

基于监督学习的协作宽带压缩 频谱检测方案

马 彬¹, 王宏明^{1,2}, 谢显中¹

(1. 重庆邮电大学移动通信技术重庆市重点实验室, 重庆 400065; 2. 重庆邮电大学通信与信息工程学院, 重庆 400065)

摘 要: 宽带压缩频谱检测存在信号稀疏度未知和次用户检测开销过大的问题. 因此, 本文提出一种高效的协作宽带压缩频谱检测方案. 首先, 推导了一种基于学习的稀疏度自适应预测模型. 其次, 设计了一种宽带频谱筛选算法. 最后, 提出一种协作宽带压缩频谱检测方案. 仿真结果表明, 自适应预测模型的拟合效果优于现有预测模型, 并且所提检测方案也有效地降低了次用户采样率和频谱重构时延.

关键词: 宽带频谱检测; 协作检测; 压缩感知; 稀疏度估计; 监督学习

中图分类号: TN929.5 **文献标识码:** A **文章编号:** 0372-2112 (2020)12-2338-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.12.008

A Collaborative Wideband Compressed Spectrum Sensing Scheme Based on Supervised Learning

MA Bin¹, WANG Hong-ming^{1,2}, XIE Xian-zhong¹

(1. Chongqing Key Laboratory of Mobile Communications Technology,

Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Wideband compressed spectrum sensing has the problems of unknown signal sparsity and high overhead of secondary users sensing. Therefore, this paper proposed an efficient cooperative scheme of wideband compressed spectrum sensing. Firstly, based on learning, a sparsity adaptive learning prediction model was derived. Secondly, a wideband spectrum filtering algorithm is designed. Finally, a cooperative wideband compressed spectrum sensing scheme was proposed. The simulation results show that the fitting effect of the adaptive prediction model are better than the existing prediction model, and the proposed sensing scheme effectively reduces the sampling rate and spectrum reconstruction delay of secondary users.

Key words: wideband spectrum sensing; collaborative sensing; compressed sensing; sparsity estimation; supervised learning

1 引言

频谱资源稀缺是未来通信技术发展所面临的重要挑战之一. 认知无线电 (Cognitive Radio, CR) 通过机会式的频谱接入策略提高频谱利用率^[1,2]. CR 中的频谱检测是保证次用户 (Secondary User, SU) 在不影响主用户的前提下充分利用空闲频谱的关键技术^[3]. 目前频谱管理机构已开始制定使用高频段的服务政策. 在高频段执行的宽带频谱检测技术需要克服传统采样定理

的高采样率问题^[4].

因此, 研究人员提出宽带压缩频谱检测方案^[5]. 该方案利用宽带信号的稀疏特性, 对信号进行随机亚抽样, 有效地降低了采样率^[6]. 在宽带压缩频谱检测中, 信号的稀疏度 k 是一个重要的参数, 反映了频谱的占用情况. 然而在实际中, 信号的 k 值是动态变化的. 为了实时预测稀疏度 k , 研究人员提出基于机器学习的稀疏度预测模型. 机器学习在 CR 网络中的带宽分配和频谱可用性估计等领域已被广泛应用^[7,8]. 与传统的预测模型

收稿日期: 2019-12-02; 修回日期: 2020-04-16; 责任编辑: 覃怀银

基金项目: 重庆市教委科学技术研究重大项目 (No. KJZD-M201900602); 重庆市基础研究与前沿探索项目 (No. CSTC2018jcyjAX0432); 重庆市研究生科研创新项目 (No. CYS19252)

相比,学习预测模型不需要某些严格的先验条件,适应性更强.

文献[9]将机器学习应用在窄带频谱检测中,利用能量向量作为特征向量训练分类器.文献[10]提出一种基于支撑向量机的窄带协作频谱检测方案.文献[11]利用深度强化学习使得次用户可以根据当前和过去的频谱检测结果分布式地做出切换决策.上述是机器学习在窄带频谱检测中的部分应用,而在宽带频谱检测中利用机器学习的研究则相对较少.文献[12]使用监督学习算法,在宽带压缩频谱检测中利用观测值等作为特征训练稀疏度预测模型.文献[13]使用支撑向量机建立频谱检测分类器,代替信号重构和检测的过程.

在宽带压缩频谱检测中,学习预测模型存在模型特征维度过高及无法动态更新观测值等问题.此外,方案在检测中对整个宽带谱重构,增加了采样成本和重构时间等开销.因此,本文首先提出利用采样向量二范数和子频谱块长度作为预测模型的特征向量,降低了模型的特征维度,提高了模型的拟合精度和自适应性.其次,提出一种基于协作的宽带频谱筛选算法,准确筛选出宽带频谱中的稀疏频谱集,降低了次用户采样率和信号重构时延.

2 当前压缩感知算法分析

系统模型如图 1 所示.假设宽带频谱长度为 N ,即有 N 个信道,每个信道只能容纳一个用户,将所有 SU 划分为 m 个 SU 群,每个 SU 群有 n 个 SU, SU_{ij} 表示第 i 个 SU 群的第 j 个 SU.

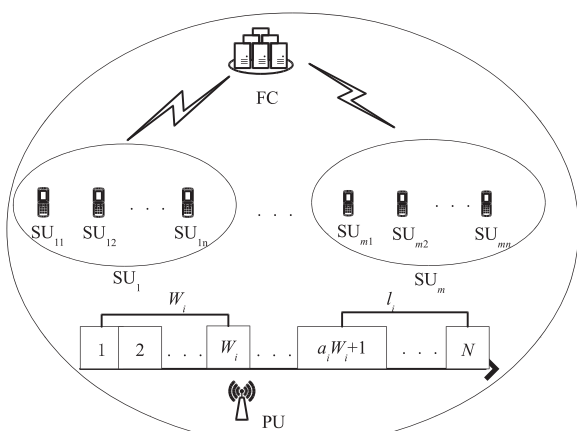


图1 系统模型

在该模型中,FC采用窗口机制为SU群提供不同的频谱划分方案,每个SU群都将划分整个宽带频谱. SU群具有不同的窗口大小,FC根据窗口大小将宽带谱分为若干子频谱块,即 $N = a_i W_i + l_i$, W_i 表示第 i 个SU群的窗口大小, a_i 表示第 i 个SU群中长度为 W_i 的子频谱

块数目, l_i 表示剩余频谱块长度.

宽带压缩频谱检测使用压缩感知理论采样.假设原始信号 s 的长度为 N ,在某个变换域的信号 $\mathbf{x} = \Psi s$, Ψ 是 $N \times N$ 的变换矩阵, \mathbf{x} 中有 k 个非零元素, $k \ll N$,称 \mathbf{x} 为 s 的 k 阶稀疏信号, k 为稀疏度.在该理论中,使用 $M \times N$ ($M \leq N$) 的感知矩阵 \mathbf{A} 获得观测向量 \mathbf{y} ,即 $\mathbf{y} = \mathbf{A}\mathbf{x} = \Phi \Psi s$, M 是观测值数目, Φ 是 $M \times N$ 的测量矩阵.研究表明,当 \mathbf{A} 满足约束等距性时^[14] 重构信号的问题为:

$$\hat{\mathbf{x}} = \operatorname{argmin} \|\mathbf{x}\|_0 \text{ s. t. } \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2 \leq \varepsilon \quad (1)$$

ε 表示误差, $\|\mathbf{x}\|_0$ 是指 \mathbf{x} 的 l_0 范数.

本文使用稀疏随机矩阵作为感知矩阵,该矩阵的每一列有 μM 个非零元素,且非零元素独立同分布.张波等证明了稀疏随机矩阵在观测值数目足够大时满足约束等距性^[15].假设稀疏随机矩阵 Θ 的每一列有 d 个非零元素,大小为 $1/\sqrt{d}$,对角矩阵 \mathbf{G} 的对角线元素等概率取 ± 1 .构造感知矩阵 $\mathbf{A} = \Theta \mathbf{G}$, \mathbf{A} 满足稀疏随机矩阵的定义.

3 基于监督学习的稀疏度预测模型

本节首先证明采样向量二范数作为特征之一的合理性,随后选取梯度下降法和支撑向量回归 (Support Vector Regression, SVR) 推导预测模型.

3.1 模型特征的选取

为了降低模型的特征维度,本文使用采样向量的二范数和子频带长度作为特征向量.

(1) Johnson-Lindenstrauss (JL) 定理:宽带信号的二范数可以反映频谱的占用水平,但压缩采样后无法计算其二范数.文献[4]描述了 JL 定理,该定理表明一个高维数据集可以被随机投影到一个低维的欧氏空间,并控制距离的失真.利用 JL 定理可以证明采样向量的二范数与宽带信号的二范数具有缩放关系,前者可以代替后者作为模型特征.

定理 1 (JL 定理) 对于一个 $r_0 \times N$ 维的投影矩阵 \mathbf{A} , $r_0 > Q\varepsilon^{-2} \log(0.5\delta)$, 参数 $\varepsilon \in (0, 1/2]$, 置信参数 $\delta \in (0, 1)$, Q 是一个常量,如果该矩阵每一个元素都是独立同分布且满足下面条件的随机变量 R :

- ① $E(R) = 0$;
- ② $D(R) = 1/r_0$;
- ③ 存在 $a > 0$, 对 \mathbf{A} 和所有 $\lambda > 0$, 有 $\operatorname{Prob}(|R| > \lambda) \leq 2e^{-a\lambda^2}$;

则向量 \mathbf{x} 满足 $(1 - \varepsilon) \|\mathbf{x}\|_2 \leq \|\mathbf{A}\mathbf{x}\|_2 \leq (1 + \varepsilon) \|\mathbf{x}\|_2$.

(2) 理论推导:下面根据 JL 定理证明 \mathbf{A} 满足 \mathbf{A} 的要求.

证明条件①:由离散随机变量的期望公式 $E(R)$

$= \sum_{i=1}^n R_i p_i$ 得:

$$E(R) = 0 \times p(0) + \frac{1}{\sqrt{d}} \times p\left(\frac{1}{\sqrt{d}}\right) + \left(-\frac{1}{\sqrt{d}}\right) \times p\left(-\frac{1}{\sqrt{d}}\right) \quad (2)$$

由于 $p\left(\frac{1}{\sqrt{d}}\right) = p\left(-\frac{1}{\sqrt{d}}\right) = \frac{d}{2M}$, 所以 $E(R) = 0$, 条件①得证.

证明条件②: 由随机变量的方差公式 $D(R) = E(R^2) - (E(R))^2$ 得:

$$D(R) = 0 \times p(0) + \frac{1}{d} \times \frac{d}{2M} + \frac{1}{d} \times \frac{d}{2M} \quad (3)$$

所以 $D(R) = 1/M$, 条件②得证.

证明条件③: 文献[16]给出亚高斯尾的定义并证明了定理 3.2, 利用亚高斯尾可以证明条件③.

定义 1 (亚高斯尾) 假设 X 是一个随机变量, 期望 $E(X) = 0$, 如果存在常量 $a > 0$, 对所有 $\lambda > 0$ 都有 $\text{Prob}(X > \lambda) \leq e^{-a\lambda^2}$, 则 X 具有亚高斯尾.

定理 2 假设 X 是一个随机变量且 $E(X) = 0$, 如果存在实数 C , 对所有 $u > 0$ 都有 $E(e^{uX}) < e^{Cu^2}$, 则 X 具有亚高斯尾.

首先计算 $E(e^{uX})$ 如下:

$$E(e^{uX}) = 1 - \frac{d}{M} + \frac{d}{2M} \times (e^{\frac{u}{\sqrt{d}}} + e^{-\frac{u}{\sqrt{d}}}) \quad (4)$$

令 $f(u) = E(e^{uX}) - e^{Cu^2}$, 则:

$$f(u) = 1 - \frac{d}{M} + \frac{d}{2M} (e^{\frac{u}{\sqrt{d}}} + e^{-\frac{u}{\sqrt{d}}}) - e^{Cu^2} \quad (5)$$

令 $g(u) = 2e^{\frac{u^2}{d} + \frac{u}{\sqrt{d}}} - e^{\frac{2u}{\sqrt{d}}} - 1$, 则:

$$g'(u) = 2e^{\frac{2u}{\sqrt{d}}} \left[\left(2 \frac{u}{\sqrt{d}} + 1 \right) e^{\frac{u^2}{d} - \frac{u}{\sqrt{d}}} - 1 \right] \quad (6)$$

令 $h(u) = \left(2 \frac{u}{\sqrt{d}} + 1 \right) e^{\frac{u^2}{d} - \frac{u}{\sqrt{d}}} - 1$, 则:

$$h'(u) = \left(4 \frac{u^2}{d} + 1 \right) e^{\frac{u^2}{d} - \frac{u}{\sqrt{d}}} \quad (7)$$

得到 $h'(u) > 0$, 且 $h(0) = 0$, 当 $u > 0$ 时, $h(u)$ 单调递增, 即 $h(u) > 0$, 所以 $g'(u) > 0$, 当 $u > 0$, $g(u)$ 单调递增, 且 $g(0) = 0$, 则:

$$2e^{\frac{u^2}{d}} > e^{\frac{u}{\sqrt{d}}} + e^{-\frac{u}{\sqrt{d}}} \quad (8)$$

将式(8)代入式(5), 令 $C = 1/d$, 则:

$$f(u) < \left(1 - \frac{d}{M} \right) (1 - e^{\frac{u^2}{d}}) \quad (9)$$

而 $d \in [1, M)$, $\left(1 - \frac{d}{M} \right) (1 - e^{\frac{u^2}{d}}) < 0$, 故 $E(e^{uX}) < e^{Cu^2}$.

根据定理 3.2, 对于 A 中的随机变量 X , 存在 $C = 1/d$, 当 $u > 0$, $E(e^{uX}) < e^{Cu^2}$ 成立, X 具有亚高斯尾,

$\text{Prob}(X > \lambda) \leq e^{-a\lambda^2}$. 同理, 当随机变量为 $-X$ 时, 有 $\text{Prob}(-X > \lambda) \leq e^{-a\lambda^2}$, 故 $\text{Prob}(|X| > \lambda) \leq 2e^{-a\lambda^2}$, 条件③得证.

综上, 矩阵 A 满足投影矩阵 Λ 的要求, 故 $(1 - \varepsilon) \|\mathbf{x}\|_2 \leq \|\mathbf{y}\|_2 \leq (1 + \varepsilon) \|\mathbf{x}\|_2$. 因此本文使用采样向量二范数和子频块长度作为预测模型的特征向量.

3.2 预测模型

下面利用特征向量推导预测模型. 模型的输入为特征向量 \mathbf{z} , $\mathbf{z} = [\|\mathbf{y}_{i1}\|_2, \dots, \|\mathbf{y}_{ij}\|_2, \dots, \|\mathbf{y}_{im}\|_2, s_i]$, $i \in [1, m]$, \mathbf{y}_{ij} 表示第 i 个 SU 群的第 j 个 SU 的采样向量, s_i 表示第 i 个 SU 群的子频谱块长度, 通过训练得到最优的权值向量 \mathbf{w} .

(1) 梯度下降法: 梯度下降法将预测函数建模为 $k_{\mathbf{w}}(\mathbf{z}) = b + \sum_{i=1}^{n+1} w_i z_i = \mathbf{w}^T \mathbf{z} + b$, b 为位移量, $k_{\mathbf{w}}(\mathbf{z})$ 为预测

结果. 代价函数 $J(\mathbf{w}) = \frac{1}{2} \sum_{l=1}^L (k_{\mathbf{w}}(\mathbf{z}^{(l)}) - k^{(l)})^2$, L 表示训练样本数目, $\mathbf{z}^{(l)}$ 表示第 l 组训练样本, $k^{(l)}$ 表示第 l 组训练样本的稀疏度. 使用梯度下降来搜索最优的 \mathbf{w} 来最小化 $J(\mathbf{w})$, 权值更新公式为 $\mathbf{w}_j = \mathbf{w}_j - \alpha \frac{\partial}{\partial \mathbf{w}_j} J(\mathbf{w})$.

(2) 支撑向量回归: SVR 的目标是寻找最佳线性回归函数 $k(\mathbf{z}) = \mathbf{w}^T \mathbf{z} + b$, 求解 \mathbf{w} 的优化问题如下:

$$\begin{aligned} \min_{\mathbf{w}} \quad & \frac{1}{2} \mathbf{w}^T \mathbf{w} + P \sum_{i=1}^l \xi_i + P \sum_{i=1}^l \xi_i^* \\ \text{s. t.} \quad & k_i(\mathbf{w}^T \mathbf{z}_i + b) < \varepsilon + \xi_i \\ & (\mathbf{w}^T \mathbf{z}_i + b) - k_i < \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \end{aligned} \quad (10)$$

其中 P 是惩罚因子, ξ_i 和 ξ_i^* 是松弛变量, ε 是误差. 这类约束优化问题通常使用对偶方法求解, 引入拉格朗日乘子 $\alpha, \alpha^*, \beta, \beta^*$, 得到其对偶问题为:

$$\begin{aligned} J = \quad & \frac{1}{2} \mathbf{w}^T \mathbf{w} + P \sum_i (\xi_i + \xi_i^*) \\ & + \sum_i \alpha_i [k_i - (\mathbf{w}^T \mathbf{z}_i + b) - \varepsilon - \xi_i] \\ & + \sum_i \alpha_i^* [(\mathbf{w}^T \mathbf{z}_i + b) - k_i - \varepsilon - \xi_i^*] \\ & - \sum_i \beta_i \xi_i - \sum_i \beta_i^* \xi_i^* \end{aligned} \quad (11)$$

J 分别对 \mathbf{w}, b, ξ_i 和 ξ_i^* 求偏导, 并令其为 0, 则:

$$\begin{cases} \frac{\partial J}{\partial \mathbf{w}} = \mathbf{w} - \left(\sum_i \alpha_i \mathbf{z}_i - \sum_i \alpha_i^* \mathbf{x}_i \right) = 0 \\ \frac{\partial J}{\partial b} = \sum_i (\alpha_i - \alpha_i^*) = 0 \\ \frac{\partial J}{\partial \xi_i} = P - \alpha_i - \beta_i = 0 \\ \frac{\partial J}{\partial \xi_i^*} = P - \alpha_i^* - \beta_i^* = 0 \end{cases} \quad (12)$$

将式(12)的解代入式(11)中可得:

$$\begin{aligned}
 J = & -\frac{1}{2} \sum_i \sum_j (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \mathbf{z}_i \mathbf{z}_j \\
 & - \sum_i (\alpha_i + \alpha_i^*) \varepsilon + \sum_i (\alpha_i - \alpha_i^*) (\mathbf{w}^T \mathbf{z}_i + b) \\
 \text{s. t. } & \sum_i \alpha_i - \alpha_i^* = 0, 0 \leq \alpha_i, \alpha_i^* \leq P
 \end{aligned} \quad (13)$$

式(13)是线性 SVR 的代价函数. 当数据集线性不可分时, 线性 SVR 无法达到最优回归, 可以使用核函数将数据集转换到高维空间, 以执行线性分离^[12]. 非线性 SVR 的代价函数为:

$$\begin{aligned}
 J = & -\frac{1}{2} \sum_i \sum_j (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(\mathbf{z}_i, \mathbf{z}_j) \\
 & - \sum_i (\alpha_i + \alpha_i^*) \varepsilon + \sum_i (\alpha_i - \alpha_i^*) (\mathbf{w}^T \mathbf{z}_i + b) \\
 \text{s. t. } & \sum_i \alpha_i - \alpha_i^* = 0, 0 \leq \alpha_i, \alpha_i^* \leq P
 \end{aligned} \quad (14)$$

其中 $K(\mathbf{z}_i, \mathbf{z}_j) = \varphi(\mathbf{z}_i)^T \varphi(\mathbf{z}_j)$, φ 是投影函数, 通常使用高斯核函数 $K(\mathbf{z}_i, \mathbf{z}_j) = e^{-\frac{\|\mathbf{z}_i - \mathbf{z}_j\|^2}{2\sigma^2}}$, σ 为宽度参数.

4 基于协作的宽带频谱压缩检测方案

本节提出一种协作宽带频谱筛选算法, 寻找宽带频谱中的稀疏频谱集, 并设计了宽带压缩频谱检测方案.

4.1 协作宽带频谱筛选算法

协作宽带频谱筛选算法如算法 1 所示. k_{ij} 为第 i 个 SU 群的第 j 个子频谱块的估计稀疏度, N_1 为集合 S_1 的长度, SUs 为请求接入的 SU 数目, M_e 是 SU 用于计算特征向量的采样数目.

算法 1 协作宽带频谱筛选算法

输入: 预测模型, 窗口大小 W_m, A, SUs, M_e

输出: 待重构频谱集

1. FC 将 SU 分为 m 个 SU 群, 每个 SU 群有 n 个 SU;
2. FC 依据窗口大小 W_m 划分宽带频谱;
3. 每个 SU 群的 n 个 SU 对其所划分的子频谱块进行特征采样, 采样数目 M_e , 并将特征向量输入预测模型, 得到相应子频谱块的 k_{ij} ;
4. 每个 SU 群根据预测的 k_{ij} 划分子频带的占用水平是高还是低, 并将结果发送给 FC;
5. FC 对所有标记为占用水平低的频谱块做交集得到最稀疏频谱集 S_1 , 对所有标记为占用水平高的频谱块做并集得到次稀疏频谱集 S_2 ;
6. 利用预测模型得到 S_1 和 S_2 的稀疏度 k_1, k_2 , 比较 SUs 与 k_1 的大小, 如果 $SUs > N_1 - k_1$, 选择 S_2 作为稀疏频谱, 反之选择 S_1 ;
7. 将选择的稀疏频谱作为待重构频谱集

在该算法中, SU 通过协作, 找到稀疏频谱集, 再根

据 SUs 与稀疏频谱集的稀疏度大小, 决定待重构频谱集. 最终选取的待重构频谱集的长度和稀疏水平都远低于整个频谱, 降低了 SU 的检测开销.

4.2 宽带压缩频谱检测方案

宽带压缩频谱检测方案如图 2 所示, 分为模型训练、频谱筛选和频谱重构三个部分.

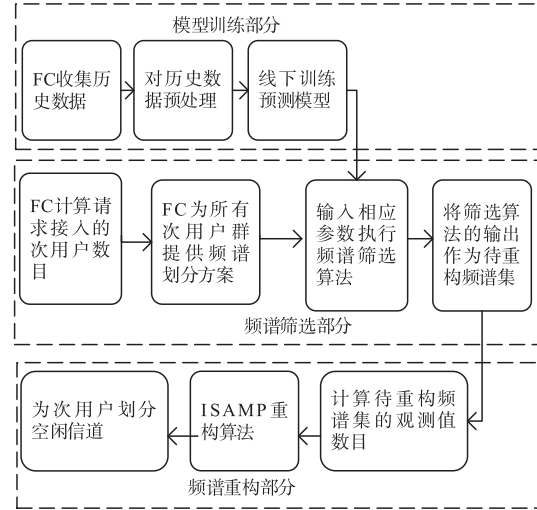


图2 宽带压缩频谱检测方案

模型训练采用线下训练线上调用的方式, FC 对历史数据进行预处理, 主要是对特征向量进行归一化, 得到训练模型. 在频谱筛选部分, SU 群根据频谱划分方案, 执行筛选算法. 频谱重构部分计算观测值数目 M , 使用改进的稀疏度自适应匹配追踪算法 (Improved Sparsity Adaptive Matching Pursuit, ISAMP)^[17] 进行重构, 为 SU 划分空闲信道.

为了提高重构精度, 重构算法选取 ISAMP 算法. ISAMP 算法在稀疏度自适应匹配追踪算法 (Sparsity Adaptive Matching Pursuit, SAMP)^[18] 的基础上增加了稀疏估计和步长调整. 与 SAMP 算法相比, ISAMP 算法重构准确度更高、重构时延更低.

5 仿真结果分析

为了分析所提方案的性能, 分别对预测模型和筛选算法进行仿真. 主要分析了模型估计精度、模型拟合效果, 频谱筛选效果和检测方案的效果. 部分参数设置如下: 数据集维度为 300, 训练集维度为 250, 测试集维度为 50, $N = 1200$, $M = 1.7k \log(N/k)$, $d = 4$, $m = 3$, $n = 5$, $M_e = 40$.

5.1 预测模型的拟合精度

图 3 是所提预测模型的拟合精度. 均方根误差 (Root Mean Square Error, RMSE) 表示模型的拟合精度, RMSE 越小拟合精度越高.

图 3(a) 是本文模型的 RMSE 随 n 变化的结果, 图 3(b) 是本文模型的 RMSE 随采样数目变化的结果. 由




图3 预测模型的RMSE

图3(a)可知,三者的RMSE总体随着 n 的增加而下降,当 n 在9左右时,RMSE趋于平稳,结果表明随着 n 的增加,模型的拟合精度越来越高,并趋于平稳.由图3(b)可知,随着采样数目的变化,模型的RMSE变化较小,三者都趋于稳定,这说明采样数目在一定范围内的

动态调整对预测模型影响较小.因为本文使用采样向量二范数作为特征,在模型训练成功后能够动态调整采样数目.而文献[12]使用采样向量作为特征,无法根据信号的实时变化调整采样数目,适应性较差.

5.2 预测模型的拟合效果对比

图4(a)是 $n=1$ 时文献[12]中模型的拟合结果,图4(b)是 $n=1$ 时本文模型的拟合结果,图4(c)是 $n=5$ 时本文模型的拟合结果.由图4(a)可知,文献[12]的模型拟合效果从好到差依次为线性SVR、非线性SVR和梯度下降法.由图4(b)可知,本文模型的拟合效果从好到差依次为线性SVR、非线性SVR和梯度下降法.由图4(c)可知,本文模型的拟合效果从好到差依次为非线性SVR、线性SVR和梯度下降法.对比图4(a)和图4(b)可得,在学习算法和 n 相同时,本文模型的 R^2 值均大于文献[12]中的 R^2 值,表明使用采样向量二范数能够显著提高预测模型的拟合效果.对比图4(b)和图4(c)可得,当 n 增加时,本文模型的拟合效果显著提升,线性SVR和非线性SVR的拟合效果较好.




图4 预测模型的拟合精度

5.3 频谱筛选效果

图5是频谱筛选算法的效果.图5(a)表示原始宽带信号,图5(b)表示频谱集 S_1 ,图5(c)表示频谱集 S_2 .仿真选择 S_1 作为待重构频谱集.由图5可知, S_1 和 S_2 都是宽带频谱中占用水平较低的频谱块.仿真表明,频谱筛选算法能够有效地筛选出宽带频谱中的稀疏频谱集,降低了待重构频谱的规模.

5.4 检测方案效果

本组实验从采样率和频谱重构时间两方面验证了

检测方案的效果,定义SU采样率为 M/N .

图6(a)是对采样率的比较,图6(b)是对频谱重构时延的比较.由图6(a)可知,文献[17]和文献[18]采样率是相同的,两者都使用理论观测值.而 S_1 的采样率低于 S_2 ,且都低于全频谱采样率.由图6(b)可知, S_1 和 S_2 的重构时延均低于全频谱重构时延.这是因为频谱筛选算法有效的剔除了宽带频谱中的密集分量,减小了待重构频谱集的长度.仿真表明本文的检测方案能够极大降低SU的检测开销.




图5 频谱筛选效果




图6 检测方案效果

6 结论

目前利用监督学习算法对宽带频谱检测的研究较少,本文设计了一种基于监督学习的协作宽带频谱检测方案.仿真结果表明所提检测方案能够准确重构稀疏频谱集,同时降低SU采样率和重构时延,提高预测模型的拟合效果和自适应性.

参考文献

- [1] MacDonald S, Popescu D C, Popescu O. Analyzing the performance of spectrum sensing in cognitive radio systems with dynamic PU activity[J]. IEEE Communications Letters, 2017, 21(9): 2037 – 2040.
- [2] Ali A, Hamouda W. Advances on spectrum sensing for cognitive radio networks; theory and applications[J]. IEEE Communications Surveys & Tutorials, 2017, 19(2): 1277 – 1304.
- [3] Haykin S. Cognitive radio; brain-empowered wireless communications[J]. IEEE Journal on Selected Areas in Communications, 2005, 23(2): 201 – 220.

- [4] Qin Z, Wang J, Chen J, et al. Adaptive compressed spectrum sensing based on cross validation in wideband cognitive radio system[J]. IEEE Systems Journal, 2017, 11(4): 2422 – 2431.
- [5] Tian Z, Giannakis G B. Compressed sensing for wideband cognitive radios[A]. 2007 IEEE International Conference on Acoustics, Speech and Signal Processing[C]. Honolulu, HI, USA: IEEE, 2007. 1357 – 1360.
- [6] Quan Z, Cui S, Sayed A H, et al. Optimal multiband joint detection for spectrum sensing in cognitive radio networks[J]. IEEE Transactions on Signal Processing, 2009, 57(3): 1128 – 1140.
- [7] He A, Bae K K, Newman T R, et al. A survey of artificial intelligence for cognitive radios[J]. IEEE Transactions on Vehicular Technology, 2010, 59(4): 1578 – 1592.
- [8] Bkassiny M, Li Y, Jayaweera S K. A Survey on machine-learning techniques in cognitive radios[J]. IEEE Communications Surveys & Tutorials, 2013, 15(3): 1136 – 1159.
- [9] Li Z, Wu W, Liu X, et al. Improved cooperative spectrum sensing model based on machine learning for cognitive radio networks[J]. IET Communications, 2018, 12(19): 2485 – 2492.
- [10] 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.
- [11] Chang H, Song H, Yi Y, et al. Distributive dynamic spectrum access through deep reinforcement learning: a reservoir computing-based approach[J]. IEEE Internet of Things Journal, 2019, 6(2): 1938 – 1948.
- [12] Khalfi B, Zaid A, Hamdaoui B. When machine learning meets compressive sampling for wideband spectrum sensing[A]. 2017 13th International Wireless Communications and Mobile Computing Conference[C]. Valencia, Spain: IEEE, 2017. 1120 – 1125.
- [13] 吕斌, 杨震, 林畅. 采用支持向量机的宽带频谱感知算法[J]. 信号处理, 2014, 000(012): 1502 – 1509.
Lv Bin, Yang Zhen, Lin Chang. Broadband spectrum sensing algorithms using SVM[J]. Journal of Signal Processing, 2014, 000(012): 1502 – 1509. (in Chinese)
- [14] Candes E J, Tao T. Decoding by linear programming[J]. IEEE Transactions on Information Theory, 2005, 51(12): 4203 – 4215.
- [15] 张波, 刘郁林, 王开. 稀疏随机矩阵有限等距性质分析[J]. 电子与信息学报, 2014, 36(1): 169 – 174.
Zhang Bo, Liu Yu-lin, Wang Kai. Restricted isometry property analysis for sparse random matrices[J]. Journal of Electronics and Information Technology, 2014, 36(1): 169 – 174. (in Chinese)

- [16] Matouek J. On variants of the johnson-lindenstrauss lemma[J]. Random Structures & Algorithms, 2008, 33(2): 142-156.
- [17] Guangyong Gao, Caixue Zhou, Zongmin Cui, et al. Improved sparsity adaptive matching pursuit algorithm[A]. 2017 3rd IEEE International Conference on Computer and Communications[C]. Chengdu, China: IEEE, 2017. 1761-1766.
- [18] Do T T, Gan L, Nguyen N, et al. Sparsity adaptive matching pursuit algorithm for practical compressed sensing[A]. Proceedings of the 42nd Asilomar Conference on Signals, Systems and Computers[C]. Pacific Grove, CA, USA: IEEE, 2008. 581-587.

作者简介



马彬 男, 1978 年生于四川宜宾, 现为重庆邮电大学教授, 主要研究方向为异构无线网络、认知无线网络等。
E-mail: mabin@cqupt.edu.cn



王宏明(通信作者) 男, 1994 年生于安徽芜湖, 现为重庆邮电大学通信与信息工程学院硕士研究生, 主要研究方向为认知无线网络。
E-mail: whm_cqupt@163.com



谢显中 男, 1966 年生于四川通江, 现为重庆邮电大学教授, 主要研究方向为干扰对齐与 MIMO 技术。
E-mail: xiexzh@cqupt.edu.cn