



# 利用信道学习获取超蜂窝网络休眠基站信道信息

邓瑞琛<sup>1,2\*</sup>, 姜之源<sup>1,2</sup>, 刘景初<sup>1,2</sup>, 周盛<sup>1,2</sup>, 牛志升<sup>1,2</sup>

1. 清华大学电子工程系, 北京 100084

2. 清华大学信息科学与技术国家实验室(筹), 北京 100084

\* 通信作者. E-mail: drc13@mails.tsinghua.edu.cn

收稿日期: 2017-03-21; 接受日期: 2017-04-26; 网络出版日期: 2017-10-09

国家重点基础研究发展计划(973)(批准号: 2012CB316000)和国家自然科学基金(批准号: 61461136004, 61571265, 91638204)资助项目

**摘要** 信道信息作为刻画无线信道状态的重要信息, 在新一代基于大规模多天线技术的系统中扮演了极其重要的角色. 而在超蜂窝架构中, 业务基站需要动态休眠以提高系统的能效. 当基站休眠时, 传统的基于导频的信道信息获取方法无法使用. 本文针对这一问题提出了基于机器学习的信道信息获取策略, 通过活跃基站多维度的信道信息来推测休眠基站的信道信息. 我们以用户选择业务基站为例, 利用人工神经网络架构设计了一套具体的信道学习解决方案. 与位置辅助信道估计方案不同, 该方案采用控制基站侧的信道信息作为输入, 避免了用户定位过程中存在的一些问题. 通过基于随机地理散射物的信道模型, 我们对该方案进行了仿真验证, 发现其预测准确率优于  $K$  近邻等其他预测算法, 性能接近于已知准确用户地理信息的位置辅助估计方案.

**关键词** 超蜂窝网络, 信道信息, 人工神经网络, 信道学习, 大规模多天线

## 1 背景介绍

随着移动业务要求的激增, 未来蜂窝网络演进的一大特点是网络的密集化<sup>[1]</sup>. 网络密集化的一个趋势是减小蜂窝尺寸, 提高频谱在空间的复用率. 但这种方法也带来了小区域干扰和能耗剧增等问题. 解决这些问题的一个可行方案是采用超蜂窝网络架构<sup>[2]</sup>. 这种架构将控制覆盖与业务覆盖适度分离, 使得业务基站能根据负载轻重进行动态休眠, 从而使网络得到全局上的优化以提高能量效率和频谱效率. 网络密集化的另一个趋势是部署大规模多天线系统<sup>[3]</sup>. 随着基站天线数的增多, 网络的空域自由度得到提高, 使得基站能够通过空分复用的方式支持多个用户同时同频进行数据传输. 当基站天线数增加到一定程度时, 小区域用户干扰和热噪声将得到消除, 并且采用简单的线性预编码方案即可接近理论性能上界<sup>[4]</sup>.

**引用格式:** 邓瑞琛, 姜之源, 刘景初, 等. 利用信道学习获取超蜂窝网络休眠基站的信道信息. 中国科学: 信息科学, 2017, 47: 1583–1591, doi: 10.1360/N112017-00039  
Deng R C, Jiang Z Y, Liu J C, et al. CSI acquisition for sleeping cells in hyper cellular networks based on channel learning (in Chinese). Sci Sin Inform, 2017, 47: 1583–1591, doi: 10.1360/N112017-00039

为了实现网络密集化的性能增益, 用户到基站的信道信息极为重要. 无论是物理层的预编码矩阵的设计还是网络层的用户关联操作, 都需要依据信道信息. 目前基站对用户信道的估计通常采用基于导频的信道估计方法, 但这种方法在部署大规模天线的超蜂窝网络中, 面临着两个问题. 第一个问题是网络对非互易信道的即时信道信息的估计开销非常大. 具体来说, 对于上行信道, 由用户端发送导频序列, 基站根据接收解调后的信号可以估计信道状况. 而对于下行信道, 分为两种情形. 如果网络工作在经过射频链路上下行校准后的时分双工和全双工模式, 满足信道互易性, 这时我们只需要估计上行信道即可获取下行信道. 而对于频分双工模式和未校准的时分双工模式来说, 信道不存在互易性, 只能通过发送下行导频的办法由用户来估计并反馈信道, 所消耗的时频资源与基站天线数成正比, 信道估计开销十分大. 我们在之前的工作中对该问题进行了充分的研究, 给出了优化后的导频设计和信道反馈方案<sup>[5~7]</sup>.

另一个问题是网络对休眠业务基站的信道估计. 由于休眠基站无法发送或者接收信号, 因此这类基站的信道获取无法采用导频估计的方法, 需要间接的方法来进行估计. 本文所考虑的信道信息属于统计信道信息, 是对即时信道信息在一定时间内 (分钟级到小时级) 进行平均所得, 其时间尺度取决于业务基站的休眠唤醒频率.

通常来说, 统计信道信息与用户地理位置密切相关. 将两者的函数关系建立成地理信道数据库, 可以根据用户的地理位置来推断信道状况<sup>[8]</sup>. 文献<sup>[9]</sup>进一步地将地理信道数据库建模为 Gauss 随机场, 通过样本学习的方法来得到整个网络的地理信道映射关系. 然而, 获取准确的用户地理位置信息是十分困难的. 通过网络端测量到达时间和到达角面临着非直射路径的干扰. 而用户端自身的定位如 GPS 则需要持续消耗设备电量并且在室内无法使用. 这些因素导致了位置辅助的信道估计方案只能在特定场景下使用.

在本文中, 我们提出了信道学习方案来解决休眠基站信道获取的问题. 这套方案也是基于用户信道与地理位置之间的关联, 但与位置辅助的信道估计方案不同, 它将用户位置信息作为隐含参数, 直接研究可见信道 (活跃业务基站和控制基站) 和不可见信道 (休眠业务基站) 之间的映射关系. 这种映射关系是通过监督式机器学习的方法进行拟合得到. 所提的信道学习方案不仅能用于估计休眠业务基站信道信息, 还能推广拓展到其他领域, 例如 Device-to-Device (D2D) 网络中的设备配对以及端到端网络的操作, 后面将有进一步的阐述.

## 2 信道学习框架

信道学习是通过可见的信道信息来推测不可见信道信息的过程<sup>[10]</sup>. 在超蜂窝网络中, 某个用户可能关联的基站集合记为  $\mathbb{A}$ , 其中处于休眠状态不可见的基站组成子集  $\mathbb{U}$ , 其他可见信道信息的基站组成子集  $\mathbb{O}$ . 记用户到基站子集  $\mathbb{O}$  的天线阵列的信道向量为  $\mathbf{h}_o$ , 用户到基站子集  $\mathbb{U}$  的天线阵列的信道为  $\mathbf{h}_u$ . 用户需要根据信道指标函数  $\mathbf{m} = m(\mathbf{h}_u)$  从休眠业务基站信道得到某些信道指标 (例如得到最佳信道对应的业务基站序号). 信道学习用于拟合从控制基站信道到该信道指标的映射函数

$$\begin{aligned} f: \mathbb{C}^{|\mathbb{O}|} &\rightarrow \mathbb{M}, \\ \mathbf{h}_o &\mapsto \mathbf{m}, \end{aligned} \quad (1)$$

其中  $\mathbb{C}$  是复数集,  $|\cdot|$  表示集合的势,  $\mathbb{M}$  是  $m(\cdot)$  的上域. 只要映射函数  $f$  存在, 就可以使用监督式机器学习来拟合它. 具体来说, 在基站活跃时通过基于导频的信道估计手段获得训练样本, 然后进行离线的监督式学习, 当基站休眠时再根据活跃基站的信道来预测信道指标. 由于监督式机器学习本身的

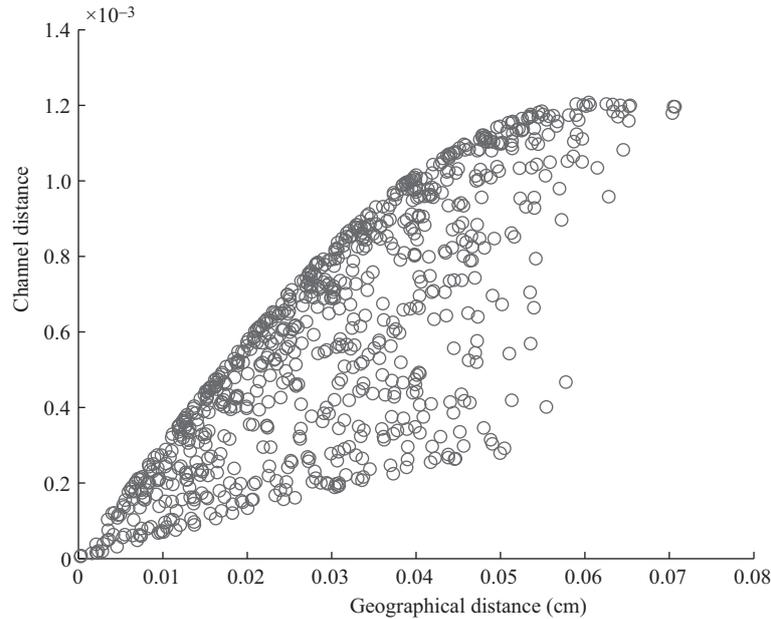


图 1 不同用户地理距离与信道响应的欧氏距离的关系. 均匀线性阵列, 100 天线单元, 10 散射体, Rice 因子设为 10 dB

Figure 1 Channel distance v.s. geographical distance between two users. ULA array with 100 antenna elements and 10 scatterers. Rice factor is set to 10 dB

特点, 信道学习的实现复杂度主要在于离线的函数学习拟合过程, 在线预测的复杂度较低, 相对于导频估计的方法更节省资源.

一般来说, 函数  $f$  的存在无法得到保证. 例如, 在一个理想的只有直射径的传播环境中, 均匀线性天线阵列两侧对称位置的用户具有相同的信道, 此时映射  $f$  存在一对多的情况, 函数  $f$  不存在. 但在实际蜂窝网络中, 由于一个小区通常被划分为几个扇区, 这种几何对称性常常是不存在的. 在下面的定理中我们说明在某些符合实际的条件下映射函数是存在的.

**定理 1** 如果用户和基站天线之间的信道是用户地理位置的函数  $\mathbf{x}$ , 即  $\mathbf{h}_o = g_o(\mathbf{x})$ ,  $\mathbf{h}_u = g_u(\mathbf{x})$ , 并且从用户地理位置到可见信道的映射函数  $g_o(\cdot)$  是可逆的, 则存在映射函数  $f$  如式 (1).

**证明** 记  $g_o(\cdot)$  的逆函数是  $g_o^{-1}(\cdot)$ , 则用户位置可以从可见信道推出, 即  $\mathbf{x} = g_o^{-1}(\mathbf{h}_o)$ , 同时不可见信道为  $\mathbf{h}_u = (g_u g_o^{-1})(\mathbf{h}_o)$ . 从而得出不可见的信道指标为  $\mathbf{m} = (m g_u g_o^{-1})(\mathbf{h}_o) = f(\mathbf{h}_o)$ .

我们注意到上述定理依赖于两个假设: 用户位置唯一确定信道, 函数  $g_o(\cdot)$  的可逆性. 下面我们针对这两个假设分别展开讨论.

(1) 用户位置是否决定了信道响应? 无线衰落信道响应可以分解成 3 部分: 路径损耗、大尺度衰落和小尺度衰落. 前两者一般被认为与地理位置相关且具有长时不变的特性. 小尺度衰落随着多径成分的变化和散射体的移动会有起伏, 但经过长时间观测平均的作用下趋向于稳定. 因此, 我们所考虑的信道状况实际上是用户地理位置的函数.

(2) 函数  $g_o(\cdot)$  是否可逆? 在大规模天线富散射体环境下, 不同用户间的信道响应是渐进正交的, 因此在这种情况下  $g_o(\cdot)$  是从用户位置到信道的一一映射, 从而是可逆的. 需要注意的是, 即使在有限天线数的情况下,  $g_o(\cdot)$  的可逆性同样可以观测到. 图 1 显示了几何随机信道模型 (GSCM) 生成的一个数值例子. 我们在半径为 700 m 的半圆形小区中心放置均匀线性天线阵, 然后随机撒布 2 个用户和

20 个散射体, 最后计算得到这两个用户到天线阵列的信道响应. 我们用信道距离表示两个信道向量之间的欧氏距离, 并绘出两个用户之间的信道距离与地理距离之间的关系图. 可以发现, 随着用户间地理距离的增加, 信道距离一直受限在两根从原点出发的射线区域内, 说明从用户地理位置到可见信道的函数  $g_o(\cdot)$  是可逆的.

### 3 信道学习的应用

信道学习作为灵活可变的统计信道信息估计方法, 不仅能作为导频估计方法的补充, 还能在导频开销巨大甚至无法发送导频的场景下作为替代. 下面针对几种典型信道学习的应用场景进行讨论.

#### 3.1 业务基站选择

与传统网络架构下用户根据信号强度选择基站的方式不同, 在超蜂窝网络中, 当用户发起数据连接请求时, 控制基站根据基站休眠情况、负载轻重和用户信道信息、需求差异为用户动态地分配业务基站以完成数据传输任务, 从而实现负载均衡和动态休眠, 达到整个网络在能效和谱效上的全局优化. 这种处理方式使得基站选择算法对用户来说是透明的, 用户只需要上报其测量得到的信道信息给基站, 避免了存储和计算的瓶颈. 然而, 由于休眠业务基站无法发送导频, 用户到这些基站的信道状态无法直接获取.

采用信道学习方法, 问题迎刃而解. 我们在维持全网覆盖的控制基站一侧布置大规模天线阵列, 将这些天线的观测结果作为可见信道, 从而推测出处于这一覆盖下的业务基站信道. 具体来说, 需要通信的用户发送探测信号给控制基站, 而控制基站根据观测得到的信道  $\mathbf{h}_0$ , 通过信道学习得到的映射函数  $f$  得到为用户所选择的最佳基站. 本文考虑最优信道关联原则, 即为用户分配具有最高信噪比的业务基站. 将信道状况结合负载均衡原则进行选择作为我们的未来工作.

#### 3.2 D2D 通信配对

D2D 通信是将两个用户终端设备直接配对进行数据传输. 它作为蜂窝网络通信的一种补充方法, 近年来得到了广泛的关注和研究. 如何选择配对设备则是 D2D 通信中的一个核心问题. 传统解决方法包括设备发送信道探测信号, 以及由网络提供终端设备的位置信息来估计信道. 前者对设备电池寿命提出了极大挑战, 而后者常常面临定位不准确的影响<sup>[11]</sup>.

信道学习为解决这个问题提供了新的维度. 和前一个应用场景类似, 假设控制基站部署大规模天线阵列. 考虑两个地理坐标分别为  $\mathbf{x}_1 \in \mathbb{R}^3$  和  $\mathbf{x}_2 \in \mathbb{R}^3$  的终端设备, 信道指标定义为两者之间信道的信噪比是否超过满足 D2D 通信需求的阈值. 将两个终端设备视为一个虚拟设备, 其虚拟地理坐标为  $\mathbf{x} = \{\mathbf{x}_1, \mathbf{x}_2\} \in \mathbb{R}^6$ , 并且其到控制基站的信道向量为原来两设备信道向量的级联. 这样, 利用信道学习的方法, 通过观测可见信道——该虚拟设备到控制基站的信道向量, 来获取信道指标——该虚拟设备内部的两设备之间信道质量. 将信道学习应用于设备配对过程中, 不仅避免了用户定位过程, 同时也使得配对的决策过程得到控制基站中心化的处理, 以减小 D2D 通信和蜂窝网络之间的干扰, 实现整个网络的频谱优化.

### 3.3 其他潜在应用

随着用户对通信速率不断增长的需求,终端设备配置多天线成为了一种趋势.在这种场景下,应用信道学习方法,信道指标函数可以定义为单个用户信道矩阵的一些特征,例如秩或者特征值分布,从而为基站端调度用户、选择调制编码方案提供参考.

信道学习方法还可以推广到更一般的映射目标.一个直接的应用是利用基站接收的信号进行用户定位.相对于传统的基站三角定位方法,使用信道学习能极大地减少非直射径的影响.进一步地,经过收发机的适当布置,这种方法还可以用于检测与信道相关的目标物体的状态,例如建筑中门的开闭,水箱中水的高度等,具有广阔的应用前景.需要注意的是,信道学习要求电磁传播环境在一段时间内保持相对稳定,当传播环境有较大变化时,需要对信道进行再学习以拟合新的信道指标映射函数.在散射环境变化较慢的网络中,映射函数  $f$  相对稳定,再学习的频率可以设定为较低值,信道学习所消耗网络资源较少.

## 4 基于人工神经网络的信道学习算法

我们以超蜂窝网络中业务基站的选择问题为例进行研究,用人工神经网络来具体实现信道学习算法.信道学习属于监督式机器学习方法,计算量主要集中于学习阶段.对于所讨论基站选择问题,在几十到几百的基站天线数场景下,神经网络规模较小,对于计算能力要求不高,并且未来随着边缘云的普及应用,神经网络参数训练将变得更容易实现.在信道学习的预测阶段,基站只需要将用户信道信息代入神经网络进行矩阵运算,计算复杂度较低.假设控制基站天线数为  $M$ ,候选业务基站数为  $K$ ,用户样本数为  $N$ .整个算法的基本流程为:用户样本经过提取角度域信息、形成量化输入信道指标、输出编码等预处理步骤以适应神经网络的学习过程,然后利用误差反向算法训练单隐藏层神经网络模型,最后利用训练好的网络对基站选择进行预测.

### 4.1 提取角度域信息

信道学习算法的第一步是从  $M$  维控制基站信道向量  $\mathbf{h}$  中提取角度域信息.空域信道响应和用户位置之间的映射关系较为复杂,直接作用于神经网络学习效果较差,因此需要将信道响应从空域转换为角度域,使其到用户位置的映射关系更明朗.在均匀线性天线阵列的假设下,采用离散 Fourier 变换即可完成这一转换关系,由样本  $n$  的控制信道向量得到对应的角度域信道信息  $\mathbf{h}_n^a$ :

$$\mathbf{h}_n^a = \mathbf{U}\mathbf{h}_n, \quad (2)$$

其中  $\mathbf{U}$  为  $M$  维 Fourier 矩阵.

### 4.2 形成量化输入信道指标

得到了角度域信息之后,我们还需要将其进行预处理形成输入信道指标.神经网络的激活函数由 Sigmoid 函数构成,当输入值过大或过小时容易达到饱和值.然而,由于路径损耗的影响,不同用户之间的信道响应可能差好几个数量级,其动态范围非常之大.为了解决这一问题,我们首先将用户信道角度域信息进行对数化,然后使用 Lloyds 算法进行量化.经过这两步处理之后,输入数据的动态范围得到了较好的限制,最终得到的输入信道指标向量  $\mathbf{x}_n$  是原来角度域幅度向量量化之后的码本序号(归

一化到  $[-1,1]$  区间):

$$\mathbf{x}_n = \text{Lloyds}(\log(\mathbf{h}_n^a)). \quad (3)$$

### 4.3 输出编码

超蜂窝中基站选择问题的天然输出结果是最佳业务基站的序号. 但是, 由于和输入编码类似的原因, 神经网络不能很好地近似取值为整数的函数. 因此, 本文采用概率编码作为输出编码方案, 也就是将输出结果编码为长度为  $K$  的向量, 其中每一个元素代表相应业务基站是最优选择的概率. 本文采用硬编码方案, 即将最优基站对应的元素设为 1, 其他元素设为 0. 设第  $n$  个样本中用户到候选基站的信道增益组成向量  $\mathbf{g}_n$ , 编码得到的输出向量为  $\mathbf{y}_n$ , 其元素为

$$\mathbf{y}_n(i) = \begin{cases} 1, & i = \arg \max \mathbf{g}_n, \\ 0, & \text{else.} \end{cases} \quad (4)$$

### 4.4 代价函数和训练过程

通过上述的预处理过程, 得到了  $N$  个新样本  $\{\mathbf{x}_n, \mathbf{y}_n\}$ ,  $n = 1, \dots, N$ , 用于神经网络学习. 神经网络训练过程中使用的代价函数为

$$f(\boldsymbol{\theta}) = \frac{1}{N} \sum_{n=1}^N [-\mathbf{y}_n^T \log \hat{\mathbf{y}}_n - (\mathbf{1} - \mathbf{y}_n)^T \log(\mathbf{1} - \hat{\mathbf{y}}_n)] + \frac{\lambda}{i} \sum_{i=1}^I \theta_i^2, \quad (5)$$

其中  $\theta_i$  ( $i = 1, \dots, I$ ) 为单隐藏层神经网络的参数,  $\hat{\mathbf{y}}_n$  为神经网络在当前参数下的输出. 代价函数由两部分组成. 第 1 部分是当前神经网络输出和期望得到的训练输出之间的平均 Kullback 交叉熵 [12]. Kullback 交叉熵形式的代价函数天然适用于输出为概率分布的神经网络, 同时相对于均方误差等其他代价函数也能提供更好的局部最优解 [13]. 代价函数的第 2 部分是正则化项, 其形式为神经网络参数的平方和, 而  $\lambda > 0$  则是正则化系数. 合适的正则化系数保证了神经网络参数的“稀疏性”, 从而避免过拟合. 本文采用误差反向传播算法来得到代价函数关于神经网络参数的偏微分, 并采用共轭梯度下降法来最小化代价函数.

### 4.5 基站选择

神经网络完成训练之后, 即可用于解决休眠场景下的基站选择问题. 将用户在控制基站天线阵列上的信道进行前述的输入预处理过程, 形成量化的输入信道指标, 再将其输入神经网络. 所得到的输出向量是选择每个候选业务基站的概率, 其中值最大的元素即为预测的最优基站.

## 5 仿真结果

### 5.1 仿真环境

在仿真中, 采用几何随机信道模型 (GSCM) [14] 来生成衰落信道. 该模型的基本思想是随机散布散射体并计算得到不同传播路径的信道增益, 再将它们叠加起来得到最终的信道响应. 为了简便起见, 我们只考虑直射径和单次散射两种传播过程.

超蜂窝网络设置如图 2 所示. 整个网络包含 1 个控制基站 (CBS) 和 5 个业务基站 (TBS). 控制基站覆盖范围为半径 700 m 的圆形区域. 为了避免镜像混淆, 只考虑圆形区域的上半部分. 散射体和

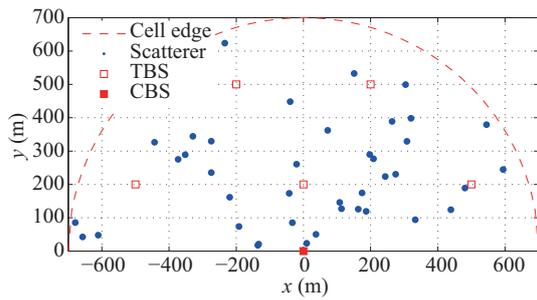


图 2 (网络版彩图) 仿真场景示意  
Figure 2 (Color online) Network layout for simulation

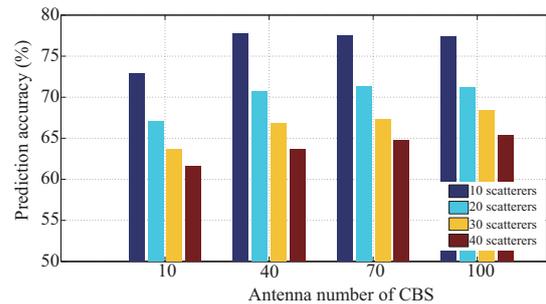


图 3 (网络版彩图) 预测准确率与天线数、散射体数的关系

Figure 3 (Color online) Prediction accuracy v.s. different number of antennas and scatterers

用户随机分布于所考虑的半圆形区域. 控制基站位于圆心, 配置有均匀线性天线阵列. Rice 因子设为 10 dB. 我们假设高信噪比条件, 忽略噪声的影响.

在每次仿真中, 随机均匀撒布 2000 个用户位置, 并随机选择其中一半作为训练样本, 剩余一半作为测试样本. (实际上, 2000 个用户样本并不意味着网络需要同时服务 2000 个用户, 单个用户在一段时间内每移动到一个新的地理位置, 都可以视作一个新的用户样本. 因此, 少量移动用户的信道测量信息可以产生大量的样本个数.) 预测准确率被定义为在测试集中对基站选择问题的正确预测比例. 在当前工作中, 只根据信道状况来进行基站选择, 正确的预测应该是选择信道增益最高的业务基站进行关联, 预测准确率被定义为在测试集中对基站选择问题的正确预测比例.

## 5.2 算法性能

图 3 显示了所提算法预测准确率与天线数、散射体数目的变化关系. 可以看到, 天线数目从 10 增长到 40 时, 预测准确度有了明显的上升, 这是由天线阵列在角度域分辨率随着天线数增多而增强所导致的. 但从 40 增长到 100 时, 预测准确度没有太大变化, 说明预测准确度已经达到饱和, 受到了单隐藏层神经网络表达能力的限制. 此外, 随着散射体数目的增多, 散射环境也变得更为复杂, 目标函数  $f(\cdot)$  变得更难以拟合, 因此预测准确率有所下降, 正如图 3 中所示.

本文同时也将信道学习算法和其他预测方法进行了比较, 结果如图 4 所示. 可以看到, 最简单的随机选择算法 (RS) 性能最差, 预测准确率为 20%.  $K$  最近邻算法 (KNN) 是将预测结果取为  $K$  个地理位置最邻近的训练样本中占主导地位的选择, 它将预测准确率提高到了 50%. 参数  $K$  取不同值时, 对预测准确率有大约 4% 的影响. 而本文所提的信道学习算法 (NN-CR) 的预测准确率达到了 73%, 大大优于前面两种方法. 我们还考虑了已知准确用户地理位置信息作为神经网络输入的算法 (NN-LO). 相对于这种算法, 信道学习算法有大约 3.9% 的性能损失. 这部分有限的性能差距是由于地理位置 - 信道函数不具有完美可逆性所导致. 但考虑到蜂窝网络中往往无法获得准确的用户地理位置信息, 本文所提的信道学习方法更为实用.

## 6 结论

本文针对超蜂窝网络中休眠业务基站信道获取的问题, 提出了信道学习方法作为解决方案, 即通

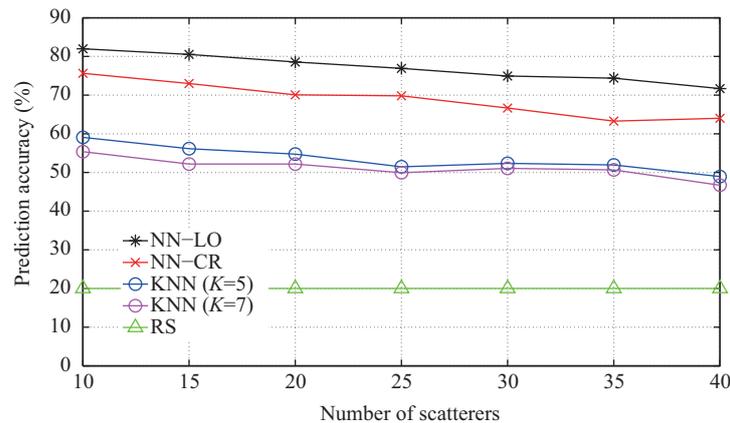


图 4 (网络版彩图) 不同算法的预测准确率比较

Figure 4 (Color online) Prediction accuracy of different algorithms

过机器学习来拟合得到从用户可见信道信息到用户不可见信道信息的函数映射关系. 同时以业务基站选择为例, 具体介绍了基于神经网络的信道学习算法. 利用几何随机信道模型进行仿真, 并将信道学习算法和其他备选方案进行对比. 结果表明, 所提算法在 5 个业务基站的场景下具有 73% 的预测准确率, 明显优于最近邻算法. 相对于已知用户准确地理位置信息的神经网络学习算法, 所提算法只有大约 3.9% 的性能损失.

## 参考文献

- Andrews J, Buzzi S, Choi W, et al. What will 5G be? *IEEE J Sel Area Commun*, 2014, 32: 1065–1082
- Niu Z S, Zhou S, Zhou S D, et al. Energy efficiency and resource optimized hyper-cellular mobile communication system architecture and its technical challenges. *Sci Sin Inform*, 2012, 42: 1191–1203 [牛志升, 周盛, 周世东, 等. 能效与资源优化的超蜂窝移动通信系统新架构及其技术挑战. *中国科学: 信息科学*, 2012, 42: 1191–1203]
- Marzetta T L. Noncooperative cellular wireless with unlimited numbers of base station antennas. *IEEE Trans Wirel Commun*, 2010, 9: 3590–3600
- Larsson E G, Edfors O, Tufvesson F, et al. Massive MIMO for next generation wireless systems. *IEEE Commun Mag*, 2014, 52: 186–195
- Jiang Z, Molisch A, Caire G, et al. Achievable rates of FDD massive MIMO systems with spatial channel correlation. *IEEE Trans Wirel Commun*, 2015, 14: 2868–2882
- Jiang Z, Zhou S, Niu Z. On dimensionality loss in FDD massive MIMO systems. In: *Proceedings of IEEE Wireless Communications and Networking Conference (WCNC)*, New Orleans, 2015
- Jiang Z, Zhou S, Niu Z. Dynamic channel acquisition in MU-MIMO. *IEEE Trans Commun*, 2014, 62: 4336–4348
- Slock D. Location aided wireless communications. In: *Proceedings of the 5th International Symposium on Communications, Control and Signal Processing (ISCCSP)*, Rome, 2012. 1–6
- Taranto R, Muppirisetty S, Raulefs R, et al. Location-aware communications for 5G networks: how location information can improve scalability, latency, and robustness of 5G. *IEEE Signal Process Mag*, 2014, 31: 102–112
- Liu J, Deng R, Zhou S, et al. Seeing the unobservable: channel learning for wireless communication networks. In: *Proceedings of IEEE Global Communications Conference (GLOBECOM)*, San Diego, 2015. 1–6
- Fodor G, Dahlman E, Mildh G, et al. Design aspects of network assisted device-to-device communications. *IEEE Commun Mag*, 2012, 50: 170–177
- Boer P T, Kroese D P, Mannor S, et al. A tutorial on the cross-entropy method. *Ann Oper Res*, 2005, 134: 19–67
- Golik P, Doetsch P, Ney H. Cross-entropy vs. squared error training: a theoretical and experimental comparison. *Interspeech*, 2013, 13: 1756–1760

14 Molisch A F. A generic model for MIMO wireless propagation channels in macro-and microcells. *IEEE Trans Signal Process*, 2004, 52: 61–71

## CSI acquisition for sleeping cells in hyper cellular networks based on channel learning

Ruichen DENG<sup>1,2\*</sup>, Zhiyuan JIANG<sup>1,2</sup>, Jingchu LIU<sup>1,2</sup>, Sheng ZHOU<sup>1,2</sup> & Zhisheng NIU<sup>1,2</sup>

1. *Department of Electronic Engineering, Tsinghua University, Beijing 100084, China;*

2. *Tsinghua National Laboratory for Information Science and Technology (TNList), Tsinghua University, Beijing 100084, China*

\* Corresponding author. E-mail: drc13@mails.tsinghua.edu.cn

**Abstract** Channel state information (CSI) plays an important role in next-generation cellular systems with massive multiple-input multiple-output (MIMO) technology as the indicator of wireless channels. In hypercellular networks (HCNs), traffic base stations (TBSs) improve energy efficiency by dynamical sleeping. However, conventional pilot-based CSI acquisition methods cannot be applied to sleeping cells. We propose a novel CSI scheme based on channel learning to address this problem. Unlike location-aided CSI acquisition schemes, the proposed method utilizes CSI at the control base station (CBS) as input to avoid errors caused by positioning. We validate our scheme in an HCN generated by the geometry-based stochastic channel model (GSCM). The prediction accuracy of the proposed scheme is better than the K-nearest neighbor (KNN) method and close to the location-aided CSI acquisition scheme, which requires the knowledge on user position.

**Keywords** hypercellular network, channel state information, artificial neural network, channel learning, massive MIMO



**Ruichen DENG** was born in 1992. He received his B.S. degree in engineering from Tsinghua University, Beijing, China, in 2013. He is currently a Ph.D. candidate at Niulab of Electronic Engineering Department, Tsinghua University. His research interests include multiuser MIMO and CSI acquisition.



**Zhiyuan JIANG** was born at Beipiao, Liaoning Province, China in 1987. He received his B.E. and Ph.D. degrees in electronic engineering from Tsinghua University, Beijing, China in 2010 and 2015, respectively. From 2015 to 2016, he worked at Ericsson Research. Since November 2016, he has been a postdoctoral research fellow at Niulab of Electronic Engineering Department, Tsinghua University. His main research interests include multiuser MIMO systems, optimizations, and optimal controls.



**Zhisheng NIU** was born in 1964. He graduated from Beijing Jiaotong University, China, in 1985, and received his M.E. and D.E. degrees from Toyohashi University of Technology, Japan, in 1989 and 1992, respectively. He is currently a professor at the Department of Electronic Engineering, Tsinghua University, Beijing, China. He is also a guest chair professor at Shandong University, China. His major research interests include queuing theory, traffic engineering, mobile Internet, radio resource management of wireless networks, and green communication and networks.