

双向中继网络中基于压缩感知的稀疏信道估计

朱 星, 李有明*

(宁波大学 通信技术研究所, 浙江 宁波 315211)

摘要: 为提高双向中继网络中稀疏信道估计的精度并减少训练序列的长度, 利用双向中继信道(Two-way Relay Channel, TWRC)的潜在稀疏特性, 研究了基于压缩感知的稀疏 TWRC 估计问题, 提出了一种改进的正交匹配追踪(Improved Orthogonal Matching Pursuit, IOMP)算法. 新算法运用迭代重加权最小二乘估计代替了正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法中的最小二乘估计过程, 通过对样本进行迭代重加权, 逐步减小了异常样本的影响, 不断地修正了估计值, 在使用相同长度的训练序列时, 提高了估计的精度. 与传统的最小二乘估计算法相比, 新算法能够在获得相同估计效果的情况下, 显著减少所需训练序列的长度. 仿真结果验证了基于新算法的稀疏 TWRC 估计的有效性.

关键词: 双向中继网络; 稀疏双向中继信道估计; 压缩感知; 改进的正交匹配追踪

中图分类号: TN911.7

文献标志码: A

文章编号: 1001-5132 (2013) 02-0028-06

信道估计是提升双向中继网络性能的一种重要方式. 利用传统最小二乘估计算法进行 TWRC 估计时, 忽略了 TWRC 的潜在稀疏特性, 这样便会导致能量和带宽被过度使用、估计效率不高^[1-2]. 大量研究表明, 实际中的许多无线通信信道往往存在稀疏多径特性, 且这种稀疏特性会随着信号空间维度的增大而更加明显^[3-4]. 近几年兴起的压缩感知(Compressive Sensing, CS)理论使得从低维的观测值中恢复出稀疏或可压缩的高维信号成为可能^[5]. 将 CS 理论应用于稀疏信道的估计能够大大减少所需训练序列的长度, 显著提高能量和频谱的利用率. 因此, 文献[6]提出了一种基于 CS 理论中的正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法的稀疏 TWRC 估计. 该方法充分利用了 TWRC 信道的潜在稀疏特性, 在达到相同估计效果时, 比传统的基于最小二乘的估计算法需要的训练序列明显要少. 然而, 由于 OMP 本身是一种贪婪迭代算法, 每一次迭代过程都直接采用最小二乘算法去估计新的逼近值, 忽略了前一次迭代

后残差值较大的位置对应的异常样本的影响, 导致最终的估计结果精度不高^[7].

笔者重点研究了基于 CS 理论的放大转发双向中继信道(Amplify-and-forward TWRC, AF-TWRC)估计, 提出了一种改进的正交匹配追踪(Improved Orthogonal Matching Pursuit, IOMP)算法, 该算法利用迭代重加权最小二乘估计来逐步减小残差值较大的位置对应的异常样本的影响, 提高了估计的精度与稳健性. 与一般的基于 CS 的稀疏信道估计方法一样^[8-9], 文中均假定所考虑的 AF-TWRC 具有潜在的稀疏特性.

1 稀疏信道模型

拥有两个用户终端 T_1 和 T_2 的典型放大转发双向中继系统如图 1 所示. 假定 T_1 , T_2 和中继节点 R 均只有一根天线. 用 h_1 和 h_2 分别表示 T_1 和 T_2 与 R 之间的脉冲响应, 这里 h_1 和 h_2 是稀疏(非零元素的个数很少)的. 令 h_1 和 h_2 的长度均为 L , $h_i (i=1,2)$ 中的非零元素均是均值为零、方差为 $\sigma_{h_i}^2 (l=0 \sim L-1)$ 的

收稿日期: 2012-10-22.

宁波大学学报(理工版)网址: <http://nbdxlg.paperopen.com/>

基金项目: 国家自然科学基金(61071119); 浙江省自然科学基金(Y1091155); 宁波大学研究生科研创新基金(G12JA033).

第一作者: 朱 星(1989-), 男, 湖北应城人, 在读硕士研究生, 主要研究方向: 压缩感知技术及其应用. E-mail: gemxing@126.com

*通信作者: 李有明(1963-), 男, 陕西扶风人, 博导/教授, 主要研究方向: 宽带接入技术. E-mail: liyouming@nbu.edu.cn

复高斯随机变量. 对于 T_1 和 T_2 发送的训练序列分别记为 x_1 和 x_2 , 令 x_1 和 x_2 的长度均为 N 且 $x_1 = \{x_{1,i}\}_{i=1}^N$, $x_2 = \{x_{2,i}\}_{i=1}^N$, 此外 x_1 和 x_2 中的元素均是独立同分布的高斯随机变量. 假定 T_1 , T_2 和 R 之间是同步的.




图1 典型的 AF-TWRC 中的信号传输模型

在第一个时隙, 中继 R 的接收信号为:

$$y_r = x_1 * h_1 + x_2 * h_2 + n_r, \quad (1)$$

这里, $*$ 表示离散时间卷积, n_r 是均值为零、方差为 $\sigma_n^2 I_{N+L-1}$ 的复高斯噪声. (1)式中的接收信号经过中继放大因子 α 放大后再由中继 R 将其广播到 T_1 和 T_2 . 不失一般性, 文中仅考虑在用户终端 T_1 处的信道估计问题, 对于在用户终端 T_2 处的信道估计问题则可以类似进行讨论. 在第二个时隙, T_1 处的接收信号可以表示如下

$$\begin{aligned} y_1 &= \alpha y_r * h_1 + n_1 = \\ &\alpha(x_1 * h_1 * h_1 + x_2 * h_2 * h_1) + \\ &\alpha n_r * h_1 + n_1 = \alpha(x_1 * b + x_2 * c) + n, \end{aligned} \quad (2)$$

这里, $b = h_1 * h_1$ 且 $c = h_2 * h_1$, 我们称 b 和 c 为等效时域信道, b 和 c 的长度是 $2L-1$. n_1 和 $n = \alpha n_r * h_1 + n_1$ 均是满足均值为零的复高斯噪声. 由(2)式可以知道 $y_1 \in R^{\tilde{N} \times 1}$, 这里 $\tilde{N} = N + 2L - 2$. 令当 $j \notin \{1, \dots, N\}$ 时 $x_{1,j} = 0$, 则根据卷积的定义, y_1 中的任意第 m 项可以表示为:

$$\begin{aligned} y_{1,m} &= \alpha \left(\sum_{j=1}^N b_j x_{1,m+1-j} + \sum_{j=1}^N c_j x_{2,m+1-j} \right) + n_m, \\ m &= 1, \dots, \tilde{N}, \end{aligned} \quad (3)$$

因此, 信道模型(2)可以化为矩阵一向量积的形式, 即

$$y_1 = \alpha(X_1 b + X_2 c) + n = \alpha X h + n, \quad (4)$$

这里, $X_{i=1,2}$ 是 $\tilde{N} \times (2L-1)$ 的部分 Toeplitz 矩阵, 其第 1 行和第 1 列分别是 $[x_{1,1}, \mathbf{0}_{2L-2}^T]$ 和 $[x_i, \mathbf{0}_{2L-2}^T]^T$; 其中 $X = [X_1, X_2] \in R^{\tilde{N} \times (4L-2)}$, 且 $h = [b^T, c^T]^T \in R^{(4L-2) \times 1}$.

2 基于压缩感知理论的稀疏 AF-TWRC 估计

2.1 压缩感知理论基础

CS 技术是一种可通过欠奈奎斯特采样恢复稀

疏或可压缩的高维信号技术, 其数学模型为^[5]:

$$y = A f, \quad (5)$$

这里, $f \in R^{N \times 1}$ 是一个在某个基矩阵 $\varphi = \{\varphi_1, \varphi_2, \dots, \varphi_N\} \in R^{N \times N}$ 上可以被稀疏表示的信号, 即 $f = \varphi \theta$, 其中, $\theta = [\theta_1, \theta_2, \dots, \theta_N]^T \in R^{N \times 1}$ 包含 K ($K \ll N$) 个非零元素 (此时通常称向量 θ 的稀疏度是 K 或向量 θ 是 K -稀疏的). $A \in R^{M \times N}$ ($K < M \ll N$) 是一个与 φ 不相关的观测矩阵. $y \in R^{M \times 1}$ 表示由压缩感知的观测过程得到的 M 个采样值. CS 技术的目标就是仅通过这 M 个采样值就恢复出稀疏向量 θ , 然后用 φ 与之相乘得到原始信号 $f = \varphi \theta$.

2.2 基于 OMP 算法的稀疏 AF-TWRC 估计^[6,10]

算法输入信息包括: 用户终端 T_1 和 T_2 发送的训练序列 x_1 和 x_2 , $h = [b^T, c^T]^T$ 的信道稀疏度 (即主要抽头个数) S , 用户终端 T_1 的接收信号 Y . $X = [X_1, X_2]$ 是由 X_1 和 X_2 组成的叠加训练序列, 且以较高的概率满足受限等距性质^[5], 这里根据(4)式中 X_1 和 X_2 的定义即可由 x_1 、 x_2 得到 X_1 和 X_2 . 同时由(4)式的 AF-TWRC 模型以及第 2.1 节的压缩感知理论, 可以将 X 作为观测矩阵. 为了便于描述, 这里假定 $h \in R^{N \times 1}$, $X \in R^{M \times N}$, $Y \in R^{M \times 1}$.

具体实现过程为:

- (1) 设定初始残差值为 $r_0 = Y$, 初始索引集为 $\Lambda_0 = \emptyset$, 并令初始迭代次数 $i = 1$.
- (2) 若 i 不满足 $\{i: i \geq 4S | i = N\}$, 则执行如下过程:
 - (a) 求解一个索引值 λ_i , 使得 $\lambda_i = \arg \max |\langle r_{i-1}, t_j \rangle|$, ($j = 1, 2, \dots, N$), 这里 t_j 表示观测矩阵 X 的第 j 列. (b) 更新索引集和 X 中被选中的元素, 即 $\Lambda_i = \Lambda_{i-1} \cup \{\lambda_i\}$, $X_i = [X_{i-1} \ t_{\lambda_i}]$, 这里 t_{λ_i} 表示观测矩阵 X 的第 λ_i 列, 令 $X_0 = \emptyset$. (c) 通过最小二乘估计方法获得在索引集 Λ_i 内的一个新的估计值 $\hat{h}_i$, 即 $\hat{h}_i = (X_i^H X_i)^{-1} X_i^H Y$. 此时, 令在索引集 Λ_i 外的新估计值为零. (d) 更新残差值 $r_i = Y - X_i \hat{h}_i$. (e) $i = i + 1$, 并返回到步骤(2)进行条件判断.

(3) 输出最终估计值 $\hat{h}$, 这里 $\hat{h}$ 包含了 $\hat{b}$ 和 $\hat{c}$. 通过以上步骤得到估计值 $\hat{h}$ 后, 根据关系式 $h = [b^T, c^T]^T$ 即可在估计值 $\hat{h}$ 中分离出信道 b 和 c 的估计值 $\hat{b}$ 和 $\hat{c}$.

然而, 由以上实现过程可见, OMP 算法在每次迭代过程中主要采用步骤(2)中(c)所描述的最小二乘估计算法来求得新的估计值, 没有考虑第 $i-1$ 次

迭代后残差 r_{i-1} 中数值较大的位置对应的 X_{i-1} 中的异常样本的影响, 在第 i 次迭代中直接将 X_{i-1} 中所有的元素合并至 X_i , 并且直接用 X_i 进行最小二乘估计, 这样 X_{i-1} 中的异常样本将继续直接影响第 i 次的估计, 使得第 i 次迭代过程中根据最小二乘原理求得的新估计值不够准确, 并导致最终的估计精度不高.

2.3 基于 IOMP 算法的稀疏 AF-TWRC 估计

笔者提出的 IOMP 算法的主要思想是根据前一次迭代结果的残差值设计一种迭代重加权系数, 运用迭代重加权最小二乘估计代替 OMP 算法中的最小二乘估计过程, 逐步减小前一次迭代后残差值较大的位置对应的异常样本对下一次迭代估计的影响. 本节首先介绍了 IOMP 算法的推导过程, 然后说明迭代重加权系数的确定方法.

2.3.1 IOMP 算法的推导

根据最小二乘估计原理, 2.2 节所描述的 OMP 算法中步骤(2)的(c)过程实际上要求一个 h_i 值使其满足:

$$\begin{aligned} \hat{h}_i &= \arg \min \{ (Y - X_i \hat{h}_i)^H (Y - X_i \hat{h}_i) \} = \\ &= \arg \min \| Y - X_i \hat{h}_i \|^2, \end{aligned} \quad (6)$$

由于在 2.2 节中假定 $Y \in R^{M \times 1}$, 若令 $\beta = X_i h_i \in R^{M \times 1}$, 则(6)式可化为:

$$\hat{h}_i = \arg \min \sum_{k=1}^M [y^k - \beta^k]^2, \quad (7)$$

这里: y^k 和 β^k 分别表示向量 $Y \in R^{M \times 1}$ 和 $\beta \in R^{M \times 1}$ 中的第 $k(1 \leq k \leq M)$ 项.

若在第 i 次迭代过程中, 将(7)式中第 k 项乘以一个加权因子 w_i^k , 则(7)式变为迭代重加权形式

$$\hat{h}_i = \arg \min \sum_{k=1}^M w_i^k [y^k - \beta_i^k]^2, \quad (8)$$

将(8)式化为矩阵形式, 即

$$\begin{aligned} \hat{h}_i &= \arg \min \sum_{k=1}^M w_i^k [y^k - \beta_i^k]^2 = \\ &= \arg \min \{ (Y - X_i \hat{h}_i)^H W_i (Y - X_i \hat{h}_i) \}, \end{aligned} \quad (9)$$

这里

$$W_i = \begin{bmatrix} w_i^1 & 0 & \cdots & 0 \\ 0 & w_i^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & w_i^M \end{bmatrix},$$

是一个 $M \times M$ 的对角矩阵, 我们称之为加权矩阵. 此时, 令

$$\partial \{ (Y - X_i \hat{h}_i)^H W_i (Y - X_i \hat{h}_i) \} / \partial \hat{h}_i = 0,$$

即可解得第 i 次迭代的估计值为:

$$\hat{h}_i = (X_i^H W_i X_i)^{-1} X_i^H W_i Y, \quad (10)$$

用(10)式的估计值代替 2.2 节 OMP 算法中步骤(2)的(c)过程的估计, 结果即得到新的 IOMP 算法.

2.3.2 迭代重加权系数的确定

为了减小第 $i-1$ 次迭代后残差值较大的位置对应的 X_{i-1} 中的异常样本继续对第 i 次迭代估计的影响, 根据(8)式所描述的迭代重加权最小二乘估计表示形式, 可将加权因子定义为:

$$w_i^k = \frac{1}{|r_{i-1}^k| + \varepsilon}, \quad (11)$$

这里: r_{i-1}^k 表示第 $i-1$ 次迭代后的残差 $r_{i-1} \in R^{M \times 1}$ 的第 $k(1 \leq k \leq M)$ 个元素, ε 是一个已知的极小的正常数, ε 用来保证当 $|r_{i-1}^k|$ 为零时的 w_i^k 有意义. 因此, 当 $|r_{i-1}^k|$ 较大时就对应一个较小的 w_i^k , 这样便减小了 $|r_{i-1}^k|$ 较大的位置对应的 X_{i-1} 中的异常样本对第 i 次迭代估计的影响. 当 $|r_{i-1}^k|$ 较小时对应一个较大的 w_i^k , 这样使第 i 次迭代过程对 $|r_{i-1}^k|$ 较小的位置对应的 X_{i-1} 中的样本引起更多的重视, 使整个迭代估计过程的精确度更高. 因此, 第 $i(i \geq 2)$ 次迭代过程的加权矩阵可表示为:

$$W_i = \begin{bmatrix} \frac{1}{|r_{i-1}^1| + \varepsilon} & 0 & \cdots & 0 \\ 0 & \frac{1}{|r_{i-1}^2| + \varepsilon} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \frac{1}{|r_{i-1}^M| + \varepsilon} \end{bmatrix}, \quad (12)$$

当 $i=1$ 时, 令 $W_1 = I_M$.

3 仿真结果与性能分析

通过计算机仿真比较提出的 IOMP 算法与 OMP 算法、最小二乘(Least Squares, LS)算法以及理想情况下的最小二乘(Ideal Least Squares, ILS)算法对稀疏 AF-TWRC 估计的归一化均方误差(Normalized Mean Square Error, NMSE)性能以及计算复杂度. 其中, ILS 算法表示主要抽头位置是已知情况下的 LS 算法(通常可将 ILS 算法估计的结

果作为理想的参考界限^[11]). 对于信道估计值 $\hat{\mathbf{b}}$ 的 $NMSE(\hat{\mathbf{c}}$ 的 $NMSE$ 拥有相同的形式)定义为:

$$NMSE(\hat{\mathbf{b}}) = \frac{E\{\sum_{n=1}^{Num} |\mathbf{b}_n - \hat{\mathbf{b}}_n|^2\}}{E\{\sum_{n=1}^{Num} |\mathbf{b}_n|^2\}}, \quad (13)$$

这里: Num 为蒙特卡洛实验仿真次数, $\hat{\mathbf{b}}_n$ 为第 n 次仿真后的估计值, $\mathbf{b}_n$ 为第 n 次仿真时信道 $\mathbf{b}$ 的真实值. 显然 $NMSE$ 越小, 则信道估计越精确.

3.1 不同信噪比情况下的 $NMSE$ 比较

仿真参数设置为: 蒙特卡洛仿真次数 $Num=1000$, 常数 $\epsilon=10^{-8}$, 信噪比变化范围为 $0\sim 30$ dB, 信道向量 $\mathbf{h}_1$ 和 $\mathbf{h}_2$ 的长度 $L=16$; $\mathbf{h}_1$ 和 $\mathbf{h}_2$ 的稀疏度(主要抽头数)均设定为 6, 则 $\mathbf{b}$ 和 $\mathbf{c}$ 的稀疏度最大为 12. 设定用户终端 T_1 和 T_2 发送的训练序列长度相同, 分别取 18, 36 和 54. 图 2 和图 3 分别为对信道 $\mathbf{b}$ 和 $\mathbf{c}$ 进行信道估计时的 $NMSE$ 随 SNR 的变化情况. 图 2 表明随着 SNR 的增加, 4 种算法对信道估计的 $NMSE$ 逐渐减小. 在相同训练序列长度和相同信噪

比的情况下, 提出的 IOMP 算法对信道 $\mathbf{b}$ 估计的 $NMSE$ 值要明显小于 OMP 算法. 而且在与传统的 LS 算法相比时, 在获得相同估计精度的情况下, IOMP 算法可以显著减少所需的训练序列长度. 在 IOMP、OMP 和 LS 这 3 种算法中, IOMP 算法与理想的 ILS 算法的估计性能差距最小. 从图 3 亦可得到与图 2 相同的结论.

3.2 不同稀疏度情况下的 $NMSE$ 比较

为了简化比较过程, 与 3.1 节类似, 设定信道 $\mathbf{h}_1$ 和 $\mathbf{h}_2$ 的稀疏度相同, 记为 s , 且 s 分别取 2, 4 和 6. 设置 T_1 和 T_2 发送的训练序列长度均为 36, 蒙特卡洛仿真次数 $Num=1000$, 常数 $\epsilon=10^{-8}$, SNR 的变化范围为 $0\sim 30$ dB, $\mathbf{h}_1$ 和 $\mathbf{h}_2$ 的长度 $L=16$. 图 4 和图 5 分别为不同信噪比下, 对信道 $\mathbf{b}$ 和 $\mathbf{c}$ 进行信道估计时的 $NMSE$ 随信道稀疏度 s 的变化情况.

从图 4 可以看出, 基于传统的 LS 算法的信道估计的 $NMSE$ 值在信道稀疏度变化时保持不变, 这是由传统的 LS 算法在信道估计时没有利用信道稀




图 2 $\mathbf{b}$ 信道估计的 $NMSE$ 随 SNR 变化




图 4 不同稀疏度下 $\mathbf{b}$ 信道估计的 $NMSE$ 随 SNR 变化




图 3 $\mathbf{c}$ 信道估计的 $NMSE$ 随 SNR 变化




图 5 不同稀疏度下 $\mathbf{c}$ 信道估计的 $NMSE$ 随 SNR 变化

疏性导致的结果. 随着稀疏度的降低, IOMP 算法和 OMP 算法估计的 $NMSE$ 均越来越小, 逐步接近 ILS 算法的估计性能, 在整个稀疏度的变化过程中, 相同稀疏度情况下, IOMP 算法的估计效果均明显优于 OMP 算法. 由图 5 同样可得类似结论.

3.3 计算复杂度比较

通过计算在训练序列长度相同时 CPU 完成一次信道估计所需的时间来衡量提出的 IOMP 算法与 OMP 算法及 LS 算法的计算复杂度. 仿真环境为: Matlab 2011b, 采用的计算机内存是 2.96 GB, 主频为 2.16 GHz, 处理器为 Intel 奔腾双核处理器, 操作系统是 Windows XP SP3. 具体仿真参数为: 常数 $\varepsilon = 10^{-8}$; $SNR=10$ dB; $\mathbf{h}_1$ 和 $\mathbf{h}_2$ 长度 $L=16$ 、稀疏度均为 6; T_1 和 T_2 发送的训练序列长度相同, 分别取 18, 36, 54, 72, 90. 图 6 为 IOMP 算法与 OMP 算法及 LS 算法所消耗的 CPU 运行时间随训练序列长度的变化情况.

图 6 显示, IOMP 算法与 OMP 算法的运行时间差小于 0.01 s, 而且 IOMP 算法与 LS 算法的消耗时间之差保持在 0.04 s 以内, 因此表明 IOMP 算法与 OMP 算法及 LS 算法的计算复杂度非常接近.




图 6 CPU 运行时间随训练序列长度变化

4 结论

利用压缩感知理论研究了双向中继网络中的稀疏信道估计, 提出了一种改进的正交匹配追踪算法. 相比于正交匹配追踪算法, 新算法首先在每一次迭代过程中利用前一次迭代结果的残差设计了一种自适应重加权因子, 然后采用迭代重加权最小二乘估计代替了正交匹配追踪算法中的最小二乘估计过程. 仿真结果表明, 新算法在相同条件

下的估计精度明显优于正交匹配追踪算法和传统的 LS 估计算法. 此外, 新算法的计算复杂度与正交匹配追踪算法和 LS 算法接近.

参考文献:

- [1] Gao F F, Zhang R, Liang Y C. Optimal channel estimation and training design for two-way relay networks[J]. IEEE Transactions on Communications, 2009, 57(10):3024-3033.
- [2] Gao F F, Zhang R, Liang Y C. Channel estimation for OFDM modulated two-way relay networks[J]. IEEE Transactions on Signal Processing, 2009, 57(11):4443-4455.
- [3] Bajwa W U, Haupt J, Sayeed A M, et al. Compressed channel sensing: A new approach to estimating sparse multipath channels[J]. Proceedings of the IEEE, 2010, 98(6):1058-1076.
- [4] Taubock G, Hlawatsch F, Eiwen D, et al. Compressive estimation of doubly selective channels in multicarrier systems: Leakage effects and sparsity-enhancing processing [J]. IEEE Journal of Selected Topics in Signal Processing, 2010, 4(2):255-271.
- [5] 焦李成, 杨淑媛, 刘芳, 等. 压缩感知回顾与展望[J]. 电子学报, 2011, 39(7):1651-1662.
- [6] 袁文文, 郑宝玉, 岳文静. 基于压缩感知技术的双向中继信道估计[J]. 信号处理, 2012, 28(1):33-38.
- [7] Hung K W, Siu W C. Robust soft-decision interpolation using weighted least squares[J]. IEEE Transactions on Image Processing, 2012, 21(3):1061-1069.
- [8] Berger C R, Wang Z H, Huang J Z, et al. Application of compressive sensing to sparse channel estimation[J]. IEEE Communications Magazine, 2010, 48(11):164-174.
- [9] Haupt J, Bajwa W U, Raz G, et al. Toeplitz compressed sensing matrices with applications to sparse channel estimation[J]. IEEE Transactions on Information Theory, 2010, 56(11):5862-5875.
- [10] Tropp 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.
- [11] Gui G, Wan Q, Adachi F. Compressed channel estimation of two-way relay networks using mixed-norm sparse constraint[J]. Research Journal of Applied Sciences, Engineering and Technology, 2012, 4(15):2279-2282.

Sparse Channel Estimation for Two-way Relay Networks Based on Compressive Sensing

ZHU Xing, LI You-ming^{*}

(Institute of Communication Technology, Ningbo University, Ningbo 315211, China)

Abstract: In order to improve the precision of sparse channel estimation and reduce the length of the training sequences required by the sparse channel estimation in two-way relay networks, the compressive sensing based sparse two-way channel (TWRC) estimation is studied by exploiting the potential sparsity of the TWRC. An improved orthogonal matching pursuit (IOMP) algorithm is proposed in this paper. The new algorithm uses an iteratively reweighted least squares method to replace the least squares estimation process of the orthogonal matching pursuit (OMP) algorithm. By applying the iteratively update weight to the samples, the new algorithm can weaken the effect of abnormal samples gradually, thus revising the estimation values during each iteration and improving the precision of the estimation when using the same length of training sequences. Furthermore, the IOMP based sparse TWRC estimation algorithm can significantly reduce the length of the training sequences under the same estimation precision when comparing to the conventional least squares estimation algorithm. Simulation results demonstrate the effectiveness of the proposed TWRC estimation algorithm.

Key words: two-way relay networks; sparse two-way relay channel estimation; compressive sensing; improved orthogonal matching pursuit estimation

(责任编辑 史小丽)