

1. 在认知无线网络环境下频谱感知的方法,其特征在于,包括:

构建数据集,认知无线网络中的次用户对主用户进行检测,每个次用户将信道中的能量值收集后发送到融合中心,融合中心将所有从次用户发来的能量值作为特征向量,认知无线网络中的主用户间断性地将自身工作状态发送到融合中心,融合中心将主用户发来的工作状态作为数据集标签;

通过Xgboost算法对数据集进行训练,得到对当前信道感知结果的机器学习模型;

在得到已训练的机器学习模型后,次用户继续收集信道中的能量值发给融合中心作为测试数据,由此融合中心的Xgboost算法模型对认知无线网络环境下进行频谱感知。

2. 如权利要求1所述的在认知无线网络环境下频谱感知的方法,其特征在于,所述Xgboost算法其目标函数如下:

$$F_{obj}(\theta) = L(\theta) + \Omega(\theta) \quad (1)$$

这里 $L(\theta) = l(\hat{y}_i, y_i)$, $\Omega(\theta) = \gamma T + \frac{1}{2} \lambda \|w\|^2$, θ 代表公式中各种参数, $L(\theta)$ 是可微的凸函数损失函数; $\Omega(\theta)$ 是惩罚模型的正则化项, T 是树中叶子数, γ 是学习率其值在0到1之间, λ 是正则化参数, w 是叶子权重;

这里需决定是否在公式(2)中学习到目标 y_i :

$$L(\theta) = \sum_{i=1}^n (l(y_i, \hat{y}_i^{t-1}) + S_i(T_i)) + \Omega(\theta) \quad (2)$$

在优化目标时构建一个树模型在每次迭代中最小化目标函数,树模型在之前每次模型学习的基础和残差上进行学习,残差为真实值减去预测值, $S_t(T_i)$ 代表生成的在第 t 次迭代中第 i 个树,公式(2)通过二阶泰勒展开式转化为公式(3),其中, $g_i = \partial_{\hat{y}_i^{t-1}} l(y_i, \hat{y}_i^{t-1})$,

$h_i = \partial_{\hat{y}_i^{t-1}}^2 l(y_i, \hat{y}_i^{t-1})$,公式(3)如下:

$$L(\theta) = \sum_{i=1}^n [l(y_i, \hat{y}_i^{t-1}) + g_i S_i(T_i) + \frac{1}{2} h_i S_i^2(T_i)] + \Omega(\theta) \quad (3)$$

最后,通过(1)式算法迭代地发现每个树最小化目标函数的分裂点。

3. 如权利要求2所述的在认知无线网络环境下频谱感知的方法,其特征在于,将凸损失函数如均方差损失函数 $l(\hat{y}_i, y_i) = (\hat{y}_i - y_i)^2$ 或者逻辑损失函数

$l(\hat{y}_i, y_i) = y_i \ln(1 + e^{-\hat{y}_i}) + (1 - y_i) \ln(1 + e^{\hat{y}_i})$ 用于等式 $L(\theta) = l(\hat{y}_i, y_i)$ 中。

4. 如权利要求1所述的在认知无线网络环境下频谱感知的方法,其特征在于,

认知无线网络中包含 s 个次用户SU, SU和主用户PU共享一个频带并假定SU与PU间不存在干扰,记 s 个SU序列为 $s = 1, \dots, S$, 记 p 个PU序列为 $p = 1, \dots, P$, c_s 和 c_p 分别代表SUs和PU的二维坐标;

每个SU对PU的能量进行检测并把能量向量发送到融合中心,融合中心利用SU发送来的能量向量分辨信道是否可用,PU有两种工作状态:在线状态、下线状态,用 M_p 代表PU的工作状态,如果 $M_p = 1$ 代表PU在线,如果 $M_p = 0$ 代表PU下线, $M = (M_1, \dots, M_p)^T$ 是代表所有PU工作状态的向,如果没有一个PU在线那么信道可用,那么 $M = 0$;

利用基于能量检测方法于PU的能量水平进行评估,其可由二元假设检验的方式表示:

H_0 :所有PU下线 ($M=0$)

H_1 :至少有一个PU在线 ($M \neq 0$)

每个SU的能量检测器在时间 τ 内采样 $w\tau$ 个复基带信号样本,带宽表示为 w 。 $R_s(i)$ 代表SU接收到的第 i 个信号样本,可用如下假设表示:

$$\begin{aligned} H_0 : R_s(i) &= N_s(i) \\ H_1 : R_s(i) &= \sum_p^p M_p h_{p,s} X_p(i) + N_s(i) \end{aligned} \quad (4)$$

在这里 $h_{p,s}$ 代表PU p 和SU s 之间的信道增益,此外, $X_p(i)$ 代表PU p 的发射信号, $N_s(i)$ 代表SU s 接收到热噪声,SU应该在感知时间段内做出正确决策。

5.如权利要求4所述的在认知无线网络环境下频谱感知的方法,其特征在于,在Xgboost算法对训练数据集进行训练中,用 Y_s 代表SU s 收到的归一化能量水平:

$$Y_s = \frac{2}{\eta} \sum_{i=1}^{w\tau} |R_s(i)|^2 \quad (5)$$

此处 η 为噪声功率谱密度定义为 $\eta = E[|N_s(i)|^2]$,因此,能量向量包含所有SU接收到的能量水平:

$$Y = (Y_1, \dots, Y_s)^T \quad (6)$$

在获得能量向量后,分析其分布,每个能量值 Y_s 服从非中心的卡方分布,自由度和非中心参数如下:

$$r = 2w\tau \quad (7)$$

$$\xi_s = \frac{2\tau}{\eta} \sum_{p=1}^p M_p g_{p,s} \rho_p \quad (8)$$

$\rho_p = \sum_{i=1}^{w\tau} [E|X_p|^2] / \tau$ 是PU p 的固定发射功率, $g_{p,s} = |h_{p,s}|^2$ 是功率衰减,其计算公式如下:

下:

$$g_{p,s} = PL(|c_s - c_p|) \cdot v_{p,s} \psi_{p,s} \quad (9)$$

$|| \cdot ||$ 代表欧氏距离, $PL(\text{dist}) = \text{dist}^{-\theta}$ 代表关于距离 dist 和损失系数 θ 的路径损失, $v_{p,s}$ 和 $\psi_{p,s}$ 分别代表多径衰落和阴影衰落,假设PU和SU满足802.22协议;

此外,在感知时间段内衰落系数 $v_{p,s}$ 和 $\psi_{p,s}$ 不变为准静态,能量水平的分布在有足够多的样本时,能量值分布基本服从高斯分布,因此能量向量可以从多元高斯分布中提取,其均值和方差如下:

$$\mu_{Y_s} = r + \xi_s \quad (10)$$

$$\sigma^2_{Y_s} = 2(r + 2\xi_s) \quad (11)$$

因此能量向量的均值向量和协方差矩阵如下:

$$\mu_{Y_s} = (\mu_{Y_1}, \dots, \mu_{Y_s})^T \quad (12)$$

$$\Sigma_{Y_s} = \text{diag}(\sigma^2_{Y_1}, \dots, \sigma^2_{Y_s}) \quad (13)$$

假设有N个训练向量($e = \{e_1, \dots, e_N\}$),其对应的标签为($l = \{l_1, \dots, l_N\}$),其中, e_n 是第n个s维训练向量, l_n 是其标签,将训练向量和对应的标签都放进分类器,在训练完成后,把测试向量放进分类器得到相应的标签,来确定信道是否可用,用 e^* 和 l^* 代表测试向量和标签,用 \hat{l} 代表测试结果的标签,如果分类器判断信道可用即所有的PU下线,则 $\hat{l} = 0$,如果分类器判断信道不可用即至少有一个PU上线则 $\hat{l} = 1$ 。

在认知无线网络环境下频谱感知的方法

技术领域

[0001] 本发明涉及无线通信与人工智能技术领域,具体涉及一种在认知无线网络环境下频谱感知的方法。

背景技术

[0002] 认知无线网络概念是在设计无线通信系统时,由于近些年无线频谱资源越来越稀缺,为了有效提高频谱资源利用率而提出的。认知无线网络依靠可感知电磁工作环境的智能无线通信设备,来动态自适应地调整自身无线电操作参数。在这里,机会频谱接入是非常重要的,它的意思是在主用户发射端被检测到下线的情况下认知用户要适时地接入频带。对于机会频谱介入,认知用户必须通过一些手段来达到感知频谱是否被占用的目的,进而使用频谱资源并最大化频谱资源利用率。所以,有效的频谱感知方法至关重要。

[0003] 当前主要的频谱感知方法有基于能量检测方法、匹配滤波方法、循环谱技术。基于能量检测方法是复杂度最低的方式,但在低信噪比情况下其性能会不太稳定。匹配滤波是一种在次用户具备主用户先验信息的时候较优的方法。循环谱技术是基于主用户信号循环平稳特征的方式,但其计算复杂度较高。匹配滤波和循环谱技术由于复杂度高或需要主用户先验知识,在大多数情景下并不实用。虽然基于能量检测的方法准确性不如其他两种方法,但其由于自身复杂度低和易于实现的特点所以其最为流行和常用。

[0004] 据我们所知,基于能量检测使用SVM算法相比于其他单一算法在频谱感知分类问题上有着最佳的性能,其由于极高的分类准确率所以非常流行和实用。这些工作都一定程度上提高了频谱感知的性能,但是还有需要继续改进提升的地方。上述基于能量检测的频谱感知方法缺陷在于:该方法没有解决误分类风险的问题,误分类风险的意思是当前信道不可用的时候分类器却判断为可用,这种分类错误会对主用户造成有害的干扰,要求其发生的概率需要尽可能的低,如果较高其影响是非常致命的。同时,前期研究在IEEE 802.22所要求的虚警率固定在0.1的概率时检测率大概为0.7左右,在实际应用中是不足的,因为较低的虚警率意味着感知用户有更大得到机会利用频谱空穴,而更高的检测率意味着主用户可以更大程度地避免被感知用户所干扰。

发明内容

[0005] 本发明的主要目的在于提供基于Xgboost算法在认知无线网络环境下的合作频谱感知方法,以解决现有技术中误分类风险高,检测率较低的问题。

[0006] 为了实现上述目的本发明在认知无线网络环境下频谱感知的方法,包括:

[0007] 构建数据集,认知无线网络中的次用户对主用户进行检测,每个次用户将信道中的能量值收集后发送到融合中心,融合中心将所有从次用户发来的能量值作为特征向量,认知无线网络中的主用户间断性地将自身工作状态发送到融合中心,融合中心将主用户发来的工作状态作为数据集标签;

[0008] 通过Xgboost算法对数据集进行训练,得到对当前信道感知结果的机器学习模型;

[0009] 在得到已训练的模型后,次用户继续收集信道中的能量值发给融合中心作为测试数据,由此融合中心的Xgboost算法模型对认知无线网络环境下进行频谱感知。

[0010] 本发明在认知无线网络环境下频谱感知的方法将能量向量喂给Xgboost分类器来决定当前信道是否可用,每一个能量向量会被打上信道可用与否的标签。本专利所做的工作主要是提高之前机器学习算法在频谱感知问题上性能的不足。

[0011] 进一步地,所述Xgboost算法其目标函数如下:

$$[0012] \quad F_{\text{obj}}(\theta) = L(\theta) + \Omega(\theta) \quad (1)$$

[0013] 这里 $L(\theta) = l(\hat{y}_i, y_i)$, $\Omega(\theta) = \gamma T + \frac{1}{2} \lambda \|w\|^2$, θ 代表公式中各种参数, $L(\theta)$ 是可微的凸函数损失函数,计算 \hat{y}_i 和 y_i 间差距,其意义是须拟合的与目标之间的部分。;

[0014] $\Omega(\theta)$ 是惩罚模型的正则化项, T 是树中叶子数, γ 是学习率其值在0到1之间, λ 是正则化参数, γ 乘以 T 是为了修剪生成树,防止过拟合, w 是叶子权重, Xgboost相比于传统的GBDT算法增加了 $\frac{1}{2} \lambda \|w\|^2$ 项,增加此项可以更加有效地防止过拟合和提高泛化能力。然而在

(1) 目标函数中的惩罚项导致传统方法的失效,所以我们需要决定是否需要决定是否需要公式(2)中学习目标 y_i :

$$[0015] \quad L(\theta) = \sum_{i=1}^n (l(y_i, \hat{y}_i^{t-1}) + S_i(T_i)) + \Omega(\theta) \quad (2)$$

[0016] 在优化目标时构建一个树模型在每次迭代中最小化目标函数,树模型在之前每次模型学习的基础和残差上进行学习,残差为真实值减去预测值, $S_t(T_i)$ 代表生成的在第 t 次迭代中第 i 个树,公式(2)通过二阶泰勒展开式转化为公式(3),其中, $g_i = \partial_{\hat{y}_i^{t-1}} l(y_i, \hat{y}_i^{t-1})$, $h_i = \partial_{\hat{y}_i^{t-1}}^2 l(y_i, \hat{y}_i^{t-1})$,因为在(2)中目标函数在使用均方差损失函数是较优,而对于其他损失函数会变得比较复杂,所以(2)通过二阶泰勒展开式转化为(3),这使得其他损失函数的应用变得简单方便。最终目标函数只由每个数据点的误差函数的一阶和二阶导数决定,这可以加速优化过程。

[0017] 公式(3)如下:

$$[0018] \quad L(\theta) = \sum_{i=1}^n [l(y_i, \hat{y}_i^{t-1}) + g_i S_i(T_i) + \frac{1}{2} h_i S_i^2(T_i)] + \Omega(\theta) \quad (3)$$

[0019] 最后,通过(1)式算法迭代地发现每个树最小化目标函数的分裂点。这种算法是一种贪心算法,其核心思想是先根据特征值排序,然后遍历每一个特征,选择每一个特征值作为分裂点,然后计算损失,在所有特征被遍历完以后,最重要的特征会成为分裂点。

[0020] Xgboost算法可用CPU多线程自动化运行并提高算法结果准确性, Xgboost在传统的GBDT算法上有了很大的提升,包括计算速度、泛化能力等。

[0021] 进一步地,将凸损失函数如均方差损失函数 $l(\hat{y}_i, y_i) = (\hat{y}_i - y_i)^2$ 或者逻辑损失函数 $l(\hat{y}_i, y_i) = y_i \ln(1 + e^{-\hat{y}_i}) + (1 - y_i) \ln(1 + e^{\hat{y}_i})$ 用于等式 $L(\theta) = l(\hat{y}_i, y_i)$ 中。

[0022] 进一步地,认知无线网络中包含 s 个次用户SU, SU和主用户PU共享一个频带并假定

SU与PU间不存在干扰,记 s 个SU序列为 $s=1, \dots, S$,记 p 个PU序列为 $p=1, \dots, P$, c_s 和 c_p 分别代表SUs和PUs的二维坐标;

[0023] 每个SU对PU的能量进行检测并把能量向量发送到融合中心,融合中心利用SU发送来的能量向量分辨信道是否可用,PU有两种工作状态:在线状态、下线状态,用 M_p 代表PU的工作状态,如果 $M_p=1$ 代表PU在线,如果 $M_p=0$ 代表PU下线, $M=(M_1, \dots, M_p)^T$ 是代表所有PU工作状态的向,如果没有一个PU在线那么信道可用,那么 $M=0$;

[0024] 利用基于能量检测方法于PU的能量水平进行评估,其可由二元假设检验的方式表示:

[0025] H_0 : 所有PU下线 ($M=0$)

[0026] H_1 : 至少有一个PU在线 ($M \neq 0$)

[0027] 每个SU的能量检测器在时间 τ 内采样 $w\tau$ 个复基带信号样本,带宽表示为 w 。 $R_s(i)$ 代表SU接收到的第 i 个信号样本,可用如下假设表示:

$$\begin{aligned} H_0: R_s(i) &= N_s(i) \\ [0028] \quad H_1: R_s(i) &= \sum_p M_p h_{p,s} X_p(i) + N_s(i) \end{aligned} \quad (4)$$

[0029] 在这里 $h_{p,s}$ 代表PUp和SU s 之间的信道增益,此外, $X_p(i)$ 代表PUp的发射信号, $N_s(i)$ 代表SU s 接收到热噪声,SU应该在感知时间段内做出正确决策。

[0030] 进一步地,在Xgboost算法对训练数据集进行训练中,用 Y_s 代表SU s 收到的归一化能量水平:

$$[0031] \quad Y_s = \frac{2}{\eta} \sum_{i=1}^{w\tau} |R_s(i)|^2 \quad (5)$$

[0032] 此处 η 为噪声功率谱密度定义为 $\eta = E[N_s(i)^2]$,因此,能量向量包含所有SU接收到的能量水平:

$$[0033] \quad Y = (Y_1, \dots, Y_s)^T \quad (6)$$

[0034] 在获得能量向量后,分析其分布,每个能量值 Y_s 服从非中心的卡方分布,自由度和非中心参数如下:

$$[0035] \quad r = 2w\tau \quad (7)$$

$$[0036] \quad \xi_s = \frac{2\tau}{\eta} \sum_{p=1}^p M_p g_{p,s} \rho_p \quad (8)$$

[0037] $\rho_p = \sum_{i=1}^{w\tau} [E|X_p|^2] / \tau$ 是PUp的固定发射功率, $g_{p,s} = |h_{p,s}|^2$ 是功率衰减,其计算公式

如下:

$$[0038] \quad g_{p,s} = PL(\|c_s - c_p\|) \cdot v_{p,s} \psi_{p,s} \quad (9)$$

[0039] $\|\cdot\|$ 代表欧氏距离, $PL(\text{dist}) = \text{dist}^{-\theta}$ 代表关于距离 dist 和损失系数 θ 的路径损失, $v_{p,s}$ 和 $\psi_{p,s}$ 分别代表多径衰落和阴影衰落,假设PU和SU满足802.22协议;

[0040] 此外,在感知时间段内衰落系数 $v_{p,s}$ 和 $\psi_{p,s}$ 不变为准静态,能量水平的分布在有足够多的样本时,能量值分布基本服从高斯分布,因此能量向量可以从多元高斯分布中提取,

其均值和方差如下：

$$[0041] \quad \mu_{Y_s} = r + \zeta_s \quad (10)$$

$$[0042] \quad \sigma^2_{Y_s} = 2(r + 2\zeta_s) \quad (11)$$

[0043] 因此能量向量的均值向量和协方差矩阵如下：

$$[0044] \quad \mu_{Y_s} = (\mu_{Y_1}, \dots, \mu_{Y_s})^T \quad (13)$$

$$[0045] \quad \sum_{Y_s} = \text{diag}(\sigma^2_{Y_1}, \dots, \sigma^2_{Y_s}) \quad (14)$$

[0046] 假设有N个训练向量 ($e = \{e_1, \dots, e_N\}$), 其对应的标签为 ($l = \{l_1, \dots, l_N\}$), 其中, e_n 是第 n 个 s 维训练向量, l_n 是其标签, 将训练向量和对应的标签都放进分类器, 在训练完成后, 把测试向量放进分类器得到相应的标签, 来确定信道是否可用, 用 e^* 和 l^* 代表测试向量和标签, 用 \hat{l} 代表测试结果的标签, 如果分类器判断信道可用即所有的PU下线, 则 $\hat{l} = \mathbf{0}$, 如果分类器判断信道不可用即至少有一个PU上线则 $\hat{l} = \mathbf{1}$ 。

[0047] 本发明相比于现有技术的优点在于: 本发明在认知无线网络环境下频谱感知的方法, 有着更强的实用性, 即使在信噪比较低的情况下性能表现也较好, 鲁棒性较强, 提高了之前机器学习算法在频谱感知问题上性能的不足, 相比于现有方法分类性能更优, 在使用满足 IEEE 802.11 要求的虚警率 0.1 的情况下, 提升了检测率, 同时误分类率、误分类风险也显著下降, 对于频谱感知应用来说, 意义重大。

[0048] 下面结合附图和具体实施方式对本发明做进一步的说明。本发明附加的方面和优点将在下面的描述中部分给出, 部分将从下面的描述中变得明显, 或通过本发明的实践了解到。

附图说明

[0049] 构成本发明的一部分的附图用来辅助对本发明的理解, 附图中所提供的内容及其在本发明中有关的说明可用于解释本发明, 但不构成对本发明的不当限定。在附图中:

[0050] 图1是合作频谱感知系统结构框架图。

[0051] 图2是基于地理位置的合作频谱感知模型图。

[0052] 图3是Xgboost算法与SVM算法(线性核函数)的ROC曲线图。

[0053] 图4是虚警率为0.1时, PU不同发射功率下Xgboost算法与SVM(线性核函数)算法的检测率图。

[0054] 图5是虚警率为0.1时, PU不同发射功率下Xgboost算法与SVM(线性核函数)算法的误分类风险率图。

[0055] 图6是虚警率为0.1时, PU不同发射功率下Xgboost算法与SVM(线性核函数)算法的误检率图。

具体实施方式

[0056] 本领域普通技术人员在基于这些说明的情况下将能够实现本发明。在结合附图对本发明进行说明前, 需要特别指出的是:

[0057] 本发明中在包括下述说明在内的各部分中所提供的技术方案和技术特征,在不冲突的情况下,这些技术方案和技术特征可以相互组合。

[0058] 此外,下述说明中涉及到的本发明的实施例通常仅是本发明一分部的实施例,而不是全部的实施例。因此,基于本发明中的实施例,本领域普通技术人员在没有做出创造性劳动的前提下所获得的所有其他实施例,都应当属于本发明保护的范围。

[0059] 关于本发明中术语和单位。本发明的说明书和权利要求书及有关的部分中的术语“包括”、“具有”以及它们的任何变形,意图在于覆盖不排他的包含。

[0060] 本发明在认知无线网络环境下频谱感知的方法,包括:

[0061] 构建数据集,认知无线网络中的次用户对主用户进行检测,每个次用户将信道中的能量值收集后发送到融合中心,融合中心将所有从次用户发来的能量值作为特征向量,认知无线网络中的主用户间断性地将自身工作状态发送到融合中心,融合中心将主用户发来的工作状态作为数据集标签;

[0062] 通过Xgboost算法对数据集进行训练,得到对当前信道感知结果的机器学习模型;

[0063] 在得到已训练的模型后,次用户继续收集信道中的能量值发给融合中心作为测试数据,由此融合中心的Xgboost算法模型对认知无线网络环境下进行频谱感知。

[0064] 本发明在认知无线网络环境下频谱感知的方法将能量向量喂给Xgboost分类器来决定当前信道是否可用,每一个能量向量会被打上信道可用与否的标签。本专利所做的工作主要是提高之前机器学习算法在频谱感知问题上性能的不足。

[0065] 所述Xgboost算法其目标函数如下:

$$[0066] \quad F_{\text{obj}}(\theta) = L(\theta) + \Omega(\theta) \quad (1)$$

[0067] 这里 $L(\theta) = l(\hat{y}_i, y_i)$, $\Omega(\theta) = \gamma T + \frac{1}{2} \lambda \|w\|^2$, θ 代表公式中各种参数, $L(\theta)$ 是可微的凸函数损失函数,计算 \hat{y}_i 和 y_i 间差距,其意义是须拟合的与目标之间的部分。;

[0068] $\Omega(\theta)$ 是惩罚模型的正则化项, T 是树中叶子数, γ 是学习率其值在 0 到 1 之间, λ 是正则化参数, γ 乘以 T 是为了修剪生成树,防止过拟合, w 是叶子权重, Xgboost 相比于传统的 GBDT 算法增加了 $\frac{1}{2} \lambda \|w\|^2$ 项,增加此项可以更加有效地防止过拟合和提高泛化能力。然而在

(1) 目标函数中的惩罚项导致传统方法的失效,所以我们需要决定是否需要公式 (2) 中学习目标 y_i :

$$[0069] \quad L(\theta) = \sum_{i=1}^n (l(y_i, \hat{y}_i^{t-1}) + S_i(T_i)) + \Omega(\theta) \quad (2)$$

[0070] 在优化目标时构建一个树模型在每次迭代中最小化目标函数,树模型在之前每次模型学习的基础和残差上进行学习,残差为真实值减去预测值, $S_t(T_i)$ 代表生成的在第 t 次迭代中第 i 个树,公式 (2) 通过二阶泰勒展开式转化为公式 (3),其中, $g_i = \partial_{\hat{y}_i^{t-1}} l(y_i, \hat{y}_i^{t-1})$, $h_i = \partial_{\hat{y}_i^{t-1}}^2 l(y_i, \hat{y}_i^{t-1})$,因为在 (2) 中目标函数在使用均方差损失函数是较优,而对于其他损失函数会变得比较复杂,所以 (2) 通过二阶泰勒展开式转化为 (3),这使得其他损失函数的应用变得简单方便。最终目标函数只由每个数据点的误差函数的一阶和二阶导数决定,这可

以加速优化过程。

[0071] 公式 (3) 如下:

$$[0072] \quad L(\theta) = \sum_{i=1}^n [l(y_i, \hat{y}_i^{t-1}) + g_i S_i(T_i) + \frac{1}{2} h_i S_i^2(T_i)] + \Omega(\theta) \quad (3)$$

[0073] 最后,通过 (1) 式算法迭代地发现每个树最小化目标函数的分裂点。这种算法是一种贪心算法,其核心思想是先根据特征值排序,然后遍历每一个特征,选择每一个特征值作为分裂点,然后计算损失,在所有特征被遍历完以后,最重要的特征会成为分裂点。

[0074] Xgboost算法可用CPU多线程自动化运行并提高算法结果准确性,Xgboost在传统的GBDT 算法上有了很大的提升,包括计算速度、泛化能力等。

[0075] 将凸损失函数如均方差损失函数 $l(\hat{y}_i, y_i) = (\hat{y}_i - y_i)^2$ 或者逻辑损失函数 $l(\hat{y}_i, y_i) = y_i \ln(1 + e^{-\hat{y}_i}) + (1 - y_i) \ln(1 + e^{\hat{y}_i})$ 用于等式 $L(\theta) = l(\hat{y}_i, y_i)$ 中。

[0076] 认知无线网络中包含s个次用户SU,SU和主用户PU共享一个频带并假定SU与PU间不存在干扰,记s个SU序列为 $s = 1, \dots, S$,记p个PU序列为 $p = 1, \dots, P$, c_s 和 c_p 分别代表SU_s和PU_p的二维坐标;

[0077] 每个SU对PU的能量进行检测并把能量向量发送到融合中心,融合中心利用SU发送来的能量向量分辨信道是否可用,PU有两种工作状态:在线状态、下线状态,用 M_p 代表PU的工作状态,如果 $M_p = 1$ 代表PU在线,如果 $M_p = 0$ 代表PU下线, $M = (M_1, \dots, M_p)^T$ 是代表所有PU工作状态的向,如果没有一个PU在线那么信道可用,那么 $M = 0$;

[0078] 利用基于能量检测方法于PU的能量水平进行评估,其可由二元假设检验的方式表示:

[0079] H_0 : 所有PU下线 ($M = 0$)

[0080] H_1 : 至少有一个PU在线 ($M \neq 0$)

[0081] 每个SU的能量检测器在时间 τ 内采样 $w\tau$ 个复基带信号样本,带宽表示为 w 。 $R_s(i)$ 代表SU接收到的第i个信号样本,可用如下假设表示:

$$[0082] \quad \begin{aligned} H_0 : R_s(i) &= N_s(i) \\ H_1 : R_s(i) &= \sum_p M_p h_{p,s} X_p(i) + N_s(i) \end{aligned} \quad (4)$$

[0083] 在这里 $h_{p,s}$ 代表PU_p和SU_s之间的信道增益,此外, $X_p(i)$ 代表PU_p的发射信号, $N_s(i)$ 代表SU_s接收到热噪声,SU应该在感知时间段内做出正确决策。

[0084] 在Xgboost算法对训练数据集进行训练中,用 Y_s 代表SU_s收到的归一化能量水平:

$$[0085] \quad Y_s = \frac{2}{\eta} \sum_{i=1}^{w\tau} |R_s(i)|^2 \quad (5)$$

[0086] 此处 η 为噪声功率谱密度定义为 $\eta = E[N_s(i)^2]$,因此,能量向量包含所有SU接收到的能量水平:

$$[0087] \quad Y = (Y_1, \dots, Y_s)^T \quad (6)$$

[0088] 在获得能量向量后,分析其分布,每个能量值 Y_s 服从非中心的卡方分布,自由度和非中心参数如下:

[0089] $r = 2w\tau$ (7)

[0090] $\xi_s = \frac{2\tau}{\eta} \sum_{p=1}^p M_p g_{p,s} \rho_p$ (8)

[0091] $\rho_p = \sum_{i=1}^{w\tau} [E|X_p|^2] / \tau$ 是PU_p的固定发射功率, $g_{p,s} = |h_{p,s}|^2$ 是功率衰减, 其计算公式

如下:

[0092] $g_{p,s} = PL(|c_s - c_p|) \cdot v_{p,s} \psi_{p,s}$ (9)

[0093] $|| \cdot ||$ 代表欧氏距离, $PL(\text{dist}) = \text{dist}^{-\theta}$ 代表关于距离 dist 和损失系数 θ 的路径损失, $v_{p,s}$ 和 $\psi_{p,s}$ 分别代表多径衰落和阴影衰落, 假设PU和SU满足802.22协议;

[0094] 此外, 在感知时间段内衰落系数 $v_{p,s}$ 和 $\psi_{p,s}$ 不变为准静态, 能量水平的分布在有足够多的样本时, 能量值分布基本服从高斯分布, 因此能量向量可以从多元高斯分布中提取, 其均值和方差如下:

[0095] $\mu_{Y_s} = r + \zeta_s$ (10)

[0096] $\sigma^2_{Y_s} = 2(r + 2\zeta_s)$ (11)

[0097] 因此能量向量的均值向量和协方差矩阵如下:

[0098] $\mu_{Y_s} = (\mu_{Y_1}, \dots, \mu_{Y_s})^T$ (12)

[0099] $\sum_{Y_s} = \text{diag}(\sigma^2_{Y_1}, \dots, \sigma^2_{Y_s})$ (13)

[0100] 假设有N个训练向量 ($e = \{e_1, \dots, e_N\}$), 其对应的标签为 ($l = \{l_1, \dots, l_N\}$), 其中, e_n 是第 n 个 s 维训练向量, l_n 是其标签, 将训练向量和对应的标签都放进分类器, 在训练完成后, 把测试向量放进分类器得到相应的标签, 来确定信道是否可用, 用 e^* 和 l^* 代表测试向量和标签, 用 \hat{l} 代表测试结果的标签, 如果分类器判断信道可用即所有的PU下线, 则 $\hat{l} = 0$, 如果分类器判断信道不可用即至少有一个PU上线则 $\hat{l} = 1$ 。

[0101] 如图1所示, 在合作频谱感知框架中, 训练阶段和测试阶段彼此独立, 并行工作。训练能量向量和对应的标签放进机器学习模型1的训练分类器11中, 测试训练向量和对应的标签放入机器学习模型1的已训练分类器12中, 判断信道是否可用, 在认知无线网络开始工作后须先对训练模块分类器进行一次训练, 这样已训练的分类器就可以按需在测试模块进行测试, 我们可以周期性的根据信道环境变化重新收集训练能量向量来更新训练模块进行训练, 虽然训练模块训练时间较长, 但不影响测试模块的正常运行,

[0102] 构建数据集, 认知无线网络中的次用户对主用户进行检测, 每个次用户将信道中的能量值收集后发送到融合中心, 融合中心将所有从次用户发来的能量值作为特征向量, 认知无线网络中的主用户间断性地将自身工作状态发送到融合中心, 融合中心将主用户发来的工作状态作为数据集标签;

[0103] 通过Xgboost算法对数据集进行训练, 得到对当前信道感知结果的机器学习模型;

[0104] 在得到已训练的模型后, 次用户继续收集信道中的能量值发给融合中心作为测试数据, 由此融合中心的Xgboost算法模型对认知无线网络环境下进行频谱感知。

[0105] 下面结合附图2说明本发明中基于地理位置的合作频谱感知模型, 为了验证本发

明基于 Xgboost算法解决认知无线网络下的频谱感知问题的可用性和可行性,进行了仿真实验并与 SVM算法进行算法性能比较。如图2,本发明设定在基于地理位置的合作频谱感知模型中,有25个SU,均匀分布在5*5的网格中,有两个PU分别在(500m,500m)和(1500m,0m)位置,在附图3。仿真参数设置如下:感知时间段 τ 为100 μ s,带宽为5MHz,噪声功率谱密度为-174dBm,每一个PU发射功率为200mW,路径损失系数为4,多径衰落和阴影衰落系数都为1,每一个PU上线的概率为0.5.SVM的核函数选择为线性核函数,因为在前期的工作中已经证明了线性核函数在此问题的优秀表现。

[0106] 结合附图3、4、5、6说明本发明相比于此前表现最好的SVM算法在PU不同发射功率下ROC曲线、检测率、误分类风险以及误分类率的性能表现。仿真是用python3.6.2在64位PC,内存RAM 16G,六核i7(3.2GHz)环境下进行的。

[0107] 本发明比较的性能指标如下:

[0108] (1) ROC曲线(Receiver operating characteristic curve),结果为实验独立运行200次后平均曲线,此指标体现了算法的整体分类性能。

[0109] (2) 检测率(DetectionProbability),PU信号存在时SU成功检测到的概率,结果为实验运行200次的平均检测率。

[0110] (3) 误分类风险(MisclassificationRisk),当PU信号存在时分类器给出PU信号不存在标签的概率,结果为实验运行200次的平均误分类风险率。

[0111] (4) 误分类率(Misclassification Error Rate),分类器判断错误的概率,即把不存在PU信号判断为存在,把存在PU信号却判断为不存在的概率,结果为实验运行200次的平均误分类率。

[0112] 附图3、4、5、6为仿真实验结果,图3中用实曲线标出SVM算法,用虚线标出了Xgboost算法。从附图3中ROC曲线可得,在训练向量为200条测试向量为1200条时,在标准固定的虚警率为0.1时,本发明的检测率提高了10%,低虚警率意味着SU有更大机会去使用频谱空穴,高检测率意味着PU能更大程度上避免被SU所干扰。图3、5、6表明在PU不同的发射功率下相比于SVM算法,本发明有着更高的检测率、误分类风险和误分类率。这都证明了本发明的可行性和可用性,可将本发明用于解决认知无线网络下的频谱感知问题。

[0113] 以上对本发明的有关内容进行了说明。本领域普通技术人员在基于这些说明的情况下将能够实现本发明。基于本发明的上述内容,本领域普通技术人员在没有做出创造性劳动的前提下所获得的所有其他实施例,都应当属于本发明保护的范围。

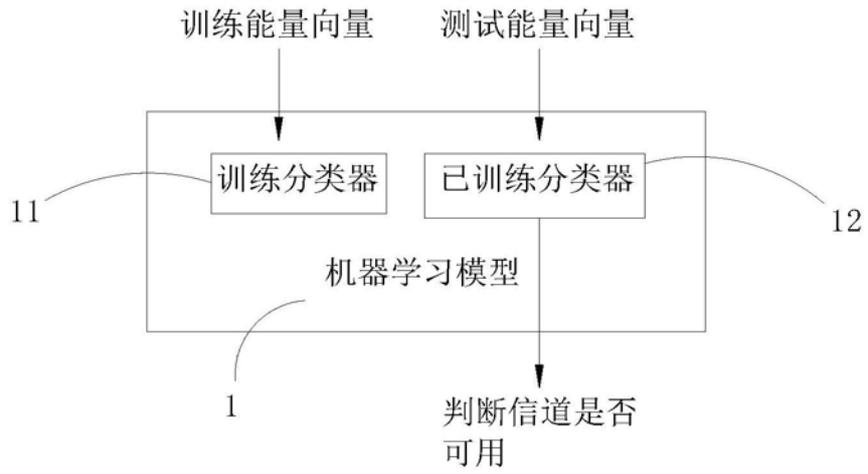


图1

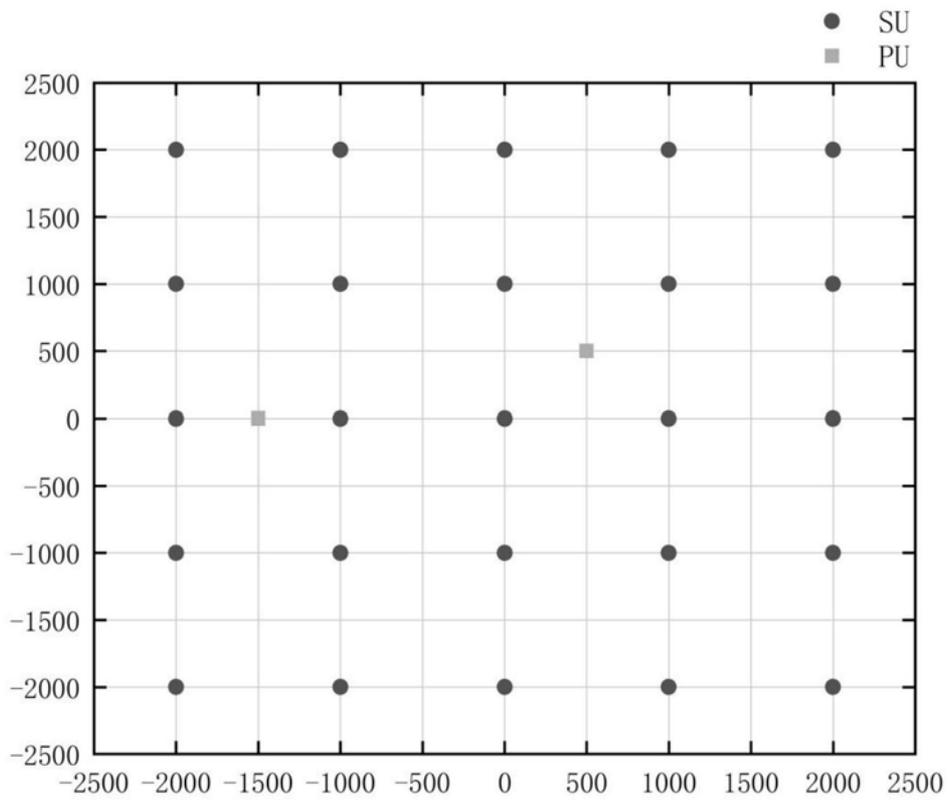


图2

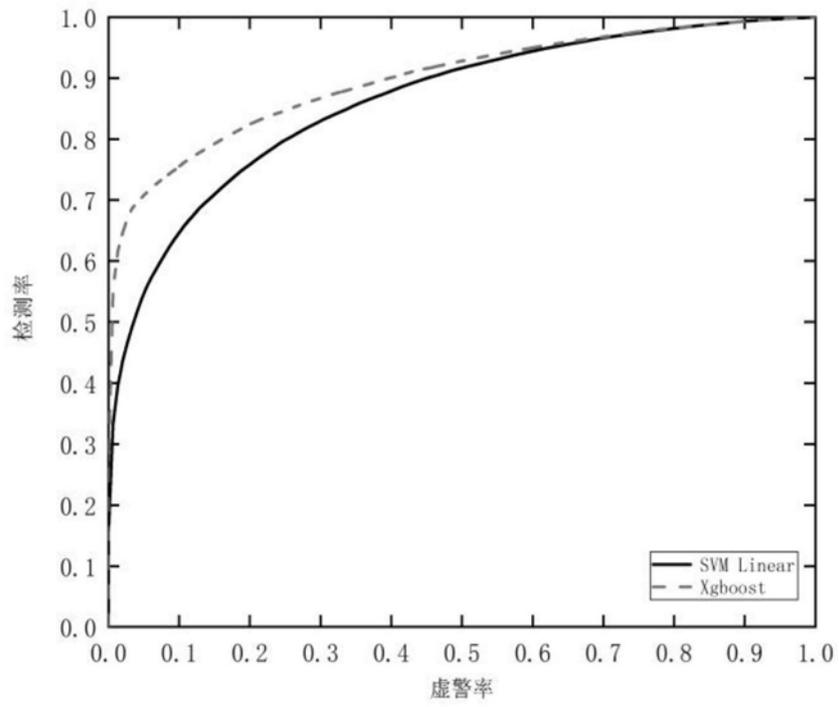


图3

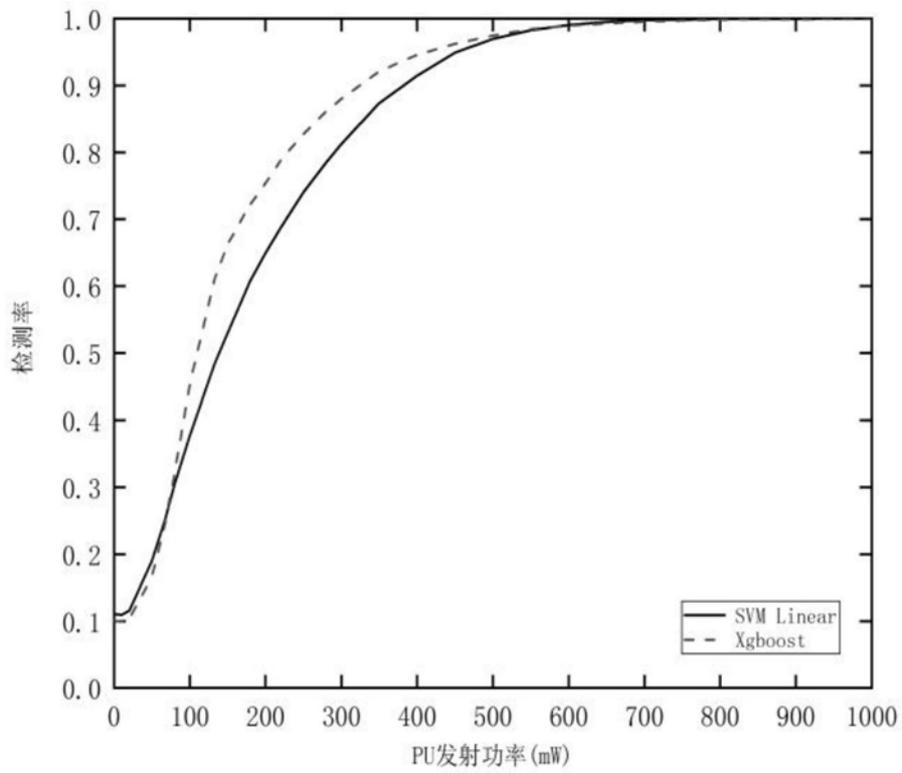


图4

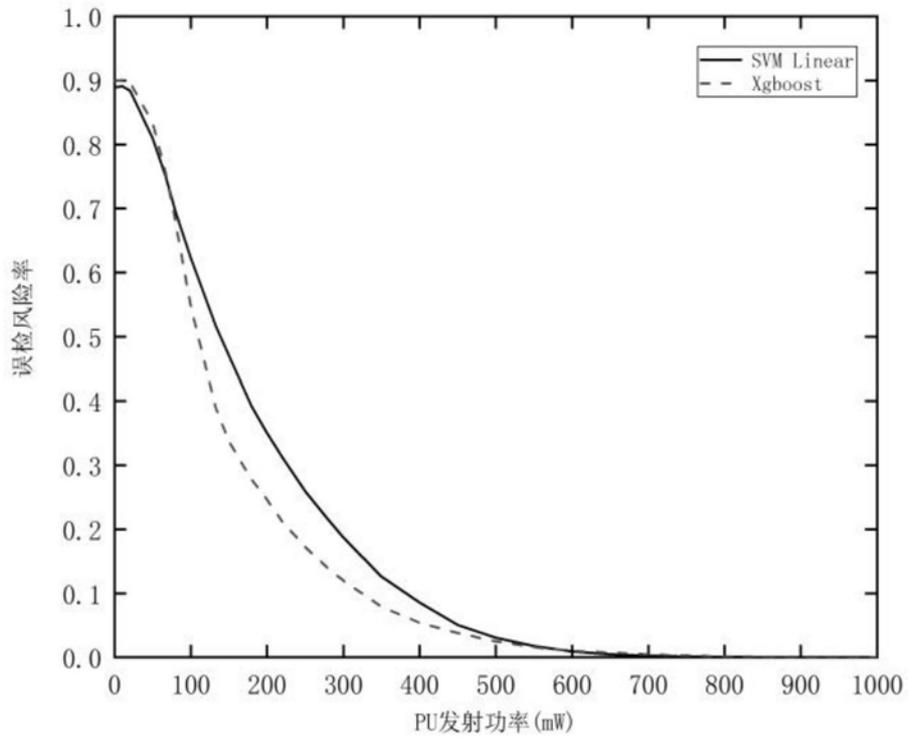


图5

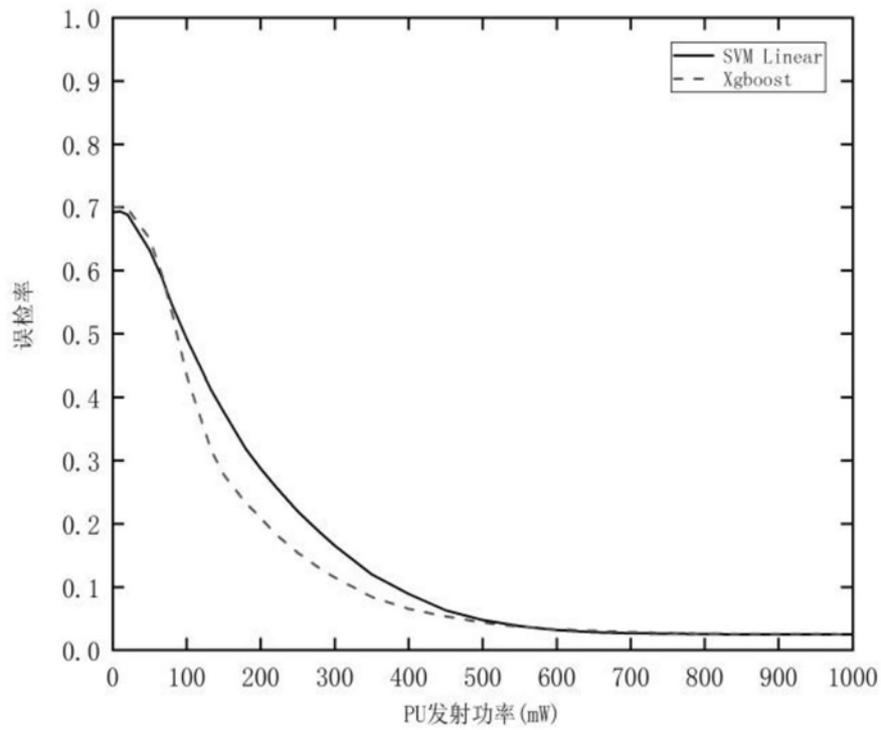


图6