

基于变分学习的 NOMA 上行信道估计方法

袁泉 王行建 刘志鹏

中国电子科技集团有限公司电子科学研究院 北京 100041

摘 要: 随着移动通信技术的飞速发展, 未来的 6G 网络将继续承接 5G 万物互联的使命, 在有限的频谱资源下容纳更多的智能终端进行通信。传统的正交多址接入 (OMA) 技术将不足以支持这种大连接需求, 非正交多址接入 (NOMA) 应运而生。然而 NOMA 技术在支持大连接的同时也带来了新的挑战。大多数 NOMA 技术是需要良好信道估计的。目前已有的 LS、LMMSE 以及 AMP 等信道估计方法需要已知信道分布作为先验, 然而这些信息有时又难以获得。为弥补这方面的不足, 本文提出了一种基于变分学习的 NOMA 上行信道估计方法, 通过神经网络训练的方式获取信道状态, 使得该方法可以在不确定信道分布的情况下实现信道估计, 信道估计的性能优于 AMP 方法。

关键词: 万物互联、正交多址接入、非正交多址接入、信道估计、变分学习;

1. 引言

近几年来通信技术的发展给人们的生活带来了翻天覆地的变化, 从 2G 简单的移动话音业务, 到后来 4G、5G 的数据业务。移动通信已逐渐深入人们生活的方方面面, 丰富了生活, 造福了社会。通信技术将在未来为人们开启一个万物互联, 万物智联的时代。但与此同时也带来了新的技术挑战。为了实现万物互联, 需要在有限的频谱资源下接入更多的用户。传统的正交多址接入技术将难以满足未来大连接的需求, 非正交多址接入技术成为业界关注的下一个新空白技术。该技术允许在同一个时频资源内同时接入多个不同用户, 相比正交多址接入技术成倍的增加了同时可接入用户数量。

新技术带给我们收益的同时也带来了新的技术挑战。非正交多址接入技术要求更加精确的信道估计。较大信道估计误差会加剧同一个时频资源内用户间的干扰, 使得 NOMA 体制下的通信质量严重下降。目前解决信道估计问题的方法有 LS、LMMSE 以及 AMP 等信道估计方法^{[1][2]}, 此类方法需要已知的信道分布作为先验。但信道分布常常又难以获得。为了解决此类,

学术界又提出了基于深度学习的信道估计方法。将收集到的测量数据作为神经网络的训练数据, 以训练神经网络的方式在未知信道分布的情况下设计信道估计算法。但目前所采用的深度学习方法多基于数据驱动, 依赖大量的训练样本。另外数据驱动的神经网络对训练集和实际数据统计分布的匹配程度要求也十分苛刻。当训练集与实际数据统计分布不一致时会出现明显的性能下降, 甚至无法完成信道估计。

为了解决以上问题, 本文提出了一种基于变分学习的 NOMA 上行信道估计方法。该方法延续了深度学习的基本思路, 信道分布通过训练神经网络的方式获得。同时神经网络的架构是基于变分推断理论设计的。而非完全的黑箱网络, 将算法与神经网络相结合。该种神经网络被称为数据模型双驱动模型。

2. NOMA 上行信道估计的系统模型

考虑单小区内上行大规模接入的场景, 假设小区内共有 J 个用户, 以授权接入的方式上行接入一个单天线基站。所有的 J 个用户共享 K 个彼此正交的频率资源。假设同一时隙下各用户是否为活跃是相互独

立的, 定义变量 $\alpha_j \in \{0,1\}$ 表示用户 j 的活跃状态。

$\alpha_j=1$ 时表示该用户为活跃用户, $\alpha_j=0$ 时表示为非活跃用户。则基站侧的接收信号可以表示为:

$$\mathbf{y} = \sum_{j=1}^J \alpha_j s_j h_j + \mathbf{w} \quad (1-1)$$

其中 s_j 为用户 j 的导频序列, h_j 为用户 j 的信道增益。本文假设每个用户各频率资源上的 h_j 相同。

$\mathbf{w} \in \mathbb{C}^K$ 表示服从均值为 0, 方差为 σ_w^2 高斯分布的复高斯白噪声。

将式 1-1 写为矩阵形式可以表示为

$$\mathbf{y} = \mathbf{S}\mathbf{H} + \mathbf{w} \quad (1-2)$$

其中 $\mathbf{S}$ 为导频矩阵, 矩阵的每一列对应为各用户的导频序列。令 $\mathbf{a} = [\alpha_1, \alpha_2, \dots, \alpha_J]$, $\mathbf{h} = [h_1, h_2, \dots, h_J]$, 则有 $\mathbf{H} = \text{diag}(\mathbf{a})\mathbf{h}$ 。

3. 基于变分学习的上行信道估计方法

对于式 1-2 线性模型下的信道估计问题, 可通过迭代计算以下两式来解决。

$$\frac{\text{Proj}_{\Phi} \left[\int p(y_l | \mathbf{h}) \prod_{m \in F(k)} I_{m \rightarrow k}^l(h_m) d\mathbf{h}_{\setminus l} \right]}{I_{j \rightarrow k}^l(h_j)} \quad (1-3)$$

$$I_{j \rightarrow k}^{l+}(h_j) \propto \frac{\text{Proj}_{\Phi} \left[p(h_j) \prod_k I_{j \leftarrow k}^{l+}(h_j) \right]}{I_{j \leftarrow k}^{l+}(h_j)} \quad (1-4)$$

区别于传统的迭代计算, 本文提出了一种用于信道估计的数据模型双驱动网络 MDVL-NET。网络的一次前向传播计算过程等同于对以上两式的迭代计算。网络的一个计算单元如图 3 所示, 对应算法的一次迭代。




图 3 MDVL-NET 的一个计算单元

图中的计算顺序为自左至右, 红色部分包含两个子神经网络。每个神经网络包含两个隐层。神经网络的输出继续作为下一个计算单元最左侧绿色模块的输入。

一个计算单元的计算过程就是上述变分推断的一次迭代过程。n 计算单元的级联就是变分推断算法的 n 次迭代。基于数据模型双驱动的信道估计神经网络 MDVL-NET 相当于变分推断的计算展开。将不易确定的参数通过神经网络训练的方式解决。

4. 仿真分析

本节通过数值仿真, 对所提出的基于变分学习的上行信道估计算法进行性能评估。

图 4 给出了不同导频长度下, 不同信道估计算法的性能对比, 设定用户数为 6。从仿真结果可以看出本文所提出的 MDVL-NET 相比其他不同类型的黑箱神经网络对不同导频长度的信道估计有更优的稳定性。虽然所有的信道估计方法在导频长度降低的情况下性能都会有所下降, 但是很明显 MDVL-NET 的信道估计均方误差增大的幅度最小。这也是数据模型双驱动网络相比于纯粹黑箱网络的性能优势。




图 4 用户数为 6 时不同导频长度下的信道估计性能对比

总结

本文提出了一种基于变分学习的上行信道估计方法 MDVL-NET。该方法对于信道估计过程中不需要未知先验信道参数的部分, 由变分推断理论进行人为设计。对于需要未知信道参数参与计算的部分通过训练 DNN 网络完成。仿真结果表明 MDVL-NET 在性能上由于 AMP 算法以及 DNN 和 LSTM 纯数据驱动网络。

参考文献

- [1] Liu L, Yu W. Massive Connectivity With Massive MIMO—Part I: Device Activity Detection and Channel Estimation[J]. IEEE Transactions on Signal Processing, 2018, 66(11):2933 – 2946.
- [2] Jiang S, Yuan X, Wang X, et al. Joint User Identification, Channel Estimation, and Signal Detection for Grant-Free NOMA[J]. IEEE Transactions on Wireless Communications, 2020, 19(10):6960 – 6976.
- [3] Ahn Y, Kim W, Shim B. Active User Detection and Channel Estimation for Massive Machine-Type Communication: Deep Learning Approach[J]. IEEE Internet of Things Journal, 2021:1 – 1.
- [4] Wu X, Zhang S, Yan J. A CNN Architecture for Learning Device Activity From MMV[J]. IEEE Communications Letters, 2021, 25(9):2933 – 2937.
- [5] Zhao T, Li F, Tian P. A Deep-Learning Method for Device Activity Detection in mMTC Under Imperfect CSI Based on Variational-Autoencoder[J]. IEEE Transactions on Vehicular Technology, 2020, 69(7):7981 – 7986.
- [6] Ye H, Li G Y, Juang B H. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems[J]. IEEE Wireless Communications Letters, 2018, 7(1):114 – 117.
- [7] Wei L, Lu S, Kamabe H, et al. User Identification and Channel Estimation by DNN-Based Decoder on Multiple-Access Channel[C]// GLOBECOM 2020 – 2020 IEEE Global Communications Conference. Taipei, Taiwan, 2020:1 – 6.
- [8] 戴维佳. mMTC非正交多址接入中的活跃用户检测和信道估计[D]. 中国科学技术大学, 2019.
- [9] Donoho D L, Maleki A, Montanari A. Message-passing algorithms for compressed sensing[J]. Proceedings of the National Academy of Sciences of the United States of America, 2009, 106(45):18914.

作者简介：袁泉(1991-)，男，汉，黑龙江省哈尔滨市，博士，工程师，研究方向：数字信号处理。