

# 基于贝叶斯优化 XGBoost 的协作频谱感知算法

胡延飞 郭滨 孙佳楠

(长春理工大学电子信息工程学院 吉林 长春 130022)

**摘要** 为了提高无线信道环境的频谱感知性能,提出一种基于贝叶斯优化 XGBoost 的协作频谱感知算法。在一个主用户(PU)和三个次用户(SU)的协作频谱感知场景下,提取信号的归一化能量特征,采用贝叶斯优化算法同时优化 XGBoost 模型的多个超参数,最后利用优化 XGBoost 算法实现待检测信号的分类。仿真结果表明,与传统频谱感知算法和 KNN、GNB、SVM、MLP 等机器学习算法相比,该算法在 Rayl 和 AWGN 信道环境检测准确率分别为 88.4% 和 90.25%,可以有效提高不同信道环境下的协作频谱感知性能。

**关键词** 认知无线电 频谱感知 贝叶斯优化 XGBoost

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.07.019

## COOPERATIVE SPECTRUM SENSING ALGORITHM BASED ON BAYESIAN OPTIMIZED XGBOOST

Hu Yanfei Guo Bin Sun Jianan

(College of Electronic Information Engineering, Changchun University of Science and Technology, Changchun 130022, Jilin, China)

**Abstract** In order to improve the spectrum sensing performance of the wireless channel environment, a cooperative spectrum sensing algorithm based on Bayesian optimization XGBoost is proposed. In a cooperative spectrum sensing scenario of a primary user (PU) and three secondary users (SU), the normalized energy characteristics of the signal were extracted. The Bayesian optimization algorithm was used to optimize multiple hyperparameters of the XGBoost model at the same time, and the optimized XGBoost algorithm was used to realize the classification of the signal to be detected. The simulation results show that compared with traditional spectrum sensing algorithms and machine learning algorithms such as KNN, GNB, SVM, MLP, the detection accuracy of this algorithm under Rayl and AWGN channel are 88.4% and 90.25%, respectively, which can effectively improve the cooperative spectrum sensing performance in different channel environments.

**Keywords** Cognitive radio Spectrum sensing Bayesian optimization XGBoost

## 0 引言

近年来由于通信行业的快速发展,人们对无线信道的需求越来越高,导致无线频谱资源越来越稀缺<sup>[1]</sup>。调查显示,有大量的无线频谱资源在数据传输过程中未被充分利用,并且存在许多闲置的空闲频谱资源<sup>[2]</sup>。目前,人们将认知无线电技术(CR)作为解决频谱利用率低的关键技术<sup>[3]</sup>。认知无线电技术是一种通过提高整体频谱利用率来克服频谱短缺的解决方案,它可以

根据感知结果调整自身的运行参数从而动态地利用不同信道上的空闲频谱资源<sup>[4]</sup>。

频谱感知技术主要通过信号检测来判断频谱是否空闲,是认知无线电系统的一项核心技术<sup>[5]</sup>。在认知无线电系统中,频谱感知算法要求能够准确感知,快速高效地捕捉到频谱空洞,前者尽量降低次用户(SU)对主用户(PU)的有害干扰,后者则提供了更多的频谱机会使认知用户接入<sup>[6]</sup>。针对感知环境的差异,频谱感知算法的研究经历了单节点频谱感知、协作频谱感知和多维度频谱感知等多个阶段,为频谱分配和共享奠

定了基础。然而,协作频谱感知一直面临诸如参数阈值优化、信道检测性能、频谱感知数据不确定性量化以及感知算法高计算复杂性等挑战<sup>[7]</sup>。

针对协作频谱感知面临的上述挑战,近年来,基于机器学习的协作频谱感知算法已广泛应用于认知无线电技术研究中。Thilina 等<sup>[8]</sup>提出基于支持向量机(SVM)、加权 K 近邻、K-means 聚类和高斯混合模型(GMM)等机器学习算法,以提高协作频谱感知性能。Azmat 等<sup>[9]</sup>将高斯朴素贝叶斯(GNB)算法应用于认知无线网络频谱感知中,获得了较好的频谱感知性能。Winston 等<sup>[10]</sup>比较了两种流行的神经网络结构,多层感知器(MLP)和径向基(RBF)神经网络在认知无线电模型中的应用,通过寻找最适合的空闲信道来分配次用户(SU)。束学渊等<sup>[11]</sup>提出一种基于 XGBoost 与协方差特征的频谱感知算法,获得了比支持向量机算法、随机森林(RF)算法及传统最大最小特征(MME)算法更高的检测性能。

然而,在机器学习算法训练中,迭代次数太少容易造成欠拟合,导致模型的问题求解能力不足,迭代次数过多可能导致过拟合,使得模型表达训练数据能力过强而泛化性能较低。因此,本文提出使用全局优化算法——贝叶斯优化算法(Bayesian Optimization Algorithm, BOA)来同时优化 XGBoost 模型的多个超参数,从而提高该算法的频谱感知性能。

## 1 频谱感知系统模型

在认知无线网络(CRN)中,假设有一个主用户(PU)和  $M$  个次用户(SU)组成,其中每个 SU 以感知周期为  $\tau$  和感知带宽为  $w$  进行能量检测。采样频率是奈奎斯特速率  $f_s = 2w$ 。因此,次用户在每个感知周期获得  $K = 2\omega\tau$  个信号样本。设  $z_i(k)$  为第  $i$  个 SU 接收信号,第  $i$  个 SU 进行频谱感知问题通常被描述为一个二元假设问题,其表示为式(1)<sup>[12]</sup>。

$$z_i(k) = \begin{cases} n_i(k)H_0 \\ h_i x(k) + n_i(k)H_1 \end{cases} \quad (1)$$

式中: $h_i$ 为 PU 到第  $i$  个 SU 的信道系数; $x(k)$ 为发射的 PU 信号; $n_i(k)$ 为第  $i$  个 SU 接收到的均值为 0,方差为  $\sigma_n^2$ 的高斯随机噪声;信道系数  $h_i$ 由路径损耗和衰落分量来描述,如式(2)所示。

$$h_i = g_i D_i^{-\frac{\alpha}{2}} \quad (2)$$

式中: $g_i$ 是衰落分量; $D_i$ 是 PU 和第  $i$  个 SU 之间的欧几里得距离; $\alpha$ 为路径损耗指数, $\alpha = 4$ 。

在频谱感知周期结束时,估计的第  $i$  个 SU 的归一

化感知能量水平表示为式(3)。

$$y_i = \frac{1}{\sigma_n^2} \sum_{k=1}^K z_i(k)^2 \quad (3)$$

$H_0$ 假设下, $z_i(k) = n_i(k) \sim N(0, \sigma_n^2)$ ,因此, $y_i$ 将符合自由度为  $K$  的中心卡方分布,即  $y_i \sim \chi_K^2$ ,如式(4)所示。

$$y_i = \sum_{k=1}^K \left( \frac{n_i(k)}{\sigma_n} \right)^2 = \sum_{k=1}^K \hat{z}_i(k)^2 \quad (4)$$

式中: $\hat{z}_i(k) \sim N(0, 1)$ 。

$H_1$ 假设下,第  $i$  个 SU 接收信号是由信道增益缩放的 PU 信号和高斯接收机噪声组成。如果假设发射的 PU 信号是方差为  $\sigma_s^2$ 的零均值高斯随机变量,那么估计的能量水平将符合形状参数为  $K/2$ ,尺度参数为  $2(1 + \gamma_i)$ 的伽马分布,即  $y_i \sim \Gamma\left(\frac{K}{2}, 2(1 + \gamma_i)\right)$ ,如式(5)所示。

$$y_i = \sum_{k=1}^K \left( \frac{h_i x(k) + n_i(k)}{\sigma_n} \right)^2 = \sum_{k=1}^K \hat{z}_i(k)^2 \quad (5)$$

式中: $\hat{z}_i(k) \sim N\left(0, 1 + \frac{h_i^2 \sigma_s^2}{\sigma_n^2}\right)$ ;  $\gamma_i$ 为信噪比,  $\gamma_i = (h_i \sigma_s / \sigma_n)^2$ 。

在传统能量检测方案中,每个 SU 通过将归一化感知能量水平  $y_i$ 与给定阈值  $\lambda$  进行比较来获得当前频谱占用状态  $s_i$ ,如式(6)所示。

$$s_i = \begin{cases} H_1 & y_i \geq \lambda \\ H_0 & y_i < \lambda \end{cases} \quad (6)$$

频谱感知虚警概率和检测概率分别为  $P_{fa}$ 和  $P_d$ ,其中  $P_{fa} = P(y \geq \lambda | H_0)$ ,  $P_d = P(y \geq \lambda | H_1)$ 。因此,给定假设  $H_0$ 的统计量,可以将第  $i$  个 SU 的虚警概率  $P_{fa}$ 写为一个中心卡方随机变量的右尾概率,如式(7)所示。

$$P_{fa} = \int_{\lambda}^{\infty} f(y_i | H_0) dy \triangleq Q_{\chi_N^2}(\lambda) \quad (7)$$

相反地,通过固定目标虚警概率  $P_{fa}^*$ ,由式(7)求得阈值参数  $\lambda$ :

$$\lambda = Q_{\chi_N^2}^{-1}(P_{fa}^*) \quad (8)$$

同样,给定阈值参数  $\lambda$ ,可以将第  $i$  个 SU 的检测概率计算为形状参数为  $K/2$ ,尺度参数为  $2(1 + \gamma_i)$ 的伽马分布的右尾概率,如式(9)所示。

$$P_{d_i} = \int_{\lambda}^{\infty} f(y_i | H_1) dy \triangleq Q_{\Gamma}(\lambda; K/2, 2(1 + \gamma_i)) \quad (9)$$

## 2 传统协作频谱感知算法

协作频谱感知是指每个 SU 分别进行本地频谱感知,将本地感知能量水平结果通过服务层发送至融合中心<sup>[13]</sup>;融合中心采用确定性决策规则,通过组合服务单元的单个决策来协作判决频谱占用状态。下面讨

论两种主要确定性决策规则,即 AND、OR 准则。

## 2.1 AND(与)准则

AND 准则是指融合中心将每个 SU 的感知结果做“与”运算<sup>[13]</sup>。当所有 SU 的感知结果为 PU 存在时,判决 PU 信号存在;若有一个 SU 感知到 PU 不存在时,判决 PU 信号不存在<sup>[14]</sup>。根据 AND 准则,融合中心通过将检测到的每个 SU 的能量水平  $y_i$  与式(8)的阈值  $\lambda$  进行比较,然后对每个 SU 的感知结果进行“与”运算来决定频谱占用状态。

$$S = \begin{cases} 1 & s_1 \odot s_2 \odot \dots \odot s_N = 1 \\ 0 & \text{其他} \end{cases}$$

式中: $\odot$ 表示逻辑“与”运算符。

## 2.2 OR(或)准则

OR 规则类似于 AND 准则,它将每个 SU 的能量水平  $y_i$  与阈值  $\lambda$  进行比较,然后对每个 SU 的感知结果进行“或”运算来决定频谱占用状态。

$$S = \begin{cases} 1 & s_1 \oplus s_2 \oplus \dots \oplus s_N = 1 \\ 0 & \text{其他} \end{cases}$$

式中: $\oplus$ 表示逻辑“或”运算符。

# 3 算法设计

## 3.1 XGBoost 算法原理

XGBoost (Extreme Gradient Boosting) 是由 CHEN 等设计的以梯度提升为框架的集成算法<sup>[15]</sup>。基本思想是将多个准确率较低的基分类器集成为一个准确更高的集成分类器,通过多次迭代、降低偏差来不断提升算法的准确率。

### 3.1.1 XGBoost 算法损失函数

XGBoost 算法是通过最小化损失函数来构建最优模型,而损失函数表示为模型的训练误差加上模型复杂度的正则项<sup>[16]</sup>。因此损失函数表示为:

$$L = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (10)$$

式中: $l(y_i, \hat{y}_i)$ 为训练模型对样本  $x_i$  的训练误差; $\Omega(f_k)$ 表示第  $k$  棵树的正则惩罚项。

根据式(10),进行  $t$  次迭代构建学习模型,由前向分布算法可知,目标损失函数可以表示为式(11)。

$$L^t = \sum_{i=1}^n l(y_i, \hat{y}_i^{t-1} + f_i(x_i)) + \Omega(f_i) + C \quad (11)$$

由于 XGBoost 算法对应模型是由多棵 CART 树累加而成,定义每棵树的复杂度为式(12)。

$$\Omega(f_i) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (12)$$

式中: $T$ 为叶节点个数; $\gamma$ 和  $\lambda$ 为模型的惩罚系数; $\omega_j$ 为每棵树叶节点的分数。将式(12)代入式(11),则 XGBoost 目标损失函数可以改写为式(13)。

$$L^t = \sum_{i=1}^n l(y_i, \hat{y}_i^{t-1} + f_i(x_i)) + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 + C \quad (13)$$

对式(13)使用二阶泰勒公式展开,同时考虑对于第  $t$  棵树, $l(y_i, \hat{y}_i^{t-1})$ 为常数,去除所有常数项,令  $G_j = \sum_{i \in I_j} g_i, H_j = \sum_{i \in I_j} h_i$ ,进一步化简为式(14)。

$$L^t \approx \sum_{i=1}^n \left[ l(y_i, \hat{y}_i^{t-1}) + g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \Omega(f_i) + C = \sum_{j=1}^T \left[ \left( \sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left( \sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T \quad (14)$$

式中: $g_i = \partial_{\hat{y}_i^{t-1}} l(y_i, \hat{y}_i^{t-1})$ 和  $h_i = \partial_{\hat{y}_i^{t-1}}^2 l(y_i, \hat{y}_i^{t-1})$ 分别表示预测误差对当前模型的一阶导和二阶导。

对  $\omega_j$ 求偏导,并令其导数为0,则有式(15)。

$$G_j + (H_j + \lambda) \omega_j = 0 \quad (15)$$

$$\text{解得: } \omega_j^* = -\frac{G_j}{H_j + \lambda}.$$

则 XGBoost 目标损失函数最优值为式(16)。

$$L^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (16)$$

式中: $L^*$ 为评价树结构好坏的打分函数。

### 3.1.2 最优树结构求解

XGBoost 算法依据打分函数  $L^*$  使用贪心算法一层一层枚举不同的树结构来求出一个最优结构树加入到迭代模型当中<sup>[16]</sup>。在构建决策树时,最优分割可以通过计算每种特征的信息增益 Gain,如式(17)所示。

$$G_{\text{aim}} = \frac{1}{2} \left[ \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (17)$$

根据式(17)计算切分增益, Gain 值越大,说明分割后能使目标函数减少得越多,分类效果越好。

## 3.2 贝叶斯优化 XGBoost

贝叶斯优化算法是使用贝叶斯推理和高斯过程在尽可能少的迭代中寻找未知函数的最小值或最大值<sup>[17]</sup>。贝叶斯优化是一种逼近思想,当计算非常复杂、迭代次数较高时能起到很好的效果,多用于超参数确定。基本思想是基于数据使用贝叶斯定理估计目标函数的后验分布,然后再根据分布选择下一个采样的超参数组合。它充分利用了前一个采样点的信息,其优化的工作方式是通过目标函数形状的学习,并找到使结果向全局最大提升的参数<sup>[18]</sup>。本文通过对 XGBoost 模型的学习率 (learning\_rate)、最大深度 (max\_depth)、子叶个数 (min\_child\_weight) 等多个超参数进

行同时优化,以提高频谱感知性能。

### 3.2.1 高斯过程

高斯过程用于对贝叶斯优化中的目标函数建模并获得其后验分布<sup>[19]</sup>。在优化算法中确定 XGBoost 模型的超参数搜索空间  $x$ , 搜索空间有限参数的任何线性组合将具有联合高斯分布。

$$f(x) \sim gp(m(x), k(x, x')) \quad (18)$$

式中:  $f(x)$  为  $x$  的目标函数,  $m(x) = E(f(x))$  为  $f(x)$  的数学期望,  $k(x, x')$  表示  $x$  的协方差函数。平均绝对误差 (MAE) 的计算公式如式 (19) 所示。

$$MAE(X, H) = \frac{1}{m} \sum_{i=1}^m |h(x^i) - y^i| \quad (19)$$

式中:  $h(x^i)$  为 XGBoost 算法的预测输出值,  $y^i$  为预测结果当前所产生的实际误差。

### 3.2.2 提取函数

提取过程是把相应的参数组合点代入高斯模型中, 便能够得到相应的平均数和方差, 随着样本数量的增加, 则后验概率与实数之间的差异将越来越小。提取过程分为两步:

(1) explore, 通过对未检验的参数组合进行挑选, 探索新的空间, 有助于估计更准确的目标函数  $f(x)$ 。

(2) exploit, 通过已经得到的最优值  $f(x^+)$ , 对该数值周围进行大范围搜索。

提取函数 (PI) 是用来寻找下一个超参数搜索空间  $x$  的函数, 表示  $x$  对应目标函数值比当前最优值大多少的概率。提取函数表示如式 (20) 所示。

$$PI(x) = \phi\left(\frac{m(x) - f(x^+) - \varepsilon}{\sigma(x)}\right) \quad (20)$$

式中:  $f(x^+)$  为目前最优的  $x$  的目标函数值;  $\phi(\cdot)$  代表正态累计分布函数;  $m(x)$  和  $\sigma(x)$  分别是高斯过程所得到的目标函数的均值和方差, 即  $f(x)$  的后验分布,  $\varepsilon$  为 trade-off 系数。

为了提取函数能在超参数空间进行最大限度的搜索, 避免仅搜索  $f(x^+)$  周围的最优值, 通过改变  $\varepsilon$  系数的值, 可以选择接下来向 explore 或 exploit 方向搜索所求参数最优值。贝叶斯优化的最终目的是在提取过程中得到能够让  $f(x)$  达到最大或最小值的  $x$  值。

### 3.3 频谱感知算法实现步骤

基于贝叶斯优化 XGBoost 的协作频谱感知算法具体实现步骤如下:

(1) 构建协作频谱感知场景, 设置频谱感知系统参数, 采集每个 SU 的归一化能量水平。

(2) 将采集到的数据作为特征向量, 分为训练样本和测试样本。

(3) 设置 XGBoost 模型的初始参数并进行预训练, 使用贝叶斯优化算法对模型参数进行连续调整。

(4) 判断是否达到最大迭代次数或终止条件, 如果达到最大次数, 则将此时的训练参数值作为模型的最优参数, 否则返回步骤 (3)。

(5) 将测试样本输入到经过训练的 XGBoost 模型中, 以实现 PU 信号的频谱感知。

## 4 实验结果与分析

实验仿真基于软件 MATLAB 和 Python, 由 MATLAB 生成训练数据和测试数据, 利用 Python 进行仿真验证本文算法的频谱感知性能, 并传统 AND、OR 准则频谱感知算法和 KNN、GNB、SVM、MLP 四种机器学习算法进行比较。实验采用  $5 \times 10^4$  次蒙特卡罗仿真模拟, 考虑如图 1 所描述的具有一个 PU 和三个 SU 的协作频谱感知场景, 以及分别在加性高斯白噪声 (AWGN) 信道和瑞利平坦衰落 (Rayl) 信道下分析不同蒙特卡罗仿真参数的频谱感知性能。蒙特卡罗仿真采用的系统参数如表 1 所示。

表 1 蒙特卡罗模拟采用的系统参数

参数	数值
带宽/MHz	$w = 5$
采样频率/MHz	$f_s = 10$
噪声功率谱密度/(dBm/Hz)	$\eta_0 = -152$
PU 先验概率	$P(H_1) = 0.5$
PU 传输功率/mW	$\sigma_s^2 = 0.1$
$SU_1 \rightarrow PU$ 距离/m	500
$SU_2 \rightarrow PU$ 距离/m	750
$SU_3 \rightarrow PU$ 距离/m	1 000
感知时间间隔/ $\mu s$	$\tau = 5$
样本数	$K = 2w\tau = 50$
训练数据集	$k \in [50; 200; 400; 800; 1\ 000]$




图 1 频谱感知的 PU、SU 位置示意图

### 4.1 加性高斯白噪声信道 (AWGN) 下的频谱感知性能

图 2 比较了 AWGN 信道下本文算法与 KNN、GNB、SVM、MLP 四种机器学习频谱感知算法的 ROC 曲线。随着虚警概率的增加,本文算法的频谱检测概率高于 KNN、GNB、SVM、MLP 四种机器学习算法。图 3 比较了 AWGN 信道下每个 SU 单独进行能量检测以及采用 AND、OR 准则传统频谱感知算法的 ROC 曲线。由于 PU 与各个 SU 之间存在距离差异,各个 SU 获得的平均 SNR 分别为  $\tilde{\gamma}_1 \approx -2$  dB,  $\tilde{\gamma}_2 \approx -9$  dB 和  $\tilde{\gamma}_3 \approx -14$  dB。距离 PU 越近的 SU 受到的噪声干扰越小,获得的频谱检测性能越好,距离 PU 越远的 SU 受到的噪声干扰越大,获得的频谱检测性能越差。这种距离差异导致在每个 SU 频谱检测性能变化较明显。 $SU_1$  的频谱感知性能远远优于  $SU_2$  和  $SU_3$  频谱感知性能。




图 2 AWGN 信道下不同频谱感知方案的 ROC 曲线




图 3 AWGN 信道下 SU 单独能量检测及传统 AND、OR 准则的 ROC 曲线

### 4.2 瑞利衰落信道 (Rayl) 下的频谱感知性能

图 4 比较了 Rayl 信道下本文算法与 KNN、GNB、SVM、MLP 四种机器学习算法的协作频谱感知性能。随着虚警概率的增加,本文算法的频谱检测概率与其他机器学习算法差异逐渐增大。图 5 比较了 Rayl 信

道下每个 SU 单独进行能量检测以及采用 AND、OR 等传统频谱感知算法获得的 ROC 曲线。图 4 和图 5 对比发现,基于 KNN、GNB、SVM、MLP 四种机器学习算法比 AND、OR 准则传统频谱感知算法具有更好的频谱检测性能。




图 4 瑞利衰落信道下不同频谱感知方案的 ROC 曲线




图 5 瑞利衰落信道下 SU 单独能量检测及传统 AND、OR 准则的 ROC 曲线

### 4.3 算法性能比较分析

为了更好地评估每种频谱感知算法的感知性能,可以通过比较每种算法在仿真曲线下面积 (AUC) 和信道状态预测的准确率来进行评估。仿真结果如图 6 和表 2 所示。图 6 比较了 AWGN 和 Rayl 信道下不同机器学习算法信道状态预测准确率。首先,在 AWGN 信道下预测准确率高于 Rayl 信道下预测 3% 的准确率;其次,在 AWGN 和 Rayl 信道下,本文算法的频谱感知准确率分别为 90.25% 和 88.4%,均优于其他几种算法。此外,从表 2 中可以发现,在两种不同的信道下,基于机器学习的频谱感知算法比传统 AND、OR 准则频谱感知算法在 AUC 度量方面表现得更好。基于贝叶斯优化 XGBoost 算法实现了更高的准确率和更高的 AUC 值。

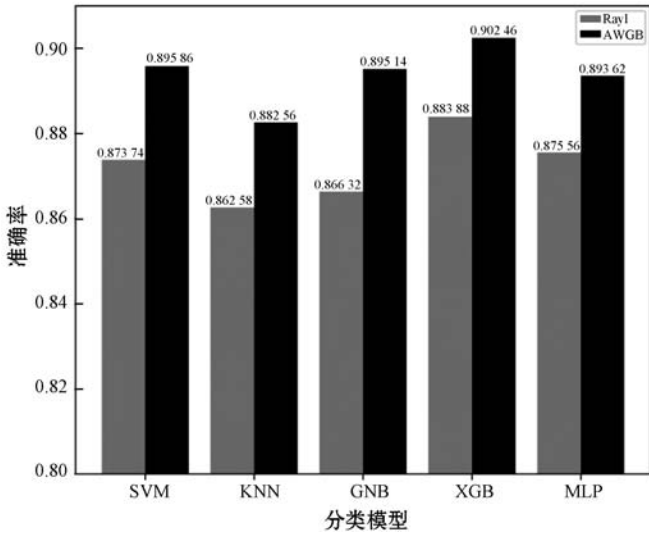


图 6 各分类模型在不同信道条件下的准确率

表 2 AWGN 和 Ray1 信道 AUC 仿真结果

频谱感知方法	AUC AWGN	AUC Ray1
AND	0.710 61	0.736 90
OR	0.931 32	0.927 10
KNN	0.945 78	0.920 71
GNB	0.961 81	0.926 73
MLP	0.960 39	0.937 84
SVM	0.962 47	0.938 21
XGB	0.967 58	0.949 58

图 7 和图 8 通过调整 PU 传输功率来提高每种频谱感知方案的感知性能所绘制的不同频谱感知方案的 AUC 度量图以及信道状态预测的准确率图。其中,当 PU 传输功率为 0.2 mW 时,信道状态预测准确率大约为 98%,AUC 值也接近于 1。随着 PU 传输功率的增大,每种频谱感知方案的感知性能均有很大程度的提高。




图 7 随着 PU 传输功率增加不同频谱感知方案准确率




图 8 随着 PU 传输功率增加频谱感知 AUC 变化结果

为了评估训练样本对瑞利衰落信道下 AUC 度量的影响,适当调整训练集的大小。训练集从  $k = 50$  到  $k = 1\ 000$  间隔取值,从而比较不同训练集下训练样本数量对 Ray1 信道 AUC 度量的影响。图 9 显示了随着训练样本的增加 AUC 的变化结果。显然,所有机器学习算法都受到训练集大小的影响,随着训练样本的增加,AUC 逐渐增加,并且 50 个样本和 400 个样本之间的差异最大。此外,本文还计算了各种机器学习算法频谱感知训练阶段的平均时间。随着训练样本的增加,训练时间增加。其中,GNB 算法的训练时间最短,KNN 算法的训练时间最长,贝叶斯优化 XGBoost 算法的训练时间少于其他两种算法,但与其他几种算法相比具有更好的检测性能。

表 3 频谱感知训练阶段的平均时间

频谱感知方法	训练时间/s
KNN	1.668
GNB	0.110
MLP	0.917
SVM	0.957
XGB	0.468




图 9 随着训练样本的增加 AUC 的变化结果

## 5 结 语

针对无线信道环境下频谱感知性能低的问题,提出一种基于贝叶斯优化 XGBoost 的协作频谱感知算法。贝叶斯优化算法用于同时优化对 XGBoost 模型有较大影响的多个超参数,从而优化 XGBoost 的性能。与传统的 AND、OR 准则频谱感知算法,以及 KNN、GNB、SVM、MLP 四种机器学习算法相比,提出的贝叶斯优化 XGBoost 算法显著提高了不同信道环境下频谱检测准确率。仿真结果表明,该算法可以很好地提高不同信道环境下的协作频谱感知性能,为认知无线电频谱感知的进一步发展提供了新的思路。

## 参 考 文 献

[1] Muchandi N, Khanai R. Cognitive radio spectrum sensing: A survey[C]//International Conference on Electrical, Electronics, and Optimization Techniques,2016:3233-3237.

[2] Wang W B, Kwasinski A, Niyato D, et al. A survey on applications of model-free strategy learning in cognitive wireless networks[J]. IEEE Communications Surveys Tutorials,2016,18(3):1717-1757.

[3] 王蕾. 宽带频谱感知技术研究[D]. 成都:电子科技大学,2020.

[4] 聂建园. 基于机器学习和压缩感知的认知无线电频谱感知研究[D]. 杭州:杭州电子科技大学,2020.

[5] Ali A, Hamouda W. Advances on spectrum sensing for cognitive radio networks: Theory and applications[J]. IEEE Communications Surveys and Tutorials,2017,19(2):1277-1304.

[6] 王晶萍. 认知无线电协作频谱感知方法研究[D]. 哈尔滨:哈尔滨工业大学,2019.

[7] Awe O P, Lambotharan S. Cooperative spectrum sensing in cognitive radio networks using multi-class support vector machine algorithms[C]//9th International Conference on Signal Processing and Communication Systems,2015:1-7.

[8] Thilina K M, Choi K W, Saquib N, et al. Machine learning techniques for cooperative spectrum sensing in cognitive radio networks[J]. IEEE Journal on Selected Areas in Communications,2013,31(11):2209-2221.

[9] Azmat F, Chen Y F, Stocks N. Analysis of spectrum occupancy using machine learning algorithms[J]. IEEE Transactions on Vehicular Technology,2015,65(9):6853-6860.

[10] Winston O, Thomas A, OkelloOdongo W. Comparing performance of MLP and RBF neural networks for TV idle channel prediction in cognitive radio[C]//Pan African International

Conference on Information Science, Computing and Telecommunications,2013:122-126.

[11] 束学渊,曹晓航. 基于 XGBoost 与协方差特征的频谱感知算法[J]. 软件导刊,2020,19(11):84-89.

[12] 林学峰. 认知无线电频谱感知技术研究[D]. 南京:南京邮电大学,2013.

[13] 陈思吉. 基于机器学习分类算法和数据库的频谱感知[D]. 重庆:重庆邮电大学,2019.

[14] 宋雅鑫. 基于压缩感知的非重构频谱感知算法研究[D]. 南京:南京邮电大学,2019.

[15] Chen T Q, Guestrin C. XGBoost: A scalable tree boosting system[C]//22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,2016:785-794.

[16] 束学渊,汪立新. 联合循环平稳特征 PCA 与 XGBoost 的频谱感知[J]. 计算机应用与软件,2020,37(4):114-118,126.

[17] 李斌,王卫星. NCA 降维和贝叶斯优化调参对分类模型的改进[J]. 计算机应用与软件,2019,36(8):281-287,299.

[18] 孙六英. 基于本福特定律和机器学习的网络入侵检测研究[D]. 武汉:武汉理工大学,2019.

[19] 李叶紫. 基于互信息和贝叶斯最优化的两种特征选择算法[D]. 广州:广东工业大学,2018.

## (上接第 92 页)

[2] 宁卓,李牧阳. 基于联盟区块链的物流信息平台 LIP-Chain[J]. 计算机技术与发展,2019,29(8):190-194.

[3] 龚葵,廖金花. 区块链技术的城市智能交通大数据平台及仿真案例分析[J]. 公路交通科技,2019,36(12):117-126.

[4] 李旭东. “区块链+物流”研究述评[J]. 广东交通职业技术学院学报,2019,18(4):42-47.

[5] 李牧阳. 基于联盟区块链的物流信息平台关键技术研究[D]. 南京:南京邮电大学,2019.

[6] 公路水运行业产品质量监督抽查管理办法(交科技规【2020】2号)[S]. 北京:交通运输部,2020.

[7] 杨永强,蔡宗辉,刘雅卓. 区块链+大数据分析[M]. 北京:机械工业出版社,2019.

[8] 李亚楠. 基于区块链的数据存储应用研究[D]. 北京:北京交通大学,2018.

[9] Ito K, Tago K, Jin Q. i-Blockchain: A blockchain-empowered individual-centric framework for privacy-preserved use of personal health data[C]//2018 9th International Conference on Information Technology in Medicine and Education, 2018:829-833.

[10] 蒋勇,文延,嘉文. 白话区块链[M]. 北京:机械工业出版社,2018.