



研究与开发

基于近似消息传递的NOMA系统信道 和脉冲噪声联合估计方法

李有明¹, 马冲亚¹, 吴永宏², 国强³

(1. 宁波大学信息科学与工程学院, 浙江 宁波 315211;

2. 中国电波传播研究所, 山东 青岛 266075;

3. 哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001)

摘 要: 针对非高斯脉冲噪声背景下的非正交多址接入 (non-orthogonal multiple access, NOMA) 系统的信道估计问题, 利用信道和脉冲噪声的稀疏特性, 提出一种基于近似消息传递的信道和脉冲噪声联合估计方法。首先构建全子载波的压缩感知方程, 然后基于稀疏贝叶斯学习理论提出一种信道、脉冲噪声和数据符号的联合估计优化问题。为解决这一超参量非线性非凸问题, 设计了一种基于高斯广义近似消息传递和稀疏贝叶斯学习理论的期望最大化实现算法。仿真结果表明, 与基于期望最大化的稀疏贝叶斯学习方法相比, 所提算法在信道和脉冲噪声估计的均方误差、误码率等方面性能虽略有下降, 但算法复杂度降低了1个数量级。

关键词: 非正交多址接入; 信道估计; 脉冲噪声估计; 稀疏贝叶斯学习; 近似消息传递

中图分类号: TN929

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024205

Joint channel and impulsive noise estimation method based on approximate message passing for NOMA systems

LI Youming¹, MA Chongya¹, WU Yonghong², GUO Qiang³

1. Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo 315211, China

2. China Research Institute of Radio Wave Propagation, Qingdao 266075, China

3. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China

Abstract: To address the channel estimation problem for non-orthogonal multiple access (NOMA) systems under non-Gaussian impulsive noise, a joint channel and impulsive noise estimation method based on approximate message passing was proposed, by exploiting the joint sparsity of the channel and impulsive noise. Firstly, based on sparse

收稿日期: 2024-04-10; 修回日期: 2024-08-30

通信作者: 李有明, liyouming@nbu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61571250); 浙江省自然科学基金资助项目 (No.LY22F010018); 科技部战略性国际科技创新合作项目重点专项基金资助项目 (No.2018YFE0206500)

Foundation Items: The National Natural Science Foundation of China (No.61571250), The Natural Science Foundation of Zhejiang Province (No.LY22F010018), The International Cooperation Project of the Ministry of Science and Technology (No.2018YFE0206500)

Bayesian learning theory, a compressed sensing equation was constructed by using all subcarriers, and then a joint estimation optimization problem for the channel, impulsive noise, and data symbols was proposed. To address this hyperparameter nonlinear non-convex problem, an expectation maximization (EM) implementation algorithm based on Gaussian generalized approximation message passing and sparse Bayesian learning (SBL) theory was designed. Simulation results show that compared to the SBL method based on EM, the proposed algorithm exhibited a slight degradation in terms of mean square error (MSE) for channel and impulsive noise estimation, bit error rate (BER). However, the complexity of the proposed algorithm was reduced by one order of magnitude.

Key words: non-orthogonal multiple access, channel estimation, impulsive noise estimation, sparse Bayesian learning, approximate message passing

0 引言

物联网的发展和应用影响着人们的生活和工作。传统的正交频分复用 (orthogonal frequency division multiplexing, OFDM) 已经无法满足物联网对大规模连接和低时延的需求。在此背景下, 非正交多址接入 (non-orthogonal multiple access, NOMA) 作为一种新兴技术, 受到了广泛的关注。NOMA 是 6G 通信系统的核心技术之一, 它允许多个用户共享同一时频资源, 极大地提高了系统的频谱效率, 从而可以满足物联网对大规模连接和低时延的需求^[1]。脉冲噪声广泛存在于物联网的诸多应用环境中, 如智能电网^[2]、车联网^[3]和工业物联网^[4]等领域。这些脉冲噪声通常来自汽车点火、电气设备开关、电子设备、工业设备等方面^[5-6], 会对通信信号传输造成严重损害^[7]。此外, 相较于正交多址系统, NOMA 系统由于功率分配和串行干扰消除, 对脉冲噪声更加敏感^[8]。因此, 研究一种针对 NOMA 系统的脉冲噪声抑制方法变得尤为重要。

传统的脉冲噪声抑制方法为参数化方法, 主要包括限幅、消隐以及联合限幅消隐^[9], 这些方法虽然原理简单、容易实施, 但是会引入非线性失真。相较于参数化方法, 基于压缩感知的脉冲噪声抑制方法因其具有更好的性能而受到广泛关注^[10-12]。这些方法大多利用空子载波或导频实现脉冲噪声抑制, 因此性能和系统的频谱效率都受

到空子载波和导频数量的限制。

为了突破空子载波和导频数量的限制, 进一步提高脉冲噪声的估计性能, 使用全子载波的脉冲噪声抑制方法逐渐受到重视。然而, 全子载波的使用不仅使计算复杂度更高, 而且由于数据符号在接收端未知, 传统的压缩感知方法难以使用。为此, 文献[13]提出了一种基于广义近似消息传递的信道和脉冲噪声联合估计方法, 该方法复杂度较低, 但是需要信道和脉冲噪声的先验信息。文献[14]提出了一种同步符号检测的信道和脉冲噪声联合估计方法, 该方法基于稀疏贝叶斯学习 (sparse Bayesian learning, SBL) 理论^[15], 通过基于期望最大化 (expectation-maximization, EM) 的 SBL 算法对信道、脉冲噪声和数据符号进行联合估计, 大幅提高了估计性能, 但计算复杂度较高。文献[16]和文献[17]将卡尔曼滤波和 SBL 结合, 进一步提升了联合估计性能, 但计算复杂度更高。

需要强调的是, 上述脉冲噪声抑制方法皆应用于 OFDM 系统, 并且有关 NOMA 系统的脉冲噪声抑制方法已引起重视。针对 NOMA 系统中脉冲噪声抑制问题, 文献[18]使用最大后验接收器抑制脉冲噪声, 但复杂度较高。文献[19]使用一种深度学习辅助的非线性处理方法实现脉冲噪声抑制, 该方法复杂度较低, 但是需要假设信道状态信息在接收端已知, 而且需要提前训练深度神经网络。针对 NOMA 通信系统, 利用全子载波设



计信道、脉冲噪声和数据符号的联合估计方法还未见报道。


为此,提出一种基于近似消息传递的信道和脉冲噪声联合估计方法。首先,利用信道和脉冲噪声的联合稀疏性,构建全子载波的压缩感知方程;然后,使用基于高斯广义近似消息传递(Gaussian generalized approximate message passing, GGAMP)^[20]和SBL理论的EM算法对信道、脉冲噪声和数据符号进行联合估计。在该算法中,GGAMP被用于实现SBL算法的E-step以优化其矩阵求逆操作,降低算法复杂度。这样,所提方法不仅可以兼具GGAMP算法的低复杂度和SBL算法的高性能,而且不需要信道和脉冲噪声的先验信息。

1 系统模型

考虑一个多用户功率域下行NOMA系统,共包含 K 个用户,如图1所示。系统配置有 N 个子载波,包括 N_d 个数据子载波、 N_p 个导频子载波、 N_v 个空子载波。将第 n 个子载波上的第 k 个用户的频域符号记为 $x_{k,n}$ 。在发送端,所有用户的频域符号经过功率分配得到第 n 个子载波上的叠加信号,即:

$$x_n = \sum_{k=1}^K \sqrt{\alpha_k} x_{k,n} \quad (1)$$

其中, $k \in \{1, 2, \dots, K\}$, $n \in \{1, 2, \dots, N\}$, α_k 为第 k 个用户的功率分配系数, $\alpha_k \in (0, 1)$, $\sum_{k=1}^K \alpha_k = 1$, α_k 的具体值根据信道条件决定。



(a) 多用户下行NOMA系统 (b) 功率分配
图1 多用户功率域下行NOMA系统

全子载波的叠加信号可以表示为 $\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ 。 $\mathbf{x}$ 经过离散傅里叶逆变换转换为时域信号 $\mathbf{t}$,该过程可以表示为:

$$\mathbf{t} = \mathbf{F}^* \mathbf{x} \quad (2)$$

其中, $\mathbf{F}$ 表示归一化的离散傅里叶变换矩阵,维度为 N , $\mathbf{F}^*$ 是 $\mathbf{F}$ 的厄米特变换。

在接收端,通过信道的时域接收信号 $\mathbf{R}$ 可以表示为:

$$\mathbf{R} = \mathbf{H}\mathbf{t} + \mathbf{u} + \boldsymbol{\varepsilon} \quad (3)$$

其中, $\mathbf{H}$ 为 $N \times N$ 的循环矩阵,其第一列的前 L 个元素由 $L \times 1$ 的信道脉冲响应向量 $\mathbf{h} = [h_1, h_2, \dots, h_L]^T$ 构成,后 $N-L$ 个元素为0, $\mathbf{u}$ 和 $\boldsymbol{\varepsilon}$ 分别为时域脉冲噪声和加性高斯白噪声。

通过离散傅里叶变换,将 $\mathbf{R}$ 从时域转换到频域,由此得到的频域接收信号 $\mathbf{y}$ 可以表示为:

$$\begin{aligned} \mathbf{y} &= \mathbf{F}\mathbf{R} = \mathbf{F}\mathbf{H}\mathbf{F}^* \mathbf{x} + \mathbf{F}\mathbf{u} + \mathbf{F}\boldsymbol{\varepsilon} = \\ &\text{diag}(\sqrt{N} \mathbf{F}_L \mathbf{h}) \mathbf{x} + \mathbf{F}\mathbf{u} + \mathbf{w} = \\ &\sqrt{N} \mathbf{X} \mathbf{F}_L \mathbf{h} + \mathbf{F}\mathbf{u} + \mathbf{w} \end{aligned} \quad (4)$$

其中, $\mathbf{X} = \text{diag}(\mathbf{x})$, $\mathbf{F}_L$ 表示由 $\mathbf{F}$ 的前 L 列组成的矩阵, $\mathbf{w}$ 表示频域背景噪声, $\mathbf{w} = \mathbf{F}\boldsymbol{\varepsilon}$ 。在式(4)中,循环矩阵 $\mathbf{H}$ 被傅里叶变换矩阵 $\mathbf{F}$ 对角化了。

2 基于近似消息传递的信道和脉冲噪声联合估计方法

构造矩阵 $\boldsymbol{\Phi} = [\sqrt{N} \mathbf{X} \mathbf{F}_L \mathbf{F}]$ 和向量 $\boldsymbol{\omega} = [\mathbf{h}^T \mathbf{u}^T]^T$,使式(4)可以重写为:

$$\mathbf{y} = \boldsymbol{\Phi} \boldsymbol{\omega} + \mathbf{w} \quad (5)$$

因为无线信道具有稀疏性,而脉冲噪声具有时域突发性,所以向量 $\mathbf{h}$ 、 $\mathbf{u}$ 以及二者联合构成的向量 $\boldsymbol{\omega}$ 均为稀疏向量。这样,通过式(5)估计 $\boldsymbol{\omega}$ 就可以被视为一个压缩感知问题,其中 $\boldsymbol{\Phi}$ 为测量矩阵, $\boldsymbol{\omega}$ 为待恢复的稀疏向量。 $\mathbf{X}$ 中的未知数据符号使得该问题成为一类超参量非线性非凸问题,因此传统的压缩感知算法不能直接用于

估计 ω 。

在这种情况下, 本文根据广义近似消息传递理论, 将式 (5) 改写为:

$$\mathbf{y} = \mathbf{z} + \mathbf{w} \quad (6)$$

其中, $\mathbf{z} = \Phi\omega$, $\mathbf{w} \sim \text{CN}(0, \sigma^2 \mathbf{I}_N)$, $\sigma^2 \mathbf{I}_N$ 为噪声方差。

ω 的似然概率分布和先验概率分布可以分别表示为:

$$P(\mathbf{y}|\omega; \sigma^2, \mathbf{X}) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left(-\frac{1}{2\sigma^2}(\mathbf{y} - \Phi\omega)^*(\mathbf{y} - \Phi\omega)\right) \quad (7)$$

$$P(\omega; \Gamma) = (2\pi)^{-\frac{(N+L)}{2}} |\Gamma|^{-\frac{1}{2}} \exp\left(-\frac{1}{2}\omega^* \Gamma^{-1} \omega\right) \quad (8)$$

其中, Γ 是协方差矩阵, $\Gamma = \text{diag}(\gamma) = \text{diag}(\gamma_1, \gamma_2, \dots, \gamma_{N+L})$ 。 Γ 、 σ^2 和 $\mathbf{X}$ 为超参量。

根据贝叶斯理论, ω 的后验概率分布同样服从高斯分布。将 ω 的后验概率均值和方差分别记为 μ 和 $\mathbf{C}$, 它们分别表示为:

$$\mu = \sigma^{-2} \mathbf{C} \Phi^* \mathbf{y} \quad (9)$$

$$\mathbf{C} = \begin{pmatrix} \mathbf{C}_{hh} & \mathbf{C}_{hu} \\ \mathbf{C}_{uh} & \mathbf{C}_{uu} \end{pmatrix} = \left(\frac{1}{\sigma^2} \Phi^* \Phi + \Gamma^{-1} \right)^{-1} \quad (10)$$

其中, 式 (10) 的矩阵求逆操作使传统的 SBL 算法在矩阵维度较大时计算复杂、耗时较长, 因此采用 GGAMP 算法同时优化式 (9) 和式 (10)。

在 GGAMP 算法中, 将 $\mathbf{z}$ 和 ω 在高斯噪声环境下的近似分别记为 $\mathbf{p}$ 和 $\mathbf{r}$, 令 $\mathbf{s}$ 表示中间变量。GGAMP 的阻尼系数分别记为 θ_s 和 θ_ω 。GGAMP 的标量估计函数采用和积版本, 即:

$$g'_s(\hat{\mathbf{p}}, \mathbf{C}_p) = 1/(1 + \sigma^2 \mathbf{C}_p) \quad (11)$$

$$g_s(\hat{\mathbf{p}}, \mathbf{C}_p) = (\frac{\hat{\mathbf{p}}}{\mathbf{C}_p} - \mathbf{y})/(\sigma^2 + \frac{1}{\mathbf{C}_p}) \quad (12)$$

$$g'_\omega(\hat{\mathbf{r}}, \mathbf{C}_r) = \gamma/(\gamma + \mathbf{C}_r) \quad (13)$$

$$g_\omega(\hat{\mathbf{r}}, \mathbf{C}_r) = (\gamma \hat{\mathbf{r}})/(\gamma + \mathbf{C}_r) \quad (14)$$

其中, $\hat{\mathbf{p}}$ 和 $\mathbf{C}_p$ 分别表示 $\mathbf{p}$ 的均值和方差, $\hat{\mathbf{r}}$ 和 $\mathbf{C}_r$ 分别表示 $\mathbf{r}$ 的均值和方差。

在第 j 次估计中, $\mathbf{p}$ 的方差和均值可以分别表示为:

$$1/\mathbf{C}_p^{(j)} = \mathbf{S} \mathbf{C}^{(j-1)} \quad (15)$$

$$\hat{\mathbf{p}}^{(j)} = \hat{\mathbf{s}}^{(j-1)} + \mathbf{C}_p^{(j)} \otimes \Phi \mu^{(j-1)} \quad (16)$$

其中, $\mathbf{S} = |\Phi^{(k)}|^2$ 表示 Φ 的每个分量的绝对值平方, $1/\mathbf{C}_p^{(j)}$ 表示 $\mathbf{C}_p^{(j)}$ 的每个分量除 1, $\otimes$ 为哈达玛积运算符号。

$\mathbf{s}$ 的方差和均值可以分别表示为:

$$\mathbf{C}_s^{(j)} = \mathbf{C}_p^{(j)} \otimes g'_s(\hat{\mathbf{p}}^{(j)}, \mathbf{C}_p^{(j)}) \quad (17)$$

$$\hat{\mathbf{s}}^{(j)} = (1 - \theta_s) \hat{\mathbf{s}}^{(j-1)} + \theta_s g_s(\hat{\mathbf{p}}^{(j)}, \mathbf{C}_p^{(j)}) \quad (18)$$

$\mathbf{r}$ 的方差和均值可以分别表示为:

$$1/\mathbf{C}_r^{(j)} = \mathbf{S}^T \mathbf{C}_s^{(j)} \quad (19)$$

$$\hat{\mathbf{r}}^{(j)} = \mu^{(j-1)} - \mathbf{C}_r^{(j)} \otimes \left((\Phi^{(k)})^T \hat{\mathbf{s}}^{(j)} \right) \quad (20)$$

其中, $1/\mathbf{C}_r^{(j)}$ 表示 $\mathbf{C}_r^{(j)}$ 的每个分量除 1。

ω 的后验方差和均值可以分别表示为:

$$\mathbf{C}^{(j)} = \mathbf{C}_r^{(j)} \otimes g'_\omega(\hat{\mathbf{r}}^{(j)}, \mathbf{C}_r^{(j)}) \quad (21)$$

$$\mu^{(j)} = (1 - \theta_\omega) \mu^{(j-1)} + \theta_\omega g_\omega(\hat{\mathbf{r}}^{(j)}, \mathbf{C}_r^{(j)}) \quad (22)$$

当 GGAMP 算法的迭代结束时, 将 $\mu^{(j)}$ 和 $\mathbf{C}^{(j)}$ 作为 ω 的均值和方差的估计值。这样, GGAMP 算法就可以近似于式 (9) 和式 (10), 即可以视作传统的基于 EM 的 SBL 算法中的 E-step 的近似。将这种二者结合的算法记为 GGAMP-SBL 算法, 其完整过程如下。

(1) E-step 近似: 采用 GGAMP 算法获得 ω 的后验均值和方差, 并将 GGAMP-SBL 算法第 k 次迭代得到的后验均值和后验方差分别记为 $\mu^{(k)}$ 和 $\mathbf{C}^{(k)}$ 。

(2) M-step: 最大化 ω 的联合概率分布在后



验概率分布下的期望, 得到超参量 Γ 、 σ^2 和 $\mathbf{X}$ 的更新方程。首先根据 $\boldsymbol{\mu}^{(k)}$ 和 $\mathbf{C}^{(k)}$, 得到第 $k+1$ 次迭代的 Γ 和 σ^2 , 即:

$$\gamma_i^{(k+1)} = C_i^{(k)} + \left(\mu_i^{(k)}\right)^2 \quad (23)$$

$$\left(\sigma^2\right)^{(k+1)} = \frac{\left\|\mathbf{y} - \boldsymbol{\Phi}^{(k)} \boldsymbol{\mu}^{(k)}\right\|_2^2 + \left(\sigma^2\right)^{(k)} \sum_{i=1}^{N+L} \left(1 - \left(\gamma_i^{(k)}\right)^{-1} C_i^{(k)}\right)}{N} \quad (24)$$

其中, $C_i^{(k)}$ 和 $\mu_i^{(k)}$ 分别为 $\mathbf{C}^{(k)}$ 和 $\boldsymbol{\mu}^{(k)}$ 的第 i 个元素, $\boldsymbol{\Phi}^{(k)} = \left[\sqrt{N} \mathbf{X}^{(k)} \mathbf{F}_L \quad \mathbf{F}\right]$, $\mathbf{X}^{(k)}$ 是第 k 次 GGAMP-SBL 得到的 $\mathbf{X}$ 估计值。

求解 $\mathbf{X}$ 的计算式可表示为:

$$\mathbf{X}^{(k+1)} = \underset{\mathbf{X}}{\operatorname{argmin}} \left(\begin{array}{c} \left\|\mathbf{y} - \boldsymbol{\Phi}^{(k)} \boldsymbol{\mu}^{(k)}\right\|_2^2 + \\ \operatorname{Tr}\left(\left(\boldsymbol{\Phi}^{(k)}\right)^* \boldsymbol{\Phi}^{(k)} \operatorname{diag}\left(\mathbf{C}^{(k)}\right)\right) \end{array} \right) \quad (25)$$

根据 $\boldsymbol{\Phi}$ 和 $\mathbf{C}$ 的定义, $\boldsymbol{\Phi}^* \boldsymbol{\Phi} \operatorname{diag}(\mathbf{C})$ 可以简写为:

$$\boldsymbol{\Phi}^* \boldsymbol{\Phi} \operatorname{diag}(\mathbf{C}) = \mathbf{N} \mathbf{X} \mathbf{F}_L \operatorname{diag}(\mathbf{C}_h) \mathbf{F}_L^* \mathbf{X}^* + \mathbf{F} \operatorname{diag}(\mathbf{C}_u) \mathbf{F}^* \quad (26)$$

其中, $\mathbf{C}_h$ 和 $\mathbf{C}_u$ 分别表示后验方差向量中的信道部分和脉冲噪声部分。

因此 $\mathbf{X}^{(k+1)}$ 的简化表达式为:

$$x_l^{(k+1)} = \underset{x_l}{\operatorname{argmin}} \left(\begin{array}{c} \left\|\mathbf{y} - \boldsymbol{\Phi}^{(k)} \boldsymbol{\mu}^{(k)}\right\|_2^2 + \\ \operatorname{Tr}\left(\mathbf{X}(l,:)^{(k)} \mathbf{N} \mathbf{F}_L \operatorname{diag}(\mathbf{C}_h^{(k)}) \mathbf{F}_L^* \left(\mathbf{X}(l,:)^{(k)}\right)^*\right) \end{array} \right) \quad (27)$$

其中, $x_l^{(k+1)}$ 表示 $\mathbf{X}^{(k+1)}$ 的对角线上的第 l 个元素, $l \in D$, D 表示数据子载波的索引集合。

当 GGAMP-SBL 算法结束时, 将 $\boldsymbol{\mu}^{(k)}$ 作为 $\boldsymbol{\omega}$

的最终估计值 $\hat{\boldsymbol{\omega}}$, 即信道和脉冲噪声的估计值 $\hat{\boldsymbol{\omega}}(1:L)$ 和 $\hat{\boldsymbol{\omega}}(L+1:L+N)$ 。完整的 GGAMP-SBL 算法如算法 1 所示。

算法 1 GGAMP-SBL 算法

输入: $\mathbf{y}$, $\boldsymbol{\Phi}_p$, $k_{\max}$, $j_{\max}$, θ_s , θ_ω , ε_g , ε_e

输出: $\hat{\boldsymbol{\omega}}$

初始化

$\gamma^{(0)} = 1$, $\left(\sigma^2\right)^{(0)} = 1$, $\mathbf{X}^{(0)}$ 通过式 (28) 求得

for $k = 1:k_{\max}$

$\boldsymbol{\Phi}^{(k)} = \left[\sqrt{N} \mathbf{X}^{(k)} \mathbf{F}_L \quad \mathbf{F}\right]$, $\mathbf{S} = \left|\boldsymbol{\Phi}^{(k)}\right|^2$, $\gamma^{(j=0)} =$

$\gamma^{(k+1)}$, $\left(\sigma^2\right)^{(j=0)} = \left(\sigma^2\right)^{(k+1)}$

for $j = 1:j_{\max}$

根据式 (15) ~ 式 (22) 获得 $\mathbf{C}^{(j)}$ 和 $\boldsymbol{\mu}^{(j)}$

if $\frac{\left\|\boldsymbol{\mu}^{(j)} - \boldsymbol{\mu}^{(j-1)}\right\|_2^2}{\left\|\boldsymbol{\mu}^{(j)}\right\|_2^2} < \varepsilon_g$

break

end if

end for

$\boldsymbol{\mu}^{(k)} = \boldsymbol{\mu}^{(j)}$, $\mathbf{C}^{(k)} = \mathbf{C}^{(j)}$

根据式 (23) 得 $\gamma^{(k+1)}$

根据式 (24) 得 $\left(\sigma^2\right)^{(k+1)}$

根据式 (27) 得 $\mathbf{X}^{(k+1)}$

if $\frac{\left\|\boldsymbol{\mu}^{(k)} - \boldsymbol{\mu}^{(k-1)}\right\|_2^2}{\left\|\boldsymbol{\mu}^{(k)}\right\|_2^2} < \varepsilon_e$

break

end if

end for

返回 $\hat{\boldsymbol{\omega}} = \boldsymbol{\mu}^{(k)}$

为了保证算法收敛, 需要 $\mathbf{X}$ 的初始估计值 $\mathbf{X}^{(0)}$, 获取 $\mathbf{X}^{(0)}$ 的过程如下。

根据式 (5)，构建只含有导频和空子载波部分的信道和脉冲噪声联合估计方程，该压缩感知方程可以表示为：

$$\mathbf{y}_p = \Phi_p \boldsymbol{\mu} + \mathbf{w}_p \quad (28)$$

其中， p 表示导频和空子载波的索引。显然 Φ_p 已知，因此可以使用 SBL 算法对 $\boldsymbol{\omega}$ 进行估计，将得到的估计值记为 $\hat{\boldsymbol{\omega}}_p$ ，相应地，将信道和脉冲噪声估计值分别记为 $\hat{\mathbf{h}}_p$ 和 $\hat{\mathbf{u}}_p$ 。

将脉冲噪声从接收信号中去除，该过程可以表示为：

$$\hat{\mathbf{y}}_p = \mathbf{y} - \mathbf{F} \hat{\mathbf{u}}_p \quad (29)$$

根据 $\hat{\mathbf{y}}_p$ 和 $\hat{\mathbf{h}}_p$ ，可以使用迫零串行干扰消除算法得到 $\mathbf{X}^{(0)}$ 。

3 复杂度 X 分析

基于 EM 的 SBL 算法的计算复杂度主要来源于式 (10) 的矩阵求逆操作，因此每次迭代的复杂度为 $O(N(N+L)^2)$ 。较高的计算复杂度使其不适用于大规模场景。相比之下，本文提出的 GGAMP-SBL 算法的复杂度主要来自 $\mathbf{S}$ 、 $\mathbf{S}^T$ 、 Φ 和 Φ^T 的矩阵乘法操作，因此每次迭代的复杂度为 $O(N(N+L))$ 。相较于基于 EM 的 SBL 算法，GGAMP-SBL 算法的复杂度降低了 1 个数量级，使其更适用于处理大规模矩阵的场景。

4 仿真结果与分析

采用蒙特卡洛法在收敛速度和估计性能两方面对本文所提 GGAMP-SBL 算法和文献[19]所提的深度神经网络 (deep neural network, DNN) 算法、文献[14]所提的 EM-SBL 算法进行比较。其中估计性能包括信道估计性能、脉冲噪声估计性能和误码率 (bit error ratio, BER)。为了公平地进行收敛速度方面的对比，将文献[14]针对 OFDM 系统的 EM-SBL 算法直接推广到 NOMA 系统。仿真软件为 MATLAB 2018b，CPU 为 AMD

Ryzen 7 5800H，内存大小 16 GB、GPU 为 GeForce RTX 3050。仿真环境如下：NOMA 系统包含两个用户，分别记为用户 1 和用户 2，每个用户均配置 256 个子载波，其中包括 64 个导频子载波、40 个空子载波和 152 个数据子载波。用户 1 和用户 2 的功率分配系数分别为 $\alpha_1=0.8$ 和 $\alpha_2=0.2$ 。算法的收敛指标分别为 $\varepsilon_g=10^{-5}$ 和 $\varepsilon_e=10^{-5}$ 。通过试错法，将 GGAMP 算法的两个阻尼系数分别设置为 $\theta_s=0.8$ 和 $\theta_w=0.8$ 。调制方式采用 4QAM。信道脉冲响应的长度为 $L=64$ 。信道参数基于 ITU-R Vehicular B 信道模型，共有 6 个抽头，每个抽头的增益都归一化到 1。脉冲噪声和背景噪声参数设置基于三元高斯混合模型 (Gaussian mixture model, GMM)，概率分别为 $\{0.9, 0.07, 0.03\}$ ，方差分别为 $\{1, 100, 1\,000\}$ 。信噪比 (signal to noise ratio, SNR) 为发射信号功率和总噪声的比值，即 $\text{SNR} = \frac{P_s}{P_t}$ 。信道和脉冲噪声估计的均方误差 (mean square error, MSE) 为 $\text{MSE} = E \left\{ \left\| \boldsymbol{\omega} - \hat{\boldsymbol{\omega}} \right\|_2^2 \right\}$ 。信道和脉冲噪声相邻两次迭代估计均值的归一化均方误差 (normalized mean square error, NMSE) 为：

$$\text{NMSE} = E \left\{ \frac{\left\| \boldsymbol{\mu}^{(k)} - \boldsymbol{\mu}^{(k-1)} \right\|_2^2}{\left\| \boldsymbol{\mu}^{(k)} \right\|_2^2} \right\} \quad (30)$$

4.1 运行时间对比

GGAMP-SBL 算法和 EM-SBL 算法的运行时间随 SNR 的变化曲线如图 2 所示。可以看出，在所有 SNR 区域内，GGAMP-SBL 算法的运行时间都少于 EM-SBL 算法，且时间差随 SNR 的变化很小。在所有 SNR 区域内，GGAMP-SBL 算法的平均运行时间比 EM-SBL 算法短约 3.6 s。这体现出相比于 EM-SBL 算法，GGAMP-SBL 算法大幅降低了运行时间，验证了在复杂度分析中得出的结论。




图2 运行时间随SNR的变化曲线

4.2 迭代性能对比

GGAMP-SBL 算法和 EM-SBL 算法在 SNR=15 dB 时 NMSE 随迭代次数的变化曲线如图 3 所示。可以看出, 两种算法的 NMSE 均随迭代次数逐渐下降, 其中 GGAMP-SBL 算法的 NMSE 在迭代次数较少时下降较快。从图 3 中还可以看出, EM-SBL 算法的 NMSE 下降速度变化不大, 而且在迭代次数约 100 次, NMSE 约 10^{-4} 时与 GGAMP-SBL 算法相交, 这表示本文所提算法在 NMSE 小于 10^{-4} 时所需迭代次数更少。




图3 NMSE随迭代次数的变化曲线

4.3 信道估计性能对比

GGAMP-SBL 算法和 EM-SBL 算法的信道估计性能随 SNR 的变化曲线如图 4 所示。可以看出,

图 4 所示 SNR 区域内两种算法的信道估计 MSE 随 SNR 的增加而减小, 且 GGAMP-SBL 算法的 MSE 均比 EM-SBL 算法高。进一步, 在低 SNR 区域 EM-SBL 算法与 GGAMP-SBL 算法的 MSE 相差较大, 而随着 SNR 的增加, 所提算法的信道估计 MSE 逐渐接近 EM-SBL 算法。这表明 GGAMP-SBL 算法在计算复杂度低、收敛更快的同时, 信道估计性能稍逊于 EM-SBL 算法。




图4 信道估计性能随SNR的变化曲线

4.4 脉冲噪声估计性能对比

GGAMP-SBL 算法和 EM-SBL 算法的脉冲噪声估计性能随 SNR 的变化曲线如图 5 所示。可以看出, 两种算法的脉冲噪声估计 MSE 随 SNR 的增加而减小。进一步, 在图 5 所示 SNR 范围内, GGAMP-SBL 算法的脉冲噪声估计性能都比 EM-SBL 算法差。这表明 GGAMP-SBL 算法相较于 EM-SBL 算法, 损失了一部分脉冲噪声估计性能。

4.5 BER性能对比

GGAMP-SBL 算法、EM-SBL 算法和 DNN 算法的 BER 随 SNR 的变化曲线如图 6 所示。可以看出, 3 种算法的 BER 均随 SNR 的增加而减小。进一步, 3 种算法的用户 1 的 BER 均比用户 2 小, 这是因为用户 1 的功率分配系数更大, 而且在串行干扰消除时没有累计误差。对于用

户1, 在所有 SNR 区域 DNN 算法的 BER 均比 GGAMP-SBL 算法低, 但是 DNN 算法需要信道状态信息已知, 并且需要提前进行训练; 对于用户 2, 在低 SNR 区域 DNN 算法的 BER 比 GGAMP-SBL 算法低, 而在高 SNR 区域 DNN 算法最低。进一步分析, 在所有 SNR 区域上 GGAMP-SBL 的两个用户的 BER 均比 EM-SBL 大。这表明 GGAMP-SBL 算法在 BER 方面的性能稍逊于 EM-SBL 算法。

针对 NOMA 系统, 从运算时间和估计性能两方面对几种算法进行了仿真验证。进一步, 将本文方法推广到 OFDM 系统, 并针对 OFDM 系统的联合估计方法, 进行了分析比较。




图5 脉冲噪声估计性能随SNR的变化曲线




图6 BER随SNR的变化曲线

4.6 OFDM系统下运行时间对比

为了更好地验证所提 GGAMP-SBL 算法在复杂度方面的优势, 原本应用于 NOMA 系统的 GGAMP-SBL 算法被扩展到 OFDM 系统, 并与文献[14]提出的 EM-SBL 算法进行对比。图 7 为 GGAMP-SBL 算法与 EM-SBL 算法在 OFDM 系统下的运行时间对比情况。可以看出, 两种算法的运行时间随 SNR 变化很小, 且在所有 SNR 区域内 GGAMP-SBL 算法均具有更短的运行时间。在所有 SNR 区域内, GGAMP-SBL 算法的平均运行时间比 EM-SBL 算法短约 2.9 s。这表明即使扩展到 OFDM 系统下, 提出的 GGAMP-SBL 算法在计算复杂度方面仍然具有优势。




图7 OFDM系统下运行时间对比

4.7 OFDM系统下联合估计 MSE 性能对比

OFDM 系统下 GGAMP-SBL 算法和 EM-SBL 算法的联合估计 MSE 随 SNR 的变化曲线如图 8 所示。可以看出, 两种算法的 MSE 均随 SNR 的增加而减少。进一步, 两种算法的 MSE 的差距也随 SNR 的增加而逐渐减少。随着 SNR 的增加, 两种算法的联合估计性能接近, 这表明所提 GGAMP-SBL 算法在 OFDM 系统下具有更低的计算复杂度, 且只损失了很小的联合估计性能。




图8 联合估计MSE性能随SNR的变化曲线

5 结束语

本文提出了一种基于近似消息传递的信道和脉冲噪声联合估计方法。基于信道和脉冲噪声的联合稀疏性，所提算法通过构建全子载波的压缩感知方程，实现了信道、脉冲噪声和数据符号的联合估计。针对基于EM的SBL算法复杂度过高的问题，本文使用GGAMP算法对其进行优化，取代了其中的矩阵求逆操作。仿真结果表明，所提算法在性能损失可以忽略的情况下，大大降低了计算复杂度。未来将研究如何在保持低复杂度的情况下，进一步提高估计性能。

参考文献:

- [1] DING Z G, LEI X F, KARAGIANNIDIS G K, et al. A survey on non-orthogonal multiple access for 5G networks: research challenges and future trends[J]. IEEE Journal on Selected Areas in Communications, 2017, 35(10): 2181-2195.
- [2] ANTONIALI M, VERSOLATTO F, TONELLO A M. An experimental characterization of the PLC noise at the source[J]. IEEE Transactions on Power Delivery, 2016, 31(3): 1068-1075.
- [3] XU Z P, YANG C C, TAN Z W, et al. Raptor code-enabled reliable data transmission for in-vehicle power line communication systems with impulsive noise[J]. IEEE Communications Letters, 2017, 21(10): 2154-2157.
- [4] SELIM B, ALAM M S, EVANGELISTA J V C, et al. NOMA-based IoT networks: impulsive noise effects and mitigation[J]. IEEE Communications Magazine, 2020, 58(11): 69-75.
- [5] LIU S C, YANG F, DING W B, et al. Double kill: compressive-sensing-based narrow-band interference and impulsive noise mitigation for vehicular communications[J]. IEEE Transactions on Vehicular Technology, 2016, 65(7): 5099-5109.
- [6] SACUTO F, LABEAU F, AGBA B L. Wide band time-correlated model for wireless communications under impulsive noise within power substation[J]. IEEE Transactions on Wireless Communications, 2014, 13(3): 1449-1461.
- [7] MAHMOOD A, CHITRE M, ARMAND M A. Detecting OFDM signals in alpha-stable noise[J]. IEEE Transactions on Communications, 2014, 62(10): 3571-3583.
- [8] SELIM B, ALAM M S, KADDOUM G, et al. Effect of impulsive noise on uplink NOMA systems[J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 3454-3458.
- [9] ZHIDKOV S V. Analysis and comparison of several simple impulsive noise mitigation schemes for OFDM receivers[J]. IEEE Transactions on Communications, 2008, 56(1): 5-9.
- [10] KORKI M, ZHANG J X, ZHANG C S, et al. Block-sparse impulsive noise reduction in OFDM systems—a novel iterative Bayesian approach[J]. IEEE Transactions on Communications, 2016, 64(1): 271-284.
- [11] LIN J, NASSAR M, EVANS B L. Impulsive noise mitigation in powerline communications using sparse Bayesian learning [J]. IEEE Journal on Selected Areas in Communications, 2013, 31(7): 1172-1183.
- [12] FENG X, WANG J F, KUAI X Y, et al. Message passing-based impulsive noise mitigation and channel estimation for underwater acoustic OFDM communications[J]. IEEE Transactions on Vehicular Technology, 2022, 71(1): 611-625.
- [13] NASSAR M, SCHNITER P, EVANS B L. A factor-graph approach to joint OFDM channel estimation and decoding in impulsive noise channels[C]//Proceedings of the 2013 Asilomar Conference on Signals, Systems and Computers. Piscataway: IEEE Press, 2013: 1929-1933.
- [14] LYU X R, LI Y M, WU Y Q, et al. Joint channel estimation

and impulsive noise mitigation method for OFDM systems using sparse Bayesian learning[J]. IEEE Access, 2019(7): 74500-74510.

- [15] WIPF D P, RAO B D. Sparse Bayesian learning for basis selection[J]. IEEE Transactions on Signal Processing, 2004, 52(8): 2153-2164.
- [16] LYU X R, LI Y M, WU Y Q, et al. Kalman filter based recursive estimation of slowly fading sparse channel in impulsive noise environment for OFDM systems[J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 2828-2835.
- [17] WANG S C, HE Z Q, NIU K, et al. New results on joint channel and impulsive noise estimation and tracking in underwater acoustic OFDM systems[J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2601-2612.
- [18] ALAM M S, SELIM B, AHMED I, et al. Bursty impulsive noise mitigation in NOMA: a MAP receiver-based approach[J]. IEEE Communications Letters, 2021, 25(9): 2790-2794.
- [19] HUSSAIN M, SHAKIR H, RASHEED H. Deep learning approaches for impulse noise mitigation and classification in NOMA-based systems[J]. IEEE Access, 2021(9): 143836-143846.
- [20] AL-SHOUKAIRI M, SCHNITER P, RAO B D. A GAMP-based low complexity sparse Bayesian learning algorithm[J]. IEEE Transactions on Signal Processing, 2018, 66(2): 294-308.

[作者简介]



李有明 (1963-), 男, 博士, 宁波大学信息科学与工程学院教授, 主要研究方向为无线宽带通信、电力线通信、协作中继、认知无线电等。



马冲亚 (1999-), 男, 宁波大学信息科学与工程学院硕士生, 主要研究方向为无线通信中的脉冲噪声抑制。



吴永宏 (1974-), 男, 博士, 中国电波传播研究所高级工程师, 主要研究方向为短波通信、网络规划和信号处理等。



国强 (1972-), 男, 博士, 哈尔滨工程大学信息与通信工程学院教授, 主要研究方向为电子对抗、智能信号处理与识别。