arXiv:2303.00832v1 [eess.SP] 1 Mar 2023

无线传感器网络中用于盲系统辨识的分布式自适应范数估计

M. Blochberger[1], F. Elvander[2], R. Ali[1], J. Østergaard[3], J. Jensen[3], M. Moonen[1], T. van Waterschoot[1]

[1]鲁汶大学，电气工程系（ESAT），STADIUS，3001 鲁汶，比利时[2]阿尔托大学，信息与通信工程系，02150 埃斯波，芬兰[3]奥尔堡大学，电子系统系，9220 奥尔堡，丹麦

摘要

（无线）传感器网络中的分布式信号处理算法通常旨在将处理任务去中心化，以降低通信成本和计算复杂度，或避免依赖单一设备（即融合中心）进行处理。在本文中，我们扩展了一种用于盲系统辨识的分布式自适应算法。该算法依赖于在每个节点处估计网络范围堆叠共识向量，而这一向量的计算需要将节点特定值（即局部向量范数）广播或中继给所有其他节点。扩展后的算法采用基于分布式平均的方案，仅利用相邻传感器节点提供的局部向量范数来估计网络范围共识范数值。我们在这些范数的瞬时估计值与递归估计值之间引入自适应混合因子，以适应时变系统。仿真结果表明，与完全连接网络或广播情形下的最优结果相比，该扩展算法能够提供相近的估计结果，同时显著减少节点间传输。

索引词——多通道信号处理、分布式信号处理、无线传感器网络、盲系统辨识、分布式平均

1. 引言

长期以来，分布式算法一直是一个活跃的研究领域，广泛应用于控制、优化和信号处理。随着当今环境中的智能多媒体设备数量不断增长，这些设备具备无处不在的处理与通信能力，分布式音频与语音信号处理也逐渐受到关注。人们已提出用于分布式信号估计 [1], 噪声控制和回声消除 [2], 以及波束成形 [3, 4, 5, 6] 等任务的算法。音频与通信应用中的另一项重要任务受到的关注较少，即多信道系统辨识，也就是在时间域或频域中估计信道响应。分布式单输入多输出（SIMO）盲系统辨识（BSI）已采用基于自适应交叉关系（CR）的算法进行研究 [7, 8]。在这一背景下，我们最近提出了一种基于自适应 CR 的算法 [9]，该算法使用交替方向乘子法（ADMM）[10]。

上述分布式盲系统辨识算法依赖于网络中相邻传感器节点之间共享的信息。然而，基于 CR 的盲系统辨识任务要求待辨识的完整系统满足非平凡性约束（详情请参阅例如 [11, 12]），这意味着计算过程中需要一个或多个变量，而这些变量需要全网共享信息。[9] 中的算法依赖于在整个网络中转发节点级数值。相比之下，为了避免网络必须是全连接网络，[7, 8]采用平均一致性 [13]方法，通过次级递推为每个信号帧估计全局变量。这两种方法都会增加节点间的变量传输；传输次数取决于网络和邻域大小，在某些应用中可能相当多，甚至无法实现。

本文在 [9] 中提出的算法基础上进行扩展，采用基于分布式平均的 [13] 估计方案来估计全局变量。与 [14, 15], 类似，该方法使我们无需全连接网络或广播即可计算全局变量。我们还引入混合因子，将瞬时值纳入平均递归，从而使我们能够：(i) 大幅减少次级迭代次数（从现有方法中的 50 次降至 1 次）；(ii) 跟踪时变系统。仿真结果表明，所提出的利用邻域内信息的低通信量算法，其盲系统辨识性能接近理想情况下可获得全网信息时的性能。

2. 采用在线交替方向乘子法的传感器网络分布式自适应 BSI

本节简要概述 [9], 中提出的自适应 SIMO BSI 算法，为本文提出的分布式平均方案做好铺垫。完整的算法推导请参阅 [9]。

2.1. 传感器网络

我们假设有一组网络节点，每个节点各有一个传感器，也就是说，每个节点提供一个信号。设这组节点为 $\mathcal{M}$，$\{1,\ldots,M\}$和 $\mathcal{E}$ 为边元组，它们连接各节点并构成一个传感器网络。每条边都是节点索引$\{i,j\} \in \mathcal{E}$的无序对，表示通信链路；我们

假设 is i瞬时 d and 误差 free, b之间 t hem. We allow

本研究工作在鲁汶大学ESAT实验室开展，属于SOUNDS欧洲培训网络的一部分。本项目获得了欧盟地平线2020研究与创新计划玛丽·斯克沃多夫斯卡-居里资助协议（编号956369）的资助。本研究还获得了弗兰德斯研究基金会（FWO）资助（编号12ZD622N），以及欧盟地平线2020研究与创新计划/ERC整合者资助：SONORA（编号773268）的部分资助。本文仅反映作者的观点，欧盟不对本文所含信息的任何使用承担责任。源代码见https://github

$\{i,i\} \in \mathcal{E}$，但为简化后续记号，这并不表示一条链路，而是表示一个显而易见的事实，即节点 i 拥有关于自身的信息。此外，令 $\mathcal{N}_i = \{j | \{i,j\} \in \mathcal{E}\}$ 表示节点 i的邻域。我们可以定义对称邻接矩阵 $\mathbf{C}$，其元素为 $C_{ij} = 1$，当 $\{i,j\} \in \mathcal{E}$ 时，否则为 0。需要指出的是，在 [9], 中，节点对 $\{i,j\} \in \mathcal{E}$ 是有序的，这会形成有向图，并产生两组邻域（“发送”和“接收”），因此对应一个非对称邻接矩阵。为简洁起见，本文仅阐述无向情形。有向图情形可根据本文给出的结果直接扩展。

2.2 信号模型

我们考虑一个单输入多输出系统，其

$$\mathbf{s}(n) = [s(n), \ldots, s(n-2L+2)]^{\mathrm{T}}, \tag{1}$$

$$\mathbf{x}_i(n) = [x_i(n), \ldots, x_i(n-L+1)]^{\mathrm{T}}, \quad i \in \mathcal{M}, \tag{2}$$

分别具有 $2L \times 1$ 个输入信号帧和 M $L \times 1$ 个输出信号帧。每个输出 $\mathbf{x}_i(n)$ 都是 $\mathbf{s}(n)$ 与相应信道脉冲响应 $\mathbf{h}_i$ 卷积后再加上加性噪声项 $\mathbf{v}_i(n)$ 的结果。假设该噪声为零均值，且与 $\mathbf{s}(n)$ 不相关。信号模型为

$$\mathbf{x}_i(n) = \mathbf{H}_i \mathbf{s}(n) + \mathbf{v}_i(n), \tag{3}$$

其中，$\mathbf{H}_i$是利用长度为 L 的 $\mathbf{h}_i$ 中的元素构造的第 i 个信道的 $L \times (2L-1)$ 线性卷积矩阵。本文假设脉冲响应的长度 L 已知。

2.3 基于在线交替方向乘子法的分布式 BSI

在 BSI 中，交叉关系问题表述仅使用输出信号 $\mathbf{x}_i(n)$，利用它们之间的相对信息来识别系统，即声学信道或通信信道 $\mathbf{h}$ $[\begin{smallmatrix}\mathrm{T}\\1\end{smallmatrix} \ \ldots \ \begin{smallmatrix}\mathrm{T}\\M\end{smallmatrix}]^{\mathrm{T}}$ $= \mathbf{h}$, , $\mathbf{h}$。该问题的解通过以下最小化问题求得 [16, 11, 12, 9]:

$$\begin{aligned} \hat{\mathbf{h}} = \arg\min_{\mathbf{h}} \quad & \mathbf{h}^{\mathrm{H}} \mathbf{R} \mathbf{h} \\ \text{s.t.} \quad & \|\mathbf{h}\| = 1, \end{aligned} \tag{4}$$

其中 $\hat{}\mathbf{h} = [\hat{}\mathbf{h}_1^{\mathrm{T}}$, ..., $\hat{}\mathbf{h}_M^{\mathrm{T}}]^{\mathrm{T}}$ 是估计得到的信道响应向量，而 $\mathbf{R}$ 是所谓的交叉关系（CR）矩阵。在 [9], 该问题通过一种分布式自适应算法求解，该算法将问题（4）拆分为节点级子问题，

$$\begin{aligned} \min_{\mathbf{w},\mathbf{h}} \quad & \sum_{i \in \mathcal{M}} \mathbf{w}_i^{\mathrm{H}} \boldsymbol{P}_i \mathbf{w}_i \\ \text{s.t.} \quad & (\mathbf{w}_i)_j = \mathbf{h}_{\mathcal{G}(i,j)} \quad i \in \mathcal{M}, j \in \mathcal{N}_i \\ & \|\mathbf{h}\| = 1. \end{aligned} \tag{5}$$

这里，每个子问题都由代价函数 $\mathbf{w}_i^{\mathrm{H}} \boldsymbol{P}_i \mathbf{w}_i$表示，其中包含节点本地信道估计 $\mathbf{w}_i$ 和 CR 矩阵 $\boldsymbol{P}_i$。二者分别类似于式（4）中的 $\mathbf{h}_i$ 和 R，但仅使用与 $\mathcal{N}_i \subset \mathcal{M}$对应的部分信道。第一个约束确保局部估计达成共识，而 $\mathcal{G}(i,j)$ 是一个映射，用于使通过边（i,j）连接的节点的局部估计相等 $\in \mathcal{E}$。一般形式共识交替方向乘子法（ADMM）[10] 以自适应更新方案（在线交替方向乘子法）[17, 18]的形式应用。ADMM 得出局部变量、共识变量和对偶变量的更新步骤。详情请参阅[9] 。该算法的共识变量即系统估计值 $\hat{}\mathbf{h}$。每个节点 i 计算

$\hat{}$ 相应的子向量 $\mathbf{h}_i$，这是本文提出的扩展所关注的计算步骤。其定义为

$$\hat{\mathbf{h}}_i^{(n)} = \frac{\bar{\mathbf{h}}_i^{(n)}}{\sqrt{\sum_{j \in \mathcal{M}} \|\bar{\mathbf{h}}_j^{(n)}\|^2}} \tag{6}$$

对于每个节点 $i \in \mathcal{M}$，其局部未归一化共识为 $\bar{}\mathbf{h}_i^{(n)} = \bar{}\mathbf{w}_i^{(n)} + \frac{1}{\rho} \bar{}\mathbf{u}_i^{(n-1)}$，它由节点级局部估计 $\bar{}\mathbf{w}_i^{(n)}$ 和对偶（拉格朗日）变量 $\bar{}\mathbf{u}_i^{(n-1)}$ 的邻域内输入节点平均值组合而成，其中 ρ 是 ADMM 惩罚参数。遗憾的是，本文不便详细介绍这些变量；详情请参阅 [9]。计算（6）的分母需要$\|\bar{}\mathbf{h}_j^{(n)}\|$ 来自所有节点的信息 $j \in \mathcal{M}$，然而，若没有全连接网络或广播，这一点无法实现。在 [9], 我们假设部分平方范数会在整个网络中转发/广播，直到所有节点都获得所需信息。

随后，我们介绍一种对 [9] 中所述算法的扩展，采用最快分布式线性平均（FDLA）方法 [13]，以避免全网数据传输。[7, 8] 中所述的一种相关方法，在用于 BSI 的分布式梯度下降算法中采用类似的迭代平均方案，以估计一个全局变量。然而，该方法每帧需要进行许多次迭代。为缓解这一问题，我们进一步引入自适应混合因子，将瞬时值纳入递推过程，从而将平均迭代分散到自适应算法的各个时间帧中。

3. 自适应范数估计

3.1. 分布式平均

$\bar{}$首先，假设我们有一些未归一化共识变量 $\mathbf{h}_i$对于 $i \in \mathcal{M}$, 我们希望以分布式方式计算它们的平方范数之和 $\sum_{j \in \mathcal{M}} \|\bar{}\mathbf{h}_j\|^2$，对于（6），在每个节点 i处进行。分布式线性组合使我们能够以分布式方式计算平均值，因此可以直接求得所需的总和。它们通常具有以下形式：

$$\phi_i(k+1) = \sum_{j \in \mathcal{N}_i} W_{ij} \phi_j(k), \quad i \in \mathcal{M}, \tag{7}$$

迭代索引为 $k = 0, ..., K$。这可以写成向量形式$\boldsymbol{\phi}(k+1) = \mathrm{W}\boldsymbol{\phi}(k)$，其中 $\boldsymbol{\phi}(k) = [\phi_1(k) \ \ldots \ \phi_M(k)]^{\mathrm{T}}$。我们希望找到矩阵 W，使得对于任意初始值 $\boldsymbol{\phi}(0)$，当 $k \to \infty$ 时，$\boldsymbol{\phi}(k)$ 的每个元素都收敛到 $\boldsymbol{\phi}(0)$ 中各元素的平均值。在此应用中，$\boldsymbol{\phi}(0)$ 的元素是初始节点级平方范数值 $\|\bar{}\mathbf{h}_i\|^2$，我们希望计算它们的总和。因此，对于所有 , , 有 $\lim_{k \to \infty} M\phi_{\underline{i}}(k)$ $\sum_{j \in \mathcal{M}} \|\bar{}_j\|^2$ $i \in \mathcal{M}$ [13] $\mathbf{h}$。通过求解 [13], 中提出的最快分布式线性平均（FDLA）问题，可以计算所需的 W，其形式为

$$\begin{aligned} \min \quad & \|\mathbf{W} - \mathbf{1}\mathbf{1}^{\mathrm{T}}/M\|_2 \\ \text{s.t.} \quad & \mathbf{W} \in \mathcal{C}, \mathbf{1}^{\mathrm{T}}\mathbf{W} = \mathbf{1}^{\mathrm{T}}, \mathbf{W}\mathbf{1} = \mathbf{1}. \end{aligned} \tag{8}$$

这里，集合 $\mathcal{C} = \{\mathrm{W} \in \mathbb{R}^{M \times M} | W_{ij} = 0 \text{ if } \{i,j\} \notin \mathcal{E}\}$ 描述了所有具有与邻接矩阵 C 相同稀疏模式的矩阵。现在，W 的第 i 行包含节点 i 的邻域权重，这些权重以非零元素的形式表示。需要注意的是，对于任何固定拓扑网络 $\mathcal{M}$ 和 $\mathcal{E}$，此操作只需执行一次。

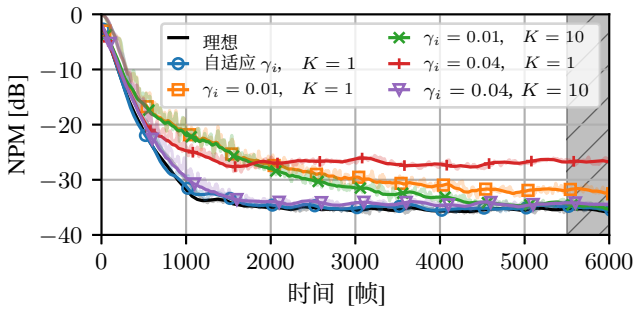

图 1：理想情况下（所有节点信息均可用，即网络完全连接/广播）30 次蒙特卡洛运行随时间变化的 NPM 中位数，固定值 γ_i，其中 $K \in \{1, 10\}$，自适应 γ_i，其中 $K = 1$。为使结果曲线更易读，对其应用了移动平均滤波器（比较透明线条和不透明线条）。阴影区域表示用于计算 图 2 的帧。

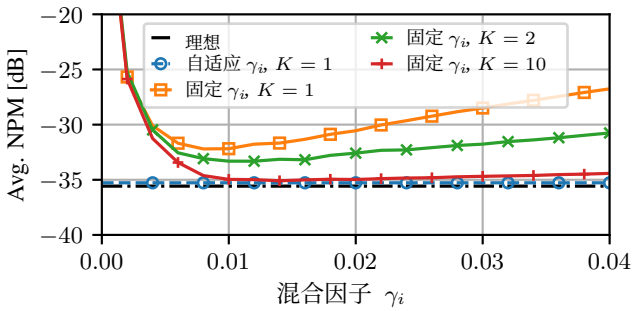

图 2：固定 γ_i $K \in \{1, 2, 10\}$ 在区间 $[0.0, 0.04]$ 和上，30 次蒙特卡洛运行的 NPM 中位数在 γ_i 收敛后 500 帧中的均值。结果包含理想算法，并列出自适应算法以供比较。

3.2. 所提出的自适应估计

鉴于未归一化的一致性估计 $\bar{\mathbf{h}}_i^{(n)}$ [9] 会随时间变化，分布式计算其范数之和也必须以自适应方式进行。基线方法是在每个帧索引 n 下计算 K 次迭代（7），其中 K 必须足够大才能实现收敛（例如，在 [7, 8] 中为 $K = 50$）。这种方法并不理想，因为每次迭代都要求节点 i 与其邻域 $\mathcal{N}_i$ 共享平均变量 $\phi_i(k)$。因此，我们首先提出将迭代分摊到多个时间帧中。一种显而易见的方法是——在每个帧 n 中——将初始值 $\phi_i^{(n)}(0)$ 设置为上一帧 $n-1$ 的第 K 次迭代 $\phi_i^{(n-1)}(K)$ 的结果。当 n 足够大时，即使将 K 设得较小，也能够实现收敛。然而，这种初步修改没有考虑信道识别的自适应方法。也就是说，当令 $\phi_i^{(0)}(0) = \|\bar{\mathbf{h}}_i^{(0)}\|^2$ 时，其中 $\bar{\mathbf{h}}_i^{(0)}$ 是在初始帧 $n = 0$ 中估计得到的，它会收敛到这些初始——质量较差的——估计值之和。相反，我们将瞬时近似，即加权邻域内求和 $\eta_i^{(n)} = \sum_{j\in\mathcal{N}_i} W_{ij}\|\bar{\mathbf{h}}_i^{(n)}\|^2$ 纳入其中；该项会引入通过更准确地估计 $\bar{\mathbf{h}}_i^{(n)}$ 而获得的新信息。我们通过将这些信息与 K 次迭代的 $\phi_i^{(n-1)}(k)$ 进行线性组合来加入该信息，并将其设置为下一帧的初始值

$$\phi_i^{(n)}(0) = \gamma_i \eta_i^{(n)} + (1-\gamma_i)\phi_i^{(n-1)}(K), \tag{9}$$

其中 $0 \le \gamma_i \le 1$ 是一个混合因子。我们利用瞬时信息 $\eta_i^{(n)}$ 来确定混合因子的取值。实验观察表明，较大的 γ_i 可加快收敛，而较小的 γ_i可降低稳态误差。我们假设，当对 $\mathbf{h}_i$ 的估计正趋于稳态时，连续帧之间的绝对差值 $|\eta_i^{(n)} - \eta_i^{(n-1)}| \to 0$。据此，我们认为，在较大的 γ_i下快速收敛后，算法应将重点转向范数估计，即分布式平均递推。这意味着 $\gamma_i \to 0$。基于这一启发式方法，我们将 $\gamma_i^{(n)}$ 设为与连续帧间瞬时近似值的绝对差成正比，并将其上限设为

$$\gamma_i^{(n)} = \min\left\{\frac{|\eta_i^{(n)} - \eta_i^{(n-1)}|}{\eta_i^{(n-1)}}, 1\right\}. \tag{10}$$

$\eta_i^{(n-1)}$ 对于 $n = 0$ 的初始值可以设为任意实数，在本例中设为 1。

自适应估计 $\phi_i^{(n)}(K)$ 随后用作（6）中的分母，即 $\sqrt{M\,\phi_i^{(n)}(K)}$。请参阅算法 1，了解本文所介绍的扩展算法的计算顺序。

4. 评估

4.1. 通信成本

为描述网络中的通信成本，我们统计每个时间帧 n内发送的变量数量。对于本文的研究，最有用的衡量方式是分析每个节点的成本。我们在本文提出扩展的算法 [9] 背景下，比较以下通信方案：

(1) 全连接网络，其中节点 i 直接与所有其他节点 $\{j \in \mathcal{N}_i = \mathcal{M}\}$ 通信 $\|\bar{\mathbf{h}}_i\|^2$，即邻域为整个网络。(2) 节点 i 仅向邻居节点$\{j \in \mathcal{N}_i \subset \mathcal{M}\}$ 通信 $\|\bar{\mathbf{h}}_i\|^2$，并执行 K 分布式平均迭代。

表 1 比较了节点 i 为计算 (6) 所需执行的发送和接收操作次数。此外，表中还展示了节点 i局部问题的复杂度，假设其使用接收到的所有信息。当 $M \gg N_i$时，完全分布式算法的优势便显而易见，因为额外的通信和局部复杂度取决于邻域大小 N_i，而非网络规模 M。

	发送操作	接收操作	局部复杂度
(1) 完全集中式	$M-1$	$M-1$	$\mathcal{O}(M^2L^2)$
(2) 邻居。	N_iK	N_iK	$\mathcal{O}(N_i^2L^2)$

表 1：计算（n）时每个节点、每帧的通信成本6。

4.2. 仿真

为了评估所提出扩展的有效性，我们进行了仿真，并将误差度量定义为归一化投影失配

$$\mathrm{NPM}(n) = 20\,\log_{10}\left(\left\|\mathbf{h} - \frac{\mathbf{h}^{\mathrm{T}}\hat{\mathbf{h}}^{(n)}}{\mathbf{h}^{\mathrm{T}}\mathbf{h}}\hat{\mathbf{h}}^{(n)}\right\| \Big/ \left\|\hat{\mathbf{h}}^{(n)}\right\|\right), \tag{11}$$

算法1：基于分布式平均的 ADMM BSI——范数值自适应估计

$\mathbf{W} \leftarrow (8)$;
$\eta_i^{(n-1)} \leftarrow 1, \forall i \in \mathcal{M}$;
对 $n = 0 \ldots$ 执行
  对于 $i \in \mathcal{M}$ 执行
    前面的步骤如 [9]中所述
    $\dot{\eta}_i^{(n)} \leftarrow \sum_{j \in \mathcal{N}_i} W_{ij} \| \bar{\mathbf{h}}_i^{(n)} \|^2$;
    $\gamma_i^{(n)} \leftarrow$ 最小化 $\left\{ \frac{|\eta_{(n)i} - \eta_{(n-1)i}|}{\eta_i^{(n-1)}}, 1 \right\}$;
    如果 $n = 0$ 则
      $\phi_i^{(0)}(0) \leftarrow \| \bar{\mathbf{h}}_i^{(0)} \|^2$;
    else
      $\phi_i^{(n)}(0) \leftarrow \gamma_i^{(n)} \eta_i^{(n)} + (1 - \gamma_i^{(n)}) \phi_i^{(n-1)}(K)$;
    end
    对于 $k = 0, \ldots, K$ **do**
      发送 $\phi_i^{(n)}(k)$ 至节点 $j \in \mathcal{N}_i$;
      $\phi_i^{(n)}(k+1) \leftarrow \sum_{j \in \mathcal{N}_i} W_{ij} \phi_j^{(n)}(k)$;
    end
    $\hat{\mathbf{h}}_i^{(n)} \leftarrow \frac{\bar{\mathbf{h}}_{(n)i}}{\sqrt{M \phi_i^{(n)}(K)}}$;
    后续步骤如 [9]中所述
  end
end

该度量常用于 BSI（例如，[11, 12, 19]），用于比较估计值 $\hat{\mathbf{h}}^{(n)}$ 与真实值 $\mathbf{h}$。

第一个仿真设置为一个由 $M = 5$ 个节点组成的网络，这些节点按环形拓扑排列，每个节点有 $N_i = 3$ 个邻居（包括节点 i）。输入信号为零均值白高斯噪声（WGN），长度为 $L = 16$ 的脉冲响应取自正态分布，并且每个信道都叠加了信噪比为 $= 10$dB的独立白高斯噪声。脉冲响应的范数缩放为从均匀分布 $\mathcal{U}_{[0.5,2.0]}$中抽取的随机值。对以下情况进行比较：

(a) $\| \bar{\mathbf{h}}_{\text{所有 } i} \|^2$ 的 $i \in \mathcal{M}$ 均可用于全局范数计算（在图1和图2中称为“理想”），(b) 采用固定 $\gamma_i \in [0.0, 0.4]$和 $K \in \{1, 2, 10\}$的邻域间通信，(c) 采用自适应 γ_i (10)和 $K = 1$。

图 1 显示了 30 次蒙特卡洛运行的中位数。可以观察到，在固定 γ_i 时，迭代次数较少时，收敛速度与稳态误差之间存在权衡（另见 图 2）。当 $K = 10$ 时，性能接近最优情况，但代价是节点之间需要额外通信。这与采用自适应 γ_i 的情况形成对比：即使在 $K = 1$ 时（即递归估计方案无需额外通信），收敛速度和稳态误差也接近最优情况。

第二种仿真设置采用 3 节点环形拓扑，邻域大小为 $N_i = 2$（包括节点 i）。输入信号、脉冲响应、加性噪声和信噪比的参数与第一种仿真相同。为测试算法对时变场景的响应，随后将 3 个脉冲响应分别缩放至范数 $\{2.2, 0.5, 1.2\}$、$\{2.2, 1.0, 1.2\}$、$\{2.2, 0.5, 2.0\}$，缩放发生在帧

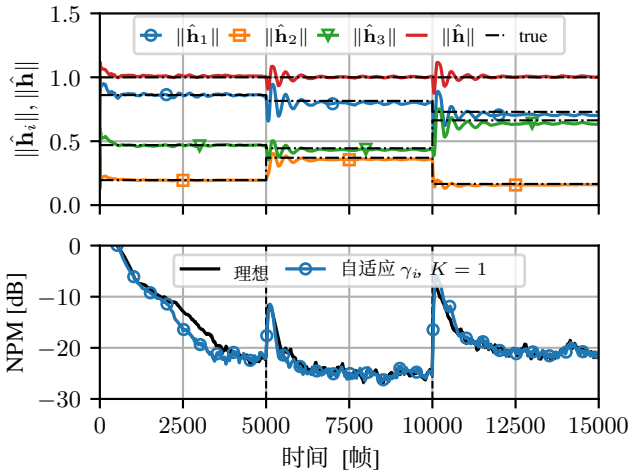

图 3：30 次蒙特卡洛运行的结果：上图：随时间变化的估计值 $\|\mathbf{h}^{(n)}\|, \|\hat{\mathbf{h}}_i^{(n)}\|$，展示的是均值。点划线表示真实值。下图：NPM 中位数，对比理想化算法与提出的扩展算法。竖直虚线表示重缩放事件。

$n \in \{0, 5000, 10000\}$ 处。图 3（下图）展示了 30 次蒙特卡洛运行的 NPM 中位数。可以观察到，最优算法与基于分布式平均的算法表现非常相似，两种算法在重缩放事件后都达到收敛状态。此外，图中还显示，$\|\hat{\mathbf{h}}^{(n)}\|$ 的估计值围绕期望值 1 出现阻尼振荡，而$\|\hat{\mathbf{h}}_i^{(n)}\|$ 的估计值则围绕重缩放后的真实范数出现阻尼振荡，分别如 图 3（上图）所示。

总之，仿真结果表明，取决于固定 γ_i的选择，即使仅进行 $K = 1$ 分布式平均迭代，也能获得接近理想情况的结果。此外，引入自适应 $\gamma_i^{(n)}$ 可使算法更快收敛，并处理时变系统。与[9]相比，这是一项改进，因为节点间通信仅需在节点邻域内进行；与[7, 8] 相比，也只需 $K = 1$，而非每帧进行 $K = 50$ 次迭代。

5. 结论

本文提出了一种扩展方法，适用于传感器网络中的分布式自适应 BSI 算法。基于分布式平均，仅利用传感器网络中邻居节点提供的信息，我们计算信道估计范数值，以施加范数约束。通过在平均过程中引入新数据来平衡递推，我们使算法能够采用自适应更新方案。用于平衡新数据与递推数据的混合因子，会根据瞬时信道估计范数自适应地设定。这些改进减少了每个时间帧的节点间传输，同时仍能实现接近最优情况的稳态估计性能；在最优情况下，所有节点都能获取全网信息。传输量最多可减少到每个时间帧仅需一次迭代，因此只需额外进行一次邻域间信息交换。我们通过仿真展示了该方法的性能，仿真采用白高斯输入信号，随机脉冲响应则取自正态分布。

6. 参考文献

[1] Alexander Bertrand 和 Marc Moonen，《全连接传感器网络中的分布式自适应节点特定信号估计——第二部分：同步与异步节点更新》，IEEE 信号处理汇刊，第 58 卷，第 10 期，第 5292–5306 页，2010 年。

[2] Santiago Ruiz、Toon van Waterschoot 和 Marc Moonen，《无线声学传感器与执行器网络中的分布式声学回声消除与噪声降低》，IEEE/ACM 音频、语音与语言处理汇刊，第 30 卷，第 534–547 页，2022 年。

[3] Yuan Zeng 和 Richard C. Hendriks，“通过随机游走实现的用于语音增强的分布式延迟求和波束成形器”，IEEE/ACM《音频、语音与语言处理汇刊》，第 22 卷，第 1 期，第 260–273 页，2014 年。[4] Shmulik Markovich-Golan、Sharon Gannot 和 Israel Cohen，“用于全连接无线声学传感器网络的分布式多约束广义旁瓣抵消器”，IEEE《音频、语音与语言处理汇刊》，第 21 卷，第 2 期，第 343–356 页，2013 年。[5] Shmulik Markovich-Golan、Alexander Bertrand、Marc Moonen 和 Sharon Gannot，“无线声学传感器网络中用于语音增强的最优分布式最小方差波束成形方法”，《信号处理》，第 107 卷，第 4–20 页，2015 年。[6] Richard Heusdens、Guoqiang Zhang、Richard C. Hendriks、Yuan Zeng 和 W. Bastiaan Kleijn，“使用消息传递的（无线）麦克风网络分布式 MVDR 波束成形”，载于《2012 年国际声学信号增强研讨会论文集》（IWAENC ’12），2012 年，第 1–4 页。[7] Chengpu Yu、Lihua Xie 和 Yeng Chai Soh，“传感器网络中的分布式盲系统辨识”，载于《2014 年 IEEE 国际声学、语音与信号处理会议论文集》（ICASSP ’14），2014 年 5 月，第 5065–5069 页。[8] Ying Liu、Hao Liu 和 Chunguang Li，“传感器网络中稀疏信道的分布式盲辨识”，载于《第 35 届中国控制会议论文集》（CCC ’16），2016 年 7 月，第 5122–5127 页。[9] Matthias Blochberger、Filip Elvander、Randall Ali、Marc Moonen、Toon van Waterschoot、Jan Østergaard 和 Jesper Jensen，“使用在线交替方向乘子法的基于互关系的分布式频域盲系统辨识”，载于《2022 年国际声学信号增强研讨会论文集》（IWAENC ’22），2022 年，第 1–5 页。[10] Stephen Boyd、Neal Parikh、Eric Chu 和 Jonathan Eckstein，“通过交替方向乘子法进行分布式优化与统计学习”，《机器学习基础与趋势》，第 3 卷，第 1 期，第 1–122 页，2011 年。[11] Yiteng Arden Huang 和 Jacob Benesty，“用于盲信道辨识的自适应多信道最小均方算法和牛顿算法”，《信号处理》，第 12 页，2002 年。[12] Yiteng Huang 和 J. Benesty，“一类频域自适应盲多信道辨识方法”，IEEE《信号处理汇刊》，第 51 卷，第 1 期，第 11–24 页，2003 年 1 月。[13] Lin Xiao 和 Stephen Boyd，“用于分布式平均的快速线性迭代”，《系统与控制快报》，第 53 卷，第 1 期，第 65–78 页，2004 年 9 月。

[14] Toon van Waterschoot 和 Marc Moonen，“无线声学传感器网络中房间声学的分布式估计与均衡”，载于《第 20 届欧洲信号处理会议论文集》（EUSIPCO ’12），2012 年，第 2709–2713 页。

[15] Bilgesu C¸akmak、Thomas Dietzen、Randall Ali、Patrick Naylor 和 Toon van Waterschoot，《无线声学传感器网络中基于指向响应功率的分布式声源定位方法》，载于《2022 年声学信号增强国际研讨会论文集》（IWAENC ’22），2022 年，第 1–5 页。

[16] Lang Tong、Guanghan Xu 和 T. Kailath，《基于二阶统计量的盲辨识与均衡：一种时域方法》，IEICE 信息理论汇刊，第 40 卷，第 2 期，第 340–349 页，1994 年 3 月。[17] Huahua Wang 和 Arindam Banerjee，《在线交替方向法（扩展版）》，第 29 届国际机器学习会议论文集（ICML ’12），2012年7月。[18] Saghar Hosseini、Airlie Chapman 和 Mehran Mesbahi，《基于对偶平均的在线分布式交替方向乘子法》，载于第 53 届 IEEE 决策与控制会议论文集（CDC ’14），2014 年 12 月，第 904–909 页。[19] Emanuel A.P. Habets 和 Patrick A. Naylor，《用于盲单输入多输出辨识的在线拟牛顿算法》，载于 2010 年 IEEE 声学、语音与信号处理国际会议论文集（ICASSP ’10），2010 年 3 月，第 2662–2665 页。