用于宽带毫米波大规模MIMO信道估计的AMP-SBL 展开

高家宝*、钟才军*、李泽元†
*浙江大学信息与电子工程学院，中国杭州，电子邮箱：{gao jiabao, caijunzhong}@zju.edu.cn
†伦敦帝国理工学院电气与电子工程系，英国伦敦，电子邮箱：geoffrey.li@imperial.ac.uk

arXiv:2302.00461v1 [cs.IT] 1 Feb 2023

摘要——在宽带毫米波（mmWave）大规模多输入多输出（MIMO）系统中，由于混合模拟数字架构会压缩接收导频信号，使信道估计成为一个压缩感知（CS）问题，因此信道估计颇具挑战。然而，现有的高性能压缩感知算法通常计算复杂度较高。另一方面，巨大带宽和大量天线所导致的波束斜视效应会降低估计性能。本文首先采用频率相关角度字典来补偿波束斜视。随后，从两个方面改进基于期望最大化（EM）的稀疏贝叶斯学习（SBL）算法：每次迭代中的 E步通过近似消息传递（AMP）实现，以降低复杂度；M步则通过深度神经网络（DNN）实现，以提升性能。仿真结果表明，所提出的基于 AMP-SBL 展开的信道估计器在保持低复杂度的同时，能够取得令人满意的性能。

索引词——毫米波、大规模 MIMO、信道估计、波束斜视、压缩感知、稀疏贝叶斯学习、近似消息传递、深度学习。

I. 引言

毫米波（mmWave）大规模多输入多输出（MIMO）具有超大带宽 [1] 和空间自由度 [2], 的优势，被认为是满足未来无线通信系统高数据速率需求不可或缺的技术。为了降低硬件成本和功耗，需要采用混合模拟-数字架构，通过移相器网络将大量天线连接到少数射频（RF）链 [3]。

要实现大规模 MIMO 的理论增益，准确的信道状态信息至关重要；然而，在混合架构中，信道状态信息的估计颇具挑战。由于线性估计器的开销会急剧增加，通常更倾向于采用压缩感知（CS）算法，直接从压缩后的接收导频信号中恢复高维信道。在现有的基于 CS 的信道估计器中，默认利用 mmWave 信号的有限散射特性所导致的角度域信道稀疏性；而对子载波维度的处理方式有两种，由此形成两类估计器。第一类是角度-频域（AF）估计器，它利用所有子信道共有的角度稀疏结构来提高估计精度。具体而言， [4], 提出了同时正交匹配追踪（SOMP）算法，通过对所有子载波上的投影取平均来降低等效噪声。将共同角度稀疏结构融入近似消息传递（AMP）算法 [5] 和稀疏贝叶斯学习（SBL）算法 [6] 的类似方法，也可提升性能。与 AF 估计器不同，角度-时延（AD）估计器进一步将频域子信道变换到稀疏时延域，并利用 AD 域中的双重信道稀疏性。[7], 提出了结合最近邻模式学习的 AMP 算法，以利用 AD 域中的块稀疏结构；也可以使用迭代收缩阈值算法（ISTA） [8] 等其他 CS 算法。尽管 AD 估计器的性能优于 AF 估计器，但其实际应用受到高复杂度的限制，因为从频域到时延域的稀疏变换会产生维度更大的稀疏向量和测量矩阵。

在宽带毫米波场景中，大规模 MIMO 信道估计面临的一项独特挑战是，由超大带宽与大量天线共同导致的波束斜视效应不可忽略，它会破坏 AF 估计器中各子信道之间的共同角度稀疏结构。在 AD 估计器中，波束斜视会导致能量扩散，并降低 AD 信道稀疏性 [9]。为应对波束斜视，文献 [10] 提出了一种特殊的检测窗口，用于捕获波束斜视模式，而不是简单地对不同子载波的变量取平均。文献 [11] 采用了与频率相关的角度字典，从而即使存在波束斜视，共同角度稀疏性仍然成立。文献 [12], 采用主化最小化迭代方法，该方法能够自然地纳入包括波束斜视在内的一般信道效应。

近年来，深度学习（DL）凭借强大的表征能力，在物理层无线通信领域取得了巨大成功。针对存在波束斜视的宽带毫米波信道估计，[13] 提出使用深度神经网络（DNN）实现广义期望一致（GEC）算法中的去噪器，从而妥善处理信道图像上的波束斜视模式。为充分利用信道稀疏性， [8], 进一步在学习得到的稀疏变换域中进行去噪，这与 AD 估计器类似。在我们之前的工作 [15], 中，期望-

最大化（EM）稀疏贝叶斯学习（SBL）算法被展开。在每次迭代中，通过专门设计的深度神经网络学习M步中高斯方差参数的更新规则，该网络能够学习非理想公共角度稀疏结构。在 [14], 中，深度神经网络仅在每次稀疏贝叶斯学习迭代中自适应调整标量形状超参数，这可以视为 [15] 的一种自由度更少的特殊情况。

我们之前的工作 [15] 仍属于 AF估计器。为了实现更准确的信道估计，本文将稀疏贝叶斯学习展开方法扩展到 AD 估计器，沿用基于 DNN 的 M 步骤设计，同时做出两项修改，以提升性能并降低复杂度。一方面，采用频率相关角度字典，避免能量扩散并提高 AD 信道的稀疏性。另一方面，通过使用近似消息传递算法实现 E步，大幅降低算法复杂度。仿真结果表明，所提出的方法能够以较低复杂度实现准确的信道估计。

II. 系统模型与问题表述

本节首先介绍混合大规模多输入多输出系统和导频信号传输模型。在介绍宽带毫米波信道模型后，将信道估计表述为一个压缩感知问题。

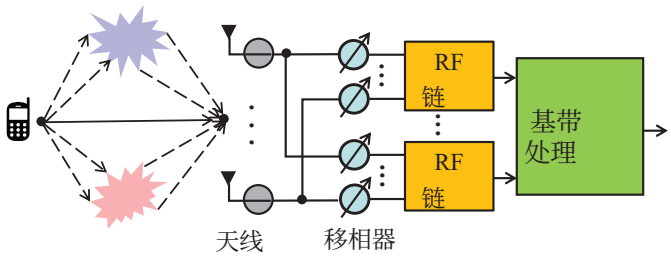

图 1：混合大规模多输入多输出系统。

A. 系统模型

如图 1所示，我们考虑一种混合大规模多输入多输出系统，其中基站（BS）配备有 N 天线均匀线性阵列（ULA）和 N_{RF} 条射频链，为单天线用户提供服务。通过为不同用户及其天线分配正交资源，也可直接扩展到多天线多用户场景。为处理频率选择性信道，总系统带宽 f_s 均匀划分为 K 个子载波。在第 q 次信道使用中，基站在第 k个子载波上的接收信号可表示为

$$\boldsymbol{y}_q^k = \boldsymbol{W}_q(\boldsymbol{h}^k s_q^k + \boldsymbol{n}_q^k) \in \mathbb{C}^{N_{RF}\times 1}, \tag{1}$$

其中，s_q^k $\boldsymbol{h}^k \in \mathbb{C}^{N\times 1}$ $\boldsymbol{n}_q^k \sim \mathcal{CN}\ \mathbf{0}\ \sigma^2\boldsymbol{I}_N$ $\boldsymbol{W}_q \in$、、$\mathbb{C}^{N_{RF}\times N}$(，)分别表示用户发送的导频信号、信道向量、合并前方差为 σ^2的噪声向量以及接收合并矩阵。由于基站已知导频信号，我们设 $s_q^k = 1$, $\forall q, k$

为方便起见，并将发射信噪比（SNR）定义为 $1/\sigma^2$。将总共Q 个信道使用时的接收信号拼接起来，可得

$$\boldsymbol{y}^k = [(\boldsymbol{y}_1^k)^T, \cdots, (\boldsymbol{y}_Q^k)^T]^T = \boldsymbol{W}\boldsymbol{h}^k + \tilde{\boldsymbol{n}}^k \in \mathbb{C}^{QN_{RF}\times 1}, \tag{2}$$

其中 $\boldsymbol{W} = [\boldsymbol{W}_1^T, \cdots, \boldsymbol{W}_Q^T]^T \in \mathbb{C}^{QN_{RF}\times N}$，其元素在集合 $\frac{1}{\sqrt{N}}\{+1, -1\}$ 中等概率随机选取（假设使用低成本的单比特移相器） [8]。等效噪声 $\tilde{\boldsymbol{n}}^k = [(\boldsymbol{W}_1\boldsymbol{n}_1^k)^T, \cdots (\boldsymbol{W}_Q\boldsymbol{n}_Q^k)^T]^T$为有色噪声，其协方差矩阵为 $\boldsymbol{R} = \mathbb{E}\{\tilde{\boldsymbol{n}}^k(\tilde{\boldsymbol{n}}^k)^H\}$ =Blkdiag($\sigma^2\boldsymbol{W}_1\boldsymbol{W}_1^H, \cdots, \sigma^2\boldsymbol{W}_Q\boldsymbol{W}_Q^H$)。为提升压缩感知算法的性能，我们采用预白化过程。具体而言，将 $\boldsymbol{R}$ 通过乔列斯基分解分解为 $\boldsymbol{R} = \sigma^2\boldsymbol{D}\boldsymbol{D}^H$。于是，第 k个子载波上的预白化接收信号为

$$\overline{\boldsymbol{y}}^k = \boldsymbol{D}^{-1}\boldsymbol{y}^k = \overline{\boldsymbol{W}}\boldsymbol{h}^k + \overline{\boldsymbol{n}}^k, \tag{3}$$

其中 $\overline{\boldsymbol{W}} = \boldsymbol{D}^{-1}\boldsymbol{W}$，且 $\overline{\boldsymbol{n}}^k = \boldsymbol{D}^{-1}\tilde{\boldsymbol{n}}^k$ 为白噪声。最后，将所有K 个子载波上的接收信号、信道和噪声按列拼接，可得

$$\boldsymbol{Y} = \boldsymbol{W}^H\boldsymbol{H} + \boldsymbol{N}. \tag{4}$$

B. 毫米波宽带信道模型

本文采用簇状毫米波信道模型 [15]。考虑到半波长天线间距， N 天线 ULA 的响应向量可定义为

$$\boldsymbol{a}_N(\cdot) \triangleq [1, e^{-j\pi(\cdot)}, \cdots, e^{-j\pi(N-1)(\cdot)}]^T/N, \tag{5}$$

那么，第 k 个上行子信道可表示为

$$\boldsymbol{h}^k = \sqrt{\frac{N}{N_cN_p}}\sum_{i=1}^{N_c}\sum_{j=1}^{N_p}\alpha_{i,j}e^{-j2\pi f_k\tau_{i,j}}\boldsymbol{a}_N(\psi_{i,j,k}), \tag{6}$$

其中， N_c 和 N_p 分别表示簇的数量和每个簇中的子路径数量； f_k $=f_c + (k - 1 - \frac{K-1}{2})\eta$ 表示第 k个子载波的频率，其中 f_c和 $\eta = \frac{f_s}{K}$分别表示中心频率和子载波频率间隔。此外，α_{i}、$_{j}$、 τ_{i}、$_{j}$以及ψ_{i}、$_{j}$、$_{k}$ 分别表示第 i个簇中第 j条子路径在基站处的路径增益、时延和等效到达角（AoA）。由于波束斜视效应，ψ_{i}、$_{j}$、$_{k}$ = $\frac{f_k}{f_c}$sin(θ_{i}, $_{j}$)会随 k变化，其中θ_{i}、$_{j}$表示实际物理路径角。关于波束斜视的详细推导见[9]。在第 i个簇中，我们有 θ_{i}、$_{j}$ = $\theta_i + \triangle\theta_{i}$、$_{j}$以及$\tau_{i}$、$_{j}$ = $\bar{\tau}_i + \triangle\tau_{i}$、$_{j}$、$\forall j$，其中 θ_i和$\bar{\tau}_i$ 分别表示平均到达角和平均时延，而$\triangle\theta_{i}$、$_{j}$和$\triangle\tau_{i}$、$_{j}$分别服从零均值拉普拉斯分布 [15]，其标准差分别为 σ_{θ_i}和 σ_{τ_i}。为简洁地表示宽带信道矩阵，我们将等效路径增益定义为$\overline{\alpha}_{i}$、$_{j}$、 α_{i}、$_{j}e^{-j2\pi f_1\tau_i}$、$_{j}$、$\forall i$、j。于是有

$$\boldsymbol{H} = \sqrt{\frac{N}{N_cN_p}}\sum_{i=1}^{N_c}\sum_{j=1}^{N_p}\overline{\alpha}_{i,j}\left(\boldsymbol{a}_N\left(\sin(\theta_{i,j})\right)\boldsymbol{a}_K(2\eta\tau_{i,j})^T\right)\odot\boldsymbol{\Theta}(\theta_{i,j}) \tag{7}$$

其中 $\boldsymbol{a}_K(2\eta\tau_{i,\ j})$可视为频域响应向量，而 $\boldsymbol{\Theta}(\theta_{i,\ j})_{n,\ k}=e^{-j\pi n\sin(\theta_{i,j})(k-1-\frac{K-1}{2})\eta/f_c}$[9]。请注意，当 N 或 f_s 较小时，可以忽略波束斜视效应，且 $\boldsymbol{\Theta}$ 接近全一矩阵。

C. 问题表述

由于接收信号位于天线-频率域，而信道在 AF 域和 AD 域中具有稀疏性，因此需要合适的字典来实现域变换。对于时延字典，采用常用的过采样DFT矩阵，定义为 $\boldsymbol{A}_D$，$[\boldsymbol{a}_K(\varphi_1)\ \cdots,\boldsymbol{a}_K(\varphi_{G_D})]\in\mathbb{C}^{K\times G_D}$，其中 G_D 时延网格为

$$\varphi_i=-1+(2i-1)/G_D, i=1,\cdots,G_D. \tag{8}$$

然而，这种设计不适用于存在波束斜视的角度字典。否则，AF 域中的共同角度稀疏结构将遭到破坏，且能量扩散会降低 AD 域中的信道稀疏性 [12], ，导致估计性能不佳。为补偿波束斜视，我们采用频率相关角度字典，其中第 k 个子信道的角度字典定义为

$$\boldsymbol{A}_A^k \quad [\boldsymbol{a}_N\ \phi_1^k\ \cdots\ \boldsymbol{a}_N\ \phi_{G_A}^k\ ]\in,\ (),$$

$\mathbb{C}^{N\times G_A}$ G_A

(), 角度网格为

$$\phi_i^k=\frac{f_k}{f_c}(-1+(2i-1)/G_A), i=1,\cdots,G_A. \tag{9}$$

借助预失真因子 $\frac{f_k}{f_c}$，即使经历波束斜视造成的失真，AF域中共有的角度稀疏结构仍然成立，并且可避免AD域中的能量扩散。将AF信道矩阵和AD信道矩阵分别记为 $\boldsymbol{Q}\in\mathbb{C}^{G_A\times K}$ 和 $\boldsymbol{X}\in\mathbb{C}^{G_A\times G_D}$，则有 $\boldsymbol{H}_{.k}=\boldsymbol{A}_A^k\boldsymbol{Q}_{.k}$，$\forall k$ 且 $\boldsymbol{Q}=\boldsymbol{X}\boldsymbol{A}_D^T$ 若忽略量化误差，则有，其中 $\boldsymbol{H}_{.k}$ 表示矩阵 k的第 $\boldsymbol{H}$列向量。将（4）中的所有矩阵向量化，可得到如下标准压缩感知形式的传输模型

$$\boldsymbol{y}=\boldsymbol{\Phi}\boldsymbol{x}+\boldsymbol{n}, \tag{10}$$

$$\boldsymbol{\Phi}\triangleq(\boldsymbol{I}_K\otimes\boldsymbol{W}^H)\boldsymbol{A}_A(\boldsymbol{A}_D\otimes\boldsymbol{I}_{G_A})\in\mathbb{C}^{KQN_{RF}\times G_DG_A}, \tag{11}$$

其中，$\boldsymbol{\Phi}$ 称为测量矩阵，$\boldsymbol{A}_A$ 、Blkdiag($\boldsymbol{A}_A^1,\cdots,\boldsymbol{A}_A^K$)，且 $\boldsymbol{n}$的协方差矩阵为$\sigma^2\boldsymbol{I}_{KQN_{RF}}$。总之，信道估计的目标是基于 $\boldsymbol{y}$、$\boldsymbol{\Phi}$和 σ^2，准确恢复 $\boldsymbol{x}$ 。估计出稀疏AD信道后，即可利用上述字典轻松重建原始天线-频率信道。

为了直观地理解波束斜视效应以及角度字典的影响，图2给出了一个示例，展示了 SBL 估计的 AF 信道和 AD 信道的模值，其中系统和信道参数与仿真中的默认设置相同。可以看出，与使用过采样DFT矩阵作为通用角度字典相比，使用所采用的与频率相关的角度字典能够使各子信道的角度稀疏支撑集对齐，并使 AD 信道更加稀疏。

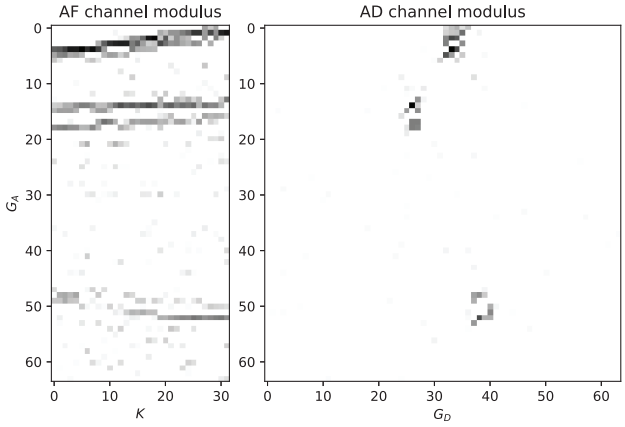

(a) 使用通用角度字典。

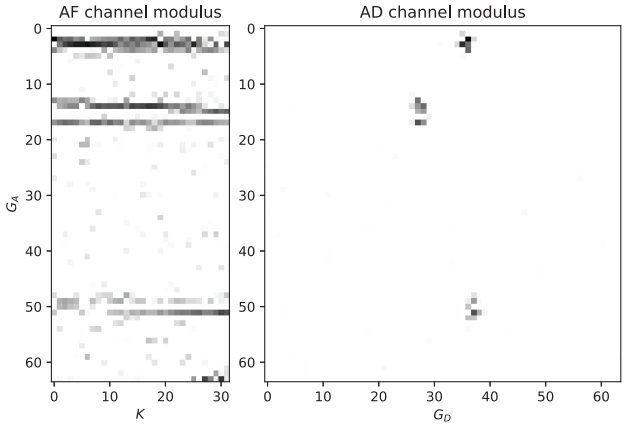

(b) 使用频率相关角度字典。

图 2：使用不同角度字典估计得到的 AF 和 AD 信道模值示例。在这些图像中，颜色越深，模值越大。

III. 基于 AMP-SBL 展开的信道估计器

本节首先简要介绍 SBL 算法的原理。随后，详细阐述为降低其复杂度并增强其能力而进行的两项改进，进而得到基于 AMP-SBL 展开的信道估计器。

A. 稀疏贝叶斯学习原理

作为最强大的压缩感知算法之一，稀疏贝叶斯学习具有良好的稀疏恢复性能，并且具有足够的灵活性来利用各种稀疏结构[6]。为了恢复稀疏AD信道 $\boldsymbol{x}$ （10）中，稀疏贝叶斯学习假设 $\boldsymbol{x}$ 服从具有对角协方差矩阵的复高斯分布：

$$\boldsymbol{x}\sim\mathcal{CN}(\boldsymbol{0},\mathrm{diag}(\boldsymbol{\gamma})), \tag{12}$$

其中，$\boldsymbol{\gamma}=[\gamma_1,\cdots,\gamma_{G_AG_D}]^T$表示 $\boldsymbol{x}$中各元素的方差参数。如图3所示，将 $\boldsymbol{\gamma}^0$ 初始化为 $\boldsymbol{1}_{G_AG_D}$后，L 执行 SBL 迭代，每次迭代均包括期望步（E步）和最大化步（M步）。具体而言，在第 l次迭代中，

通过 E 步更新后验均值和协方差，并通过 M 步更新方差参数 $\boldsymbol{\gamma}^l$。得益于 SBL[16], 的促稀疏特性，最后一次迭代收敛后的后验均值将成为稀疏向量，并将其视为信道估计，即$\hat{}\boldsymbol{x} = \boldsymbol{\mu}_{\boldsymbol{x}}^L$。将第 l次迭代中 E 步和 M 步执行的函数分别记为 $f^l(\cdot)$ 和 $g^l(\cdot)$。在原始 SBL 算法 [16]中， $f^l(\cdot)$ 包含式（13）和式（14）中的运算，而 $g^l(\cdot)$ 执行式（15）中的运算：

$$\boldsymbol{\mu}_{\boldsymbol{x}}^l = \boldsymbol{R}_{\boldsymbol{x}}^{l-1}\boldsymbol{\Phi}^H(\boldsymbol{\Phi}\boldsymbol{R}_{\boldsymbol{x}}^{l-1}\boldsymbol{\Phi}^H + \sigma^2\boldsymbol{I})^{-1}\boldsymbol{y}, \tag{13}$$

$$\boldsymbol{\tau}_{\boldsymbol{x}}^l = \mathrm{diag}\left(\boldsymbol{R}_{\boldsymbol{x}}^{l-1} - \boldsymbol{R}_{\boldsymbol{x}}^{l-1}\boldsymbol{\Phi}^H(\boldsymbol{\Phi}\boldsymbol{R}_{\boldsymbol{x}}^{l-1}\boldsymbol{\Phi}^H + \sigma^2\boldsymbol{I})^{-1}\boldsymbol{\Phi}\boldsymbol{R}_{\boldsymbol{x}}^{l-1}\right), \tag{14}$$

$$\boldsymbol{\gamma}^l = |\boldsymbol{\mu}_{\boldsymbol{x}}^l|^2 + \boldsymbol{\tau}_{\boldsymbol{x}}^l. \tag{15}$$

（13–15）的详细推导可参见[16]。接下来将介绍对 f^l（·）和 g^l（·）所做的修改。

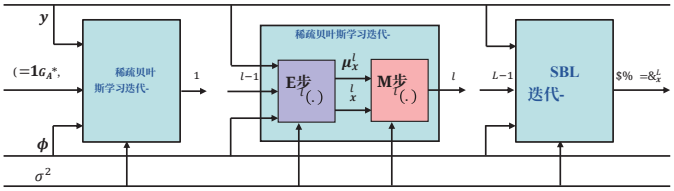

图3：稀疏贝叶斯学习展开框架。

B. 低复杂度的基于近似消息传递的E步

尽管性能优异，稀疏贝叶斯学习的原始E步由于矩阵求逆和乘法而具有较高的复杂度，尤其是在稀疏向量和测量矩阵维度较大的AD估计器中。本文提出[17], 一种基于AMP算法的低复杂度E步替代实现。通过适当近似，E步中计算量最大的部分可通过几次低成本的矩阵向量乘法完成。然而，作为降低复杂度的代价，AMP-SBL对非独立同分布高斯的困难测量矩阵的鲁棒性较差。酉预处理有助于缓解这一问题 [17]。对 $\boldsymbol{\Phi}$进行奇异值分解，可得 $\boldsymbol{\Phi} = \boldsymbol{U}\boldsymbol{\Sigma}\boldsymbol{V}$，其中 $\boldsymbol{U}$ 是酉矩阵，且不会改变噪声协方差。然后，将式（10）变换为

$$\boldsymbol{r} = \boldsymbol{A}\boldsymbol{x} + \boldsymbol{w}, \tag{16}$$

其中 $\boldsymbol{r} = \boldsymbol{U}^H\boldsymbol{y}$、 $\boldsymbol{A} = \boldsymbol{U}^H\boldsymbol{\Phi}$ 和 $\boldsymbol{w} = \boldsymbol{U}^H\boldsymbol{n}$。应用基于近似消息传递的E步后， f^l（·）执行的操作如算法1所示。此外， $\boldsymbol{\gamma}^0$ 初始化为 $\mathbf{1}_{G_AG_D}$，而 $\boldsymbol{\mu}_{\boldsymbol{x}}^0$和 $\boldsymbol{s}^0$ 分别初始化为 $\mathbf{0}_{G_AG_D}$ 和 $\mathbf{0}_{KQN_{RF}}$。符号 $(\cdot)^{\cdot 2}$ 和 $./$ 分别表示逐元素平方和除法。

C. 基于 DNN 的 M 步骤

(15)中的M步仅当$\boldsymbol{x}$ 各元素彼此独立时才是最优的，而在实际的稀疏化簇状毫米波信道中，这一条件并不成立。此外，稀疏贝叶斯学习

Algorithm 1 The E-step in the l-th iteration of AMP-SBL

$\boldsymbol{\tau}_p = |\boldsymbol{A}|^{\cdot 2}\boldsymbol{\tau}_{\boldsymbol{x}}^{l-1}$;
$\boldsymbol{p} = \boldsymbol{A}\boldsymbol{\mu}_{\boldsymbol{x}}^{l-1} - \boldsymbol{\tau}_p \cdot \boldsymbol{s}^{l-1}$, $\boldsymbol{\tau}_s = \mathbf{1}./(\boldsymbol{\tau}_p + \sigma^2\mathbf{1})$;
$\boldsymbol{s}^l = \boldsymbol{\tau}_s \cdot (\boldsymbol{r} - \boldsymbol{p})$, $\boldsymbol{\tau}_q = \mathbf{1}./(|\boldsymbol{A}^H|^{\cdot 2}\boldsymbol{\tau}_s)$;
$\boldsymbol{q} = \boldsymbol{\mu}_{\boldsymbol{x}}^{l-1} + \boldsymbol{\tau}_q \cdot (\boldsymbol{A}^H\boldsymbol{s}^l)$;
$\boldsymbol{\mu}_{\boldsymbol{x}}^l = \boldsymbol{q}./(\mathbf{1} + \boldsymbol{\tau}_q \cdot \boldsymbol{\gamma}^{l-1})$, $\boldsymbol{\tau}_{\boldsymbol{x}}^l = \boldsymbol{\tau}_q./(\mathbf{1} + \boldsymbol{\tau}_q \cdot \boldsymbol{\gamma}^{l-1})$;

采用这种M步通常需要数十次迭代才能收敛，因此复杂度很高。最后，尽管酉预处理在一定程度上提高了AMP-SBL的鲁棒性，但仍无法应对(11)中的高度结构化测量矩阵。在仿真中，我们发现，在大多数情况下，随着迭代推进，AMP-SBL会发散。鉴于原始M步存在上述局限性，我们提出使用深度神经网络学习最优M步，其方差参数更新规则在真实信道数据[15]上兼具有效性和效率。

由于信道稀疏性和稀疏结构反映在 AD 域中，我们首先将第 l次迭代中的特征 $\boldsymbol{\mu}_{\boldsymbol{x}}^l$ 和 $\boldsymbol{\tau}_{\boldsymbol{x}}^l$重塑为$(G_A, G_D)$维矩阵，并沿扩展维度堆叠这些矩阵，得到$(G_A, G_D, 2)$维类图像输入特征张量，记为 $\boldsymbol{F}^l$。随后，自然地使用二维卷积层来提取$\boldsymbol{F}^l$中的局部相关模式，如图2所示，并预测方差参数矩阵，再将其重塑回向量形式，以计算下一次迭代的特征。为提高训练效率和稳定性，我们采用残差连接，使每次迭代中的 DNN 学习对前一次迭代输出的方差参数进行修正。通过交叉验证，我们确定使用两个卷积层，分别包含8 个和1 个滤波器。所有滤波器的尺寸均为3。第 l次迭代中的 DNN 架构如图4所示，其映射函数可表示为

$$\boldsymbol{\gamma}^l = g_R(\boldsymbol{\gamma}^{l-1} + f_{C_2}^l(g_R(f_{C_1}^l(\boldsymbol{F}^l;\boldsymbol{\theta}_1^l));\boldsymbol{\theta}_2^l)), \tag{17}$$

其中， $f_{C_1}^l(\cdot;\boldsymbol{\theta}_1^l)$ 和 $f_{C_2}^l(\cdot;\boldsymbol{\theta}_2^l)$ 分别表示第一个和第二个卷积层的卷积运算，其权重分别为$\boldsymbol{\theta}_1^l$ 和 $\boldsymbol{\theta}_2^l$；而 $g_R(x) = \max(0, x)$ 表示 ReLU 激活函数，用于引入非线性并保证非负性。

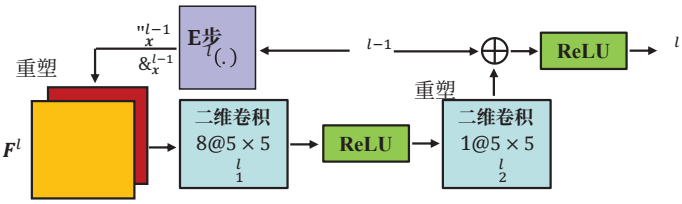

图 4：第 l 次迭代中深度神经网络的架构。

我们分别生成 8,000、1,000 和 1,000 个信道样本，用于网络训练、验证和测试。批量大小设为 128，并为每个批次重新生成随机噪声，以提高数据集多样性。优化器采用 Adam

，损失函数为均方误差（MSE）。采用逐层训练，这对AMP-SBL展开算法的收敛至关重要。首先，构建一个两次迭代的残差网络，随机初始化卷积滤波器的权重并训练至收敛。之后，每次添加一次迭代，并将新添加迭代中深度神经网络的权重从前一次迭代复制过来。随后训练整个网络直至收敛。这样总共需要进行 $L-1$ 次训练。每次训练都采用相同的策略：初始学习率设为 10^{-3}，并每经过 4 个训练轮次将学习率衰减 10 倍，以加快训练；同时采用耐心值为 10 的早停策略，以避免过拟合。

D. 基线算法与复杂度分析

不同算法的实数浮点运算次数（FLOPs）列于表 I 中。为简化符号，定义 G，G_AG_D 以及 M，QN_RF。比较表中的前三种算法可以看出，基于深度神经网络的 M 步骤仅增加了少量 FLOPs，而基于近似消息传递的 E 步骤的复杂度则显著低于原始实现。由于测量矩阵和稀疏向量的维度更小，AF 估计器的复杂度低于 AD 估计器。然而，如仿真结果所示，其性能并不理想。除原始的稀疏贝叶斯学习外，我们还比较了 PC-SBL [18]和 M-SBL [19] 等启发式变体，它们能够利用 AD块稀疏结构和 AF共同稀疏结构来提升性能，且不会增加复杂度。我们还复现了 LISTA [8] 算法，该算法采用深度学习并考虑了波束斜视。此外，还应计入根据估计的稀疏信道重构原始信道所需的 FLOPs，其在 AF 和 AD 估计器中的表达式分别为 $8KG_AN$ 和 $8KG_AN+8KG$。为了展示字典的影响，仿真中还将给出采用通用频率无关角度字典（FID）时的结果。在这种情况下，只有 M-SBL AF 每次迭代的 FLOPs 会变为 $16M^2G_A+8KMG_A$。

算法	每次迭代的浮点运算次数
（PC-）稀疏贝叶斯学习 [18]	$16(KM)^2G$
SBL 展开 [15]	$(16(KM)^2+432)G$
AMP-SBL展开	$(20KM+432)G$
(M-)SBL AF [19]	$16KM^2G_A$
LISTA [8]	$4K\left((4M+256)N+32768\right)$

表 I：不同算法每次迭代的浮点运算次数。

IV. 仿真结果

本节提供仿真结果，以验证所提方法的优越性。默认的系统和信道参数如下：$N=32$,$N_{RF}=4$，$Q=4$，$N_c=3$，$N_p=10$，$\alpha_{i,j}\sim\mathcal{CN}(0,1)$ $\theta_i\sim\mathcal{U}[0,2\pi]$，$\bar{\tau}_i\sim\mathcal{U}[0,25\text{纳秒}]$,$\sigma_{\theta_i}=4°$,$\sigma_{\tau_i}$ =0.06纳秒，$f_c=28$ GHz，$f_s=4$ GHz，$K=32$，G_A =$G_D=64$，信噪比 $=10$ 分贝。归一化均方误差定义为 $\mathbb{E}\{||\boldsymbol{H}-\hat{\boldsymbol{H}}||_F^2/||\boldsymbol{H}||_F^2\}$ 用于衡量信道估计性能，其数值通过对 200 组随机数据样本取平均得到。为便于复现，源代码可在此处获取：https : //github.com/EricGJB/AD SBL Unfold.

图 5 展示了不同算法在性能与复杂度之间的权衡，这一点在浮点运算次数-NMSE平面上的位置上得到了直观体现。所有算法均进行迭代，直至性能收敛，迭代次数如图例所示。可以看到，AF 估计器的性能较差，这验证了采用 AD 估计器的动机。尽管 PC-SBL 和 SBL 展开的性能与 AMP-SBL 展开相近，甚至更好，但由于 E 步更复杂且收敛较慢，其复杂度要高得多，因此更像是性能上限，而非实用选择。LISTA 的复杂度很低，但性能并不令人满意。因此，在某种程度上，我们可以认为，所提出的方法位于平面的左下角，实现了最佳的性能-复杂度权衡。此外，频率相关角度字典的优势也得到了验证，这源于图 2中展示的 AF 信道稀疏结构和 AD 信道稀疏性的改善。需要注意的是，图中未显示 AMP-SBL，因为它的 NMSE 极大，导致算法失效。这意味着嵌入深度神经网络不仅有益，而且是必不可少的，尤其是在测量矩阵较难处理时，它能够实现低复杂度的 AD 估计器。

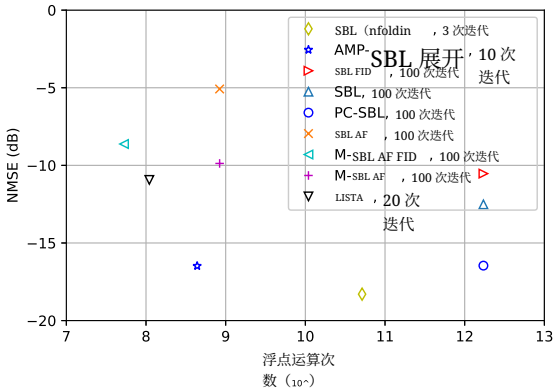

图 5：性能与复杂度的关系。

为验证所提方法的普适性，图 6展示了信噪比的影响，其中 $Q=4$。如图所示，AMP-SBL展开始终优于 M-SBL AF 和 LISTA，并且在低信噪比范围内取得了几乎与 SBL 展开相同的性能，证明了其优越性。在高信噪比范围内，由于 E 步中的近似处理，AMP-SBL 展开的性能趋于饱和，且不如 PC-SBL 和 SBL 展开。尽管如此，AMP-SBL 展开的复杂度极低，即使性能只是中等，也使其在实际应用中极具吸引力。

.....的影响 Q 也在图7中展示，其中信噪比 =

10 分贝。可以看出，在各种 Q下，AMP-SBL展开的性能与 PC-SBL 相近，且明显优于 M-SBL AF 和 LISTA，因此在节省导频开销方面也具有优势。例如，AMP-SBL展开在 $Q=2$ 下的归一化均方误差与 LISTA 在 $Q=4$ 下的归一化均方误差，以及 M-SBL AF 在 $Q=5$下的归一化均方误差相当，因此分别可节省两倍和三倍的导频开销。

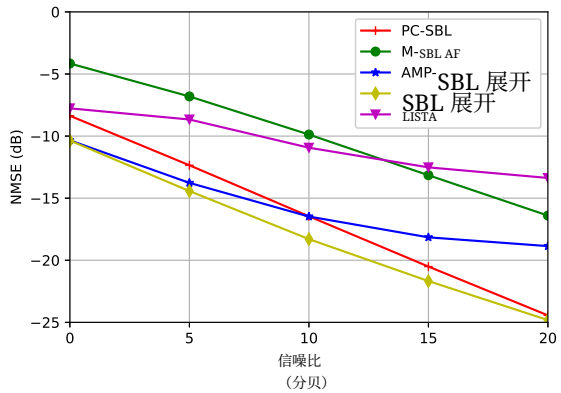

图6：性能与信噪比的关系。

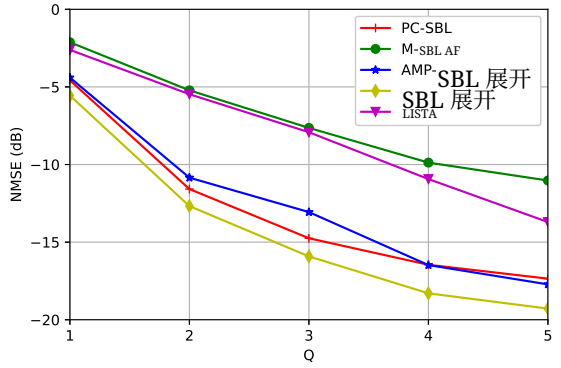

图 7：性能与 Q 的关系。

V. 结论

本文首先利用频率相关角度字典补偿波束斜视。随后，我们提出了一种基于 AMP-SBL 展开的方法，用于角度-时延域宽带毫米波大规模 MIMO 信道估计。与原始 SBL 算法相比，基于近似消息传递的E步显著降低了复杂度，而基于 DNN 的 M 步骤则能够利用高度结构化的测量矩阵实现精确估计。仿真结果表明，在各种系统配置下，所提方法均具有良好的性能与复杂度折衷。未来，我们还将考虑将其扩展至更具挑战性的近场太赫兹场景。

参考文献

[1] S. Rangan、T. S. Rappaport 和 E. Erkip，“毫米波蜂窝无线网络：潜力与挑战”，《IEEE 会议录》，第 102 卷，第 3 期，第 366–385 页，2014 年 3 月。[2] L. Lu 、 G. Y. Li 、 A. L. Swindlehurst 、 A. Ashikhmin 和 R. Zhang，“ 大规模 MIMO 概述：优势与挑战”，《IEEE 信号处理精选主题期刊》，第 8 卷，第 5 期，第 742–758 页，2014 年 10 月。[3] F. Sohrabi 和 W. Yu，“大规模天线阵列的混合数字与模拟波束成形设计”，《IEEE 信号处理精选主题期刊》，第 10 卷，第 3 期，第 501–513 页，2016 年 4 月。[4] J. Rodr´ıguez-Fern´andez、N. Gonz´alez-Prelcic、K. Venugopal 和 R. W. Heath，“频率选择性混合毫米波 MIMO 系统的频域压缩信道估计”，《IEEE 无线通信汇刊》，第 17 卷，第 5 期，第 2946–2960 页，2018 年 5 月。[5] X. Ma、Z. Gao、F. Gao 和 M. Di Renzo，“面向毫米波大规模混合 MIMO 系统的模型驱动深度学习信道估计与反馈”，《IEEE 通信领域精选期刊》，第 39 卷，第 8 期，第 2388–2406 页，2021 年 8 月。[6] S. Srivastava、A. Mishra、A. Rajoriya、A. K. Jagannatham 和 G. Ascheid，“块稀疏毫米波混合 MIMO 系统的准静态与时变信道估计：基于稀疏贝叶斯学习（SBL）的方法”，《IEEE 信号处理汇刊》，第 67 卷，第 5 期，第 1251–1266 页，2019 年 3 月。[7] X. Lin、S. Wu、C. Jiang、L. Kuang、J. Yan 和 L. Hanzo，“利用宽带多用户毫米波大规模 MIMO-OFDM 信道的稀疏结构进行信道估计”，《IEEE 无线通信汇刊》，第 17 卷，第 6 期，第 3959–3973 页，2018 年 6 月。[8] W. Jin、H. He、C. -K. Wen、S. Jin 和 G. Y. Li，“基于模型驱动深度学习的宽带毫米波系统自适应信道估计”，载于《IEEE 全球通信大会（GLOBECOM）会议录》，西班牙马德里，2021 年 12 月。[9] B. Wang、F. Gao、S. Jin、H. Lin 和 G. Y. Li，“毫米波大规模 MIMO 系统中的空间与频率宽带效应”，《IEEE 信号处理汇刊》，第 66 卷，第 13 期，第 3393–3406 页，2018 年 7 月。[10] J. Tan 和 L. Dai，“毫米波大规模 MIMO 宽带信道估计”，《中国通信》，第 18 卷，第 5 期，第 66–80 页，2021 年 5 月。[11] M. Wang、F. Gao、N. Shlezinger、M. F. Flanagan 和 Y. C. Eldar，“一种用于存在波束斜视的毫米波大规模 MIMO 信道的基于块稀疏性的估计器”，《IEEE 信号处理汇刊》，第 68 卷，64，2020 年，第 49 页。–. [12] B. Wang、M. Jian、F. Gao、G. Y. Li 和 H. Lin，“宽带毫米波大规模 MIMO-OFDM 系统中的波束斜视与信道估计”，《IEEE 信号处理汇刊》，第 67 卷，第 23 期，第 5893–5908 页，2019 年 12 月。[13] H. He、R. Wang、W. Jin、S. Jin、C. Wen 和 G. Y. Li，“宽带毫米波 MIMO 的波束空间信道估计：一种模型驱动的无监督学习方法”，《IEEE 无线通信汇刊》，提前在线发表，2022 年。[14] D. Gao、Q. Guo、M. Jin、G. Liao 和 Y. C. Eldar，“稀疏贝叶斯学习的超参数自动调优”，2022 年 5 月，arXiv: *2211 04847* [ ] 2211 04847 . . 在线。[15] 获取地址：https://arxiv.org/abs/。J. Gao、C. Zhong、G. Y. Li、J. B. Soriaga 和 A. Behboodi，“宽带混合毫米波大规模 MIMO 的基于深度学习的信道估计”，2022 年 5 月，arXiv:2205.05202。 [在线]。获取地址：https://arxiv.org/abs/ 2205 05202 。D. P. Wipf 和 B. D. Rao，“用于基选择的稀疏贝叶斯学习”，《IEEE 信号处理汇刊》，第 52 卷，第 8 期，第 2153–2164 页，2004 年 8 月。[16] [17] M. Luo、Q. Guo、M. Jin、Y. C. Eldar、D. Huang 和 X. Meng，“用于稀疏贝叶斯学习的酉近似消息传递”，《IEEE 信号处理汇刊》，第 69 卷，第 6023–6039 页，2021 年。[18] J. Fang、Y. Shen、H. Li 和 P. Wang，“用于恢复块稀疏信号的模式耦合稀疏贝叶斯学习”，《IEEE 信号处理汇刊》，第 63 卷，第 2 期，第 360–372 页，2015 年 1 月。[19] D. P. Wipf 和 B. D. Rao，“求解同时稀疏逼近问题的经验贝叶斯策略”，《IEEE 信号处理汇刊》，第 55 卷，第 7 期，第 3704–3716 页，2007 年 7 月。