

BCS 实现的射频层析成像链路选择方法

郝晓曦^{1,2}, 杨志勇¹, 郭雪梅¹, 王国利¹

(1. 中山大学信息科学与技术学院, 广东广州 510006; 2. 五邑大学机电工程学院, 广东江门 529020)

摘 要: 针对压缩射频层析成像中随机链路选取策略无法有效避免选取冗余链路, 本文提出一种利用贝叶斯压缩传感实现的射频链路选择策略. 该策略首先通过定义链路冗余度和链路熵, 建立表示射频链路信息量与冗余度关系的最小熵链路决策模型, 其次将贝叶斯压缩传感所提供的自适应投影测量框架与最小熵链路决策模型结合, 最终实现链路选择和目标估计. 环境目标定位实验表明, 所提出的射频链路选择策略是有效的和可行的. 与随机选择策略比较, 其能够有效减少冗余或无关链路的选取, 提高传感效率.

关键词: 压缩射频层析成像; 射频链路选择; 贝叶斯压缩传感; 冗余链路

中图分类号: TN929.5, TP212.9

文献标识码: A

文章编号: 0372-2112 (2013) 12-2507-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2013.12.030

A Method of Link Selection for Radio Frequency Tomography with Bayesian Compressive Sensing

HAO Xiao-xi^{1,2}, YANG Zhi-yong¹, GUO Xue-mei¹, WANG Guo-li¹

(1. School of Information Science and Technology, Sun Yat-sen University, Guangzhou, Guangdong 510006, China;

2. School of Mechanical and Electrical Engineering, Wuyi University, Jiangmen, Guangdong 529020, China)

Abstract: A radio frequency (RF) link selection method based on Bayesian compressive sensing (BCS) is presented to efficiently avoid selecting redundant links with random measurement for compressed RF tomography. Firstly, link entropy and redundancy are defined, and then the minimum differential entropy link decision model is established, which indicates the relationship between the RF link information and redundancy. Secondly, the presented model is combined with BCS based adaptive projections measurement framework, to realize link selection and target estimation. Localization experiments illustrate efficiency and feasibility of the proposed method, which can efficiently avoid the selection of redundant links and improve the sensing efficiency compared with the random selection method.

Key words: radio tomographic imaging; link selection; Bayesian compressive sensing; redundant link

1 引言

射频层析成像是一种利用射频信号实现阴影衰落测量以获取环境图像的层析成像方法, 是无线射频技术和层析成像原理有机结合的产物^[1,2], 在智能环境监控^[3,4]、救援^[5]、勘探^[6]、医疗监护^[7]以及工业生产^[8,9]等领域中有着巨大的应用价值. 无线传感器网络是目前广泛采用的射频层析成像实现模式, 即在环境周围部署射频节点形成覆盖环境的射频传感网络^[10,11]. 在此模式下的射频层析成像包括 3 个环节: 链路选择、投影测量以及目标重构. 其中, 链路选择是指在射频传感网络中选择能够感知目标所需的射频链路, 投影测量是根据链路选择结果获取相应射频链路接收信号强度 (Received

Signal Strength, RSS) 数据, 目标重构是依据测量数据反演或推断环境目标影像^[2,12,13]. 显然, 链路选择是射频层析成像的首要任务, 是投影测量数据获取的依据, 也是目标重构的基础. 构建合理的射频链路选取策略是确保射频层析成像可行性和高效性的重要手段.

J. Wilsoon 和 N. Patwari 等人首次提出射频层析成像时, 采用射频传感网络中所有链路测量信息重构环境目标图像^[1,14]. 事实上, 环境状态中兴趣目标信息本质上是稀疏的, 因此压缩传感 (Compressed Sensing, CS) 理论^[15,16]适用于环境射频层析成像. 射频传感网络形成的通信链路可用于实现射频投影测量, 与压缩传感稀疏信号重构原理相结合, 形成压缩传感支配的射频层析成像机制, 即压缩射频层析成像技术^[7,17]. 压缩传感理论

指出,测量矩阵必须满足非相干条件才能保证高概率重构,其中随机矩阵已被证明满足非相干条件^[18,19].在压缩射频层析成像中,保证测量矩阵是随机矩阵的前提是链路必须随机选取,换句话说,压缩射频层析成像的链路选择策略是在没有先验知识的情况下,依赖随机方式选取测量链路有条件的保证目标图像的重构.因此随机链路选取方式不可避免涉及大量冗余或无关的链路,大大降低了压缩射频层析成像的实效性,成为制约压缩射频层析成像在实际应用的技术瓶颈.

针对无线射频传感网络实现模式的压缩传感效率技术瓶颈,特别是链路随机选取方式产生冗余链路的固有缺陷,本文提出一种利用贝叶斯压缩传感(Bayesian Compressive Sensing, BCS)^[18,20]实现的射频链路选择策略.从方法的角度看,通过定义链路冗余度和链路熵,建立表示射频链路信息量与冗余度关系的最小熵链路决策模型.从实现的角度看,利用贝叶斯压缩传感所提供的自适应投影测量框架与最小熵链路决策模型结合,实现链路选择.由此形成提升压缩传感效率的机制能够有效避免冗余或无关链路的选择,提高传感效率.实际环境目标定位实验表明,本文提出的射频链路选择策略是有效的和可行的.与随机选择策略比较,所提出的链路选择策略能够有效减少冗余或无关链路的选择,提高传感效率.

2 问题的提出

压缩射频层析成像的本质是利用少量射频链路测得的由目标所引发的 RSS 变化重构出 RSS 衰落分布状态影像,进而推断目标位置信息^[2,13].这一过程可以用如下数学形式表示^[18,19]:

$$\mathbf{r} = \Phi \mathbf{x} + \mathbf{n} \quad (1)$$

其中, $\mathbf{r} = \{r_i | i = 1, \dots, M\}$ 表示测量矢量, M 表示射频链路总数, r_i 表示第 i 次测量时所选链路测得的 RSS 值. $\mathbf{x} = \{x_j | j = 1, \dots, N\}$ 表示目标图像的像素值,目标图像像素值直接反映了相应位置发生阴影衰落的程度, N 表示目标图像像素总数. $\Phi = \{\phi_i | i = 1, \dots, M\}$ 表示投影向量按行组成的 $M \times N$ 的测量矩阵, ϕ_i 表示第 i 条链路对应的投影向量. $\mathbf{n} = \{n_i | i = 1, \dots, M\}$ 表示测量噪声矢量.

压缩射频层析成像中,一次测量表示在无线传感网络所建立的射频链路中选择一条射频链路.在测量过程中,依照射频链路选择策略选取射频链路,再根据所选择链路的位置及测得的 RSS 值建立对应的测量矩阵 Φ 以及测量矢量 $\mathbf{r}$,最后通过求解式(1)的逆问题,获得对目标位置的估计.由这一过程可以看出,射频链路选择策略是压缩射频层析成像过程中的关键问题.

链路选择策略的根本目的在于尽可能减少冗余链

路的选取,以提高射频层析成像的传感效率和实效性,降低网络资源的过度使用.压缩射频层析成像中,若目标图像 $\mathbf{x}$ 的稀疏度为 K 且稀疏位置已知时,仅需要 K 次测量即可获得重构结果.然而在实际测量过程中,没有任何先验信息的前提下,为确保重构结果的精度,往往需要大量的测量链路信息.由文献[15]可知,当以高概率重构目标图像时,所需的随机测量次数不应低于 $C \cdot K \cdot \log N$,因此随机测量中必然存在大量冗余链路.

针对压缩射频层析成像中随机测量无法有效避免冗余链路选取,本文提出的解决思路是:首先,建立链路携带信息量与链路冗余度之间的关系,找出判断链路是否冗余的依据.其次,建立便于实现的减少冗余链路的选择策略.由压缩传感理论可知,当测量投影包含足够的信息量时,则可以利用较少的测量实现目标重构.因此,利用信息论中熵理论建立链路的冗余度与所携带信息量的关系.

定义 链路熵表示一条链路所携带信息的多少,即增加该条链路前、后获得重构结果信息熵的变化,具体形式如下:

$$\Delta h = h(\mathbf{x}_m) - h(\mathbf{x}_{m+1}) \quad (2)$$

其中, Δh 表示链路熵. $\mathbf{x}_m = \mathcal{A}(\Phi_m, \mathbf{r}_m)$, $\mathbf{x}_{m+1} = \mathcal{A}(\Phi_{m+1}, \mathbf{r}_{m+1})$ 分别表示利用 m 条链路以及在 m 条链路的基础上增加一条链路所得到的重构结果, $h(\mathbf{x}_m)$, $h(\mathbf{x}_{m+1})$ 分别表示 $\mathbf{x}_m$, $\mathbf{x}_{m+1}$ 的熵.显然,当增加一条链路后获得的重构目标的不确定度一定小于等于没有增加该条链路获得的重构目标,即 $h(\mathbf{x}_m) \geq h(\mathbf{x}_{m+1})$.换句话说,当所增加的链路携带的信息量越大,增加链路后得到重构信号的不确定性越小,对应的熵也越小.我们定义无法使重构信号的不确定度减少的射频链路称之为冗余链路.根据式(2)可知,判断一条链路是否冗余可以通过判断增加该条链路前后获得重构结果的熵的差值 Δh 大小实现,即可以通过判断一条链路携带信息量的多少实现. Δh 越大,表明新增链路使得重构目标的不确定性越小,链路携带的信息量越大,链路的冗余越小.

在压缩射频层析成像中,假设目标图像满足多元高斯分布,且 m 条链路获得的重构结果 $\mathbf{x}_m$ 的方差为 Σ_m ,则根据文献[18,21], $\mathbf{x}_m$ 的微分熵表示为:

$$h(\mathbf{x}_m) = - \int p(\mathbf{x}_m) \log p(\mathbf{x}_m) d\mathbf{x}_m = \frac{1}{2} \log |\Sigma_m| + C \quad (3)$$

其中, C 是常数.同理,在 m 条链路的基础上增加一条链路获得的重构结果 $\mathbf{x}_{m+1}$ 微分熵表示为:

$$h(\mathbf{x}_{m+1}) = \frac{1}{2} \log |\Sigma_{m+1}| + C \quad (4)$$

其中, Σ_{m+1} 表示重构结果 $\mathbf{x}_{m+1}$ 的方差.将式(3)和(4)带

入式(2)得:

$$\Delta h = h(\mathbf{x}_m) - h(\mathbf{x}_{m+1}) = \frac{1}{2} \log |\Sigma_m| + C - \left(\frac{1}{2} \log |\Sigma_{m+1}| + C \right) = \frac{1}{2} \log \frac{\Sigma_m}{\Sigma_{m+1}} \quad (5)$$

式(5)表明,一条链路所携带信息量的多少可以由增加该条链路前后重构目标的方差比 Σ_m/Σ_{m+1} 决定,当 Σ_m/Σ_{m+1} 越大,链路携带的信息量越多。

经典压缩传感重构算法只能利用测量信息对重构目标进行估计,无法提供估计目标的误差推断,所以无法判断所选链路是否为冗余.而 BCS 作为一种求解压缩传感逆问题的新框架,能够提供一种自适应的测量机制^[20].这种机制下,概率模型能够同时估计重构目标的均值和方差,而方差估计可以作为自适应选取新增测量投影的判断依据.因此,本文将 BCS 引入到压缩射频层析成像中,提出了一种能够有效减少冗余链路的 BCS 链路选择策略。

利用 BCS 实现的冗余链路判断方法如图 1 所示.图 1 表明对于任意一条测量链路,先利用 BCS 方法估计链路重构目标时的方差,再根据方差估计,计算该条链路携带信息量的多少,以此判断链路是否为冗余.链路信息熵决策和方差估计的具体技术细节由下一节详细给出。




图1 BCS实现的冗余链路判断方法

3 主要结果

判断一条链路是否为冗余是以熵决策模型为判断依据.熵决策模型的核心任务是根据链路熵的定义,推导出可实现的链路冗余判断方法.方差估计是熵决策模型中用于判断冗余链路的重要参数.本节详细给出由熵决策推导出的链路选择方法,以及熵决策中误差的估计方法。

3.1 目标的方差估计

目标的方差估计是投影测量阶段作为降低新增链路冗余度的判断手段,它是根据 BCS 提供的机制将目标图像重构过程看作线性回归问题,利用稀疏贝叶斯学习对权值赋予先验条件概率分布,引入超参数,使超参数的边缘对数似然函数最大化来获得的.方差估计主要是根据已经选择链路的测量值通过 BCS 算法计算获得的。

假设由 m 条链路获得目标估计 $\mathbf{x}_m$ 服从均值为 0, 方差为 σ^2 的高斯先验分布,由贝叶斯准则可知^[9], $\mathbf{x}_m$ 的后验分布满足:

$$p(\mathbf{x}_m | \mathbf{r}_m, \alpha_m, \beta_m) \sim N(\mu_m, \Sigma_m) \quad (6)$$

其中, $\mu_m = \beta_m \sigma_m \Phi_m^T \mathbf{r}_m$, $\Sigma_m = \beta_m \Phi_m^T \Phi_m + \mathbf{A}_m$, $\mathbf{A}_m = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_m)$, α_m 和 β_m 是超参数.根据文献[21],估计参数 μ_m 和 Σ_m 的贝叶斯学习问题可转化为求解参数 α_m 和 β_m 问题.设参数 α_m 和 β_m 的对数边缘似然为:

$$\begin{aligned} L(\alpha_m, \beta_m) &= \log p(\mathbf{r}_m | \alpha_m, \beta_m) \\ &= \log \int p(\mathbf{r}_m | \alpha_m, \beta_m) p(\mathbf{x}_m | \alpha_m) d\mathbf{x} \\ &= -\frac{1}{2} [m \log 2\pi + \log |\mathbf{C}_m| + \mathbf{r}_m^T \mathbf{C}_m^{-1} \mathbf{r}_m] \end{aligned} \quad (7)$$

其中, $\mathbf{C}_m = \sigma^2 \mathbf{I} + \Phi_m \mathbf{A}^{-1} \Phi_m^T$.对式(7)求 II 型最大似然来估计超参数 α_m 和 β_m 的最优值 $\hat{\alpha}_m$ 和 $\hat{\beta}_m$. $\mathbf{x}_m$ 的后验估计均值和方差与 $\hat{\alpha}_m$ 和 $\hat{\beta}_m$ 的关系分别为:

$$\hat{\mu}_m = \hat{\beta}_m (\mathbf{A} + \hat{\beta}_m \Phi_m^T \Phi_m)^{-1} \Phi_m^T \mathbf{r}_m \quad (8)$$

$$\hat{\Sigma}_m = (\mathbf{A} + \hat{\beta}_m \Phi_m^T \Phi_m)^{-1} \quad (9)$$

由此获得 m 条链路获得目标的方差为 $\hat{\Sigma}_m$.

3.2 链路选择的熵决策

第二部分中,分析得到链路熵的计算只与对应重构目标的方差有关.将由 BCS 估计获得的 m 条链路的方差(式(9))带入式(3)得:

$$\begin{aligned} h(\mathbf{x}_m) &= \frac{1}{2} \log |\Sigma_m| + C \\ &= -\frac{1}{2} \log |\mathbf{A}_m + \hat{\beta}_m \Phi_m^T \Phi_m| + C \end{aligned} \quad (10)$$

其中, C 是与测量矩阵 Φ_m 无关的常数.同理,在 m 条链路的基础上增加一条链路后,对应的测量矩阵和重构结果分别为 Φ_{m+1} 和 $\mathbf{x}_{m+1}$,则 $\mathbf{x}_{m+1}$ 的微分熵表示为:

$$\begin{aligned} h(\mathbf{x}_{m+1}) &= -\frac{1}{2} \log |\mathbf{A}_{m+1} + \hat{\beta}_{m+1} \Phi_{m+1}^T \Phi_{m+1}| + C \\ &= h(\mathbf{x}_m) - \frac{1}{2} \log |1 + \hat{\beta}_{m+1} \Phi_{m+1}^T \Sigma_m \Phi_{m+1}| \end{aligned} \quad (11)$$

其中, Φ_{m+1} 表示新增一条链路在 Φ_{m+1} 中增加的行向量。

根据链路熵的定义,将式(10)和式(11)式带入式(5)得新增一条链路携带的信息量:

$$\Delta h = h(\mathbf{x}_m) - h(\mathbf{x}_{m+1}) = \frac{1}{2} \log (1 + \hat{\beta}_{m+1} \Phi_{m+1}^T \Sigma_m \Phi_{m+1}) \quad (12)$$

为确保新增链路的冗余度最小,新增链路携带的信息量需要尽可能大,即使得 Δh 最大.为确保 Δh 最大,新增链路对应的行向量 Φ_{m+1}^T 必须满足 $\Phi_{m+1}^T \Sigma_m \Phi_{m+1}$ 最大.因此,在已选择 m 条链路的基础上,增加一条链路的决策依据为:

$$\Phi_{m+1} = \arg \max \Phi_l^T \Sigma_m \Phi_l, l = 1, 2, \dots, M - m \quad (13)$$

其中, Φ_l 是在剩余的 $M - m$ 条链路中的遍历。

此处需要说明两点:(1)判断新增链路是否冗余时,利用了该条链路所对应的转换矩阵的行向量,而行

向量仅与链路部署有关,与具体的链路测量值无关;
(2)新增链路携带信息量只与没有增加该条链路时目标估计的误差值 Σ_m 有关.

4 实验结果与分析

4.1 无线传感网络实验环境构建

无线传感网络实验环境的搭建是在中山大学信息科学与技术学院实验室内,如图 3(a)所示.在一个 $4.5 \times 4.5 \text{m}^2$ 的房间内摆放着 18 个节点,每个节点之间的距离是 1m,节点距地面距离为 1m.网络节点是 MICAz,节点的工作频率为 2.4GHz,采用 IEEE802.15.4 标准通讯协议.节点的传输功率为 -10dBm.用一个节点作为基站,采集其它节点数据,并将数据通过 USB 接口传输到笔记本电脑里进行数据处理.为避免节点之间传输冲突,标记每个节点的 ID 号,并设置如下简单的传输协议:从节点 ID 为 1 到 18 发送数据,当一个节点发送信号时,其它节点作为接收节点,接收节点检查该发送节点的编号,并判断是否轮到自己发送信号,若没到,继续等待.假设一个节点不能发送信号,超过时限,则下一个节点继续发送.基站接收节点的数据包包括发送节点的编号以及接收到所有其它节点的 RSS 值.接收到自己的 RSS 值设定为 -45dBm.一个节点传输一次数据记为一个周期(1s 完成 11 个周期).在数据处理时,系统的标定利用检测区域无目标时的测量值.每条链路的测量值取该条链路所接收到采样的平均值.

4.2 实现过程

如图 2 所示,将投影测量过程分为两个阶段:初始测量阶段和增量测量阶段.初始测量阶段,随机选择

m 条射频链路,获取测量区域先验信息并对目标进行初始估计.增量测量阶段,不断增加测量链路,对初始目标估计进行补偿和修正.其中为了降低新增链路的冗余度,利用链路的最小微分熵决策计算新增链路的信息量.具体的链路选择算法表 1.




图2 BCS实现的射频层析成像链路选择实现过程

4.3 实验结果及分析

图 3 是基于 BCS 射频层析成像免持定位实验结果.在双目标定位实验中,将目标兴趣区域划分 18×18 的网格像素,两人分别站在传感网络测量区域内,其实际位置坐标分别为 (1.75, 0.25) 和 (3.75, 2.25), 如图 3(a).图 3(b)为使用所有 153 条射频链路测量信息,再利用 Tikhonov 正则化最小二乘算法^[22]恢复目标.通过定位结果我们可以判断出目标位置的大致区域,但无法精确判断具体坐标位置.图 3(c)为随机链路选择方法的重构结果,该方法随机选取 70 条链路,再利用 LASSO 方法^[23]重构目标.图 3(d)为 BCS 方法实现的定位结果,该方法先随机选取 10 条链路作为初始测量,在此基础上利用最小微分熵决策选取 50 条链路作为新增链路,最后利用算法 I 实现目标重构,即:




图3 免持定位实验结果

算法 I

初始化:随机选择 m 条测量链路,建立测量矩阵 Φ_m

步骤 1:根据式(8)和(9)估计 $\mathbf{x}_m$ 的权值 $\hat{\mu}_m$ 和误差 $\hat{\Sigma}_m$

步骤 2:利用式(13)选择新增链路

步骤 3:建立新的测量矩阵 Φ_{m+1} ,并利用步骤 1 的方法获得 $\mathbf{x}_{m+1}$ 的权值 $\hat{\mu}_{m+1}$ 和误差 $\hat{\Sigma}_{m+1}$

步骤 4:重复步骤 1 至步骤 3,直至 $\|\mathbf{x}_{m+1} - \mathbf{x}_m\|_2 \leq \delta$ 停止

不难看出,本文所提出的方法能够准确的判断目

标位置,且使用的链路较前两种方法少。

在多目标定位实验结果中,目标兴趣区域被划分为 18×18 的网格像素,测量区域中三人的位置坐标为 $(1.75, 3.25)$, $(4.25, 2.25)$ 和 $(3.25, 0.75)$ (如图 3(e)). 图 3(f) 为利用所有 153 条链路的测量信息,再根据 Tikhonov 正则化最小二乘算法恢复目标. 图 3(g) 通过随机选择链路 90 条链路,再利用 LASSO 算法重构目标. 图 3(h) 是先随机选择 20 条链路用作初始化,之后根据 BCS 链路选择方法选取 50 条链路,再利用算法 1 对目标进行估计。




图4 免持实验链路随机选择与BCS选择的链路熵比较

三种方法的定位结果表明最小二乘方法已无法实现多目标的定位,这主要是由于在测量过程中,冗余的测量链路增加了测量噪声,使得位置信息淹没在噪声中. 随机方法可以判断出目标所在大致区域,但是目标位置精度难以保证,这主要是由于随机链路的选择无法有效避免冗余或无关链路被选择. 基于 BCS 的方法能够正确判断出目标位置. 多目标实验中验证了引入了基于 BCS 的测量链路选择策略,可以有效降低冗余或无关链路的选择,使得测量噪声减少提高重构结果的精度。

图 4(a) 为随机方法与 BCS 方法所选链路所具有的链路熵比较. 随机方法的链路熵是根据式 (2) 计算获得,BCS 方法的链路熵则由式 (5) 计算获得. 显然,利用 BCS 方法选择链路具有的链路熵值大于利用随机方法选择链路的熵. 图 4(a) 表明利用 BCS 方法在初始化之后,所选增加的链路都是在剩余链路中具有最大信息

量的那条链路,由此验证了本文所提出方法能够有效地避免冗余链路的选择. 图 4(b) 多目标情况下两种方法下选择的链路具有的链路熵的比较. 显然,与双目标结论类似,BCS 方法所选链路具有的链路熵大于随机选择方法,表明本文提出的方法能够有效避免冗余链路的选择。

5 结论

本文提出一种基于贝叶斯压缩传感的射频层析成像链路选择策略,通过定位实验结果得到以下结论: (1) 提高传感效率. 在测量过程中,由于链路的选取是以重构结果的最小微分熵作为决策模型,减少冗余或无关链路的选择,提高传感效率; (2) 保证重构精度. 通过不断增加测量信息实现对重构图像的修正和补偿,保证重构精度。

本文所提出的链路选择策略在初始链路的选择和重构算法对精度影响方面还需要进行进一步讨论. 初始链路的选择会影响增加链路的数目,若初始链路选择合理,会降后继增加链路的条数,进一步测量提高效率. 不同的重构算法对目标重构精度有一定的影响. 未来的工作,将在这两个方面进行深入的研究。

参考文献

- [1] Wilson J, Patwari N. Radio tomographic imaging with wireless networks[J]. IEEE Transactions on Mobile Computing, 2010, 9 (5): 621 – 632.
 - [2] Patwari N, Wilson J. RF sensor networks for device-free localization: measurements, models and algorithms[J]. Proceedings of the IEEE, 2010, 98(11): 1961 – 1973.
 - [3] Pahlavan K, Ye Y, Khan U, et al. RF localization inside human body: enabling micro-robotic navigation for medical applications [A]. 2011 International Conference on Localization and GNSS (ICL-GNSS)[C]. New York: IEEE, 2011. 133 – 139.
 - [4] Estrin D. Embedding the Internet[R]. Los Angeles: University of Southern California, 1999.
 - [5] Hunt A, Tillery C, Wild N. Through-the-wall surveillance technologies[J]. Corrections Today, 2001, 63(4): 132.
 - [6] Monte L, et al. Radio frequency tomography for tunnel detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(3): 1128 – 1137.
 - [7] Wilson J, Patwari N. Radio tomographic imaging with wireless networks[J]. IEEE Transactions on Mobile Computing, 2010, 9 (5): 621 – 632.
 - [8] 傅健, 王宏钧, 李斌, 等. 板壳状微电子器件的数字层析成像检测方法[J]. 电子学报, 2010, 38(7): 1580 – 1584.
- FU Jian, WANG Hong-jun, et al. Computed laminography imaging inspection method for plate-shell microelectronic de-

- vices[J]. Acta Electronica Sinica, 2010, 38(7): 1580 – 1584. (in Chinese)
- [9] 李翠环, 杨晓光, 汪友华. 电容层析成像图像重构的三阶混合算法[J]. 电子学报, 2012, 40(3): 500 – 504.
LI Cui-huan, YANG Xiao-guang, WANG You-hua. A three order hybrid algorithm for electrical capacitance tomography[J]. Acta Electronica Sinica, 2012, 40(3): 500 – 504. (in Chinese)
- [10] Patwari N, Agrawal P. Effects of correlated shadowing: connectivity, localization, and RF tomography[A]. 2008 International Conference on Information Processing in Sensor Networks[C]. USA: IEEE/ACM, 2008. 82 – 93.
- [11] Agrawal P, Patwari N. Correlated link shadow fading in multi-hop wireless networks[J]. Wireless Communications, 2009, 8(8): 4024 – 4036.
- [12] Kak A C, Slaney M, Wang G. Principles of computerized tomographic imaging[J]. Medical Physics, 2002, 29: 107.
- [13] Wilson A J. Device-free Localization with Received Signal Strength Measurements in Wireless Networks[D]. Salt Lake City: The University of Utah, 2010.
- [14] Wilson J, Patwari N. Radio tomographic imaging with wireless networks[J]. IEEE Transactions on Mobile Computing, 2010, 9(5): 621 – 632.
- [15] Donoho D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289 – 1306.
- [16] Candes E, Tao T. Near optimal signal recovery from random projections: Universal encoding strategies[J]. IEEE Transactions on Information Theory, 2006, 52(12): 5406 – 5425.
- [17] Kanso M A, Rabbat M G. Compressed RF Tomography for Wireless Sensor Networks: Centralized and Decentralized Approaches[M]. Berlin Heidelberg: Springer, 2009. 173 – 186.
- [18] Ji S, Xue Y, Carin L. Bayesian compressive sensing[J]. IEEE Transactions on Signal Processing, 2008, 56(6): 621 – 632.
- [19] Candes E J, Romberg J, Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information[J]. IEEE Transactions on Information Theory, 2006, 52(2): 489 – 509.
- [20] Tipping M. Sparse Bayesian learning and the relevance vector machine[J]. Machine Learning Research, 2001, 1: 211 – 244.
- [21] Cover T M, Thomas J A. Elements of Information Theory (second edition) [M]. SIAM; Wiley-Interscience, 2012. 247 – 250.
- [22] Vogel C R. Computational Methods for Inverse Problems [M]. SIAM: Society for Industrial and Applied Mathematics, 2002. 142 – 145.
- [23] Tibshirani R. Regression shrinkage and selection via the lasso [J]. Journal of the Royal Statistical Society, 1996, 58(1): 267 – 288.

作者简介



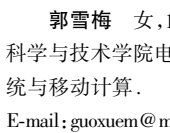
郝晓曦 女, 1981 年 1 月出生于辽宁省沈阳市. 中山大学信息科学与技术学院在读博士. 五邑大学机电工程学院讲师. 主要研究方向为射频频析成像理论及其应用.

E-mail: cici_haoxiaoxi@126.com



杨志勇 男, 1982 年 12 月生于河南省开封市. 中山大学信息科学与技术学院在读博士. 主要研究方向无线传感网络理论及应用.

E-mail: yzy8212@163.com



郭雪梅 女, 1964 年 7 月生于内蒙古呼和浩特市. 中山大学信息科学与技术学院电子与通信工程系副教授. 主要研究方向嵌入式系统与移动计算.

E-mail: guoxuemei@mail.sysu.edu.cn



王国利(通信作者) 男, 1965 年 4 月生于内蒙古呼和浩特市. 中山大学信息科学与技术学院教授、博士生导师. 主要研究方向压缩传感支配的智能感知技术研究等.

E-mail: isswgl@mail.sysu.edu.cn