法 [J]. 电讯技术, 2013, 53(2): 166-171.
LU Yang. Differential Cooperative Compressed Spectrum Estimation for Cognitive Radio [J]. Telecommunication Engineering, 2013, 53(2): 166-171. (in Chinese)

- [8] Yang X, Lei K J, Peng S L, et al. Blind detection for primary user based on the sample covariance matrix in cognitive radio [J]. IEEE Communications Letters, 2011, 15(1): 40-42.
- [9] Zeng Y H, Liang Y C. Eigenvalue-based spectrum sensing algorithms for cognitive radio [J]. IEEE Transactions on Communications, 2009, 57(6): 1784-1793.
- [10] Bkassiny M, Li Y, Jayaweera S. A Survey on Machine-Learning Techniques in Cognitive Radios [J]. IEEE Journal of Communications Surveys & Tutorials, 2012, 45(5): 1-24.
- [11] Hu H, Song J, Wang Y. Signal classification based on spectral correlation analysis and SVM in cognitive radio [C]// Proceedings of 2008 22nd International Conference on Advanced Information Networking and Applications. GinoWan, Okinawa, Japan: IEEE, 2008: 883-887.
- [12] Jolliffe I. Principal component analysis [M]. New York: Springer Verlag, 2002.
- [13] Bowd C, Medeiros F A, Zhang Z, et al. Relevance vector machine and support vector machine classifier analysis of scanning laser polarimetry retinal nerve fiber layer measurements [J]. Investigative Ophthalmology and Visual Science, 2005, 46(5): 1322-1329.

作者简介:



王鑫(1979—),男,辽宁沈阳人,2008年毕业于东北大学获工学硕士学位,现为东北大学博士研究生、沈阳建筑大学讲师,主要研究方向为认知网络频谱感知、信号处理、模式识别。

WANG Xin was born in Shenyang, Liaoning Province, in 1979. He received the M. S. degree from Northeastern University in 2008. He is now a lecturer and currently working toward the Ph. D. degree. His research concerns spectrum sensing in cognitive networks, signal processing and pattern recognition.

Email: wangxin7988@163.com