

1-18-2021

Joint Low Rank and Sparsity-based Channel Estimation for FDD Massive MIMO

Zhou Jin

Tianjin University of Finance and Economy, School of Science and Technology, Tianjin 300222, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Joint Low Rank and Sparsity-based Channel Estimation for FDD Massive MIMO

Abstract

Abstract: Channel estimation of millimeter wave communication needs large system load. In order to reduce the load, *a low-rank and sparse feature of the wireless channel is combined, and a channel estimation algorithm framework based on non-convex low-rank approximation is proposed.* Aiming at the large computation of the channel model-based dictionary learning algorithm, *a dictionary learning algorithm for deep neural network channel feature classification is designed.* The simulation shows that the average square error of the proposed method is better than the channel model-based dictionary learning method, the channel estimation method under the Bayesian framework, and the compressed sensing channel estimation method under the specific city microcellular channel model. The signal-to-noise ratio required by the algorithm is the lowest when the mean square error is the same. The number of pilots required is lower than the above three methods.

Keywords

massive MIMO, non-convex, deep neural network, channel state information, dictionary learning

Recommended Citation

Zhou Jin. Joint Low Rank and Sparsity-based Channel Estimation for FDD Massive MIMO[J]. Journal of System Simulation, 2021, 33(1): 99-108.

联合低秩及稀疏结构特性的毫米波通信下行信道估计

周金

(天津财经大学 理工学院, 天津 300222)

摘要: 毫米波通信的信道估计给系统带来较大负荷。为降低系统开销, 联合无线信道低秩和稀疏特征, 提出一种基于非凸低秩逼近的信道估计算法框架。针对基于信道建模的字典学习方法运算量大的问题, 设计了基于深度神经网络信道特征分类的字典学习算法。仿真表明: 在特定城市微蜂窝信道模型下, 该方法的均方误差性能均优于基于信道建模的字典学习方法、贝叶斯框架下的信道估计方法以及基于压缩感知信道估计方法; 获取相同归一化均方误差时本文算法所需的信噪比最低; 所需导频数量低于上述 3 种方法。

关键词: 超大规模智能天线; 非凸算法; 深度神经网络; 信道状态信息; 字典学习

中图分类号: TN929.5; TP391 文献标志码: A 文章编号: 1004-731X (2021) 01-0099-10

DOI: 10.16182/j.issn1004731x.joss.19-0629

Joint Low Rank and Sparsity-based Channel Estimation for FDD Massive MIMO

Zhou Jin

(Tianjin University of Finance and Economy, School of Science and Technology, Tianjin 300222, China)

Abstract: Channel estimation of millimeter wave communication needs large system load. In order to reduce the load, a low-rank and sparse feature of the wireless channel is combined, and a channel estimation algorithm framework based on non-convex low-rank approximation is proposed. Aiming at the large computation of the channel model-based dictionary learning algorithm, a dictionary learning algorithm for deep neural network channel feature classification is designed. The simulation shows that the average square error of the proposed method is better than the channel model-based dictionary learning method, the channel estimation method under the Bayesian framework, and the compressed sensing channel estimation method under the specific city microcellular channel model. The signal-to-noise ratio required by the algorithm is the lowest when the mean square error is the same. The number of pilots required is lower than the above three methods.

Keywords: massive MIMO; non-convex; deep neural network; channel state information; dictionary learning

引言

随着人们对高速无线传输通信系统需求的迅速增加, 超大规模多输入多输出系统(Multiple Input and Multiple Output, MIMO)在提高系统容量及频谱利用率方面的突出能力, 受到了学术及工业领域

的广泛关注^[1-2]。MIMO 技术已被广泛应用先进的通信标准, 如 IEEE 802.11 ac^[3], IEEE 802.16 m^[4], 3GPP 长期演进网络^[5-6]等。由于天线数量趋向于无穷大时, 优越的空间复用能力成为实现 5G 的重要途径, 超大规模 MIMO 系统中, 基站侧安装了大量天线, 旨在大幅度扩展信道容量和空间复用度。

收稿日期: 2019-12-03 修回日期: 2020-04-09

基金项目: 国家重点研发计划(2017YFC0806402), 国家自然科学基金(61502331), 2019 年天津市智能制造专项基金(20191002), 天津市自然科学基金(18JCYBJC85100), 教育部人文社会科学研究规划基金(19YJA630046)

作者简介: 周金(1981-), 女, 博士, 讲师, 研究方向为毫米波通信物理层、5G 电网通信。E-mail: zhoujin@tjufe.edu.cn

而获得准确的信道状态信息(Channel State Information, CSI)是获得最佳系统性能的前提。在检测 CSI 方面,时分双工(Time Division Duplex, TDD)模式使用上下行互易性,终端将导频序列发送给基站,基站可以由上行链路获取发送端 CSI。在频分双工(Frequency Division Duplex, FDD)模式下,信道的互易性条件不再满足。传统的信道状态检测方法是:基站发送下行导频信号,移动台接收并检测导频信号,然后将 CSI 反馈给基站。传统的信道检测算法是最小二乘法。该方法的缺点是导频序列的长度必须与基站天线的数量成正比,这使得信道估计很难在相干时间内完成。而且,上行反馈负载较大,对于大规模 MIMO 系统采用传统的信道估计方法是不现实的。

毫米波通信导频负荷大、上行反馈量化所需计算量大等问题可利用信道的结构化特性来解决。文献[7]为降低导频负荷及上行链路反馈开销,提出了一种基于多用户环境下基于信道联合稀疏结构特性的分布式压缩感知信道估计算法。文献[8]提出一种基于空间和时间联合信道估计的结构化压缩感知框架,该框架通过使用 MIMO 信道的共享稀疏集降低导频负荷。然而,该方法增加了终端计算负荷,所采用的基于子空间追踪算法的信号恢复概率有待提高。文献[9]提出一种 FDD 超大规模 MIMO 通信环境下基于空间共有稀疏性的自适应信道估计及反馈框架。利用超大规模 MIMO 信道的低秩特性,文献[10]提出一种针对 FDD 下行信道估计的方法。该方法挖掘了信道协方差矩阵的低秩特性或近似低秩特性,获取了较好的信道估计性能。然而,信道协方差矩阵的计算量大,不适合多用户小区的实际通信场景。文献[11]利用超大规模 MIMO 信道的低秩特性对下行信道进行估计,并利用迭代最优化及深度学习 2 种算法对信道的低秩估计问题求解。然而,上述各种方法存在以下问题:(1) 仅利用了信道的稀疏或低秩特性,而稀疏低秩特性的联合信道估计可以进一步降低训练及反馈负荷及开销。(2) 在很多实际应用场景中,信道状态信息只

有在适合的基的转换下才表现出稀疏性,这种基即冗余字典。因此,上述基于信道稀疏特性的算法在一些实际通信场景中会使信道状态估计的准确率下降。文献[11]针对信道角度域的稀疏特性,采用学习字典取代预设字典,对 FDD 超大规模 MIMO 系统进行了下行信道估计,得到了较好信道稀疏表征性能。然而,该方法的学习字典来自信道的实际测量值,实验操作复杂,不适合对实时性要求高的工业信息传输系统。

在现有的基于信道约束问题中,常采用核范数对信道的低秩特性来近似^[12-14]。然而,基于松弛凸优化问题的核范数问题得到的通常是次优解^[15]。文献[15]提出一种 l_0 范数的非凸近似来逼近秩函数,利用迭代权系数核范数算法进行求解。

针对上述问题,本文对 FDD 超大规模 MIMO 下行信道进行估计,同时利用信道角度域的低秩及稀疏特约束。对于信道的低秩特性,利用非凸方法进行低秩逼近,并设计迭代最优化算法;利用学习字典进行信道的稀疏表征,通过信道测量进行字典学习。为降低信道测量的复杂度,本文采用基于深度神经网络(Deep Neural Network, DNN)的信道测量方法对链路关键特征的进行分类测量。一方面,减少了系统测量负荷;另一方面,该方法可以全面地提取信道结构特征,从而构建一种适用于链路特性的非完备字典。

1 系统模型

为实现 FDD 系统的下行链路信道估计,基站发送训练导频序列。移动台估计信道状况,并将 CSI 反馈给基站。假设每个手机有 M 根天线,基站配置 N 根天线。终端接收到的信号表示为:

$$\mathbf{y}_d = \mathbf{P}\mathbf{h} + \boldsymbol{\omega}_d \quad (1)$$

式中: $\mathbf{h} \in \mathbb{C}^{N \times M}$ 为下行信道响应; $\boldsymbol{\omega}_d \in \mathbb{C}^{T_d \times 1}$ 为接收机端的噪声向量,服从零均值、单位方差的高斯分布; $\mathbf{P} \in \mathbb{C}^{T_d \times N}$ 为下行导频序列,包含 T_d 个导频符号,且 $\|\mathbf{P}\|_F^2 = \rho_d T_d$; ρ_d 为导频序列的信噪比。

使用诸如最小二乘法的常规信道估计方法,信道估

计由式(2)给出:

$$\hat{\mathbf{h}}^{LS} = \mathbf{P}^\dagger \mathbf{y}_d \quad (2)$$

式中: \mathbf{P}^\dagger 为矩阵 \mathbf{P} 的广义逆矩阵。精确获取信道状态信息要求满足 $T_d \geq N$, 即导频序列长度必须大于等于天线数。对于超大规模 MIMO 系统, 基站天线的数量 N 很大, 需要很长的训练周期才能完成信道估计, 这使得在信道相干时间内不可能完成信道估计。另外, 终端必须将信道信息反馈给基站, 这也要求反馈负荷与信道矩阵维数成正比。在信道相干时间内完成信道估计对超大规模 MIMO 系统构成了巨大挑战。为了完成有限负荷条件下的下行信道估计, 基于压缩感知的信道估计技术受到关注。在压缩感知框架中, 只要原始信号在某些基上是稀疏的, 就可以使用较少的测量值来表征高维信号(本文中的高维信号是指超大规模 MIMO 信道)。

假设信道是稀疏的, 矩阵字典 $\mathbf{D} \in \mathbb{C}^{N \times M}$ ($N \geq M$), 根据稀疏表征理论, 得到 $\mathbf{h} = \mathbf{D}\boldsymbol{\beta}_d$, 其中 $\boldsymbol{\beta}_d \in \mathbb{C}^{M \times 1}$ 为稀疏向量。因此下行信道估计问题可转换为式(3):

$$\mathbf{y}_d = \mathbf{P}\mathbf{h} + \boldsymbol{\omega}_d = \mathbf{P}\mathbf{D}\boldsymbol{\beta}_d + \boldsymbol{\omega}_d \quad (3)$$

如果 \mathbf{y}_d , \mathbf{P} 及 \mathbf{D} 已知, 则 $\boldsymbol{\beta}_d$ 可解, CSI 可通过 $\hat{\mathbf{h}} = \mathbf{D}\hat{\boldsymbol{\beta}}_d$ 求解, 其中 $\hat{\boldsymbol{\beta}}_d$ 及 $\hat{\mathbf{h}}$ 分别为估计的稀疏系数及估计的信道响应。当 $T_d < N$ 时, 如果信道在某些条件下稀疏, 则可以恢复出高维度信道矩阵。 $S = \|\boldsymbol{\beta}_d\|_0 \leq N$ 表示信道的稀疏度, 并假设 $\|\boldsymbol{\omega}_d\|_2 \leq \varepsilon$, 则信道估计可转换为式(4):

$$\hat{\boldsymbol{\beta}}_d = \arg \min \|\boldsymbol{\beta}_d\|_0, \text{ s.t. } \|\mathbf{y}_d - \mathbf{P}\mathbf{D}\boldsymbol{\beta}_d\|_0 \leq \varepsilon \quad (4)$$

根据现有理论, 当满足 $T_d \geq cS \log(N/S)$ (c 为常数)时, 利用 l_1 范数来取代 l_0 范数进行松弛求解时, 可以高精度恢复 $\boldsymbol{\beta}_d$ 。因此, 仅通过使用与信道稀疏度成比例的训练符号就可以实现精确的信道估计, 不再需要训练周期长度与基站天线的数量成比例。然而, 当 $T_d < N$ 时, 式(4)为欠定方程。该系统有无穷多个解, 必须通过稀疏约束来求解。因此, 有必要研究最小稀疏度的约束条件。

2 本文算法整体框架

本文整体算法为 3 个阶段, 框架如图 1 所示。

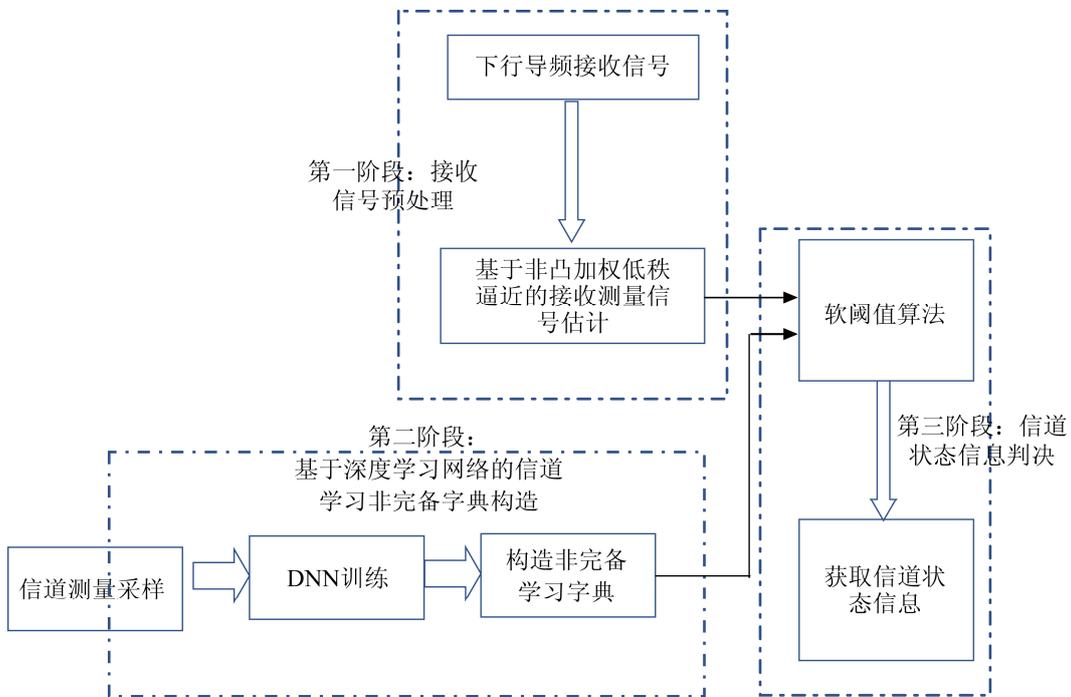


图 1 本文算法实现框图

Fig. 1 Block diagram of proposed method

(1) 接收信号预处理阶段：根据超大规模 MIMO 信道的低秩及稀疏特性，建立信道状态获取的数学模型，利用非凸加权低秩逼近方法取代传统的核范数低秩逼近模型，对下行接收导频信号进行提取及估计测量。

(2) 非完备式学习字典构建：为克服超完备字典的构建复杂度，实现信道估计在工业级物联网电力平台的高实时要求，对无线信道测量采样值进行深度神经网络(Deep Neural Network, DNN)训练，构建基于特定工业传输场景下的信道学习字典。

(3) 在前 2 个阶段输出信号的基础上，利用软阈值方法获取求解信道状态信息。完成 FDD 下行超大规模 MIMO 毫米波通信环境下的信道状态信息的高精度估计。

3 联合低秩及学习字典的信道估计算法

3.1 非凸算法的低秩矩阵约束

将信道模型转换为图像，可以看出信道状态信息图像同时具备低秩及稀疏特性^[18]。因此，式(1)的接收测量收集模型中恢复信道状态信息的过程可视为低秩矩阵采样过程。本文的目标是从接收信号中分离出信道的稀疏低秩成分，分离的关键是接收信号低秩部分的子空间是否与冗余字典的基张成的子空间无关。文献[18]指出式(1)中的接收测量矩阵 \mathbf{Y} 为低秩矩阵，同时，超大规模 MIMO 信道同时具备稀疏特性。因此，在低秩及稀疏约束双重条件下，信道状态获取模型可表达为：

$$\begin{aligned} \arg \min_{\mathbf{h}, \beta_d} & \|\mathbf{Y}_{\text{LR}}\|_* + \lambda \|\beta_d\|_1 + \mu \|\mathbf{Y}_{\text{LR}} - \mathbf{D}\beta_d\|_F^2 \\ \text{subject to} & \mathbf{h} = \mathbf{D}\beta_d \end{aligned} \quad (5)$$

式中： \mathbf{Y}_{LR} 与式(1)中的下行导频接收信号 \mathbf{y}_d 为相同矩阵，LR 为低秩，用来突出下行接收导频信号 \mathbf{Y} 的低秩特性，式(5)第 1 项为低秩矩阵的核范数近似，即 $\|\mathbf{Y}_{\text{LR}}\|_* = \sum_i \sigma_i(\mathbf{Y}_{\text{LR}})$ ，其中 $\sigma_i(\mathbf{Y}_{\text{LR}})$ 表示矩阵 \mathbf{Y}_{LR} 的奇异值。第 2 项为稀疏成份的 l_1 范数，目的是稀疏度进行约束。第 3 项是 Frobenius 范数，用

来确保观测信号的一致连续性。式(5)被视作凸优化问题，可以通过多种求解方式有效地求解。但是，它的解总是次优的，因为核范数只是秩函数的一个松散近似。关于 l_0 范数的松弛函数，非凸罚函数在解的准确性上优于传统的 l_1 范数松弛。非凸罚函数定义为 $f(t) = \eta(|t|)$ ，在实数域 \mathbf{R} 上， $\eta(t)$ 是单调非递减非凸函数，并且满足 $\eta(0)=0$ 。

奇异值对应的向量范数 l_1 ，即为矩阵对应的核范数，其范数 l_0 则为该矩阵对应的秩，因此，把向量的非凸罚函数延申到矩阵奇异值向量具有可信性，得到矩阵的非凸加权核范数。具体含义为任意矩阵 \mathbf{X} ，将非凸函数进行映射处理之后的和作为非凸加权对应的核范数，因此得到：非凸加权核范数定义为： $|\mathbf{X}|_{mw} = \sum_{i=1}^n g(\sigma_i^{\mathbf{X}})$ ， $n \leq m$ 。其中： $\sigma_i^{\mathbf{X}}$ 为矩阵 \mathbf{X} 的第 i 个奇异值；矩阵 \mathbf{X} 的非凸罚函数为 $|\mathbf{X}|_{mw}$ ； $g(t)$ 为作用在矩阵奇异值上的非凸罚函数。实函数 $g(t)$ 需要满足 2 个条件： $g(0)=0$ ； $g(t)$ 在区间 $[0, 1]$ 内为非单调递减的非凸函数。

基于上述理论，本节提出了一种将非凸算法用于信道低秩函数逼近，因此将式(5)的下行信道估计转化为式(6)的解：

$$\min_{\mathbf{h}, \beta_d} \alpha \sum_i g(\sigma_i(\mathbf{Y}_{\text{LR}})) + \lambda \|\beta_d\|_1 + \mu \|\mathbf{Y}_{\text{LR}} - \mathbf{D}\beta_d\|_F^2 \quad (6)$$

如果使用非凸函数代替式(5)中的核范数作为低秩矩阵的近似值， α 表示非凸函数 $g(t)$ 前的系数，第 3 项为旨在约束估计误差的损失函数。式(6)包含连续变量和离散变量，包括非凸函数，因为非凸函数的加权核范数低秩问题很困难，不能直接求解。以下算法用于使用交替方向方法解决该问题。

3.2 低秩矩阵恢复求解

根据交替方向算法，式(6)通过固定某个变量，求解其他变量的方法来获取。即当固定字典矩阵 \mathbf{D} 时，式(6)中 \mathbf{Y}_{LR} 的获取可视为矩阵完备化问题。因此，信道的低秩部分分离可以转换为式(7)：

$$\min_{\mathbf{Y}_{\text{LR}}} \alpha \sum_i g(\sigma_i(\mathbf{Y}_{\text{LR}})) + \mu \|\mathbf{Y}_{\text{LR}} - \mathbf{D}\beta_d\|_F^2 \quad (7)$$

因为函数 $g(t)$ 是区间 $[0, +\infty)$ 上的非凸函数，且

满足式(8)成立:

$$g(\sigma_i^k) + \omega_i^k (\sigma_i - \sigma_i^k) \geq g(\sigma_i) \quad (8)$$

低秩矩阵 \mathbf{Y}_{LR} 在第 k 次迭代时表示为 \mathbf{Y}_{LR}^k , σ_i^k 表示第 k 次迭代时 \mathbf{Y}_{LR}^k 的第 i 个奇异值, 记作 $\sigma_i^k = \sigma_i(\mathbf{Y}_{LR}^k)$ 。由于 $g(t)$ 是非凸函数, 式(7)直接求解比较困难。式(8)给出了非凸函数的线性近似, 因此, 式(7)可以通过式(9)迭代求解:

$$\begin{aligned} \mathbf{Y}_{LR}^{k+1} = \arg \min_h \alpha \sum_i \left[g(\sigma_i^k) + \omega_i^k (\sigma_i - \sigma_i^k) \right] + \\ \frac{\mu}{2} \left\| \mathbf{Y}_{LR}^k - \mathbf{P} \mathbf{D} \boldsymbol{\beta}_d \right\|_F^2 = \\ \arg \min_h \frac{\mu}{2} \left\| \mathbf{Y}_{LR}^k - \mathbf{P} \mathbf{D} \boldsymbol{\beta}_d \right\|_F^2 + \alpha \sum_i \omega_i^k \sigma_i^k \quad (9) \end{aligned}$$

式中: k 为当前迭代次数; σ_i^k 为低秩矩阵 \mathbf{Y}_{LR} 的第 i 个奇异值; ω_i^k 为 $t = \sigma_i^k$ 时非凸非单调递减函数 $g(t)$ 在区间 $[0, +\infty)$ 上的子梯度。为便于求解式(9), 使用了一阶泰勒展开式(9)。函数在矩阵 $\mathbf{K} \in \mathbf{R}^{M \times N}$ 的一阶泰勒展 $\Gamma(\mathbf{Y}) = \frac{\mu}{2} \left\| \mathbf{Y}_{LR} - \mathbf{P} \mathbf{D} \boldsymbol{\beta}_d \right\|_F^2$, 表示为:

$$\begin{aligned} \Gamma(\mathbf{Y}_{LR}) \approx \Gamma(\mathbf{K}) + \langle \nabla \Gamma(\mathbf{K}), \mathbf{Y}_{LR} - \mathbf{K} \rangle + \frac{\mu}{2} \left\| \mathbf{Y}_{LR} - \mathbf{K} \right\|_F^2 = \\ \left\langle 2(\mathbf{Y}_{LR} - \mathbf{P} \mathbf{D} \mathbf{K} - \mathbf{P} \mathbf{D} \boldsymbol{\beta}_d), \mathbf{Y}_{LR} - \mathbf{K} \right\rangle + \frac{\mu}{2} \left\| \mathbf{Y}_{LR} - \mathbf{K} \right\|_F^2 \end{aligned}$$

式中: $\mu > L(\Gamma)$, $L(\Gamma)$ 为函数 $\Gamma(\mathbf{Y}_{LR})$ 的 Lipschitz 常量。因此式(9)可转换为

$$\begin{aligned} \mathbf{Y}_{LR}^{k+1} = \arg \min_h \alpha \sum_i \omega_i^k \sigma_i(\mathbf{Y}_{LR}) + \\ \frac{\mu}{2} \left\| \mathbf{Y}_{LR} - \left(\mathbf{Y}_{LR}^k + \frac{1}{\mu} (\mathbf{Y}_{LR}^k - \mathbf{P} \mathbf{D} \boldsymbol{\beta}_d) \right) \right\|_F^2 \quad (10) \end{aligned}$$

式(10)仍然是非凸优化问题, 但是根据以下定理, 存在对该问题的解析解决方案。

定理 1^[15]: 对任意 $\lambda > 0$, $\mathbf{Y} \in \mathbf{R}^{m \times n}$, 如果 $0 \leq w_1 \leq w_2 \leq \dots \leq w_n$, 最小化问题

$$\min_X \lambda \sum_{i=1}^n w_i \sigma_i^Y + \frac{1}{2} \left\| \mathbf{X} - \mathbf{Y} \right\|_F^2 \quad (11)$$

可通过加权奇异值算子获取最优解:

$$\mathbf{X}^* = \mathbf{U} \mathbf{S}_{\lambda w}(\boldsymbol{\Sigma}) \mathbf{V}^T \quad (12)$$

式中, $\mathbf{Y} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T$ 是矩阵 \mathbf{Y} 的奇异值分解, 奇异值记作 $\sigma_1^Y \geq \sigma_2^Y \geq \dots \geq \sigma_n^Y \geq 0$; 其中 $\mathbf{S}_{\lambda w}(\boldsymbol{\Sigma})$ 为对角阵, 其对角线元素是 $(\Sigma_{ii} - \lambda w_i)_+$, $i \in \{1, 2, \dots, n\}$ 。

其中 $(t-a)_+ = \begin{cases} t-a & t > a \\ 0 & t \leq a \end{cases}$ 。基于上述推导, 本文使用算法 1 来分离并提取低秩接收信号 \mathbf{Y}_{LR} , 算法流程为:

算法 1: 基于非凸低秩逼近理论及交替方向方法的下行接收测量信号提取算法

1 输入: 下行导频接收信号测量值, 基站导频序列 \mathbf{p} 。

2 输出: $\mathbf{Y}_{LR}^* = \mathbf{Y}_{LR}^{k+1}$

3 初始化: 令 $k=0$, λ , $w_i^k = 0$, $i=1, 2, \dots, n$ 。

迭代过程:

4 算法不收敛时

根据定理 1, 计算式(10)的解析解 \mathbf{Y}_{LR}^{k+1} ;

$\omega_i^{k+1} = \partial g(\sigma_i(\mathbf{Y}_{LR}^{k+1}))$, 计算非凸函数 $g(t)$ 的子梯度; 其中 $t = \sigma_i(\mathbf{Y}_{LR}^{k+1})$, $\sigma_1(\mathbf{Y}_{LR}^{k+1}) \geq \dots \geq \sigma_n(\mathbf{Y}_{LR}^{k+1})$ 。

收敛条件: $\left\| \mathbf{Y}_{LR} - \mathbf{D} \boldsymbol{\beta}_d \right\|_F^2 \leq \varepsilon$, $\varepsilon = 10^{-5}$

结束循环

3.3 基于深度神经网络的字典学习

通常情况下, 使用过完备 DFT 字典实现信道的稀疏恢复。然而, 预先设计的固定词典不能根据小区传播环境来自适应地挖掘信道的结构信息。为降低字典训练阶段的系统复杂度, 更好的方法是设计一个特定于传输环境并且适合于信道特性的非完备字典。Ding Yacong 等^[18]提出了基于学习字典进行信道稀疏化恢复的信道估计方法。与预设字典方法不同, 所提出的方法从信道测量值中学习字典。在学习过程中, 对稀疏表示进行了优化, 并通过稀疏约束来提取信道稀疏向量。对小区中不同位置的信道特性进行无限次测量, 并训练信道测量向量以获得自适应的超完备字典。但是, 该方案随机、多次进行信道测量, 缺乏对信道典型位置的选取, 可能会丢失表征信道重要结构特征的信道信息, 降低字典训练的准确性, 增加测量信息的冗余度。

因此, 本节采用基于 DNN 的信道测量方法对链路关键特征进行分类测量。一方面, 减少了系统测量负荷。另一方面, 该方法可以全面提取大多数信道结构特征, 从而构建了一种适用于链路特性的非完备字典。该部分对应算法总体框架的第 3 阶段, 具体实现过程如图 2 所示。

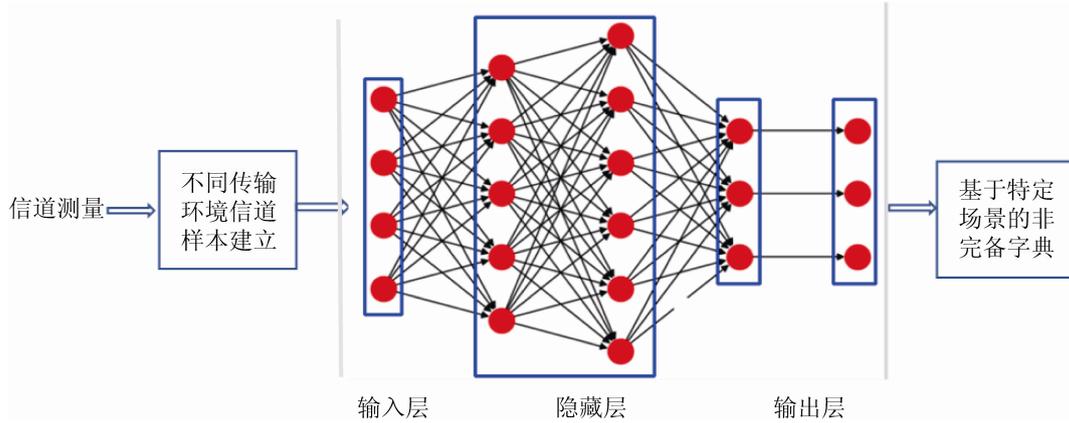


图2 深度神经网络训练模型

Fig. 2 Model of deep neural network

本节提出一种使用 DNN 对路径损耗和角域特征进行分类的算法。该方法首先设置实际传输环境中的 NLOS 和 LOS 路径传播场景，然后使用深度神经网络，从路径损耗、多径分量能量、延迟、相位和角度域等特征对信道测量向量进行分类。训练时，将具有相似参数的链路分组到同一组中，并获得基于组的信道测量值。

对信道测量值进行采样，得到：

$$h(mT_S) = \sum_{l=0}^{L-1} \alpha_l \delta(mT_S - \tau_l), m=1,2,\dots,N \quad (13)$$

式中： T_S 为采样间隔； L 表示多径数目； α_l 和 τ_l 分别表示第 l 条路径的衰减与时延； N 表示采样次数。对采样信号取模，得到：

$$g_m = |h(mT_S)|, m=1,2,\dots,N \quad (14)$$

随着时间的演进，信号 g_m 趋向于 0，因此，只需 M^2 ($M^2 < N$) 个采样信号即可构建深度神经网络的输入集合 \mathbf{X} ：

$$\mathbf{X} = \begin{bmatrix} g_1 & g_2 & \cdots & g_M \\ g_{M+1} & g_{M+2} & \cdots & g_{2M} \\ \vdots & \vdots & & \vdots \\ g_{M(M+1)+1} & g_{M(M+1)+2} & \cdots & g_{M^2} \end{bmatrix} \quad (15)$$

DNN 中含隐藏层 3 个，每层包括输出单元 64 个和隐藏单元 1024 个。由训练样本的输入得到不同传输环境下的信道测量值矩阵 \mathbf{X} 。输入单元维度等于稀疏特征向量的维度。本文的深度神经网络采用前馈结构，输入层为 1845 维特征向量，输出层

具备分类功能，信道的特征向量构成非完备字典。为提高网络算法的收敛速度，采用交叉熵损失函数联合 Sigmoid 作为隐藏层单元的激活函数。隐藏层初始化采用 He initialization 方法。此外，深度神经网络参数量巨大，本文采用 Nesterov 加速梯度 (Nesterov Accelerated Gradient, NAG) 方法进行参数优化。假设输出层结果与预设结果有较大差异，即由隐藏层向输入层反馈，以修改各单元的权值。利用基于最小均方误差函数的后向传播计算梯度，即对信道测量样本与估计出的信道估计矩阵的最小均方误差作为损失函数。基本目标函数定义为：

$$J_{MSE}(\mathbf{W}, \mathbf{b}) = \frac{1}{M} \sum_{m=1}^M \left\| \hat{X}_m(\mathbf{U}, \mathbf{W}, \mathbf{b}) - X_m \right\|_2^2 \quad (16)$$

式中： \hat{X}_m 为估计出的信道状态信息； \mathbf{W} 、 \mathbf{b} 为权值及待训练的基矩阵； M 为训练矩阵维度； \mathbf{U} 为输入特征向量。目标函数 J 旨在使得到的信道估计值和信道测量值 X_m 之间的均方误差最小化。3 个隐藏层采用 20% 的 dropout 来抑制训练过程中的过拟合现象。将无线信道测量矩阵作为深度学习网络的输入信号。第 l 个隐藏层的输出为：

$$G_j^l = f\left(\sum_{i=1}^J \omega_{ij}^{l-1} H_i^{l-1}\right), \quad j=1,2,\dots,J, l=1,2,\dots,L \quad (17)$$

式中： ω_{ij}^{l-1} 为第 $l-1$ 层第 i 个节点与第 l 层第 j 个节点的权重； H_i^{l-1} 为第 $l-1$ 层第 i 个节点的输出值； J 为每层节点数； $f(\bullet)$ 为隐藏层的激活函数。采用梯

度下降方法更新参数得到:

$$\Delta(W_{m+1}^k, b_{m+1}^k) = -\lambda \frac{\partial J}{\partial (W_{m+1}^k, b_{m+1}^k)} + \omega \Delta(W_m^k, b_m^k), \quad 1 \leq k \leq K+1 \quad (18)$$

式中: λ 为学习速率; 动量 ω 用来加速算法的收敛速度; K 为隐藏层数。DNN 获取非完备训练字典流程总结为:

step 1: 构造要分类的测量数据集。式(13)表示了大规模 MIMO 信道模型。

step 2: DNN 训练算法主要分为 2 个阶段: 前向反馈、反向传播。

step 3: 在训练结束时, 通过训练后的 DNN 在大规模 MIMO 信道上执行特征提取, 以识别信道特征。

本文所提出的字典学习算法为:

算法 1: 非完备字典学习算法

1 输入: 稀疏度 S

2 输出: 字典 D

step 1: 测量基站至移动台的不同路径, 提取信道测量向量 $\mathbf{h}_i, i=1, 2, \dots, L$;

step 2: 对信道测量值采样并将采样值输入至 DNN, 执行式(16)~(18);

step 3: 收集并合并 DNN 的输出 \mathbf{h} 向量构成非完备学习字典 D 。

3.4 信道稀疏表征求解

在获得字典之后, 对信道矩阵进行稀疏恢复。本文使用的算法为:

输入: \mathbf{Y}_{LR}

输出: $\beta_d, \hat{\mathbf{h}}$

利用软阈值方法 $\mathbf{Y}_{LR}^{k+1} = \arg \min_{\beta_d} \lambda \|\beta_d\|_1 +$

$\frac{\mu}{2} \left\| \mathbf{Y}_{LR} - \left(\mathbf{Y}_{LR}^k + \frac{1}{\mu} (\mathbf{Y}_{LR} - \mathbf{P} \mathbf{D} \beta_d) \right) \right\|_F^2$ 计算得到 β_d ,

根据 $\hat{\mathbf{h}} = \hat{\mathbf{D}} \hat{\beta}_d$ 得到信道的稀疏表征恢复成份。

4 仿真实验及分析

本文对信道模型进行了性能仿真。假设基站配

备了均匀矩形数组天线, 终端配备了单个天线。无线信道模型采用非可视距(Not Line of Sight, NLOS) UMi-Street Canyon(城市微蜂窝信道)场景, 载波频率为 28 GHz。将该框架与基于信道模型的字典学习方法(Dictionary Learning based Channel Model, DLCM)^[11], 贝叶斯框架下基于联合稀疏和低秩结构的信道估计(Joint Sparse and Low-rank Bayesian Learning, SLAB)^[16], 基于压缩感知的稀疏信道估计(CSSCE, compressed sensing based sparse channel estimation)^[17], 表 1 中列出了参数。

表 1 实验仿真所用主要参数
Tab. 1 Primary parameters in experimental simulation

参数	物理意义	数值
N_t	基站天线数	128
f_c	发射机载频中心频率	28 GHz
B_w	用户带宽	100 MHz
L_p	信道多径数	16
L	信道抽头数目	64

(1) 信道矩阵秩与归一化均方误差(Normalized Mean Square Error, NMSE)性能

图 3 是信噪比为 5 dB 和 15 dB 的所有算法的 NMSE 性能与信道矩阵秩的关系图。从图 3 中可以看出, DLCM 和 CSSCE 算法对矩阵秩的变化不敏感, 与 SLAB 相比, 本文提出的算法在低秩情况下的性能得到了显著提高。这是因为算法 DLCM 和 CSSCE 并未考虑信道的低秩性能, 而对于非凸方法, 其算法优于利用核范数逼近的 SLAB 算法。尽管信道在 MIMO 场景中具有较低的秩, 但传统算法并未充分利用这些特征。本文算法充分利用了信道的低秩特性。图 3(a)中, 当信道矩阵秩小于 15 时, CSSCE 和 SLAB 算法的性能不如本文算法。这是因为从最小二乘角度看, CSSCE 性能最优, 但是该算法对噪声敏感, 在低信噪比的情况下性能较差, 而 SLAB 算法则是基于贝叶斯后验均值的, 因此抗噪鲁棒性优于最小二乘算法。因此, 当信噪比较低, 矩阵的秩较大时, SLAB 算法优于 CSSCE。当比特能量信噪比 EbNo 增加到 15 dB 时, 结果与图 3(b)相似。

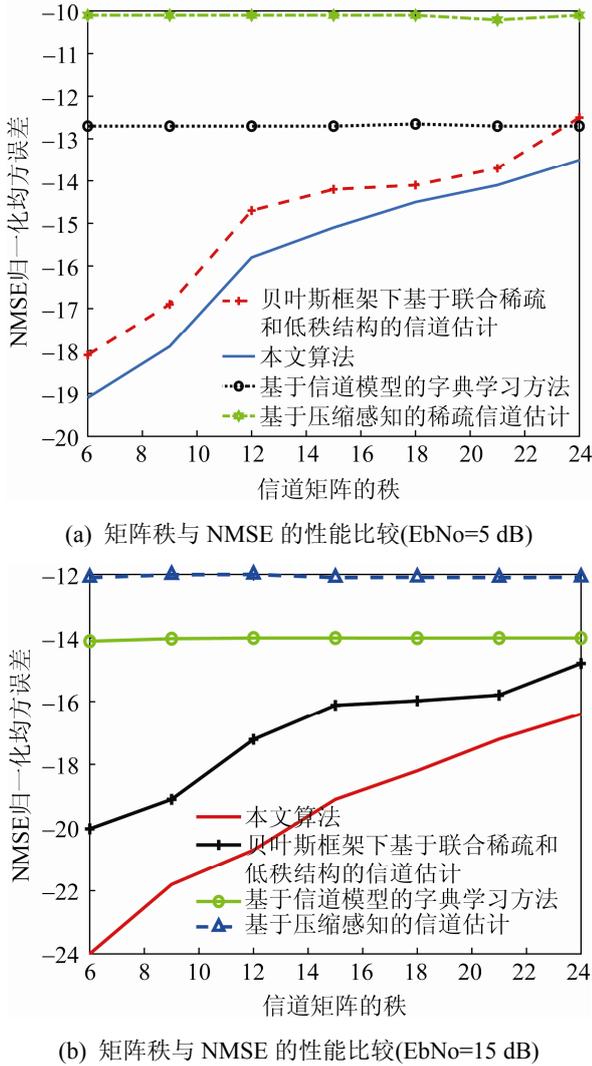


图3 矩阵秩与NMSE性能比较

Fig. 3 Performance comparison of channel rank and NMSE

(2) 归一化均方误差性能随信噪比的变化

图4是4种算法的归一化均方误差性能与EbNo的关系图。本文提出的算法胜过DLCM, SLBF和CSSCE, 其原因是:

1) DLCM算法对小区中的信道进行随机大规模测量, 无法准确捕获所有链路特征, 数据存储负荷大。本文提出的方法对信道场景进行分类, 然后根据信道类别提取测量值的关键特征, 构成非完备字典, 因此, 本文相比DLCM方法能获得更高的信道估计精度, 即在相同的比特能量信噪比条件下, 本文算法相比DLCM算法的归一化均方误差更低。

2) 当SLBF进行信道低秩逼近时, 采用核范

数, 而这种逼近方法不是最优的。本文使用的非凸近似算法是低秩近似的最佳解决方案。因此, 与SLBF相比, 可以更准确地提取通道的主要特征。

3) CSSCE算法只挖掘了信道的稀疏特性, 忽略了信道角度域的低秩特性, 因此相比本文所提算法, 不能准确挖掘信道的潜在内部结构化特性。

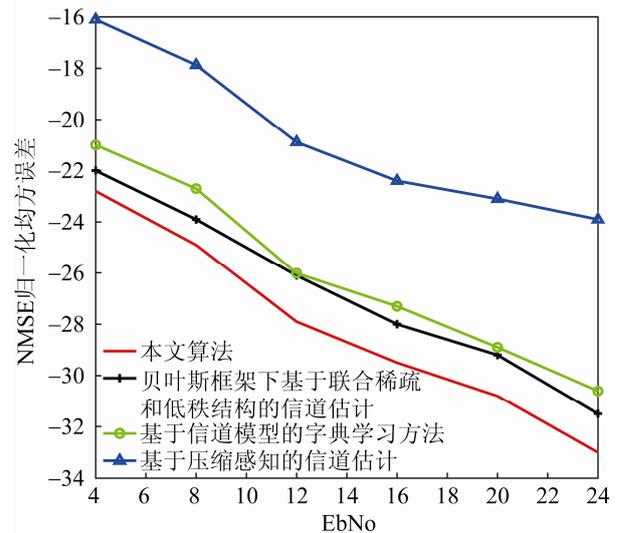


图4 信噪比与归一化均方误差的性能比较

Fig. 4 Performance comparison of EbNo and NMSE

(3) 导频数目与归一化均方误差性能

图5展现了4种算法在基站上针对不同数量导频的NMSE性能比较。在本实验中, 设置EbNo=10 dB。归一化均方误差随着训练导频数量的增加而减少。与其他2种方法相比, SLAB和本文提出的算法降低了下行链路训练导频数量。这是因为SLAB和本文算法利用了信道的低秩特性, 进一步约束了信道的稀疏性能, 与DLCM和CSSCE相比, 降低了下行链路信道的有效维度和训练负荷。由于通过非凸低秩逼近可获得最优解, 本文算法可以更好地进行低秩近似。因此, 在相同NMSE性能下, 本文所需的训练序列数量小于SLAB算法。

(4) 4种方法计算效率比较及分析

从图4看出, 达到相同的NMSE性能, 本文提出的算法所需的下行导频序列长度最低。理论上, 导频序列越长, 信道估计所耗时间越久, 信道状态信息越精确, 但同时, 需要占用更多的频带资

源传送导频信号, 造成频带利用率降低。因此, 本文算法的频带利用率高于其他 3 种方法, 利用相对较少的导频序列即可获取精确的信道估计结果。

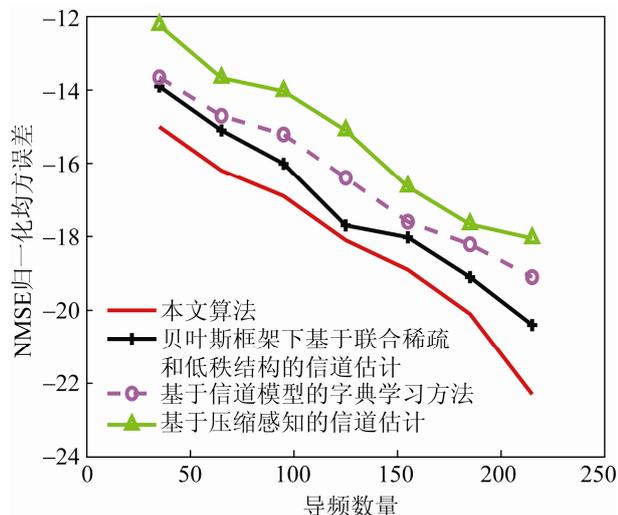


图 5 导频数量与归一化均方误差的性能比较

Fig. 5 Performance of number of pilots and NMSE

5 结论

针对超大规模 MIMO FDD 系统, 本文提出了一种挖掘信道的联合低秩和稀疏特性的估计信道估计框架。在提出的方案中, 基站向移动站发送下行链路导频序列, 移动台对接收到的下行导频信号量化处理, 然后将上行链路反馈给基站, 并在基站执行信道估计算法。本文采用非凸算法代替传统的核范数来逼近无线信道的秩, 通过非预设字典学习稀疏系数。在该方法中, 字典的构建独立于传输信号, 通过测量多次信道冲激响应实验测量来获取信道采集矩阵, 然后通过 DNN 提取信道关键特性构成非完备字典, 通过稀疏表征完成信道状态获取。仿真实验从 NMSE 与导频数目等特性验证了本文提出方法的优越性。

参考文献:

[1] Feng C, Jing Y D, Jin S. Interference and Outage Probability Analysis for Massive MIMO Downlink with MF Precoding[J]. IEEE Signal Processing Letters (S1070-9908), 2016, 23(3): 366-370.
[2] Ding Y, Rao B D. Dictionary Learning-Based Sparse

Channel Representation and Estimation for FDD Massive MIMO Systems[J]. IEEE Transactions on Wireless Communications (S1536-1276), 2018, 17(8): 5437-5451.
[3] Abeysekera B A H S, Matsuda T. Dynamic Contention Window Control Mechanism to Achieve Fairness between Uplink and Downlink Flows in IEEE 802.11 Wireless LANs[J]. IEEE Transactions on Wireless Communications (S1536-1276), 2008, 7(9): 3517-3525.
[4] Li Q H, Lin X T E, Zhang J Z. Advancement of MIMO technology in WiMAX: from IEEE 802.16d/e/j to 802.16m[J]. IEEE Communications Magazine (S0163-6804), 2009, 47(6): 100-107.
[5] Ding Z Guo, Liu Y W, Choi J H. Application of Non-Orthogonal Multiple Access in LTE and 5G Networks[J]. IEEE Communications Magazine (S2169-3536), 2017, 55(2): 185-191.
[6] El-Khamy S E, Moussa K H. Millimeter Multi-User Massive MIMO Simplified Using Antenna Selection and One-Bit Quantized Channel Estimation[C]. URSI Asia-Pacific Radio Science Conference (URSI AP-RASC). Seoul, South Korea: IEEE, 2016: 769-772.
[7] Rao X, Lau V K N. Distributed Compressive CSIT Estimation and Feedback for FDD Multi-User Massive MIMO Systems[J]. IEEE Transactions on Signal Processing (S1053-587X), 2014, 62(12): 3261-3271.
[8] Gao Z, Dai L, Dai W, et al. Structured Compressive Sensing-Based Spatio-Temporal Joint Channel Estimation for FDD Massive MIMO[J]. IEEE Transactions on Communications (S0090-6778), 2016, 64(2): 601-617.
[9] Fang J, Li X J, Li H B. Low-Rank Covariance-Assisted Downlink Training and Channel Estimation for FDD Massive MIMO Systems[J]. IEEE Transactions on Wireless Communications (S1536-1276), 2017, 16(3): 1935-1947.
[10] Sun H R, Zhao Z P, Fu X. Limited Feedback Double Directional Massive MIMO Channel Estimation: From Low-Rank Modeling to Deep Learning[C]. IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Kalamata, Greece: IEEE, 2018: 1948-3252.
[11] Ding Y, Rao B D. Dictionary Learning-Based Sparse Channel Representation and Estimation for FDD Massive MIMO Systems[J]. IEEE Transactions on Wireless Communications (S1536-1276), 2018, 17(8): 5437-5451.
[12] 姜薇. 基于矩阵完备理论的大规模 MIMO 系统信道估计研究[J]. 南京邮电大学学报(自然科学版), 2019, 39(5): 20-25.

- Jiang Wei. Channel Estimation based on Matrix Completion for Massive MIMO systems[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2019, 39(5): 20-25.
- [13] 孙梦璐. 基于低秩矩阵完备的大规模 MIMO 系统信道估计研究[J]. 计算机应用研究, 2018, 35(6): 1841-1844.
- Sun Menglu. Channel Estimation based on Low-rank Matrix Completion for Massive MIMO Systems[J]. Application Research of Computers, 2018, 35(6): 1841-1844.
- [14] Sun H R. Limited Feedback Double Directional Massive MIMO Channel Estimation: From Low-Rank Modeling to Deep Learning[C]. IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Kalamata, Greece: IEEE, 2018: 1948-3252.
- [15] Lu C Y, Tang J H. Nonconvex Nonsmooth Low Rank Minimization via Iteratively Reweighted Nuclear Norm[J]. IEEE Transactions on Image Processing (S1057-7149), 2016, 25(2): 829-839.
- [16] Liu K H, Li X J, Fang J, et al. Bayesian mmWave Channel Estimation via Exploiting Joint Sparse and Low-Rank Structures[J]. IEEE Access (S2169-3536), 2019(7): 48961-48970.
- [17] He X Y, Song R F, Zhu W P. Pilot Allocation for Distributed-compressed Sensing Based Sparse channel estimation in MIMO-OFDM Systems[J]. IEEE Transactions on Vehicular Technology (S0018-9545), 2016, 65(10): 2990-3004.
- [18] Li X J, Fang J. Millimeter Wave Channel Estimation via Exploiting Joint Sparse and Low-Rank Structures[J]. IEEE Transactions on Wireless Communications (S1536-1276), 2018, 17(2): 1123-1133.