

自适应环境变化的 RSS 室内定位方法

王婷婷^{1,2}, 柯炜^{2,3}, 孙超²

(1. 南京信息工程大学 江苏省气象探测与信息处理重点实验室, 江苏 南京 210044;
2. 南京师范大学 江苏省光电技术重点实验室, 江苏 南京 210023; 3. 民政部减灾和应急工程重点实验室, 北京 100124)

摘要: 根据定位问题的天然稀疏性, 提出一种基于两步字典学习的定位方法, 依据测量值动态调整字典, 使稀疏模型能够自适应 RSS 的变化。同时提出一种改进的加权 l_1 范数稀疏重构算法, 提高低信噪比情况下的重构精度。实验结果表明该方法可以在目标数量未知的情况下实现多目标定位, 并具有较强的抗噪声能力。

关键词: 室内定位; 字典学习; 压缩感知; 加权 l_1 范数最小化

中图分类号: TN301

文献标识码: A

文章编号: 1000-436X(2014)10-0210-08

Environmental-adaptive RSS-based indoor localization

WANG Ting-ting^{1,2}, KE Wei^{2,3}, SUN Chao²

(1. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science & Technology, Nanjing 210044, China;

2. Jiangsu Key Lab of Opto-Electronic Technology, Nanjing Normal University, Nanjing 210023, China;

3. Key Laboratory of Disaster Reduction and Emergency Response Engineering of the Ministry of Civil Affairs, Beijing 100124, China)

Abstract: A novel two-step dictionary learning (DL) framework was proposed to dynamically adjust the overcomplete basis (a.k.a. dictionary) for matching the changes of the RSS measurements, and then the sparse solution can better represent location estimations. Moreover, a modified re-weighting l_1 norm minimization algorithm was proposed to improve reconstruction performance for sparse signals. The effectiveness of the proposed scheme is demonstrated by experimental results where the locations of targets can be obtained from noisy signals, even if the number of targets is not known a priori.

Key words: indoor localization; dictionary learning (DL); compressive sensing; weighted l_1 norm minimization

1 引言

室内无线定位技术作为定位领域的一个重要研究方向, 具有广泛的应用前景。尽管以 GPS、北斗为代表的卫星定位系统在室外定位中取得了巨大成功, 但由于受到卫星信号穿透性问题的限制, 室内一般无法接收到卫星定位信号, 因此高精度的室内定位一直是定位领域所面临的一个难点问题。

近年来随着通信技术的蓬勃发展, 基于民用通信网络的定位技术得到了飞速发展。特别是随着无线局域网 (WLAN, wireless local area network) 的普及和高速发展, 利用现有 WLAN 网络进行室内定位, 不仅可以节省定位系统的建设成本, 而且定位终端可以借助智能手机等现成设备, 因而国内外出现了研究 WLAN 室内定位技术的热潮^[1]。目前常用的 WLAN 定位方法包括基于波达方向的定位方法, 基

收稿日期: 2014-04-15; 修回日期: 2014-08-30

基金项目: 国家教育部博士点基金资助项目(20133207120007); 国家自然科学基金青年科学基金资助项目(61405094); 江苏高校优势学科 II 建设工程基金资助项目(“信息与通信工程”优势学科); 江苏省高校自然科学研究面上基金资助项目(14KJB510018); 民政部减灾和应急工程重点实验室开放基金资助项目(LDRERE20120303); 气象探测与信息处理重点实验室开放基金资助项目(KDXS1301)

Foundation Items: The Ph.D. Programs Foundation of the Ministry of Education of China (20133207120007); The National Natural Science Foundation of China (61405094); The Priority Academic Program Development of Jiangsu Higher Education Institutions; The University Science Research Project of Jiangsu Province (14KJB510018); The Open Research Fund of Key Laboratory of Disaster Reduction and Emergency Response Engineering of the Ministry of Civil Affairs (LDRERE20120303); The Open Research Fund of Jiangsu Key Laboratory of Meteorological Observation and Information Processing (KDXS1301)

于到达时间或时间差的定位方法和基于接收信号强度 RSS 的定位方法等，其中基于 RSS 的定位方法由于对传输带宽要求低，无需额外硬件的优点得到广泛应用^[2]。

近年来，压缩感知 (CS, compressive sensing) 理论的成熟和发展给传统的定位方法带来了一场革命性的变革，在室内定位的研究上也揭开了崭新一页。根据定位问题的天然稀疏性，Cevher 等人首先将目标定位问题建模为分布式稀疏逼近问题，减少了节点间通信成本^[3,4]。文献[5,6]对基于 RSS 和压缩感知的室内定位技术进行了较为系统的研究，提出了基于 RSS 采样值数据预处理和 l_1 范数优化的室内定位技术，并实现了多目标定位。崔琪梅等人则针对 RSS 室内定位问题，提出了 2 种不同的压缩感知定位方法^[7,8]。文献[9]给出了同时实现目标计数和定位的稀疏信号重构方法，并给出了贪婪匹配追踪 (GMP) 算法。这些工作都显示了压缩感知理论与技术强大的生命力及其在无线定位研究中广阔的应用前景。然而，与传统 RSS 室内定位方法一样，基于 CS 理论的室内定位依然面临着 2 个难题，导致其定位精度难有实质性提高。一是噪声因素的影响，由于目前稀疏重构普遍采用 l_1 范数代替 l_0 范数进行稀疏约束，而在 l_1 范数约束模型中，目标函数会对大系数施加更多的约束以保证整个代价函数的收敛性。在定位应用中，大系数往往对应于定位目标，而小系数可能对应于噪声，这样常用的贪婪算法和凸优化算法等可能在重构过程中削弱大系数的贡献，而对小系数没有施加过多约束，从而导致重构准确性下降，在低信噪比时甚至会出现将噪声误判为定位目标。二是 RSS 测量值易受温度、湿度、室内布局、建筑材料和人员活动等环境因素的影响^[10]，甚至房门的开闭都会引起 RSS 测量值的波动。更重要的是这种影响具有时变性和不可预知性，从而导致 RSS 测量值无法与强度—距离损耗公式^[11]相匹配，使得距离估计值产生较大误差，最终影响到定位性能。

针对以上问题，本文提出一种改进的加权 l_1 范数稀疏重构算法，通过合理加权对大、小稀疏实现合理约束，在含噪模式下，这种自适应调整机制使得加权 l_1 范数约束模型可以获得对 l_0 范数模型的准确逼近。同时利用最近发展迅速的字典学习技术，根据接收信号不断调整冗余字典，使之能够自适应环境的动态改变，使得稀疏重构结果能够精确得出

位置信息。目前常见的字典学习算法有 K-SVD 算法、基于代理函数优化的方法、递归最小二乘法等^[12]，但这些方法大都计算量较大，无法满足实时定位的要求。鉴于此，本文提出一种两步字典学习框架，首先在离线阶段将字典学习问题转化为二次规划问题，利用适合大规模运算的投影梯度算法^[13]得到与当前环境相适配的字典。随着环境的动态变化，字典也必须相适应动态调整，但每次都计算一个二次规划问题，运算量仍较大。因此，在线阶段本文利用基于增量方式的在线字典学习算法，每次字典更新只需在原先字典的基础上叠加一个变化量，这样可有效减少计算量，以便适应实时定位需要。

2 系统模型

系统模型如图 1 所示，整个定位区域均匀划分为 N 个格点，其中有 M 个无线接入点 (AP, access point) 和 K 个待定位移动台，一般 $N \gg M > K$ 。系统工作时每个移动台周期性地发射信号，发射周期为 T ，并且移动台之间相互独立；AP 周期性地收集信号，收集周期也为 T ，将该周期内收到的信号强度值做累加，周期时间片结束后，每个 AP 将累加结果发送给定位中心。定位中心的服务器运行定位算法，计算出移动台位于 N 个网格中的哪些位置。




图 1 定位系统

由于移动台只在其中的一个或几个格点处（或其附近），也即在某一特定时间移动台所在的位置在空间域上是稀疏的。于是，一旦定位区域内的格点位置划定，移动台在空间上的位置可精确地用一

个 $N \times 1$ 的稀疏索引向量 \mathbf{x} 表示, 移动台位置所对应格点处索引值为 1, 而其他格点对应索引值为 0, 即

$$\mathbf{x} = [0, 1, \dots, 0, 1, 0, \dots, 0]^T \quad (1)$$

如此一来, 定位问题就转变为依据接收信号判断稀疏向量 \mathbf{x} 中非零值所在位置的问题。按照压缩感知原理, 当定位中心接收到各 AP 传回的信号 \mathbf{y} 后, 稀疏定位模型可表示为

$$\mathbf{y} = \Phi \mathbf{x} + \mathbf{v} \quad (2)$$

其中, \mathbf{v} 为 $M \times 1$ 的矢量, 表示噪声干扰; Φ 为一个 $M \times N$ 的矩阵, 表示冗余字典。 Φ 中的任一项 Φ_{ij} , $1 \leq i \leq M, 1 \leq j \leq N$, 表示移动台在第 j 个格点处发射信号, 第 i 个 AP 接收到信号的强度。由于格点一旦划定, 格点位置为已知, 再加上 AP 位置是事先已知的, 所以理想字典 Φ 中的每个元素可根据经典的强度—距离损耗公式^[11]

$$P_r = P_0 - 10\alpha \lg(d/d_0) \quad (3)$$

计算得到, 其中, P_r 表示接收功率, P_0 表示在参考传输距离为 d_0 处的接收信号强度, d 为信号传输距离。 α 为路径衰减指数, 一般介于 2 至 5 之间, 室内环境通常取为 2.6^[11]。当冗余字典构造完成后, 利用压缩感知中的稀疏重构算法得到 \mathbf{x} 中非零值位置, 那么其对应格点位置就是要估计的移动台位置。为保证满足压缩感知理论的不相干性条件, 可在稀疏恢复前采用文献[5]的方法先进行正交化预处理, 然后再利用如贪婪算法^[14]或凸优化算法^[15]等就可以恢复出稀疏矢量 \mathbf{x} 。

然而, 以上稀疏定位模型是建立在理想条件下的, 首先式(3)所描述的强度—距离关系是一种最简单的近似, 忽略了其他因素的影响, 实际中不仅 α 因取决于建筑材料和建筑物类型而不固定, 而且由于温度、湿度和人员活动等时变因素的影响, 真实测量 RSS 值会与式(3)计算出的 RSS 值产生较大偏差, 此时稀疏重构的结果也会相应产生误差。本文用矩阵 Γ 表示理想字典和真实测量值之间的差别, 因此对于实际情况, 式(2)修正为

$$\mathbf{y} = (\Phi + \Gamma)\mathbf{x} + \mathbf{v} = \mathbf{D}\mathbf{x} + \mathbf{v} \quad (4)$$

其中, $\mathbf{D} = (\Phi + \Gamma)$ 表示真实的冗余字典。显然真实字典 \mathbf{D} 和理想字典 Φ 之间存在着明显差别, 而且 Γ 是时变且预先未知的。为了能在实际环境下得到精确的定位结果, 本文将利用两步字典学习技术根据测量值动态调整字典, 使之能够适应 RSS 的变化。

3 基于两步字典学习的稀疏定位算法

字典学习算法利用训练样本 $\mathbf{Y} = [\mathbf{y}_1 \mathbf{y}_2 \dots \mathbf{y}_L]$ 去训练字典以便得到最优的稀疏化结果。字典学习一般可以归结为如下优化问题

$$\arg \min_{\mathbf{D}, \mathbf{X}} \|\mathbf{Y} - \mathbf{D}\mathbf{X}\|_F^2 \quad s.t. \|\mathbf{x}_i\|_0 \leq K, i = 1, \dots, L \quad (5)$$

其中, $\mathbf{X} = [\mathbf{x}_1 \mathbf{x}_2 \dots \mathbf{x}_L]$ 为稀疏矩阵, 其分量 \mathbf{x}_i 表示对应训练矢量 \mathbf{y}_i 的稀疏向量, K 表示稀疏度, $\|\cdot\|_F$ 表示 Frobenius 范数, L 表示样本数目。由于此问题通常是非凸的, 所以一般采用交替学习方式进行求解, 即先固定字典 \mathbf{D} 保持不变, 利用稀疏恢复算法求解 \mathbf{x}_i ; 然后固定 \mathbf{x}_i 保持不变, 利用字典学习算法更新字典 \mathbf{D} , 本文同样采用这种方式。

3.1 稀疏恢复阶段

在稀疏恢复阶段, 字典 \mathbf{D} 保持不变, 通过重构算法计算稀疏向量。根据 CS 理论, 准确描述稀疏性的模型是 l_0 范数, 即

$$\min \|\mathbf{x}_i\|_0 \quad s.t. \|\mathbf{y}_i - \mathbf{D}\mathbf{x}_i\|_2 \leq \varepsilon, i = 1, \dots, L \quad (6)$$

由于 l_0 范数的求解是 NP 难问题, 因此常用 l_1 范数来代替 l_0 范数进行稀疏约束, 并且文献[16]指出当满足一定条件时, 用 l_1 范数可以达到与 l_0 范数相同的结果。

然而在很多实际应用中, 特别是在低信噪比情况下, 采用 l_1 范数逼近 l_0 范数仍存在一定的误差。正如式(6)所示的 l_0 范数约束模型, 对于任何一个向量, 其 l_0 范数仅存在 0、1 之分, 因此大系数和小系数对目标函数的贡献是相同的。然而在 l_1 范数约束模型中, 求解对象为模值最小情况下对应的解, 此时向量 \mathbf{x}_i 中大系数和小系数对目标函数的贡献是不一样的, 即大系数模值大, 相应贡献大, 反之亦然。因此在求解过程中, 目标函数会对大系数施加更多约束以保证整个代价函数的收敛性。然而在定位应用中, 大系数往往对应于定位目标, 而小系数可能对应于噪声。由于 l_1 范数约束模型对待大、小系数的不公平性, 则可能在优化过程削弱大系数的贡献, 而对小系数没有施加过多约束, 从而导致重构准确性下降, 在低信噪比时甚至会将噪声误判为定位目标。

针对此问题, Candès 最早引入加权范数约束思想^[17], 通过对 l_1 范数约束模型进行加权, 使重构信号中的大系数和小系数获得同等约束, 即式(6)改为

$$\min \|w\mathbf{x}_i\| \quad s.t. \|y_i - D\mathbf{x}_i\|_2 \leq \varepsilon, i=1, \dots, L \quad (7)$$

其中, w 为 N 维对角加权矩阵, 其对角线上元素取为 $w_j=1/(|x_i(j)|+\eta)$, η 是一个小量, 防止 w_j 出现奇异值。显然, 当重构系数 $x_i(j)$ 较小时, 所对应的权值 w_j 较大, 反之亦然。如此一来, 刚好可以拉近大、小系数在目标函数贡献性上的差距, 因此加权过程相当于在优化过程中实现了对大、小系数的平衡“惩罚”。在含噪模式下, 这种自适应调整机制使得加权 l_1 范数约束模型可以获得对 l_0 范数的更好逼近。

虽然加权 l_1 范数约束模型更容易获得最优稀疏解, 但是在实验中发现: 在 Candès 的加权方式下, 参数 η 的调节会使重构信号中的大、小系数的权值向同一方向变化(或增大或减小), 如增大 η 会导致权值函数的整体降低, 这样在减小对大系数“惩罚”的同时, 也减小了对小系数的“惩罚”, 使得在信噪比较低时, 对噪声的抑制效果不明显。而且权值的最大值会随 η 的不同而发生较大变化, 这样会使得对小系数的“惩罚”变化剧烈, 权值的变化程度和权值最大值之间相互关联, 会使得重构结果缺乏稳定性。针对该问题, 本文提出一种新的加权函数形式

$$w_j = \begin{cases} 1/(|x_i(j)|+\eta), & |x_i(j)| > \delta \\ \beta\eta/(|x_i(j)|+\eta), & |x_i(j)| < \delta \end{cases} \quad (8)$$

其中, δ 为门限值, 当重构信号中的系数超过门限时, 可认为是大系数, 仍采用 Candès 的加权方式; 反之, 则采用修正的加权方式。对于小系数, 参数 β 表征了权值的整体调整程度, β 越大则权值 w_j 的整体调整程度就越大, 而且当 $|x_i(j)|$ 非常小(接近 0) 时, β 近似表征了权值函数的最大值, 可以保证对小系数(往往对应的是噪声)的约束; η 表示了权值对稀疏系数的敏感程度, η 越大, 权值 w_j 受稀疏 $|x_i(j)|$ 的影响越小, 反之亦然。换言之, η 在其中起到微调的作用, 而不像 Candès 加权方式中会对权值的最大值产生较大影响。因此, 在本文的改进方式中, β 决定权值函数最大值, η 微调惩罚程度, 二者的结合使得不必担心惩罚程度的改变对整体幅值的影响, 从而使得在信噪比较低的情况下, 能较好地去除噪声的影响, 同时确保真实信号细节信息基本不损失。完整的修正加权 l_1 范数稀疏恢复算法如图 2 所示, 其中步骤 3 定义的代价函数仍是一个凸优化问题, 可采用常规的重构算法求解。

3.2 字典学习阶段

由于初始字典 Φ 完全是根据经验模型式(3)计算出来的, 其中每一个元素可以认为是理想值, 与实际信号一般存在着偏差, 直接用 Φ 进行稀疏恢复出的结果也往往带有较大误差。鉴于此, 本文提出两步字典学习框架, 首先在离线阶段进行大数据集的训练, 改变初始字典的失配状态, 使字典能和当前信号环境特征相适应。接着, 为了能适应信号环境的时变特性, 使用在线字典学习算法根据接收信号动态进行字典修正。

1) 输入: $D, Y, \eta, \delta, \beta, \rho$;

2) 设置迭代次数 T , 令 $w_j^{(0)} = 1, i=1, \dots, L$

3) 求解 $\mathbf{x}_i^{(0)} = \arg \min \|w^{(0)} \mathbf{x}_i\|$
 $s.t. \|y_i - D\mathbf{x}_i\|_2 \leq \varepsilon$

4) 更新权值: $w_j^{(t+1)} = \begin{cases} 1/(|x_i^{(0)}|+\eta), & |x_i^{(0)}| > \delta \\ \beta\eta/(|x_i^{(0)}|+\eta), & |x_i^{(0)}| < \delta \end{cases}$

5) 迭代终止判断: 当 $\|\mathbf{x}_i^{(t+1)} - \mathbf{x}_i^{(t)}\|_2 < \rho$ 或 $t > T$ 时终止迭代; 否则 $t=t+1$, 返回步骤 3)

图 2 算法 1: 修正加权 l_1 范数稀疏恢复算法

3.2.1 离线学习阶段

在这一阶段, 稀疏矩阵 X 是固定的, 因此字典学习问题可以表示为下述优化问题

$$\min \|Y - DX\|_F^2 / 2, s.t. d_i^H d_i \leq 1, i=1, \dots, N \quad (9)$$

其中, d_i 为矩阵 D 的列矢量。根据矩阵运算规则,

$$\begin{aligned} \|Y - DX\|_F^2 &= \text{tr}[(Y - DX)^H(Y - DX)] \\ &= \text{tr}(DXX^H D^H) - 2\text{tr}(YX^H D^H) + \text{tr}(YY^H) \\ &= \text{vec}(D^H)^H(I \otimes XX^H)\text{vec}(D^H) - \\ &\quad 2\text{vec}(XY^H)^H \text{vec}(D^H) + \text{tr}(YY^H) \end{aligned} \quad (10)$$

其中, \otimes 表示 Kronecker 积。为表达清楚起见, 令 $\mathbf{a} = \text{vec}(D^H)$, $\mathbf{G} = I \otimes XX^H$, $\boldsymbol{\gamma} = \text{vec}(XY^H)$, 并且忽略掉与 D 无关的项, 则式(10)的离线字典学习问题可以等价转化为

$$\min \frac{1}{2} \mathbf{a}^H \mathbf{G} \mathbf{a} - \boldsymbol{\gamma}^H \mathbf{a}, \quad s.t. d_i^H d_i \leq 1, i=1, \dots, K \quad (11)$$

注意式(11)是一个标准的约束二次规划问题, 可以利用梯度投影^[13]等方法求解。同时, 容易发现矩阵 \mathbf{G} 是一个正定矩阵, 则式(11)是一个凸函数, 可以保证在离线训练阶段得到全局最优解。

3.2.2 在线学习阶段

尽管离线字典学习已经根据训练数据调整了初始字典，使之能够适应当前状态。但是，无线电磁环境是不断变化的，影响 RSS 的因素也是时变的，仅经过一次训练的字典很难符合各种时变模式。而且，求解约束二次规划问题运算量依然是较大的，不适合实时定位的要求。文献[18]提出了一种采用增量方式的在线字典学习方式，字典更新只需在原来字典的每一列上叠加一个增量即可，运算量很小，符合实时定位的要求。按照文献[18]，在线阶段字典的每一列可以按下式更新

$$u_j \leftarrow d_j + (b_j - Da_j) / A(j, j), \quad j = 1, 2, \dots, N \quad (12)$$

$$d_j \leftarrow \frac{1}{\max(\|u_j\|_2, 1)} u_j \quad (13)$$

其中, d_j, b_j, a_j 分别为矩阵 D, B_n 和 A_n 的第 j 列矢量。矩阵 A_n 和 B_n 是在线字典学习算法中用到的中间量, $A(j, j)$ 表示 A_n 中的第 j 行第 j 列元素。由于在线字典学习算法不仅运算量小, 而且可以根据实时接收数据及时更新字典, 这样既可以动态跟踪 RSS 的时变效应, 又可以克服离线字典学习算法运算量大的弊端。完整的两步字典学习算法如图 3 所示。

3.3 算法复杂度分析

本文所提算法的复杂度由稀疏重构算法的复杂度和两步字典学习算法的复杂度共同决定。相比于经典的 l_1 范数重构算法, 本文采用的加权 l_1 范数重构算法仅仅增加了权值计算的运算量, 由于权值运算仅涉及简单的加法和乘除等初等运算, 所以增加的运算量很少, 几乎可以忽略不计。本文算法增加的运算量主要是字典学习步骤的运算量。由于离线字典学习阶段采用梯度投影方法计算约束二次规划问题, 其中涉及到计算量大的操作主要包括矩阵求逆和矩阵乘法运算。矩阵求逆操作的复杂度为 $O(N^3)$, 矩阵相乘操作的复杂度为 $O(N^2)$, 其中, N 表示字典的维数。所以此步骤的运算量是比较大的, 并且随着 N 的增加, 运算量急速增加, 但这一步是在离线阶段完成的, 并不影响定位的实时性。在线字典学习采用增量式字典更新方法, 每次只需在原字典的每一列上添加一个增量即可, 而在计算这个增量的过程主要运算是矢量与矩阵的乘法, 其复杂度为 $O(N)$ 。因此运算量要比离线学习阶段少很多, 基本可以满足实时更新的需要。随着硬件性能的不断提高, 该算法可以满足绝大多数的实时应用。

4 实验结果

本节主要评测本文提出算法在不同信噪比和存在 RSS 波动情况下的定位精度, 并选择文献[5]中基于 l_1 范数约束的方法 (称为算法 1) 和文献[9]中基于 GMP 的方法 (称为算法 2) 进行性能对比。由于实际环境中 RSS 的变化具有随机性, 为了能真实反映出实际环境中的定位性能, 本文采用以下得到的实测数据对上述几种算法进行验证和对比。实验区域选择为南京师范大学的行健楼, 该楼共有 6 层, 其中第 3 层布局具有一般性, 包括实验室、教室、电梯等, 且存在较多的人员走动, 因而实验选在该层的部分区域 (50 m×30 m) 进行。在大楼内部部署了 13 个无线接入点 (采用思科公司的 Linksys WRT54G Wireless-G Router), 结合大楼内已有的其他 5 个无线接入点, 共同完成定位。无线接入点的 MAC 地址和相应接收信号强度值通过 OpenNetCF 提供的开源类库直接从终端设备的网络接口卡中获取。为了获得信噪比参数, 在每次实验前用罗德斯瓦茨公司的 FSH8 型手持频谱仪 (工作频段 9 kHz~8 GHz) 测量每个接入点处的接收信号频谱。由于 FSH8 型手持

初始化: 产生训练样本 Y 和理想字典 Φ ;
 离线学习阶段:
 1) 设置迭代次数 T1, 令 $\hat{D}_{\text{off}}^{(0)} = \Phi$;
for $n=1$ to T1
 2) 稀疏重构: 固定 $\hat{D}_{\text{off}}^{(n-1)}$ 不变, 用图 2 中算法得到稀疏系数 $\hat{x}_{\text{off}}^{(n)}$;
 3) 字典更新: 固定 $\hat{x}_{\text{off}}^{(n)}$ 不变, 用梯度投影法求解式(11), 得到更新字典 $\hat{D}_{\text{off}}^{(n)}$;
end for
 4) 输出: $\hat{D}_{\text{off}} = \hat{D}_{\text{off}}^{(T1)}$; $\hat{x}_{\text{off}} = \hat{x}_{\text{off}}^{(T1)}$;
 在线学习阶段:
 1) 输入 $\hat{D}_{\text{on}}^{(0)} = \hat{D}_{\text{off}}$; 迭代次数 T2:
 $A_0 \leftarrow 0$; $B_0 \leftarrow 0$;
for $n=1$ to T2
 2) 稀疏重构: 用图 2 中算法求解
 $x_{\text{on}}^{(n)} = \arg \min \|W^{(n)} x_{\text{on}}^{(n)}\|_1$
 $s.t. \|y^{(n)} - \hat{D}_{\text{on}}^{(n-1)} x_{\text{on}}^{(n)}\|_2 \leq \epsilon$
 3) $A_n \leftarrow A_{n-1} + x_{\text{on}}^{(n)} x_{\text{on}}^{(n)H}$;
 4) $B_n \leftarrow B_{n-1} + y^{(n)} x_{\text{on}}^{(n)H}$;
 5) 字典更新: 按照式(12)和式(13)进行字典更新;
end for

图 3 算法 2: 两步字典学习算法

频谱仪的平均本底噪声最低可到 -161 dBm, 仪器本身的噪声干扰可以忽略不计, 而信号集中在 2.4 GHz 附近, 并且相对噪声带宽较窄, 容易将信号频谱和环境噪声频谱区分开来, 这种做法与工程上经常采用的终端法^[19]类似。在得到每一处的噪声功率之后, 取 18 个测量值的平均作为当前测量的噪声功率, 通过调整发射功率大小可以得到不同的信噪比。门限值 $\delta=0.1$, η 取为 0.05 , β 取为 10 。定位中心由笔记本电脑(配置为英特尔的 i5 CPU, 3.1 GHz 主频, 4 GB 内存)实现, 负责处理测量数据和运行定位算法。定位性能用均方根误差(RMSE, root mean square error)和失效率来衡量。

$$RMSE = \frac{1}{QK} \sum_{q=1}^Q \sum_{i=1}^K \sqrt{\|\hat{P}_q(i) - P_q(i)\|_2^2} \quad (14)$$

其中, Q 为测试次数, $\hat{P}_q(i)$ 为第 i 个目标第 q 次测量时的估计位置, $P_q(i)$ 为第 i 个目标第 q 次测量时的真实位置。 $RMSE$ 可以衡量不同定位算法的平均定位精度, 但在多目标定位时有时会出现多数目标的定位精度很高, 因 1 、 2 个目标定位误差较大拉低 $RMSE$ 的情况。为了公平起见, 引入定位失效率指标, 并且规定当目标估计位置与真实位置直接距离相差 3 m 以上时, 定位失效。定位失效率为

$$\text{失效率} = \frac{\|\hat{P}_q(i) - P_q(i)\|_2 > 3 \text{ m 的次数}}{QK} \times 100\% \quad (15)$$

4.1 定位性能比较

将 $50 \text{ m} \times 30 \text{ m}$ 的定位区域均匀划分为若干格点, 实验中将横轴按 1 m 进行划分, 纵轴按 3 m 和 1 m 这 2 种精度进行划分, 分别得到 3 m^2 和 1 m^2 这 2 种精度的格点, 也即分别对应 $N=500$ 和 $N=1500$ 。设置目标数为 3 , 目标位置随机选取, 信噪比为 15 dB, 在上午 10 点~ 11 点人员活动比较密集的时段重复进行了实验 50 次, 每次实验随机在定位区域内选择 3 个位置。其中前 10 次数据用于离线字典训练, 并产生初始字典; 而余下 40 次数据用于定位测试, 由于在线字典是实时更新的, 所以在定位测试的同时也完成了在线字典训练。定位结果如表 1 所示。

从表 1 上可以看出, 本文算法的定位误差要小于其他 2 种算法, 即使格点精度为 3 m^2 时, 定位精

度也有 2.77 m, 失效率也低于 10% , 这意味着绝大多数时候采用本文算法能满足室内定位需求。由于 GMP 算法的抗噪声能力较弱, 算法 2 的定位精度最低。算法 1 的失效率与本文算法接近, 这说明基于 l_1 范数约束的方法能够保证大多数目标的定位精度在小于 3 m 的有效范围内, 但算法 1 的均方根误差要高于本文算法, 说明其失效目标的偏离误差是相当大的。当格点划分精度由 $s=3 \text{ m}$ 提高到 $s=1 \text{ m}^2$ 时, 3 种算法的定位精度都有提高, 但计算时间也都明显上升。算法 2 由于采用贪婪算法进行稀疏重构, 运行速度最快; 而本文算法由于增加了字典学习环节, 所需计算时间最多。但必须注意的是, 本文算法所增加的运行时间主要是离线学习阶段求解约束二次规划所占用的时间, 由于该部分计算离线阶段一次完成, 不需要反复计算, 而在线阶段所增加的时间并不长。考虑到本文算法在定位精度和失效率方面的优势, 所增加的这一点复杂度是可以接受的。

表 1 不同格点精度下的性能比较

算法		RMSE/m	失效率/%	平均耗时/s
对比算法 1	$s=3 \text{ m}^2$	3.91	9	0.610
对比算法 2	$s=3 \text{ m}^2$	4.35	16	0.325
本文算法	$s=3 \text{ m}^2$	2.77	8	1.211(离线)+0.750(在线)
对比算法 1	$s=1 \text{ m}^2$	2.03	7	0.876
对比算法 2	$s=1 \text{ m}^2$	2.81	12	0.551
本文算法	$s=1 \text{ m}^2$	1.51	6	2.957(离线)+0.997(在线)

图 4 给出了一天工作时间内 RSS 波动对定位性能影响的比较, 格点精度选为 1 m^2 , 其他参数设置不变。从图 4 可以看出算法 1 和算法 2 受 RSS 波动的影响是很大的, 尤其是算法 2 一天之中的定位精度波动接近 1.5 m。对比算法 1 虽在定位前对 RSS 测量值进行预处理, 但由于缺乏对时变信号的自适应能力, 作用有限。而本文算法由于采用在线字典学习实时调整字典与接收信号相匹配, 自适应 RSS 波动的变化, 所以一天之中的定位精度波动很小, 能够保持定位性能的稳定性。

图 5 给出了对一天工作时间内所有时刻测量值进行统计的定位误差的累积概率分布, 格点精度选为 1 m^2 , 其他参数设置不变。从图 4 可以看出, 本文算法定位误差在 3 m 以内的概率达到 90% , 高于修正加权 l_1 范数稀疏恢复算法的 82% 和算法 2 的 77% 。这进一步说明采用字典学习和加权 l_1 范数最

小化方法后，在提高定位精度的同时，可以提高定位的稳定性，可以保证以较大概率实现有效定位。




图 4 环境变化对定位精度的影响




图 5 3 种算法定位误差的累积概率分布

4.2 参数影响分析

图 6 给出目标数为 2，格点精度选为 1 m^2 时 3 种算法在不同信噪比下的 RMSE 对比。由于改进的加权 l_1 范数约束模型能较好地去除噪声的影响，同时确保真实信号细节基本不损失，所以本文算法要优于其他 2 种算法，在低信噪比时性能改善尤为明显，能将定位精度提高约 2 m。当信噪比大于 20 dB 时，本文算法的定位误差基本不再变化，且定位精度都在 1 m 之内。

图 7 给出了信噪比为 15 dB 时，3 种算法定位误差随目标数量变化的情况，格点精度仍取为 1 m^2 。从图上可以看出，尽管 GMP 算法克服了一般贪婪算法^[14]必须预先已知稀疏度的局限，但仍然需要通

过迭代搜索方式得到稀疏度的估计值才能实现稀疏重构，在有噪情况下很难保证稀疏度估计的准确性，所以 GMP 算法受稀疏度估计的影响，随着目标数量增加，算法 2 的定位误差逐渐增大。而基于 l_1 范数约束的凸优化算法在求解时无需稀疏度的先验信息，所以本文算法和算法 1 的定位误差几乎不随目标数量变化，这意味着这类算法可以更好地适应多目标定位的要求，即使在未知目标数量时也可以实现多目标定位。




图 6 SNR 对定位精度的影响




图 7 目标数量对定位精度的影响

图 8 给出了目标数为 3，格点精度选为 1 m^2 ， $SNR=10 \text{ dB}$ 、 15 dB 和 20 dB 时，本文算法的定位误差与门限值 δ 之间的关系。从图 8 可以看出，当 δ 小于 0.3 时，本文算法的定位误差基本稳定，且此结果不受信噪比大小的影响。但当 δ 大于 0.3 后，定位误差将随着 δ 的增加而迅速增加，这是由于门限值设得过大，有时会把稀疏矢量 \mathbf{x} 中一些大稀疏分量误判为小系数，从而在加权时错误地给予大权重进行约束，进而导致对定位目标的误判。




图 8 门限值对定位精度的影响

5 结束语

本文针对基于 RSS 的室内定位易受环境影响的问题, 依据压缩感知理论提出一种两步字典学习框架, 根据测量值动态地调整字典, 使稀疏模型能够动态适应信号环境的变化, 提高定位精度。同时为了解决低信噪比情况下的稀疏重构问题, 提出一种改进的加权 l_1 数稀疏重构算法, 通过合理加权实现对大、小系数的合理约束, 从而使得在信噪比较低的情况下, 能较好地去除噪声的影响, 同时确保真实信号细节基本不损失。实验结果表明本文提出的 RSS 定位方法可以在目标数量未知的情况下较准确地实现多目标定位, 并具有较强的抗噪声能力。同时该算法的复杂度仍能满足实时应用。

参考文献:

- [1] 宋震龙, 蒋刚毅, 黄晔等. 基于偏度-峰度检验的无线局域网室内定位算法[J]. 通信学报, 2012, 33(5): 99-105.
SONG Z L, JIANG G Y, HUANG C, *et al.* WLAN indoor positioning algorithm based on skewness-kurtosis testing[J]. Journal on Communications, 2012, 33(5): 99-105.
- [2] LIU H, DARABI H, BANERJEE H, *et al.* Survey of wireless indoor positioning techniques and systems[J]. IEEE Transactions on Systems, Man, and Cybernetics-Part C, 2007, 37(6): 1067-1080.
- [3] CEVHER V, DUARTE M F, BARANIUK R G Distributed target localization via spatial sparsity[A]. EUSIPCO[C]. 2008. 25-29.
- [4] CEVHER V, BOUFONOUS P, BARANIUK R G, *et al.* Near-optimal bayesian localization via incoherence and sparsity[A]. IPSN[C]. 2009. 205-216.
- [5] FENG C, AU W S A, VALAEE S, TAN Z. Received-signal-strength-based indoor positioning using compressive sensing[J]. IEEE Transactions on Mobile Computing, 2012, 11(12): 1983-1993.
- [6] AU W S A, FENG C, VALAEE S, *et al.* Indoor tracking and navigation using received signal strength and compressive sensing on a mobile device[J]. IEEE Transactions on Mobile Computing, 2013, 12(10): 2050-2062.
- [7] CUI Q, DENG J, ZHANG X. Compressive sensing based wireless localization in indoor scenarios[J]. China Communications, 2012, 19(4): 1-12.
- [8] DENG J, CUI Q, ZHANG X, *et al.* Compressive sensing based indoor positioning with denosing and filtering in LF space[A]. PIMRC[C]. 2012. 2477-2482.
- [9] ZHANG B, CHENG X, ZHANG N. Sparse target counting and localization in sensor networks based on compressive sensing[A]. IEEE INFOCOM[C]. 2011. 2255-2263.
- [10] KAMOL K, PRASHANT K. Properties of indoor received signal strength for WLAN location fingerprinting[A]. First Annual International Mobile and Ubiquitous Systems Conference[C]. 2004. 14-23.
- [11] RAPPAPORT T S. Wireless Communication: Principles and Practice[M]. Englewood Cliffs, NJ: Prentice-Hall, 1999.
- [12] RUBINSTEIN R, BRUCKSTEIN A M and Elad M. Dictionaries for sparse representation modeling[J]. Proc of IEEE, 2010, 98(6): 1045-1057.
- [13] NOCEDAL J, WRIGHT S J. Numerical Optimization[M]. New York: Springer Verlag, 2006.
- [14] TROP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.
- [15] CHEN S S, DONOHO D L, SAUNDERS M A. Atomic decomposition by basis pursuit[J]. SIAM Review, 2001, 43(1): 129-159.
- [16] CANDES E J, WAKIN M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [17] CANDES E J, WAKIN M B, and BOYD S P. Enhancing sparsity by reweighted l_1 minimization[J]. Journal of Fourier Analysis Application, 2008, 14(5/6): 877-905.
- [18] MAIRAL J, BACH F, PONCE J, *et al.* Online learning for matrix factorization and sparse coding[J]. J Mach Learn Res, 2010, 11(3): 19-60.
- [19] 朱辉. 实用射频测试与测量[M]. 北京: 电子工业出版社, 2012.
ZHU H. Practical RF Test and Measurement[M]. Beijing: Electronic Industry Press, 2012, China.

作者简介:



王婷婷 (1979-), 女, 江苏南通人, 博士, 南京信息工程大学讲师, 主要研究方向为传感网络无线定位和信号处理。

柯炜 (1976-), 男, 江苏南通人, 南京师范大学副教授, 主要研究方向为无线通信技术、无线定位和信号处理。

孙超 (1989-), 男, 江苏扬州人, 南京师范大学硕士生, 主要研究方向为无线定位和无线通信技术。