

基于深度学习的压缩感知 FDD 大规模 MIMO 系统稀疏信道估计算法

黄源¹, 何怡刚^{1,2}, 吴裕庭¹, 程彤彤¹, 隋永波¹, 宁曙光¹

(1. 合肥工业大学电气与自动化工程学院, 安徽 合肥 230009; 2. 武汉大学电气工程学院, 湖北 武汉 430072)

摘 要: 针对 FDD 大规模多输入多输出 (MIMO) 下行链路系统, 提出了一种新型的基于深度学习的压缩感知稀疏信道估计算法, 即卷积重构网络 (ConCSNet)。在不需要稀疏度的情况下, 通过数据驱动的方式, 利用 ConCSNet 求解从测量向量 \mathbf{y} 到信号 \mathbf{h} 的逆变换过程, 从而解决压缩感知框架下的欠定最优化问题, 实现对原始稀疏信道的重构。仿真结果表明, 所提算法能更快速、准确地恢复稀疏度未知的大规模 MIMO 系统的信道状态信息。

关键词: 无线通信; FDD 大规模 MIMO 系统; 稀疏信道估计; 深度学习

中图分类号: TN929.5

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021128

Deep learning for compressed sensing based sparse channel estimation in FDD massive MIMO systems

HUANG Yuan¹, HE Yigang^{1,2}, WU Yuting¹, CHENG Tongtong¹, SUI Yongbo¹, NING Shuguang¹

1. The School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China

2. The School of Electrical Engineering, Wuhan University, Wuhan 430072, China

Abstract: For FDD massive multi-input multi-output (MIMO) downlink system, a novel deep learning method for compressed sensing based sparse channel estimation was proposed, which was called convolutional compressed sensing network (ConCSNet). In the ConCSNet, the convolutional neural network was utilized to solve the inverse transformation process from measurement vector \mathbf{y} to signal \mathbf{h} and solve the underdetermined optimization problem through data-driven method without sparsity. Simulation results show that the algorithm can recover the channel state information in massive MIMO Systems with unknown sparsity more quickly and accurately.

Keywords: wireless communication, FDD massive MIMO system, sparse channel estimation, deep learning

1 引言

由于频谱利用率高、波束成形增益大的优点, 大规模多输入多输出 (MIMO, multi-input multi-output) 技术被认为是未来无线通信中的关键使能技术之一^[1-5]。在 FDD (frequency division duplexing) 大规模 MIMO 系统的下行链路中, 准确的信道状态信息对波束成形至关重要。随着基站端天

线数不断增加, 通信系统矩阵规模日益复杂, 精确的 FDD 大规模 MIMO 系统稀疏信道估计成为挑战性的问题。

传统的线性大规模 MIMO 系统信道估计算法包括最小二乘 (LS, least square) 算法^[6]和最小均方误差 (MMSE, minimum mean square error) 算法^[7]等。其中, LS 采取伪逆求解的算法, 性能较差; MMSE 通过计算信道的二阶统计量, 性能得到了较

收稿日期: 2021-02-23; 修回日期: 2021-05-08

通信作者: 何怡刚, 18655136887@163.com

基金项目: 国家重点研发计划基金资助项目 (No.2016YFF0102200); 国家自然科学基金资助项目 (No.51577046, No.51637004)

Foundation Items: The National Key Research and Development Program of China (No.2016YFF0102200), The National Natural Science Foundation of China (No.51577046, No.51637004)

大提高。然而，这些算法均需要较多的导频资源才能准确地估计信道，因此频谱资源利用率较低。

近年来，研究人员通过对信道进行研究发现无线多径信道在时域、频域和空域中均存在稀疏特性^[8]。通过挖掘信道的稀疏特性，应用压缩感知（CS, compressed sensing）相关理论实现一种有效的信道估计算法已成为当下研究的热点。基于无线信道所具有的时域稀疏特性，文献[9]提出了一种改进的正交匹配追踪（OMP, orthogonal matching pursuit）算法，以降低导频开销，提高信道估计精度。对于 FDD 模式下的大规模 MIMO 系统下行信道估计，文献[10]采用压缩感知技术来减少信道估计训练和反馈过程中的资源开销，并利用用户信道矩阵中的联合稀疏性，提出了一种分布式压缩感知信道估计方案，即联合正交匹配追踪（JOMP, joint orthogonal matching pursuit）算法。该算法可以通过用户端获取的压缩信号使基站端完成信道的精确估计。为了摆脱 OMP 算法对信道稀疏度的先验条件的依赖，文献[11]提出了一种应用于具有时间相关性的 MIMO-OFDM 系统的改进稀疏自适应匹配追踪（SAMP, sparsity adaptive matching pursuit）算法。在不需要获得信道稀疏度先验知识的情况下，该算法能够完成信道重构过程中对支撑集的自适应选择，从而提高信道估计的性能。文献[12]在 SAMP 算法的基础上进一步提出了一种基于块稀疏共轭梯度自适应匹配追踪（BSBCG-SAMP, block sparsity based conjugate gradient SAMP）算法。该算法考虑了时延域大规模 MIMO 信道的时空公共稀疏性，能够自适应地获取信道结构化稀疏矩阵的稀疏度。虽然 BSBCG-SAMP 精度较高，但是其在迭代过程中受信噪比的影响较大。在噪声环境中，该算法的估计性能会急速下降。然而，这些算法大多采用结构化稀疏特性对无线信道进行估计，利用迭代优化策略求解欠定最优化问题。这些重构算法的弱点是收敛速度慢。该弱点将 CS 技术限制在非实时场景的应用中，并且这种迭代优化的密集计算已成为 CS 在无线信道估计应用中的瓶颈。

为了进一步提高信道估计的精度和解决 CS 算法在实时场景中应用的问题，本文针对 FDD 大规模 MIMO 下行链路提出了一种基于深度学习的 CS 稀疏信道估计算法，即卷积重构网络（ConCSNet, convolutional compressive sensing network）。该算法的主要思想是在没有稀疏度的前提下，采用数据驱

动的方法，通过卷积神经网络求解从测量向量 \mathbf{y} 到信号 \mathbf{h} 的逆变换过程，从而解决 CS 框架下的欠定最优化问题，并实现对原始信道的重构。其次，该算法采取离线训练和在线学习的模式，实现对无线信道的实时估计。实验结果表明，与传统的基于贪婪算法的压缩感知稀疏信道估计算法相比，本文提出的 ConCSNet 算法精度较高，且运算速度较快。

2 系统模型

本文考虑一个单小区多用户 FDD 大规模 MIMO 系统下行链路系统，基站与移动端散射信号如图 1 所示。




图 1 基站与移动端散射信号示意

该系统具有 N_T 根发射天线， N_R 根接收天线和 N 个子载波。发射信号经过频率选择性衰落信道到达接收端，假设信道参数在一个 OFDM 符号中为常量，信道长度为 L 。该系统具有 W 个导频符号，并且分别位于子载波 k_1, k_2, \dots, k_W 上。第 n 根接收天线所接收到的信号可以表示为

$$\mathbf{y}_n^W = \sum_{m=1}^{N_T} \text{diag}(\mathbf{x}_m^W) \mathbf{H}_{nm}^W + \mathbf{z}_n^W = \sum_{m=1}^{N_T} \text{diag}(\mathbf{x}_m^W) \mathbf{F}^W \mathbf{h}_{nm} + \mathbf{z}_n^W \quad (1)$$

其中， \mathbf{y}_n^W 表示第 n 根接收天线在 W 个导频子载波上的符号组成的接收信号向量， \mathbf{x}_m^W 表示第 m 根发送天线在 W 个导频子载波上的符号组成的发送信号向量， \mathbf{z}_n^W 为高斯白噪声信号矩阵， \mathbf{H}_{nm}^W 表示第 m 根发射天线与第 n 根接收天线之间的信道频率响应。令 \mathbf{F} 表示 N 点离散傅里叶变换， \mathbf{F} 可以表示为

$$\mathbf{F} = \frac{1}{\sqrt{N}} \begin{bmatrix} \alpha_N^{00} & \alpha_N^{01} & \cdots & \alpha_N^{0(N-1)} \\ \alpha_N^{10} & \alpha_N^{11} & \cdots & \alpha_N^{1(N-1)} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha_N^{(N-1)0} & \alpha_N^{(N-1)1} & \cdots & \alpha_N^{(N-1)(N-1)} \end{bmatrix} \quad (2)$$

令 \mathbf{F}^W 为 \mathbf{F} 中对应的 W 行和前 L 列组成的 $W \times L$ 维矩阵, $\mathbf{h}_{nm} \in \mathbb{C}^{L \times 1}$ 为信道的时域脉冲响应矩阵。时域多径信道 \mathbf{h}_{nm} 通常呈现稀疏特性, 即大部分能量集中在少量信道抽头上, 而其余小部分能量分布低于噪声门限, 且信道非零抽头数目远小于信道长度 L 。 \mathbf{h}_{nm} 可以表示为

$$\mathbf{h}_{nm} = \sum_{l=0}^{L-1} \alpha_{nm}(l) \delta(t - \tau_l) \quad (3)$$

其中, \mathbf{h}_{nm} 的稀疏度为 $K(K \ll L)$, 且 $K = |\text{supp}(\mathbf{h}_{nm})_0| = |\{l: |\mathbf{h}_{nm}(l)| > \rho_{th}, 1 \leq l \leq L\}|$, ρ_{th} 为噪声门限, $\text{supp}(\mathbf{h}_{nm})$ 表示信道 \mathbf{h}_{nm} 的支撑集索引; $\alpha_{nm}(l)$ 和 τ_l 分别表示第 l 条路径的复数增益和时延。

令 $\tilde{\mathbf{h}}_n = \left[(\mathbf{h}_{n,1})^T, (\mathbf{h}_{n,2})^T, \dots, (\mathbf{h}_{n,N_T})^T \right]^T$ 为 $N_T L \times 1$ 的矩阵, 即所有发射天线和第 n 根接收天线的信道。 $\mathbf{x} = \left[\text{diag}(\mathbf{x}_1^W) \mathbf{F}^W, \text{diag}(\mathbf{x}_2^W) \mathbf{F}^W, \dots, \text{diag}(\mathbf{x}_{N_T}^W) \mathbf{F}^W \right]$ 是 $W \times N_T L$ 的矩阵。则式(1)可以重新表示为

$$\mathbf{y}_n^W = \mathbf{x} \tilde{\mathbf{h}}_n + \mathbf{z}_n^W \quad (4)$$

然而, 式(4)仅考虑了第 n 根接收天线。如果考虑所有的接收天线, 式(4)可进一步表示为

$$\mathbf{y} = \mathbf{T} \mathbf{h} + \mathbf{z} \quad (5)$$

其中, $\mathbf{y} = \left[(\mathbf{y}_1^W)^T, (\mathbf{y}_2^W)^T, \dots, (\mathbf{y}_{N_R}^W)^T \right]^T \in \mathbb{C}^{N_R W \times 1}$, $\mathbf{T} = I_{N_R} \odot \left[\text{diag}(\mathbf{x}_1^W) \mathbf{F}^W, \text{diag}(\mathbf{x}_2^W) \mathbf{F}^W, \dots, \text{diag}(\mathbf{x}_{N_T}^W) \mathbf{F}^W \right] \in \mathbb{C}^{N_R W \times N_R N_T L}$, $\mathbf{h} = \left[(\mathbf{h}_{n,1})^T, (\mathbf{h}_{n,2})^T, \dots, (\mathbf{h}_{n,N_T})^T, \dots, (\mathbf{h}_{N_R,1})^T, (\mathbf{h}_{N_R,2})^T, \dots, (\mathbf{h}_{N_R,N_T})^T \right]^T$ 是一个 $N_R N_T L \times 1$ 的矩阵, $\mathbf{z} = \left[(\mathbf{z}_1^W)^T, (\mathbf{z}_2^W)^T, \dots, (\mathbf{z}_{N_R}^W)^T \right]^T \in \mathbb{C}^{N_R W \times 1}$ 。

3 基于传统贪婪算法的压缩感知稀疏信道估计算法

由式(5)可知, 接收信号 \mathbf{y} 的长度远小于信道 \mathbf{h} 的长度, 即 $N_R W \ll N_R N_T L$ 。因此, 式(5)是一个欠定方程, 存在无穷多个解, 难以重构原始信道 \mathbf{h} 。然而, 根据 CS 的相关理论可知^[13], 当原始信号是 K 稀疏的, 并且 \mathbf{y} 与 \mathbf{T} 满足有限等距准则 (RIP, restricted isometry property) 时, 原始信号可以由测量值 \mathbf{y} 通过求解最优 l_0 范数问题精确重构。因此, 稀疏度为 K 的信道 \mathbf{h} 可以通过求解一个欠定最优化

问题, 然后从包含 $N_R W$ 个测量值的信号 \mathbf{y} 中得到完美的重构, 即

$$\begin{aligned} \min_{\mathbf{h}} \quad & \|\mathbf{T} \mathbf{h}\|_0 \\ \text{s.t.} \quad & \|\mathbf{y} - \mathbf{T} \mathbf{h}\|_2 \leq \xi \end{aligned} \quad (6)$$

其中, ξ 为噪声方差。值得注意的是, 当导频是高斯随机矩阵时, 观测矩阵 \mathbf{T} 满足有限等距约束准则。许多基于传统贪婪算法的压缩感知稀疏信道估计算法相继被提出, 并不断完善式(6)的求解方法和重构性能, 如正交匹配追踪 OMP 算法^[9]、稀疏自适应匹配追踪 SAMP 算法^[11]、压缩采样匹配追踪 (CoSaMP, compressive sampling matching pursuit) 算法^[14]和广义正交匹配追踪 (gOMP, generalized orthogonal matching pursuit) 算法^[15]。

基于传统贪婪算法的压缩感知信道估计算法原理如图 2 所示。该算法首先通过感知矩阵 \mathbf{T} 对稀疏信道 \mathbf{h} 进行压缩采样, 然后利用贪婪算法对接收信号 \mathbf{y} 和感知矩阵 \mathbf{T} 采用迭代优化的策略求解式(6)欠定最优化问题, 从而求解得到稀疏信道 $\hat{\mathbf{h}}$ 。

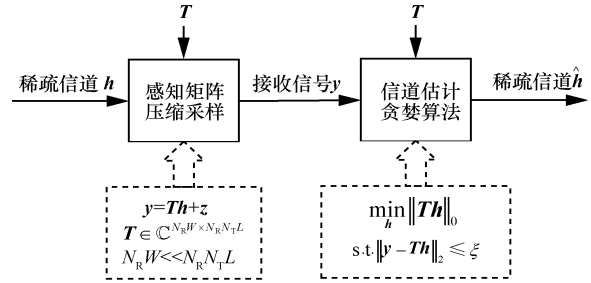


图 2 基于传统贪婪算法的压缩感知信道估计算法原理

4 基于深度学习的压缩感知稀疏信道估计

针对 FDD 大规模 MIMO 下行链路的稀疏信道估计技术研究, 上述传统贪婪算法的压缩感知信道估计算法通过迭代优化的策略求解 CS 模型中的欠定最优化问题。这种迭代优化的密集计算以及不能保证全局最优的问题已成为 CS 在大规模 MIMO 系统稀疏信道估计应用中的瓶颈。为了进一步提高信道估计的精度和运算速度, 以解决 CS 算法在大规模 MIMO 系统实时场景的应用中运算速率慢的问题, 本文进一步提出了一种基于深度学习的压缩感知 ConCSNet 稀疏信道估计算法。

基于深度学习的压缩感知信道估计算法原理如图 3 所示。首先, 通过感知矩阵 \mathbf{T} 对稀疏信道 \mathbf{h} 进行压缩采样; 然后, 利用深度学习的方法对接收

信号 \mathbf{y} 采用端到端的学习优化策略求解式(6)欠定最优化问题从而求解得到稀疏信道 $\hat{\mathbf{h}}$ 。这 2 个步骤分别对应于压缩感知理论中的压缩采样和稀疏重构过程。然而,与传统的基于贪婪算法的 CS 信道估计算法相比,本文提出的基于深度学习的压缩感知稀疏信道估计算法有根本的区别:1) 本文所提出的算法在求解过程中不需要知道信道稀疏度的先验知识和感知矩阵 \mathbf{T} , 这样能进一步拓展该算法在信道估计领域中的应用范围;2) 求解式(6)欠定最优化问题采用端到端的方式,而不是迭代优化的方式,这样能极大地提高大规模矩阵运算的求解速度。本文将进一步对所提基于深度学习的压缩感知 ConCSNet 稀疏信道重构算法进行详细说明。

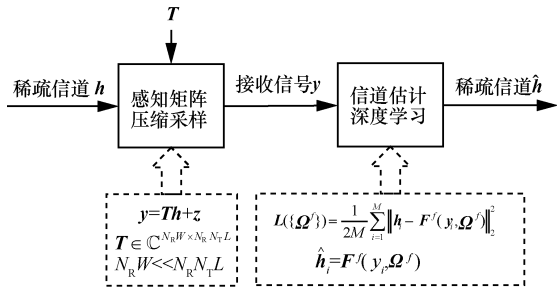


图 3 基于深度学习的压缩感知信道估计算法原理

本文所提 ConCSNet 结构如图 4 所示。该算法首先通过感知矩阵 \mathbf{T} 对稀疏信道 \mathbf{h} 进行压缩采样得到接收信号 \mathbf{y} , 然后使用一个全连接层的线性映射网络得到信道的近似解, 最后由多层的卷积神经网络得到更高质量的重构信道。值得注意的是, 由于接收信号 \mathbf{y} 和信道信息 \mathbf{h} 均为复数, 并且神经网络通常以实数作为输入, 因此需要对数据进行预处理

理, 这里分别对训练数据以及标签的实部和虚部进行拼接。为了尽可能地保留复数信号 \mathbf{y} 的信息和提高信道估计的精度, 在 ConCSNet 算法的输入端, 将复数 $\mathbf{y} \in \mathbb{C}^{N_r N_t L}$ 转化为输入矩阵 $\bar{\mathbf{y}} = [\mathbf{y}_R, \mathbf{y}_I, \mathbf{y}_E] \in \mathbb{C}^{3N_r N_t L}$, 其中, \mathbf{y}_R 为 \mathbf{y} 的实部, \mathbf{y}_I 为 \mathbf{y} 的虚部, $\mathbf{y}_E = [|\mathbf{y}_1|^2, \dots, |\mathbf{y}_{N_r N_t L}|^2]$ 为 \mathbf{y} 的能量值。而标签 $\mathbf{h} \in \mathbb{C}^{N_r N_t L}$ 转化为一个三维 $N_r N_t \times L \times 2$ 的矩阵 $\bar{\mathbf{h}}$, 该矩阵的第三个维度用来刻画数据的实部和虚部。在 ReconNet (reconstruction network) 深度学习重构框架^[16]中, 卷积层只有 6 层, 且所使用的卷积核过大, 不但增加了计算的复杂度, 而且重构的细节部分效果不佳。因此, 该网络不适用于更高精度需求的信道估计场景。而本文提出的 ConCSNet 算法一方面增加了卷积层的层数, 扩展了卷积神经网络的规模; 另一方面缩小了部分较大的卷积核, 使该网络更聚焦于重构细节。接下来, 本文将对 ConCSNet 所包含的线性映射网络和卷积学习网络分别进行介绍。

4.1 线性映射网络

对于式(5), 从测量信号 \mathbf{y} 重构出原始信道信息 \mathbf{h} , 该步骤可近似看作一个线性映射的过程, 即 $\mathbf{h} = \mathbf{\Omega} \mathbf{y}$, 其中, $\mathbf{\Omega} \in \mathbb{C}^{N_r N_t L \times N_r N_t L}$ 为线性映射矩阵。由于 $N_r N_t L \ll N_r N_t L$, 该映射过程求解的是一个欠定最优化问题, 难以求出精确解。在基于贪婪算法的 CS 信道估计算法中, 通常利用感知矩阵 \mathbf{T} 的伪逆和接收信号 \mathbf{y} 的乘积求出初始的重构信道, 然后通过迭代的方式逐步优化得到精确的稀疏信道。因此, 与贪婪算法类似, 本文采用线性映射网络 \mathbf{F}^f 求

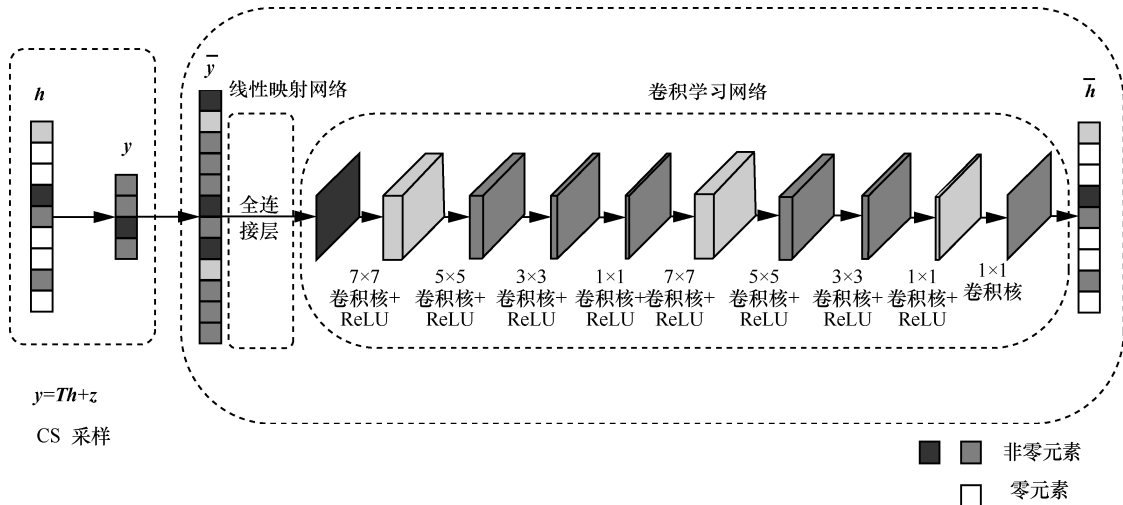


图 4 ConCSNet 结构

得初始的重构信道。线性映射过程得到的信道信息 $\hat{\mathbf{h}}$ 为近似解，其对应的线性映射矩阵为 $\mathbf{\Omega}^f$ ，并使 $\|\bar{\mathbf{h}} - \mathbf{\Omega}^f \bar{\mathbf{y}}\|_2^2$ 的误差最小。假设训练集中包含 M 个训练样本，即 $\{(\bar{\mathbf{y}}_1, \bar{\mathbf{h}}_1), (\bar{\mathbf{y}}_2, \bar{\mathbf{h}}_2), \dots, (\bar{\mathbf{y}}_M, \bar{\mathbf{h}}_M)\}$ 。其中， $\bar{\mathbf{y}}_i \in \mathbb{C}^{3N_r N_t \times 1}$ 为接收信号的测量值， $\bar{\mathbf{h}}_i \in \mathbb{C}^{N_r N_t \times L \times 2}$ 为时域频率选择性衰落信道信息矩阵。对于该全连接层线性映射网络，其损失函数可以表达为

$$L(\{\mathbf{\Omega}^f\}) = \frac{1}{M} \sum_{i=1}^M \|\bar{\mathbf{h}}_i - F^f(\bar{\mathbf{y}}_i, \mathbf{\Omega}^f)\|_2^2 \quad (7)$$

其中， $F^f(\cdot)$ 表示线性映射，训练过程使用 Adam 方法进行训练。则该网络得到的信道 \mathbf{h} 的近似解为

$$\hat{\mathbf{h}}_i = F^f(\bar{\mathbf{y}}_i, \mathbf{\Omega}^f) \quad (8)$$

4.2 卷积学习网络

对于上述线性映射网络，可得到估计信道的近似解 $\hat{\mathbf{h}}_i$ ，为了得到高精度的信道估计值，需做进一步处理，即增加一组由 9 个卷积层组成的全卷积网络。相关描述如下：第 1 层和第 5 层均使用 7×7 的卷积核，均生成 64 个特征图；第 2 层和第 6 层均使用 5×5 的卷积核，均生成 32 个特征图；第 3 层和第 7 层均使用 3×3 的卷积核，均生成 16 个特征图；第 4 层和第 8 层均使用 1×1 的卷积核，均生成 2 个特征图；第 9 层使用 1×1 的卷积核，生成 2 个特征图，并输出高精度的信道重构结果。除了第 9 层不需要激活函数 ReLU (rectified linear unit)，其余 8 层均使用 ReLU。整个网络使用全 1 填充，以保证所有层中的特征图的大小保持不变。将式(7)求得的全连接层参数 $\mathbf{\Omega}^f$ 作为卷积学习网络训练的初始值，并使用 Adam 方法更新线性映射网络中的参数 $\mathbf{\Omega}^f$ 和卷积学习网络的参数 $\mathbf{\Omega}^c$ 。该网络训练过程使用均方误差 (MSE, mean squared error) 作为损失函数，即

$$L(\{\mathbf{\Omega}^f, \mathbf{\Omega}^c\}) = \frac{1}{M} \sum_{i=1}^M \|\bar{\mathbf{h}}_i - F^c(F^f(\bar{\mathbf{y}}_i, \mathbf{\Omega}^f), \mathbf{\Omega}^c)\|_2^2 \quad (9)$$

则该网络得到的信道 \mathbf{h} 的精确解为

$$\bar{\mathbf{h}}_i^* = F^c(F^f(\bar{\mathbf{y}}_i, \mathbf{\Omega}^f), \mathbf{\Omega}^c) \quad (10)$$

然后，合并数据 $\bar{\mathbf{h}}_i^* \in \mathbb{C}^{N_r N_t \times L \times 2}$ 的实部和虚部，并进一步转换为复数信道矩阵 $\mathbf{h}_i^* \in \mathbb{C}^{N_r N_t \times L \times 1}$ 。

5 仿真与实验结果分析

针对 FDD 大规模 MIMO 下行链路系统，本文

将进一步验证所提出的基于深度学习的压缩感知稀疏信道估计 ConCSNet 算法的性能。该仿真系统发射端和接收端的天线数分别为 16 和 4，OFDM 总子载波数为 1 024；每一径频率选择性衰落信道的长度和稀疏度分别为 128 和 9；导频数为 64，并且所有导频都以块状的方式随机放置。本文采用 LTE-Advanced 信道模型^[17]，主要包含 3 种应用场景：扩展行人 (EPA, extended pedestrian A)、扩展车辆 (EVA, extended vehicular A) 和扩展典型城市 (ETU, extended typical urban) 模型。本文中主要考虑 EVA 无线通信环境，其主要参数如表 1 所示。

表 1 大规模 MIMO 系统参数

参数	值
时延/ns	0, 30, 150, 310, 370, 710, 1 090, 1 730, 2 510
功率/dB	0, -1.5, -1.4, -3.6, -0.6, -9.1, -7.0, -12.0, -16.9
信道衰落模型	瑞利衰落信道
多普勒频移/Hz	50
信道抽头数	9
天线配置	16×4
导频数	30
带宽/MHz	20
载波频率/GHz	2

5.1 评估标准

为了进一步客观评估所提出 ConCSNet 深度学习信道估计算法和其他重构算法的性能，本文采用均方误差 (MSE, mean square error) 和峰值信噪比 (PSNR, peak signal-to-noise ratio) 作为评价指标进行分析。

MSE 用来衡量重构值与真实值之间的差距。MSE 越小，说明重构性能越好。MSE 的表达式为

$$\mathcal{E} = \frac{1}{N_E} \sum_{n=0}^{N_E} \|\mathbf{h} - \mathbf{h}_n^*\|_2^2 \quad (11)$$

其中， N_E 为仿真次数，本文取值为 20。

PSNR 提供了一个衡量信号失真或是噪声水平的客观标准。通常 PSNR 越大，则说明信号重构失真度越小。其定义为

$$\text{PSNR} = 10 \lg \frac{63^2}{\frac{1}{N_E} \sum_{n=0}^{N_E} \|\mathbf{h} - \mathbf{h}_n^*\|_2^2} \quad (12)$$

5.2 ConCSNet 训练参数配置及细节

所提 ConCSNet 的训练过程包括以下 2 个步骤。

首先, 训练线性映射网络 $F^f(\cdot)$, 学习率为 0.001, 动量因子为 0.95; $F^f(\cdot)$ 训练完成后, 对整个网络进行训练, 此时改用较小的学习率 0.000 1, 也使用 Adam 方法进行训练, 其动量因子为 0.99。其次, 采集 204 800 个样本作为总数据集, 随机打乱后, 依次取 128 000、38 400 和 38 400 个样本分别作为训练集、验证集和测试集。其中, 训练集用于模型训练, 验证集用于估计模型的训练水平, 测试集用于评估模型最终的性能。批量大小是 128, 学习率衰减因子为 0.96, 学习率的衰减周期为 100。本文使用 Tensorflow 框架实现该网络, 并使用 Intel Core i5-4200H CPU 在 2.8 GHz 下对其进行训练。

5.3 实验结果

本节将所提 ConCSNet 与已有算法进行比较, 对比算法分别为 LS^[6]、Orale LS、OMP^[9]、SAMP^[11]、CoSaMP^[14]、gOMP^[15]和 ReconNet^[16]。其中, LS 为直接线性重构算法, Orale LS 为已知全部索引集的精确重构, OMP、SAMP、CoSaMP 和 gOMP 算法为压缩感知迭代重构算法, ReconNet 和 ConCSNet 为基于深度学习的重构算法。

在信噪比为 0~30 dB 的条件下, LS、Orale LS、OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet 的 MSE 性能如图 5 所示。实验结果表明, SAMP 在低信噪比下重构性能较差, 而在较高信噪比下重构性能优于 CoSaMP。这是因为 SAMP 阈值参数的确定直接与信道重构的精度相关, 阈值参数设置太小则容易引入更多索引集, 在后续的残差比较过程中步长不断扩大而无法准确估计稀疏度, 导致在低信噪比下的重建过程中容易出现混乱, 信道估计的精度较差。gOMP 随着信噪比的增加逐渐逼近 ReconNet 的重构性能。以深度学习为代表的 ConCSNet 和 ReconNet 重构算法, 在各信噪比下的重构性能均优于基于传统贪婪算法的 CS 重构算法 (OMP、SAMP、CoSaMP、gOMP)。当信噪比为 15 dB 时, ReconNet 的 MSE 比 gOMP 少 2×10^{-4} dB, 而 ConCSNet 的 MSE 比 gOMP 少 4×10^{-4} dB。这是因为基于深度学习的算法能够很好地根据大规模的数据集学习到重构信号潜在的特征量, 并通过非线性映射完成重构过程。所提 ConCSNet 由于优化了网络端输入量的信息、采用初始线性映射网络和进一步优化的卷积学习网络进行信号重构, 重构性能相比 ReconNet 得到了进一步改善。




图 5 不同信噪比下, 各算法的 MSE 性能比较

图 6 和表 2 分别给出了 LS、Orale LS、OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet 算法在不同采样率下的 MSE 性能, 其中信噪比为 15 dB, 并定义采样率为导频数与信道长度的比值。

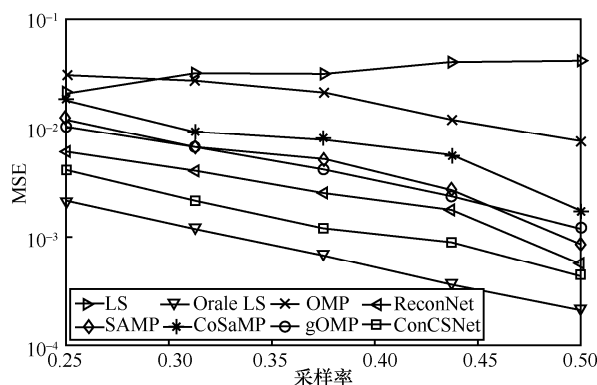


图 6 不同采样率下, 不同算法的 MSE 性能比较

实验结果表明, 采样率的增加对各算法的重构性能都能得到改善。当采样率为 0.3 时, gOMP 的性能劣于 SAMP。当采样率为 0.375 时, ReconNet 的 MSE 比 gOMP 少 1.1×10^{-3} dB, ConCSNet 的 MSE 比 ReconNet 少 0.001 3 dB, 而 PSNR 性能领先 3.19 dB。进一步地, 当采样率为 0.25~0.5 时, 基于传统贪婪算法的压缩感知重构算法 (SAMP、CoSaMP 等) 的信道估计性能不稳定。这是因为此类贪婪算法是根据残差向量与感知矩阵之间相关性较大的一些分量, 逐步找到原始信号的支撑集, 并进一步重构原始信号。因此此类算法的特点是在满足 RIP 时, 可以对原始信号以一定的概率进行重构。当采样率取不同值时, 则会影响重构的概率, 因而出现波动和不稳定的现象。而基于深度学习的重构算法 ConCSNet 和 ReconNet 均能保持较好的性能, 且 ConCSNet 优于 ReconNet。

表 2 不同采样率时的性能对比

重构算法	采样率=0.25			采样率=0.375			采样率=0.50		
	MSE/dB	PSNR/dB	运算时间/s	MSE/dB	PSNR/dB	运算时间/s	MSE/dB	PSNR/dB	运算时间/s
LS	0.030 7	51.12	0.027	0.091 0	46.40	0.036	0.042 8	49.67	0.045
Orale LS	2.112×10^{-4}	72.74	0.021	1.081×10^{-4}	75.65	0.027	5.998×10^{-5}	78.21	0.026
OMP	0.131 5	44.80	0.254	0.026 4	51.77	0.255	0.004 7	59.27	0.259
SAMP	0.009 9	56.03	0.152	0.005 2	58.83	0.188	7.242×10^{-4}	67.39	0.192
CoSaMP	0.017 9	53.46	0.127	0.009 8	56.07	0.126	0.001 8	63.43	0.158
gOMP	0.012 8	54.91	0.131	0.003 6	60.42	0.145	0.001 2	65.20	0.148
ReconNet	0.006 2	58.02	0.042	0.002 5	62.01	0.049	6.506×10^{-4}	67.85	0.056
ConCSNet	0.004 1	59.86	0.055	0.001 2	65.20	0.061	4.513×10^{-4}	69.44	0.063

图 7 分别展示了 LS、Orale LS、OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet 在不同稀疏度下的 MSE 性能，其中信噪比为 10 dB，采样率为 0.5。实验结果表明，当稀疏度大于 6 时，SAMP 的性能逐渐优于 CoSaMP。在相同的稀疏比下，由于利用了信道稀疏性，基于 CS 的信道估计算法（OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet）比传统的线性算法 LS 具有更好的性能，说明压缩感知理论在稀疏信道估计的应用中不但能提高导频的利用率，而且能够进一步提高 FDD 大规模 MIMO 信道估计的精度。当稀疏度为 9 时，ReconNet 的 MSE 比 gOMP 少 1.6×10^{-3} dB，而 ConCSNet 的 MSE 比 ReconNet 少 0.000 8 dB。随着稀疏度的增加，信道包含的信息也越丰富，各算法的重构性能逐渐变差。针对 FDD 大规模 MIMO 下行链路系统稀疏信道估计，本文提出的 ConCSNet 在不同的稀疏度下均能保持良好的重构性能，并优于 ReconNet。

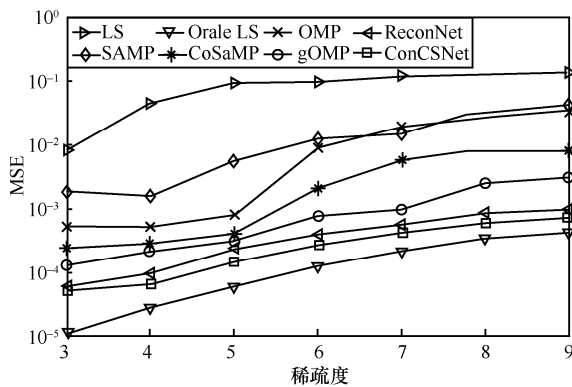


图 7 不同稀疏度下，不同算法的信道估计 MSE 性能比较

表 3 分别给出了 LS、Orale LS、OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet 在不同场景（EPA、EVA 和 ETU）时的 MSE 和 PSNR 性能。在不同场景下，本文提出的 ConCSNet 均优于其他算法，并且在 ETU 场景下，ConCSNet 的 MSE 性能优于 ReconNet 1.751×10^{-4} dB，而 PSNR 性能领先 0.88 dB。由此可见，本文提出的基于深度学习的 ConCSNet 适用于多场景环境。

此外，表 2 和表 3 均给出了在不同测试环境下的 LS、Orale LS、OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet 的运算时间，以反映各算法的时间复杂度。实验结果表明，基于深度学习的 ConCSNet 和 ReconNet 相比于传统迭代的 CS 重构算法，其重构速度提高 2~3 倍。由表 2 可知，本文提出的 ConCSNet 由于增加了卷积的层数，相比于 ReconNet，重构时间多 0.01~0.02 s。但是，相比于 OMP 等算法，多花费的时间占比较小，且进一步提高了重构性能。因而，本文提出的 ConCSNet 综合性能相比于其他算法仍然较优异，展现出较好的应用前景。

图 8 描述了 LS、OMP、SAMP、CoSaMP、gOMP、ReconNet 和 ConCSNet 在信噪比为 0~30 dB 时的系统误比特率性能。误比特率是衡量信道估计算法对系统整体性能影响的宏观指标。仿真结果表明，随着信噪比的增大，各算法的误比特率性能下降，说明信噪比越高，信道重构误比特率性能越好。当信噪比一致时，与其他算法相比，本文提出的 ConCSNet 算法具有更好的性能。当信噪比为 20 dB 时，系统的误比特率达到 4.34×10^{-4} 。

表 3 不同场景时的性能对比

重构算法	EPA			EVA			ETU		
	MSE/dB	PSNR/dB	时间/s	MSE/dB	PSNR/dB	时间/s	MSE/dB	PSNR/dB	时间/s
LS	0.122 7	45.10	0.026	0.129 8	44.85	0.032	0.136 9	44.62	0.031
Orale_LS	2.216×10^{-4}	72.53	0.025	4.514×10^{-5}	79.44	0.024	4.516×10^{-5}	79.44	0.026
OMP	1.9369×10^{-2}	53.11	0.253	3.236×10^{-2}	50.89	0.258	3.691×10^{-2}	50.31	0.256
SAMP	1.552×10^{-2}	54.07	0.161	4.776×10^{-2}	49.20	0.164	4.327×10^{-2}	49.62	0.167
CoSaMP	5.851×10^{-3}	58.31	0.129	1.115×10^{-2}	55.51	0.332	9.129×10^{-3}	56.38	0.142
gOMP	1.128×10^{-3}	65.46	0.147	3.762×10^{-3}	60.23	0.158	3.242×10^{-3}	60.88	0.162
ReconNet	6.071×10^{-4}	68.15	0.052	8.921×10^{-4}	66.48	0.055	9.621×10^{-4}	66.15	0.058
ConCSNet	4.561×10^{-4}	69.39	0.061	7.513×10^{-4}	67.23	0.066	7.873×10^{-4}	67.03	0.069




图 8 不同信噪比下, 不同算法的信道估计误比特率性能比较

6 结束语

针对 FDD 大规模 MIMO 下行链路系统模型, 本文提出了一种新型的基于深度学习的压缩感知稀疏信道估计算法 ConCSNet。该算法在不需要稀疏度的情况下, 通过数据驱动的方式, 采用卷积神经网络学习从测量向量 \mathbf{y} 到信号 \mathbf{h} 的逆变换, 从而解决 CS 框架下的欠定最优化问题, 并实现对原始信道的重构。实验结果表明, 与传统的基于 CS 的信道估计算法相比, 本文提出的 ConCSNet 的性能提升明显, 且重构速度能提高 2~3 倍。该算法能够解决传统的基于迭代的 CS 大规模 MIMO 信道估计算法计算时间长、重构效果不佳的问题。

参考文献:

[1] PAPAFAEIROPOULOS A, KOURTESSIS P, RENZO M D, et al. Performance analysis of cell-free massive MIMO systems: astochastic

geometry approach[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4):3523-3537.

[2] LU L, LI G Y, SWINDLEHURST A L, et al. An overview of massive MIMO: benefits and challenges[J]. IEEE Journal of Selected Topics in Signal Processing, 2014, 8(5):742-758.

[3] 彭章友, 王森, 李林霄, 等. 基于波束选择的毫米波 massive MIMO 预编码算法研究[J]. 电子测量技术, 2016, 39(7):183-189.

PENG Z Y, WANG M, LI L X, et al. Research about a low dimensional beamspace precoder method in mm-w massive MU-MIMO systems[J]. Electronic Measurement Technology, 2016, 39(7):183-189.

[4] 戈立军, 郭徽, 李月, 等. 大规模 MIMO 系统稀疏度自适应信道估计算法[J]. 通信学报, 2017, 38(12): 57-62.

GE L J, GUO H, LI Y, et al. Sparsity adaptive channel estimation algorithm based on compressive sensing for massive MIMO systems[J]. Journal on Communications, 2017, 38(12): 57-62.

[5] LIN X C, WU S, JIANG C X, et al. Estimation of broadband multiuser millimeter wave massive MIMO-OFDM channels by exploiting their sparse structure[J]. IEEE Transactions on Wireless Communications, 2018, 17(6): 3959-3973.

[6] RIADI A, BOULOUIRD M, HASSANI M M. Performance of massive-MIMO OFDM system with M-QAM modulation based on LS channel estimation[C]//2019 International Conference on Advanced Systems and Emergent Technologies. Piscataway: IEEE Press, 2019:74-78

[7] LI K, SONG X, AHMAD M O, et al. An improved multicell MMSE channel estimation in a massive MIMO system[J]. International Journal of Antennas and Propagation, 2014, 6(2):1-9.

[8] GAO Z, DAI L L, DAI W, et al. Structured compressive sensing-based spatio-temporal joint channel estimation for FDD massive MIMO[J]. IEEE Transactions on Communications, 2016, 64(2): 601-617.

[9] WU X D, YANG G H, HOU F, et al. Low-complexity downlink channel estimation for millimeter-wave FDD massive MIMO systems[J]. IEEE Wireless Communications Letters, 2019, 8(4): 1103-1107.

[10] RAO X B, LAU V K N. Distributed compressive CSIT estimation and feedback for FDD multi-user massive MIMO systems[J]. IEEE Trans-

actions on Signal Processing, 2014, 62(12): 3261-3271.

- [11] ZHANG Y, VENKATESAN R, DOBRE O A, et al. Novel compressed sensing-based channel estimation algorithm and near-optimal pilot placement scheme[J]. IEEE Transactions on Wireless Communications, 2016, 15(4):2590-2603.
- [12] WANG P, ZHANG H, YANG L. Estimation of block sparse channels with conjugate gradient SAMP in massive MIMO systems[C]//2019 4th International Conference on Electromechanical Control Technology and Transportation. Piscataway: IEEE Press, 2019:33-38.
- [13] CANDÈS E J, WAKIN M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [14] GUI G, WAN Q, PENG W, et al. Sparse multipath channel estimation using compressive sampling matching pursuit algorithm[C]//IEEE Vehicular Technology Society Asia Pacific Wireless Communication Symposium. Piscataway: IEEE Press, 2010: 19-22.
- [15] 高飞, 彭云柯, 薛艳明. 基于 GOMP 及其改进的 OFDM 系统稀疏信道估计[J]. 北京理工大学学报, 2016, 36(9): 956-959.
- GAO F, PENG Y K, XUE Y M. Generalized orthogonal matching pursuit and improved algorithms for compressive sensing based sparse channel estimation in OFDM systems[J]. Transactions of Beijing Institute of Technology, 2016, 36(9): 956-959.
- [16] KULKARNI K, LOHIT S, TURAGA P, et al. ReconNet: non-iterative reconstruction of images from compressively sensed measurements[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016:449-458.
- [17] GHOSH A, RATASUK R, MONDAL B, et al. LTE-advanced: next-generation wireless broadband technology [J]. IEEE Wireless Communications, 2010, 17(3):10-22.

[作者简介]



黄源 (1993-), 男, 湖北黄石人, 合肥工业大学博士生, 主要研究方向为大规模 MIMO 无线信道估计和压缩感知技术。



何怡刚 (1966-), 男, 湖南邵阳人, 博士, 合肥工业大学教授、博士生导师, 主要研究方向为模拟和混合集成电路设计、测试与故障诊断、智能电网技术、射频识别技术、虚拟仪器和智能信号处理。

吴裕庭 (1992-), 男, 安徽铜陵人, 合肥工业大学博士生, 主要研究方向为无线信道建模。

程彤彤 (1993-), 男, 安徽淮南人, 合肥工业大学博士生, 主要研究方向为无线信道预编码技术。

隋永波 (1990-), 男, 山东潍坊人, 合肥工业大学博士生, 主要研究方向为无线信道预测技术。

宁暑光 (1991-), 男, 安徽阜阳人, 合肥工业大学博士生, 主要研究方向为电力设备故障诊断与定位。