

采用去网格相关向量机的水下多径稀疏信道估计*

林格平^{1,2,3} 马晓川^{1,2,3†} 鄢社锋^{1,2,3} 蒋理^{1,2,3}

(1 中国科学院声学研究所 北京 100190)

(2 中国科学院大学 北京 100190)

(3 中国科学院水下航行器信息技术重点实验室 北京 100190)

2017 年 2 月 23 日收到

2017 年 5 月 6 日定稿

摘要 在采用训练序列的水下稀疏信道估计问题中, 由于采样过程的存在产生了测量矩阵的网格, 所以当多径时延不恰好位于网格上时, 传统的有网格方法就无法准确估计出该多径的位置, 在网格间距较大时这个问题更加严重。针对这个问题, 本文构建了一个去网格的稀疏信道估计模型, 这个估计模型的测量矩阵包含了对网格外偏差进行调整的参数, 在此基础上进一步采用相关向量机的方法对这个调整参数进行估计, 得到网格外的偏差值。针对两种不同的水下稀疏多径信道模型进行的仿真试验证明, 此方法相比其它有网格稀疏信道估计算法, 在估计误差和误码率上有提升, 在网格间距较大时, 优势更加明显。
PACS 数: 43.60, 43.30

Underwater acoustic multipath sparse channel estimation via gridless relevance vector machine method

LIN Geping^{1,2,3} MA Xiaochuan^{1,2,3} YAN Shefeng^{1,2,3} JIANG Li^{1,2,3}

(1 *Institute of Acoustics, Chinese Academy of Sciences* Beijing 100190)

(2 *University of Chinese Academy of Sciences* Beijing 100190)

(3 *Key Laboratory of Information Technology for AUVs, CAS* Beijing 100190)

Received Feb. 23, 2017

Revised May 6, 2017

Abstract In the scenario of underwater acoustic sparse channel estimation with training sequences, grid points in the measuring matrix are caused by discretizing procedure. Estimating accuracy might not be guaranteed with state-of-the-art methods when multipath delays don't exactly locate on the grid points. In this paper, we construct a gridless measuring matrix for sparse channel estimation which contains a off-grid adjusting factor and further using Relevance Vector Machine algorithm to estimate this factor to estimate the offset. This paper first describes the approach and then testifies its estimating result in numerical experiments on two different underwater channels. The results demonstrate that this method outperforms conventional ones in estimating error and bit error rate and this is even more obvious when the grid gets coarser.

引言

水声环境的多径效应是造成水声信道的复杂性的重要原因, 它使信号产生衰减和畸变, 影响水下通信系统的性能, 所以对水声多径信道的信道估计非

常重要。水声信道是一种典型的稀疏信道^[1]。所谓稀疏信道, 是指从发射端到接收端, 携带信息的信号能量集中在少数路径上, 而其它路径上的信号能量基本为零。在水声信道中, 我们考虑海面反射、海底反射、海面-海底反射和直达路径 4 种路径。

较为传统的多径稀疏信道估计方法多数基于最

* 国家自然科学基金项目(61471352, 61431020)资助

† 通讯作者: 马晓川, maxc@mail.ioa.ac.cn

小二乘 (Least Square, LS)^[2-4]、最小均方误差 (Minimum Mean Square Error, MMSE) 和最大似然 (Maximum Likelihood, ML) 等准则而进行, 或者进行匹配滤波。此类方法或计算量巨大, 或估计精度较差, 应用价值不高。近年来水声稀疏信道估计问题开始转向新兴的算法。有学者借鉴阵列信号处理中的子空间算法比如 MUSIC 和 ESPRIT^[5] 来进行水下稀疏信道估计^[6], 也有学者采用时频方法来进行估计^[7]。而在压缩感知和稀疏恢复理论被提出后, 更多的学者开始转向此类算法的应用, 比如 l_1 范数最优化的方法^[8-10], 近似 l_0 范数的迭代估计方法^[11], 贪婪算法中的匹配追踪和正交匹配追踪^[6,12-15], 以及贝叶斯稀疏学习 (Sparse Bayesian Learning, SBL) 或相关向量机 (Relevance Vector Machine, RVM) 算法^[16-17]。此类算法充分利用了水声信道的稀疏性, 具有更高的效率和精度, 非常适合处理水下稀疏信道估计的问题, 但是由于离散采样过程的天然存在, 以上稀疏估计方法采用的测量矩阵都设置了时延网格, 对多径时延的估计都局限在网格之上。而更加普遍的情况是, 这些多径时延不会恰好位于网格上, 这种情况下, 这些方法就不能估计出多径时延在网格之外的偏差。尤其在网格间距较大的情况下, 估计精度会非常差。

从这个问题出发, 本文在原有的稀疏信道估计模型基础上进行了改进, 引入了网格外偏差调整参数, 建立去网格 (gridless) 的稀疏信道估计测量矩阵, 然后再根据贝叶斯原理采用 RVM 进行参数估计, 得到多径时延在网格外偏差的大小, 从而得到更加精确的稀疏信道估计结果。本文在进行了理论推导后又进一步针对两种不同类型的水声稀疏信道模型进行了仿真试验, 并从信道冲激响应的估计结果、信道多径时延位置准确性、信道估计的均方误差、信道估计的效率以及误码率等 5 个方面来展现本文所提方法的估计效果。仿真试验结果验证了本文所提出的方法在水声稀疏信道估计问题中尤其在大网格间距情况下的优势。

1 系统模型的建立

1.1 稀疏信道估计的基本信号模型

为了在时域对信道进行研究, 本研究关注线性时不变的信道。参考文献 14、文献 18 和文献 19, 我们首先采取一个基本的通信模型, 即常见的单载波点对点通信, 调制方式为 BPSK, 载频为 13 kHz, 数据传输率为 1000 bps, 带宽为 2 kHz, 将其看作窄带信号, 对信号频率为 13 kHz 的信道进行估计。在数据

帧前插入训练序列来进行信道估计。训练序列基带信号用 $\mathbf{x} \in \mathbb{R}^M$ 来表示, 则发射的训练序列信号为:

$$s(t) = x(t) \exp[j(2\pi ft + \theta)], \quad (1)$$

其中 f 为载波频率, θ 为初始相位, 通常令 $\theta=0$, 则信道的冲激响应用 \mathbf{h} 表示为:

$$h(t) = \sum_{k=1}^N a_k \delta(t - \tau_k), \quad (2)$$

其中 N 为多途路径数目, a_k 和 τ_k 对应于信道各个路径的衰减系数和延时, 则接收到数据可以写成:

$$y(t) = \sum_{k=1}^N a_k x(t - \tau_k) \exp[j2\pi(f_d t - f\tau_k)] + w(t), \quad (3)$$

其中, f_d 为多普勒频移, 此时可暂不考虑多普勒效应带来的频移, 则接收到的基带信号为:

$$y(t) = \sum_{k=1}^N a_k x(t - \tau_k) + w(t), \quad (4)$$

$w(t)$ 表示的是信息传输过程中的加性噪声, 这里假设为高斯白噪声, 将上式重写为:

$$y(m) = \sum_{n=0}^{N-1} h(n)x(m-n) + w(m), \quad (5)$$

$$(m = 0, 1, \dots, M-1)$$

然后用 \mathbf{X} 表示卷积中的信号矩阵, 这里把它当作稀疏恢复中的测量矩阵来使用。将式 (5) 写成矩阵形式, 得到:

$$\mathbf{y} = \mathbf{X}\mathbf{h} + \mathbf{w}, \quad (6)$$

$$\mathbf{y} = [y(0), y(1), \dots, y(M-1)]^T, \quad (7)$$

$$\mathbf{h} = [h(0), h(1), \dots, h(N-1)]^T, \quad (8)$$

$$\mathbf{w} = [w(0), w(1), \dots, w(M-1)]^T, \quad (9)$$

$$\mathbf{X} = \begin{bmatrix} x(0) & x(-1) & \dots & x(-N+1) \\ x(1) & x(0) & \dots & x(-N+2) \\ \dots & \dots & \dots & \dots \\ x(M-1) & x(M-2) & \dots & x(M-N) \end{bmatrix}, \quad (10)$$

\mathbf{X} 是由训练序列构成的 Toeplitz 矩阵, 每一行或一列相邻的两项的时间间隔为网格间距。由于信道的稀疏性, \mathbf{h} 中的多数成分为零, 非零项代表不同延时的幅度值。估计这个信道就是找出这些延时并计算这些非零项的大小。如果其中非零项个数为 K , 那么这个信道称为 K -稀疏的或信道的稀疏级为 K 。

1.2 测量矩阵的去网格化改进

在之前的研究中, 我们估计得到的多径时延都落在测量矩阵划分好的网格中, 比如将长度为 250 ms 的信道划分成 50 份, 那么估计出的信道延时将肯定被约束在 5 ms 的整数倍, 但这现实情况不会这么理想。当对延时估计精度要求较高时, 上面研究的方法就无能为力了, 所以我们考虑将时延精确化估计, 使用去网格相关向量机 (Gridless Relevance Vector Machine, GL-RVM) 进行稀疏信道估计, 文献 20—文献 24 对去网格的压缩感知方法进行了探讨并多应用于阵列信号处理中的波达方向估计。

去网格的相关向量机算法在模型建立上对式 (6) 的形式进行了改进, 采用线性逼近对原来的测量矩阵进行处理, 得到更加精细的测量矩阵模型。对于式 (6), 假设 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$, 假设测量矩阵网格间距为 T_g , 而多径时延恰好位于 kT_g 处, 可以得到 $\mathbf{x}_k = [x(-kT_g), x(-k+1)T_g, \dots, x(0), \dots, x(M-k)T_g]^T$, 由这一路多径给接收端带来的贡献为 $\kappa_k = h_k \mathbf{x}_k$, 其中 h_k 为这一路多径的幅度增益。但实际上多径时延 t_k 不太可能恰好位于 kT_g 处, 而是会存在一定的偏差, 即 $\beta_k = t_k - kT_g$, 可采用线性逼近对此进行修正, 即 $\kappa_k = h_k(\mathbf{x}_k + \mathbf{b}_k \beta_k)$, 则测量矩阵的每一列更新为:

$$\phi_k = \mathbf{x}_k + \mathbf{b}_k \beta_k, \quad k \in (1, 2, \dots, N) \quad (11)$$

其中, $\mathbf{b}_k = \mathbf{x}'(k)$ 。

进而得到更新以后的稀疏信道估计测量矩阵:

$$\Phi(\beta) = \mathbf{X} + \mathbf{B} \text{diag}(\beta), \quad (12)$$

以及更新后的信道估计模型:

$$\mathbf{y} = \Phi(\beta) \mathbf{h} + \mathbf{w}, \quad (13)$$

其中的 \mathbf{X} 为式 (10) 中介绍的有网格的测量矩阵, 而 \mathbf{B} 由 \mathbf{X} 求微分得到, 即:

$$\mathbf{B} = \begin{bmatrix} x'(0) & x'(-1) & \dots & x'(-N+1) \\ x'(1) & x'(0) & \dots & x'(-N+2) \\ \dots & \dots & \dots & \dots \\ x'(M-1) & x'(M-2) & \dots & x'(M-N) \end{bmatrix}, \quad (14)$$

$\beta = [\beta_1, \dots, \beta_N]^T$ 是网格外调整参数, 这就是本文建立的去网格稀疏信道估计模型。模型建立之后, 对多径时延的估计就不仅是稀疏信道参数 \mathbf{h} 的估计, 而且包括网格外调整参数 β 的估计, 而传统的有网格估计恰恰是 $\beta = \mathbf{0}$ 时的特例。在下一节将详细介绍采用 RVM, 一种贝叶斯方法对这两个量的估计方法。可以预见的是, 这种模型带来的结果是使得估计更

加精细化, 对稀疏信号非零位置的判断更加准确, 在网格间距较大, 采样率较低时, 这种算法的优势将很明显。

2 贝叶斯参数估计

首先在式 (6) 中的噪声 \mathbf{w} 为高斯白噪声的前提下, 得到:

$$p(\mathbf{w}|\alpha_0) = \prod_{k=1}^N \mathcal{N}(w(t)|\mathbf{0}, \alpha_0^{-1} \mathbf{I}), \quad (15)$$

其中 $\alpha_0 = \sigma^{-2}$ 代表噪声参数, σ^2 是噪声方差, 然后得到:

$$p(\mathbf{y}|\mathbf{h}, \alpha_0, \beta) = \prod_{t=0}^T \mathcal{N}(y(t)|\Phi(\beta) \mathbf{h}(t), \alpha_0^{-1} \mathbf{I}). \quad (16)$$

本文中假设 α_0 未知, 假设 α_0 的超先验为 Gamma 分布, 这是一种与高斯分布共轭的分布,

$$p(\alpha_0; c, d) = \Gamma(\alpha_0|c, d), \quad (17)$$

$$\Gamma(\alpha_0|c, d) = [\Gamma(c)]^{-1} d^c \alpha_0^{c-1} \exp\{-d\alpha_0\}, \quad (18)$$

其中 $\Gamma(\cdot)$ 为 Gamma 函数, c 和 d 是设置的超参数。

对于信道冲激响应, 已知它满足稀疏条件, 对这个条件加以利用, 并将它的先验分成两层结构:

$$p(\mathbf{h}; \rho) = \int p(\mathbf{h}|\alpha) p(\alpha; \rho) d\alpha, \quad (19)$$

其中 $\rho > 0$, $\alpha \in \mathbb{R}^N$, 且:

$$p(\mathbf{h}|\alpha) = \prod_{t=0}^T \mathcal{N}(h(t)|\mathbf{0}, \Lambda), \quad (20)$$

$$p(\alpha; \rho) = \prod_{n=1}^N \Gamma(\alpha_n|1, \rho), \quad (21)$$

其中 $\Lambda = \text{diag}(\alpha)$, 这样得到的 \mathbf{h} 符合 Laplace 分布, 这是一种具备了稀疏性质的概率密度:

$$p(\mathbf{h}|\rho) = \rho \exp(-\rho \|\mathbf{h}\|_1). \quad (22)$$

对于 β , 假设它满足一致分布:

$$\beta \sim U \left(\left[-\frac{1}{2}r, \frac{1}{2}r \right]^N \right). \quad (23)$$

最后将以上层级贝叶斯模型的各个部分联立, 得到联合概率密度函数为:

$$p(\mathbf{h}, \mathbf{y}, \alpha_0, \alpha, \beta) = p(\mathbf{y}|\mathbf{h}, \alpha_0, \beta) p(\mathbf{h}|\alpha) p(\alpha) p(\alpha_0) p(\beta), \quad (24)$$

其中等式右边各项由式 (16)、式 (17)、式 (20)、式 (21)、式 (23) 给出。

下一步要进行的是对 \mathbf{h} 的后验进行高斯分析和确定其中的参数值。由于 $p(\mathbf{h}, \alpha_0, \boldsymbol{\alpha}, \boldsymbol{\beta} | \mathbf{Y})$ 的精确求解比较困难, 参照文献 25 采用证据过程的方法进行后验估计。

由式 (24) 知, $p(\mathbf{h}, \mathbf{y}, \alpha_0, \boldsymbol{\alpha}, \boldsymbol{\beta})$ 是高斯分布, 那么由于 $p(\mathbf{h} | \mathbf{y}, \alpha_0, \boldsymbol{\alpha}, \boldsymbol{\beta}) \propto p(\mathbf{h}, \mathbf{y}, \alpha_0, \boldsymbol{\alpha}, \boldsymbol{\beta})$ 也是高斯分布, 假设其均值和方差为 $\boldsymbol{\mu}$ 和 $\boldsymbol{\Sigma}$, 对于随机变量 $\mathbf{u} \sim \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ 来说, 它的概率密度函数为:

$$\mathcal{N}(\mathbf{u} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\pi^N |\boldsymbol{\Sigma}|} \exp\{-\frac{1}{2}(\mathbf{u} - \boldsymbol{\mu})^H \boldsymbol{\Sigma}^{-1}(\mathbf{u} - \boldsymbol{\mu})\}. \quad (25)$$

得到:

$$\boldsymbol{\mu} = \alpha_0 \boldsymbol{\Sigma} \boldsymbol{\Phi}^H \mathbf{Y}, \quad (26)$$

$$\boldsymbol{\Sigma} = (\alpha_0 \boldsymbol{\Phi}^H \boldsymbol{\Phi} + \boldsymbol{\Lambda}^{-1})^{-1}, \quad (27)$$

其中的 $\boldsymbol{\mu}$ 就是要估计的信道冲激响应 \mathbf{h} 。

以上两式中存在 3 个参数 α_0 , $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 需要估计, 根据 MAP 准则对其进行估计, 建立目标函数 $\mathcal{L} = \log p(\alpha_0, \boldsymbol{\alpha}, \boldsymbol{\beta} | \mathbf{y})$, 令它最大, 得到的参数值就是我们要求的参数值。这里采用求偏导的方法来求解。对 α_0 和 $\boldsymbol{\alpha}$ 进行更新得到:

$$\frac{\partial \mathcal{L}}{\partial \alpha_i} = 0 \Rightarrow \alpha_i^{\text{new}} = \frac{\gamma_i}{\mu_i^2}, \quad (28)$$

$$\frac{\partial \mathcal{L}}{\partial \alpha_0} = 0 \Rightarrow \alpha_0^{\text{new}} = \frac{M - \sum_i \gamma_i}{\|\mathbf{y} - \boldsymbol{\Phi} \mathbf{h}\|^2}, \quad (29)$$

而对于 $\boldsymbol{\beta}$, 将以上估计结果代入新的目标函数:

$$\mathcal{L}_\beta = \arg \min_{\boldsymbol{\beta}} \|\mathbf{y} - [\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})] \mathbf{h}\|_2^2. \quad (30)$$

这里采用 EM 算法 (Expectation Maximization, 期望最大) 算法进行处理。式 (30) 右边的期望为:

$$\begin{aligned} E\{\|\mathbf{y} - [\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})] \mathbf{h}\|_2^2\} &= E\{\|\mathbf{y} - [\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})] \boldsymbol{\mu}\|_2^2\} + \\ \text{Tr}[\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})] \boldsymbol{\Sigma} [\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})]^H &\approx \frac{1}{\alpha_0^2} + \text{Tr}[\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})] \boldsymbol{\Sigma} [\mathbf{X} + \mathbf{B} \text{diag}(\boldsymbol{\beta})]^H = \\ \frac{1}{\alpha_0^2} + 2\text{Tr}(\mathbf{B}^H \mathbf{X} \boldsymbol{\Sigma} \text{diag}(\boldsymbol{\beta})) + \text{Tr}(\text{diag}(\boldsymbol{\beta}) \boldsymbol{\Sigma} \text{diag}(\boldsymbol{\beta}) \mathbf{B}^H \mathbf{B}) + C &= \\ \frac{1}{\alpha_0^2} + 2\text{diag}(\mathbf{B}^H \mathbf{X} \boldsymbol{\Sigma}) \boldsymbol{\beta} + \boldsymbol{\beta}^T (\boldsymbol{\Sigma} \odot \mathbf{B}^H \mathbf{B}) \boldsymbol{\beta} + C. & \end{aligned} \quad (31)$$

上式对 $\boldsymbol{\beta}$ 求导, 令它为零, 得到:

$$\beta_i = -\frac{\text{diag}(\mathbf{B}^H \mathbf{X} \boldsymbol{\Sigma})_i}{\alpha_i (\mathbf{B}^H \mathbf{B})_{ii}}. \quad (32)$$

采用上式由已经求出的 α_0 , $\boldsymbol{\alpha}$ 对 $\boldsymbol{\beta}$ 进行估计。

本文提出的 GL-RVM 按照如下步骤进行: 首先对参数 α_0 , $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 进行初始化, 然后由它们求出 $\boldsymbol{\Sigma}$ 和 $\boldsymbol{\mu}$, 再用这两个值更新参数 α_0 , $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 的值, 并如此迭代地进行下去, 直到满足收敛条件。由于 EM 算法能保证代价函数的单调递增, 所以 GL-RVM 的收敛条件一定在若干次迭代之后满足。

3 仿真试验

本节中, 将采用上一节提出的算法, 在稀疏信道估计的情景下进行仿真试验, 来观察这种算法的估计效果, 并且与已经存在的几种算法比如 OMP(正交匹配追踪)、StOMP(分段正交匹配追踪)、BMP(贝叶斯匹配追踪)、RVM 等有网格的稀疏信道估计算法进行估计效果方面的比较。

仿真试验工作在 CPU 主频为 2.6G Hz、内存存在 3 GB、操作系统为 Windows 7 的计算机上以及 MATLAB 环境下进行, 参照文献 26, 采用线性调频信号作为训练序列, 表示为:

$$x(n) = \cos(2\pi(\xi n^2 + \eta n)), \quad n = 0, 1, \dots, M-1, \quad (33)$$

其中的参数定义为 $\xi = 1/6(M-1)$, $\eta = 2$, 采样频率 $f_s = 6$ kHz, 得到的训练序列中心频率为 13 kHz, 带宽为 2 kHz, 将其作为训练序列对这个信道模型进行估计。噪声 \mathbf{w} 为 Matlab 产生的加性高斯白噪声。

首先针对一种简单的稀疏信道环境进行仿真试验。信道总长度为 200, 非零的多径时延一共有 4 个, 网格间距为 2, 4 个多径时延的时延位置均设置在网格之外, 即 21.2, 50.4, 71.6 和 153.8, 信噪比设置为 20 dB, 得到的仿真结果如图 1 所示。

由仿真结果可以看出, 在这种简单的稀疏信道估计情景下, GL-RVM 非常准确地找到了多径时延的位置, 而相比之下 RVM 则偏差较大。

进而针对浅海水声通信场景进行研究,所以在研究中采用了由射线声学建立的浅海声场模型,进而得到信道状态信息 h ,如图 2 所示。模型建立条件参考文献 14、文献 18 和文献 19,模型和通信系统具体参数如表 1 所示。试验中采用的信噪比从 1 dB 到 30 dB,仿真试验的蒙特卡罗次数为 100。我们从信道冲激响应的估计结果、信道多径时延位置准确性、信道估计的均方误差、信道估计的效率以及 DFE (Decision Feedback Equalizer, 判决反馈均衡器) 均衡后的误码率等 5 个方面来展现 GL-RVM 的估计效果。

表 1 仿真试验中采用的模型 1 通信参数

发射机深度	25m
接收机深度	100 m
距离	3 km
载频	13 kHz
码元速率	1000 B
数据率	1000 bps
调制方式	BPSK
带宽	2 kHz
信道稀疏度	16




图 1 GL-RVM 与 RVM 进行稀疏信道估计的效果对比

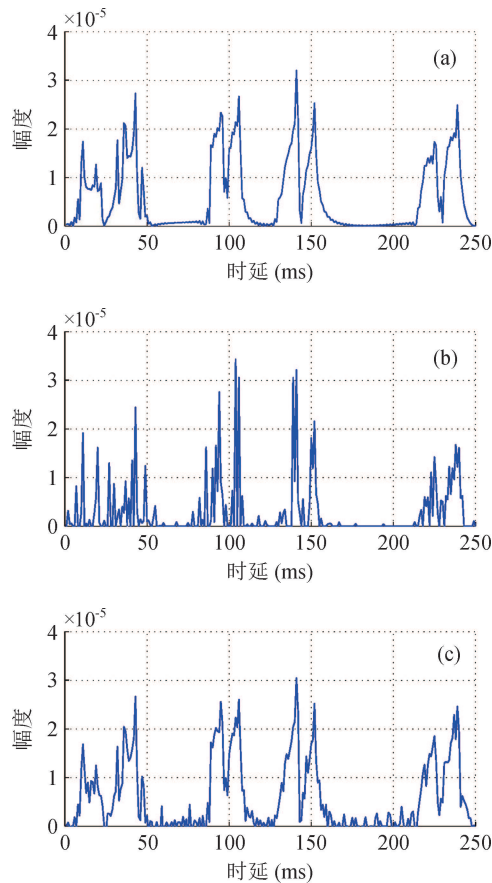


图 2 (a) 模型 1 的实际信道冲激响应; (b) RVM 估计结果; (c) GL-RVM 估计结果

图 2 为信道冲激响应和 RVM 以及两种不同网格情形下的 GL-RVM 算法估计结果,网格设置为 $r=15$ ms,信噪比为 26 dB。由于选取的训练序列采样周期归一化为 1,故而用采样点数表示路径时延。可以看出,RVM 对时延位置和幅度的估计都不甚理想,有较大偏差,并且伴随着更多的伪峰,而 GL-RVM 则可以更加准确地估计出多径时延的位置和幅度。

图 3 为 RVM 和 GL-RVM 分别与信道冲激响应的散点图对比,网格设置为 $r=15$ ms,信噪比为

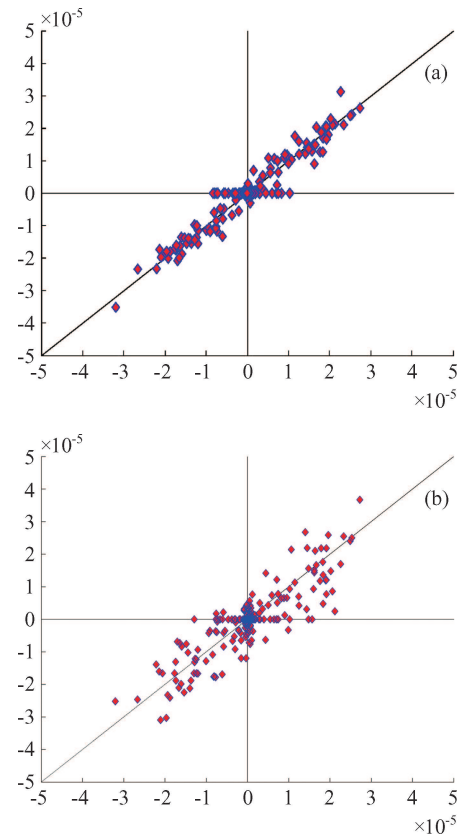


图 3 (a) GL-RVM 估计结果和实际信道冲激响应的散点图对比 (模型 1); (b) RVM 估计结果和实际信道冲激响应的散点图对比 (模型 1)

26 dB, 我们发现 GL-RVM 的散点图更加接近对称轴, 表明 GL-RVM 的估计更加接近信道冲激响应实际数值。

图 4 为 GL-RVM 与 StOMP, OMP, BMP 以及 RVM 的估计误差对比。误差用 MSE (Mean Square Error, 均方误差) 来表示, 表达式为 $MSE = 1/R \sum_{i=1}^R \| \mathbf{h} - \hat{\mathbf{h}}_i \|^2_2$, R 为蒙特卡罗试验次数。网格间距设置为 $r = 2$ ms。由该图可以看出, 低信噪比条件下 (SNR < 5 dB), GL-RVM 估计效果好于大多数算法, 只是相比 BMP 和 BOMP 还有所差距, 但是当信噪比超过 5 dB 时, GL-RVM 就全面好于其它算法。

图 5 为分别采用 GL-RVM 与 StOMP, MP, LS, OMP, BMP 以及 RVM 进行水下稀疏信道估计后, 再由 DFE 进行均衡后的误码率对比, 网格间距 $r =$

15 ms。我们发现, 低信噪比 (< 10 dB) 条件下, GL-RVM 的估计效果优势不明显, 与其它算法接近, 但是当信噪比高于 15 dB 时, GL-RVM 算法的优势就非常明显。虽然在信噪比高于 25 dB 时, 这种算法的优势有所减小, 但仍然全面好于其它有网格的算法。

进而, 将 RVM 的网格密度设置为采样间隔, 即 0.5 ms, 再与网格间距为 5 ms 时的 GL-RVM 进行对比。表 2 为此时不同信噪比下两种方法的估计时间对比。

可以看出若将网格密度设置为采用间隔, 将会带来巨大的计算量和耗时, 造成估计效率大大降低。而在估计精度方面, 二者对多径位置估计的散点图仿真结果如图 6 所示。

信噪比分别为 5 dB, 10 dB, 16 dB 时采用不同网




图 4 GL-RVM 与几种稀疏信道估计算法的估计误差对比 (模型 1): $r = 15$ ms




图 5 经过 GL-RVM 与几种稀疏信道估计算法的信道估计后再进行 DFE 均衡的误码率对比 (模型 1): $r = 15$ ms

表 2 GL-RVM 和 RVM 在不同网格间距和信噪比条件下的估计时间 (模型 1) (单位: s)

	SNR = 5 dB	SNR = 10 dB	SNR = 16 dB
GL-RVM ($r = 5$ ms)	5.8	5.6	5.2
RVM ($r = 0.5$ ms)	15.2	16.8	17.6

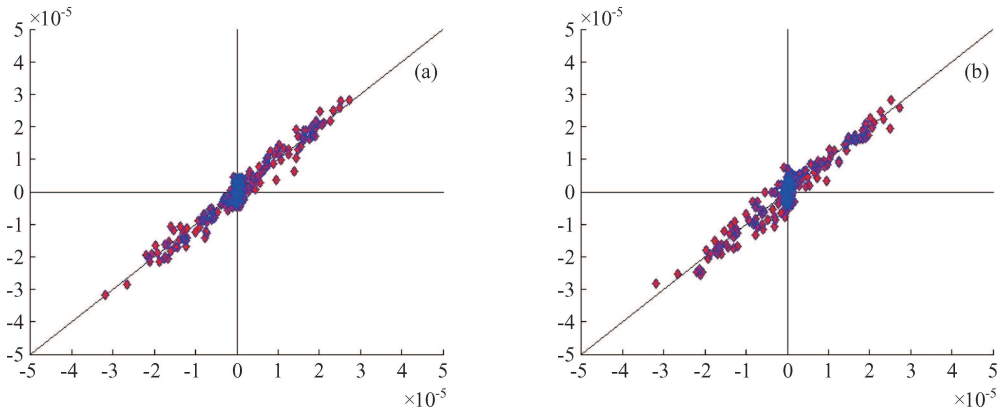


图 6 (a) GL-RVM 估计结果和实际信道冲激响应的散点图对比 (模型 1): SNR = 26 dB, $r = 5$ ms;
(b) RVM 估计结果和实际信道冲激响应的散点图对比 (模型 1): SNR = 26 dB, $r = 15$ ms

表 3 GL-RVM 和 RVM 在不同网格间距和信噪比条件下的估计 MSE (模型 1) (单位: dB)

	SNR=5 dB	SNR=10 dB	SNR=16 dB
GL-RVM ($r=5$ ms)	-6.3	-10.5	-25.7
RVM ($r=0.5$ ms)	-6.7	-9.6	-27.3

表 4 RVM 和 GL-RVM 的平均运算时间对比: SNR=16 dB, 5 dB (单位: s)

	SNR=16 dB				SNR=5 dB			
	$r=5$ ms	$r=10$ ms	$r=15$ ms	$r=20$ ms	$r=5$ ms	$r=10$ ms	$r=15$ ms	$r=20$ ms
GL-RVM	5.2	0.89	0.12	0.068	5.8	0.92	0.092	0.055
RVM	1.2	0.66	0.25	0.13	1.4	0.73	0.31	0.18

格间距的 RVM 和 GL-RVM 进行估计后的 MSE 对比如表 3 所示。

由此可见, 网格间距为 0.5 ms 时的 RVM 估计在效率上远远低于网格间距为 5 ms 时的 GL-RVM, 而两者的估计精度差别不大, 在提高网格密度后, RVM 相比 GL-RVM 没有明显优势。所以综合考虑以上因素, 采用低网格密度的 GL-RVM 进行稀疏信道估计是更优的选择。

表 4 为信噪比为 16 dB 和 5 dB 的情形下, 网格设置为 $r=5$ ms, $r=10$ ms, $r=15$ ms 和 $r=20$ ms 时 RVM 和 GL-RVM 的运算时间对比。很容易看出, 在网格设置较密时, RVM 具有更高的效率, 而当网格较疏时, GL-RVM 具有更快的计算速度, 网格超过 15 ms 时, GL-RVM 将运算时间缩短了超过一倍, 效率上有了明显提高。所以在实际应用中, 我们建议采用 $r=15$ ms 的网格间距来保证运算速度和估计精度。

进而, 为了验证本方法在其它水声通信背景下的估计效果, 我们改变参数, 采用另外一种信道模型再次进行仿真试验, 具体参数如表 5 所示。这种模型的信道冲激响应如图 7(a) 所示。

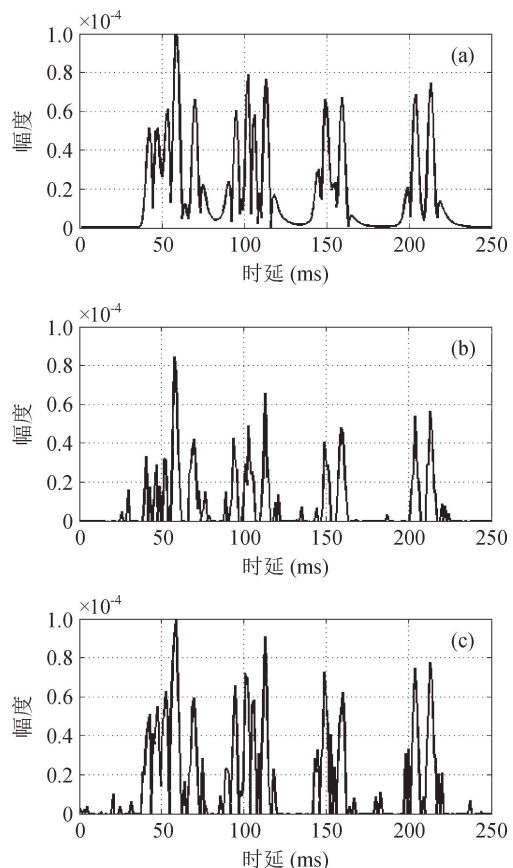
表 5 仿真试验中采用的模型 2 的通信参数

发射机深度	100 m
接收机深度	100 m
距离	2 km
载频	13 kHz
码元速率	1000 B
数据率	1000 bps
调制方式	BPSK
带宽	2 kHz
信道稀疏度	35

计算得到的信道冲激响应如下图所示可以看到多径数的明显提高和簇状分布的增强。采用 RVM 进行多径稀疏信道估计的结果如图 7(b) 和图 7(c) 所示。

由图 7(b) 和图 7(c) 可以看出, 不论是对信道多径位置还是幅度的估计, GL-RVM 都明显强于 RVM。进而比较了两者在估计误差和误码率方面的优劣, 结果如图 8 和图 9 所示。

由图 8 和图 9 可以看出, 在模型 2 增加信道多径数的情况下, GL-RVM 算法的估计误差和误码率仍然全面好于其它有网格的稀疏信道估计算法。

图 7 (a) 模型 2 的实际信道冲激响应; (b) RVM 估计结果; (c) GL-RVM 估计结果: SNR=26 dB, $r=15$ ms

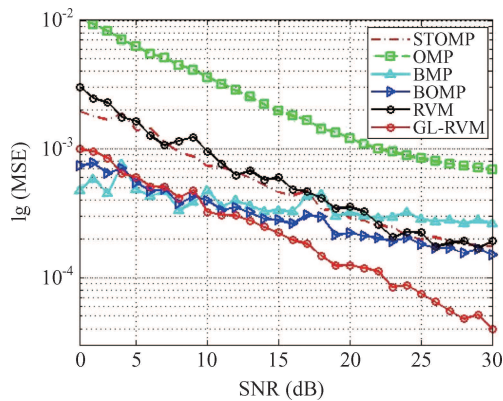


图 8 GL-RVM 与几种稀疏信道估计算法的估计误差对比 (模型 2): $r=15$ ms




图 9 经过 GL-RVM 与几种稀疏信道估计算法的信道估计后再进行 DFE 均衡的误码率对比 (模型 2): $r=15$ ms

4 结论

本文提出了去网格的相关向量机方法进行高精度的水下多径稀疏信道估计, 有效解决了网格带来的估计误差问题。仿真试验结果证明, 该方法对多径时延位于网格外的水下稀疏信道估计问题较其它有网格的估计算法在估计精度和误码率性能上有所提高, 在多径数较大且呈簇状集中分布的水下多径稀疏信道估计中优势更加明显。由此可见, 本文提出的算法不失为一种好的水下多径稀疏信道估计算法, 非常适用于网格间距较大的水下多径稀疏信道估计。但同时这种去网格化改进也带来了计算负担的加重, 尤其在网格较密的情况下, GL-RVM 的估计效率不够理想, 在对估计效率要求不甚高的情形下, 本文提出的方法更加适用。另外由于条件限制, 本文并没有使用实际水声通信试验数据来验证本方法的优劣, 这将是今后的主要改进方向。

参 考 文 献

- Kocic M, Brady D, Stojanovic M. Sparse equalization for real-time digital underwater acoustic communications. In OCEANS'95. MT-S/IEEE, Challenges of Our Changing Global Environment, Conference Proceedings, IEEE, 1995; **3**: 1417—1422
- Vaccaro R J, Ramalingam C S, Tufts D W *et al.* Least-squares time delay estimation for transient signals in a multipath environment. *J. Acoust. Soc. Am.*, 1992; **92**(1): 210—218
- 蒋德军, 胡涛. 时延估计技术及其在多途环境中的应用. *声学学报*, 2001; **26**(1): 34—40
- 李璇, 鄢社锋, 马晓川. 对角加载最小二乘法的时间延迟估计. *声学学报*, 2011; **36**(5): 469—475
- Van Trees H L. Detection, estimation, and modulation theory, optimum array processing. John Wiley & Sons, 2004
- Berger C R, Zhou S, Preisig J C *et al.* Sparse channel estimation for multicarrier underwater acoustic communication: From subspace methods to compressed sensing. *IEEE Transactions on Signal Processing*, 2010; **58**(3): 1708—721
- 李蓉艳, 马远良, 杨坤德. 浅海水声信道响应的盲估计. *声学学报*, 2007; **32**(1): 10—18
- 白晓慧, 孙超, 易锋等. 低信噪比下的浅海水声稀疏信道估计. *西北工业大学学报*, 2013; **31**(1): 115—121
- Qi C H, Wang X D, Wu L A. Underwater acoustic channel estimation based on sparse recovery algorithms. *IET Signal Processing*, 2011; **5**(8): 739—747
- Huang J Z, Berger C R, Zhou S L *et al.* Comparison of basis pursuit algorithms for sparse channel estimation in underwater acoustic ofdm. In OCEANS 2010 IEEE-Sydney, IEEE, 2010: 1—6
- 伍飞云, 童峰. 块稀疏水声信道的改进压缩感知估计. *声学学报*, 2017; **42**(1): 27—36
- Kang T, Song H C, Hodgkiss W S *et al.* Long-range multi-carrier acoustic communications in shallow water based on iterative sparse channel estimation. *J. Acoust. Soc. Am.*, 2010; **128**(6): EL372—EL377
- Tropp J A. Greed is good: Algorithmic results for sparse approximation. *IEEE Transactions on Information Theory*, 2004; **50**(10): 2231—2242
- Cotter S F, Rao B D. Sparse channel estimation via matching pursuit with application to equalization. *IEEE Transactions on Communications*, 2002; **50**(3): 374—377
- 周跃海, 伍飞云, 童峰. 水声多输入多输出信道的分布式压缩感知估计. *声学学报*, 2015; **40**(4): 519—528
- Tipping M E. Sparse Bayesian learning and the relevance vector machine. *The Journal of Machine Learning Research*, 2001; **1**(3): 211—244
- Pedersen N L, Manchón C N, Shutin D *et al.* Application of Bayesian hierarchical prior modeling to sparse channel estimation. IEEE International Conference on Communications (ICC), 2012: 3487—3492
- Wen J H, Chang J F. The effect of multipath interference on the performance of packet radios. *IEEE Transactions on Communications*, 1990; **38**(6): 740—743
- Manickam T G, Vaccaro R J. A non-iterative deconvolution method for estimating multipath channel responses. IEEE International Conference on Acoustics, Speech, and Signal Processing, 1993; **1**: 333—336

-
- 20 Yang Z, Xie L, Zhang C. Off-grid direction of arrival estimation using sparse Bayesian inference. *IEEE Transactions on Signal Processing*, 2013; **61**(1): 38—43
- 21 Zhu H, Leus G, Giannakis G B. Sparsity-cognizant total least-squares for perturbed compressive sampling. *IEEE Transactions on Signal Processing*, 2011; **59**(5): 2002—2016
- 22 Tang G G, Bhaskar B N, Shah P *et al.* Compressed sensing off the grid. *IEEE Transactions on Information Theory*, 2013; **59**(11): 7465—7490
- 23 Zhao T, Nehorai A. Sparse direction of arrival estimation using co-prime arrays with off-grid targets. *IEEE Signal Processing Letters*, 2014; **21**(1): 26—29
- 24 Ozay M, Esnaola I, Vural F T Y *et al.* Sparse attack construction and state estimation in the smart grid: Centralized and distributed models. *IEEE Journal on Selected Areas in Communications*, 2013; **31**(7): 1306—1318
- 25 MacKay D J C. Bayesian interpolation. *Neural Computation*, 1992; **4**(3): 415—447
- 26 Zeng W J, Jiang X, Li X L *et al.* Deconvolution of sparse underwater acoustic multipath channel with a large time-delay spread. *The Journal of the Acoustical Society of America*, 2010; **127**(2): 909—919