

第3章 智能通信信息处理

3.1 智能射频通信传输

3.1.1 信道模型

1. 5G 信道测量与模型综述

5G 移动通信系统已经在 2022 年大规模投入商用了,其目标是为任何人和事物提供随时随地的高速连接。与第四代(4G)系统相比,它应实现 1000 倍的系统容量、100 倍的数据速率、3~5 倍的频谱效率和 10~100 倍的能效。如今在 5G 领域依然进行着一些前沿技术研究,如海量多输入多输出通信、车对车通信、高速列车通信、毫米波/太赫兹通信等。这些技术的提出均引入了新的信道特征,并对 5G 信道建模提出了新的要求。此外,5G 系统应适应于广泛的场景,诸如室内、城市、郊区、农村地区都对 5G 信道建模提出了新的要求,概括如下。

宽频率范围: 新的 5G 信道模型应支持较宽的频率范围,例如,350MHz 至 100000MHz。在较高频带的模型,高于 6GHz 的情况下,应保持与较低频带下的模型兼容,例如,低于 6GHz。

宽带宽: 新的 5G 信道模型应具有支持大信道带宽的能力,例如,500MHz 至 4000MHz。

多种场景: 新的 5G 信道模型应能够支持室内、城市、郊区、农村、高速列车(HST)等场景。

双向三维(3D)建模: 一个新的 5G 信道模型应该提供全 3D 建模,包括精确的 3D 天线建模和 3D 传播建模。

平滑时间演变: 新的 5G 信道模型必须随时间平滑演进,包括参数漂移和集群淡入淡出,这对于支持 5G 通信的移动性和波束跟踪非常重要。

空间一致性: 空间一致性意味着两个位置接近的发射机或接收机应具有相似的信道特性,包括大尺度参数(LSP)、小尺度参数(SSP)、视线/非视线(LoS/NLoS)条件和室内/室外状态在内的信道状态应作为位置的函数以连续和现实的方式变化。

频率相关性和频率一致性: 一个新的 5G 信道模型的参数和统计数据应随着频率平滑变化。相邻频率处的信道参数和统计应具有强相关性。

大规模 MIMO: 新的 5G 信道模型必须支持海量 MIMO,即球面波阵面和阵列非平稳性必须适当建模。

高移动性: 新的 5G 信道模型应支持高移动性场景,比如 HST 场景,列车速度甚至超过



500km/h。该模型应能够捕获高移动性信道的某些特性,例如多普勒频率和非平稳性。此外,渠道模型必须在各种 HST 场景中可靠地工作,包括开放空间、高架桥、路堑、丘陵地形、隧道、车站场景等。

2. 大规模 MIMO 信道特征及模型

大规模 MIMO 是指在一端或两端配备数百甚至上千个天线,大量天线使得大量 MIMO 信道在整个阵列中表现出非平稳特性,这与传统 MIMO 信道的情况明显不同。如图 3.1 所示,视距(LoS)到达角(AoA)在整个 7.3m 线性阵列中,从 100° 逐渐变为 80° ,这表明平面波假设或远场假设在大规模 MIMO 系统中无效。





图 3.1 LoS 情况下阵列上的 APS(见彩插)


此外,测量结果表明,传播环境中的簇可以沿着阵列出现和消失。某些群集在整个阵列上可见,而其他群集仅在阵列的一部分上可见。除线性阵列,其他形式的大型天线阵列也被报道在大量的 MIMO 信道测量中。在文献[23]中,测量在 15GHz 下进行,带宽为 4GHz。采用一个虚拟的 40×40 (1600 个阵元)平面天线阵列,并将其划分为若干 7×7 的子阵列,以研究大规模 MIMO 信道在阵列上的非平稳特性。测量结果表明,K 因子、延迟扩展、方位角到达扩展(AASA)和仰角到达扩展(EASA)在阵列平面上具有清晰边界的块中变化。还可以观察到穿过阵列孔径的簇的生灭行为。

在室内办公室环境中同样进行了测量,文献[24]在 11GHz、16GHz、28GHz 和 38GHz 频带的室内办公室环境中,使用矢量网络分析仪(VNA)和大型虚拟均匀矩形阵列(URA)进行测量。元件间距设置为半波长,四个毫米波波段的阵列元件总数为 51×51 、 76×76 、 91×91 和 121×121 。采用空间交替广义期望最大化(SAGE)算法提取多径分量(MPC)参数。验证和分析了大量 MIMO 传播特性,包括球面波阵面、簇的出现和消失,以及参数在阵列上的漂移。延迟分布、AAS、EAS 随 TX 位置变化如图 3.2 所示。


除天线阵列上的信道非平稳性,阵列结构对大规模 MIMO 系统性能的影响同样值得关注。文献[25-26]中的测量是在校园中以 2.6GHz 和 50MHz 的带宽进行的。在这些测量中使用了虚拟均匀线阵(ULA)和均匀圆阵(UCA)。UCA 实例图和 ULA 实例图如图 3.3 所示。ULA 和 UCA 都包含 128 个天线单元,单元间隔为半波长。ULA 的天线沿着 7.3 米的线展开。UCA 的天线分布在直径和高度均约为 30cm 的圆柱体中。与使用 UCA 的信道相



(a) 延迟分布(DS)随TX位置的变化




(b) AAS随TX位置的变化



(c) EAS随TX位置的变化

图 3.2 延迟分布(DS)、AAS、EAS 随 TX 位置的变化(见彩插)

比,使用 ULA 的信道表现出更显著的阵列非平稳性和更好的用户去相关性,并且可以实现更高的和速率容量。此外,两种情况下的大规模 MIMO 信道都具有比传统 MIMO 信道更好的空间分离性、用户信道正交性和信道稳定性。



(a) UCA

(b) ULA

图 3.3 UCA 实例图和 ULA 实例图

此外,有研究表明,与 LoS 情况下的信道相比,具有丰富散射的非视距(NLoS)情况下的



信道表现出更好的空间分离和用户信道正交性。在文献[27]中,测量是在 5.8GHz、100MHz 带宽的室内食堂环境中进行的,总共使用了 64 个天线,并重新排列成 3 种不同的阵列形状,即 $25\text{cm} \times 28\text{cm}$ 的正方形紧凑二维(2D)矩形阵、2m 长的大孔径线阵和 6m 长的超大孔径线阵。测量结果表明,该阵列具有最大的孔径,该设置提供了最佳的用户正交性,并实现了接近独立同分布信道。观察到阵列之间的显著功率变化,并且具有最大孔径的线性阵列显示出最大功率变化。注意,对于紧凑的 2D 阵列,甚至观察到大于 10dB 的功率变化。与 UCA 和矩形阵列相比,ULA 的大孔径带来更好的空间分离和用户正交性等优点。然而,ULA 仅在一维上具有角分辨率。UCA 和矩形阵列可以在二维上分辨波。此外,从实用的角度看,尺寸较小的天线阵列更容易部署。在“Spread NLoS”和“楼梯前的自由空间”场景中,归一化特征值与用户数量关系如图 3.4 所示。




图 3.4 在“Spread NLoS”和“楼梯前的自由空间”场景中,归一化特征值与用户数量关系

在大规模 MIMO 信道中,由于天线阵列的尺寸较大,发射机/接收机与集群之间的距离可能短于瑞利距离,定义为 $2L/\lambda$,其中 L 是天线阵列的孔径尺寸, λ 是波长。因此,远场条件未被满足。应考虑球面波阵面,而不是平面波阵面。此外,大规模 MIMO 信道具有显著的阵列非平稳性。具体来说,不同的天线可以看到不同的簇集。诸如功率和延迟之类的路径参数可能不同的天线上漂移。在大规模 MIMO 信道建模中,应解决所有上述挑战。

大多数大规模 MIMO 信道模型都是基于成熟的几何的随机模型(GBSM),如文献[28]提出的载频为 GHz 量级的大规模多输入多输出(MIMO)通信系统的三维宽带双簇信道非平稳理论模型;文献[29]提出的非平稳宽带多共焦椭圆二维信道模型;文献[30]提出的非平稳多环信道模型等。

当天线的数量很大时,发射机(集群)和接收机之间的距离 D 可能不大于瑞利距离 $2L^2/\lambda$,其中 L 是天线阵列的尺寸, λ 是载波波长。在这种情况下,球面波阵面的影响是显著的。其次,簇的出现和消失可以发生在阵列轴上。结果,每个天线可以具有其自己的可观察簇集合。在诸如 SCM 扩展模型、COST 2100 信道模型、METIS GBSM 之类的大多数高级 GBSM 中尚未考虑这一点。

3. 车联网信道特征及模型

1) 通道特征

近年来,智能交通系统(ITS)作为解决交通拥堵和道路安全问题的有前途的解决方案受



到广泛的关注和期望,因此,作为 ITS 最重要的技术支持之一,车载通信受到学术界和工业界的广泛关注。通过在车辆、交通基础设施和基站(BS)之间建立可靠和高效的通信链路,可以为许多智能交通应用提供必要的信息交互,例如自动驾驶、碰撞避免、路线优化等。

对于车辆通信,通常认为最典型的部件是车辆到车辆(V2V)链路。值得注意的是,与一般蜂窝通信相比,V2V 通信链路具有许多特殊属性,例如天线高度低、时变严重,以及来自车辆的大量局部散射体。这些差异导致 V2V 信道是高度动态的并且易受各种传播环境的影响。因此,了解 V2V 信道的传播机制和信道特性是 V2V 通信系统设计和评估的关键前提。在这一领域已经有一些有价值的研究:如文献[31]综述了车辆通信的传播和信道建模领域的最新发展,文献[32]模拟了一种停车场的 5GHz V2V 信道特性,文献[33]模拟了卡车作为障碍物对农村和公路场景中车对车通信的影响等。将车辆通信以及车辆信道建模与其他类型的无线通信区分开的最重要的特征是:

- (1) 通信发生的不同环境。
- (2) 不同通信类型的组合,V2V、车辆对基础设施(V2I)和车辆对行人(V2P)通信。
- (3) 影响车辆通信的静态和移动的物体。

这些特征共同导致复杂的传播环境,这是建模的一个挑战。图 3.5 显示了在典型的城市环境中,由于动态环境、低天线高度和车辆的高机动性,小规模和大规模信号统计数据如何快速变化。从图 3.6 所示的传播特性看,环境的累积特性导致信号从发射器传播到接收器,并与大量周围物体相互作用。即使对于单次反弹(例如,第一阶)反射和衍射,在接收器处产生的射线的数量也很大。目标的高密度与通信车辆及其周围环境的高移动性相结合,表明捕获车辆信道的特性远非微不足道。




图 3.5 城市环境中 V2V 通信的 5.9GHz 接收功率测量

虽然许多现有的移动的信道模型已经广泛用于蜂窝系统,但是由于前面提到的车辆信道的独特特征,它们通常不太适合于车辆系统。举一个例子:发射机和接收机天线的相对高度的差异可能导致显著不同的信号传播行为。车辆通信中的操作频率和通信距离也不同于蜂窝系统中的操作频率和通信距离。车辆通信系统预期在 5.9GHz 和短距离(10~500m)上操作,而当前部署的蜂窝系统在 700~2100MHz 的范围在长距离(高达数十千米)上操作。

截至目前,全球的学者在各种场景下进行了一系列 V2V 信道测量,如开放式高速公路、郊区、校园、十字路口等测量结果表明,V2V 信道的衰落幅度在这些普通场景下最适合




图 3.6 城市区域传播机制的模拟(见彩插)

Nakagami 分布,在高速公路和城市中的测量表明,V2V 信道的衰落幅度与 Weibull 分布的拟合比,与 Nakagami 分布的拟合更好。当车辆在较短距离内移动时,由于 LoS 路径较强,衰落幅度趋于 Rician 分布;当两车距离增大时,LoS 路径变弱,衰落幅度趋于 Rayleigh 分布。此外,时延扩展作为信道的关键参数之一,描述了时延在平均时延附近的扩展,反映了信道的多径丰富度。根据不同的传播场景和流量,V2V 信道的均方根(RMS)延迟扩展范围从几十纳秒到几百纳秒。参考文献表明 RMS 延迟扩展可以用对数正态分布拟合。也许 V2V 信道和传统蜂窝信道之间的最大区别是多普勒扩展。V2V 信道由于快速变化的环境和发射机与接收机之间的高相对速度而通常具有大的多普勒扩展。相同的中心频率和车辆速度,大的多普勒频移到 1100 Hz 或更高版本造成反射接近车辆 V2V 通道测量,在交通拥堵的情况下进行仿真结果的条件,发现交通标志、卡车和桥梁,而不是其他车辆造成的多径传播。

2) 通道模型

由于独特的传播条件,V2V 信道与蜂窝通信信道相比表现出非常不同的传播特性。在 V2V 通信中,发射机和接收机都相对较低,并且被大量散射体包围。发射机和接收机以及散射体可能会移动,导致较大的多普勒频移,并使信道不稳定。高速公路、城市峡谷等传播环境也会对河道特性产生较大影响。在 V2V 信道建模中,必须仔细考虑所有上述传播条件。

早期的 V2V 信道模型是 2D GBSM,例如双环模型。双环模型假设发射机和接收机被位于两个规则环上的大量局部散射体包围。从模型的几何结构出发,可以得到时间自相关函数(ACF)和多普勒功率谱密度(PSD)等统计特性的解析解。一种改进的 V2V 信道的负载模型如图 3.7 所示。该模型考虑了 LoS、单次反弹和双次反弹分量,既适用于微小区,也适用于宏小区。通过使用多个散射环,窄带双环模型被扩展为宽带模型,其中 Cheng 等通过组合双环模型和椭圆模型提出自适应 V2V 模型,如图 3.8 所示。通过改变不同传播分量的功率比例,该模型可以适应广泛的 V2V 场景,如宏小区、微小区和微微小区。Wu H 在 multi-ring 模型基础上提出一种协作 MIMO 信道模型。通过调整一些关键参数,该模型可适应 12 种混合场景,即 4 种物理场景(宏观、微观、微微小区和室内场景)乘以 3 种应用场景(BS、MS



和继电器合作),并能捕捉当地散射的影响密度频道统计数据。




图 3.7 双环模型




图 3.8 组合型自适应双环模型

2D V2V 模型假设波在水平面内传播,更适合某些场景,例如农村地区。然而,在城市场景中,发射器和接收器位置接近,并且波可能从高层建筑物衍射和反射。因此,必须考虑水平面和垂直平面中的波传播。Zajic 和 Stüber 提出一种基于 3D 双圆柱体的 V2V 通道模型,如图 3.9 所示。其中假设散射体位于两个圆柱体的表面上。Yuan 等将工作扩展到 3D 非静态模型,该模型结合了 LoS 组件、双球面模型和多个共焦椭圆柱模型,使用 von Mises-Fisher 分布描述方位角和仰角。Zajic 和 Stüber 提议的 3D 模型被认为比 2D 模型更通用、更真实,并且可以适应广泛的 V2V 场景。

非几何随机模型(NGSM),如抽头延迟线(TDL)模型也用于 V2V 信道建模。在 TDL




图 3.9 3D 双圆柱体的 V2V 通道模型

模型中,信道脉冲响应(CIR)由线性有限脉冲响应(FIR)滤波器表示。TDL 模型的每个抽头由具有不可分辨延迟的多个 MPC 组成。抽头权重通过随机过程建模,振幅遵循 Rayleigh、Rician 或 Weibull 分布。早期基于 TDL 的 V2V 模型是根据 Acosta—Marum 和 Ingram 在城市和高速公路上进行的一系列测量结果开发的。然而,这些模型基于 WSS 假设,不能表示 V2V 通道的非平稳性,这可能导致系统性能预测的错误结果。文献[32]提出了非平稳相关散射 TDL 信道模型。为了对 V2V 信道的非平稳性进行建模,诸如延迟和功率的参数被建模为时变的。路径的生存期用一个“持续过程”建模,它由一个一阶两状态马尔可夫链控制。进一步的数据分析表明,V2V 信道既不满足 WSS 假设,也不满足经典的 US 假设。文献[33]基于测量结果,给出了模型的抽头相关性。TDL 模型结构简单,计算复杂度远低于 GBSM 模型。然而,GBSM 模型由于具有复杂的几何结构,可以通过调整大量参数配置表示真实的传播环境,因此比 TDL 模型更具通用性。确定性模型(如 RT 模型)也被用于 V2V 渠道建模。Reichardt 等使用 RT 模型研究了天线位置对飞行器的影响。通过重建虚拟传播环境,并在 GO 和 UTD 理论的帮助下,RT 模型可以在模拟和测量结果之间实现良好的一致性。一般而言,RT 模型可以提供准确的和特定场地的模拟,但通常具有较大的计算复杂性。




图 3.10 通过 RT 模型模拟城市交叉口场景(见彩插)



4. 6G 信道测量与模型探索

在应用需求方面,从 1G 到 4G 无线通信网络的主要演进是通信移动的和宽带化,而 5G 则从 4G 的移动宽带(MBB)扩展到增强型 MBB(eMBB)加上物联网。物联网还包括大规模机器类通信(mMTC)和超可靠低时延通信(uRLLC)。从 2020 年开始,5G 无线通信网络在全球范围内展开部署。然而,5G 将无法满足未来网络的所有要求。因此,6G 无线通信网络应当着手开始研究,并计划在 2030 年后部署。

5G 主要集中于 eMBB、mMTC 和 uRLLC,6G 无线通信网络有望进一步增强 MBB,扩大物联网的边界和覆盖范围,使网络/设备更加智能,同时有希望引入几种其他应用场景,例如长距离和高移动性通信、极低功率通信、空-空-地-海一体化网络、人工智能赋能网络等在新应用需求的推动下,6G 不得不引入新的技术要求和性能指标。5G 的峰值数据速率为 20GB/s,而 6G 网络由于使用太赫兹和光无线频段,数据速率可达到 1~10TB/s。在高频带的帮助下,用户体验的数据速率可以达到每秒千兆字节的水平。区域流量容量可超过 1GB/s/m²。应用 AI 提供更好的网络管理,频谱效率可以提升 3~5 倍,而能效相比 5G 可以提升 10 倍左右。由于使用了极其异构的网络(HetNets)、多样化的通信场景和高频带的大带宽,连接密度将增加 10~100 倍。由于超高速飞行器、无人机和卫星的运动,机动性将支持高于 1000km/h。延迟预计低于 1ms。此外,还应引入其他重要的性能指标,例如成本效益、安全容量、覆盖范围、智能化水平等,更全面地评估 6G 网络。

为了满足这些应用需求和性能指标,6G 通信网络将发生新的范式转变,并依赖于新的使能技术。新的范式转变可以概括为全球覆盖、全频谱、全应用和强安全或内生安全。为了提供全球覆盖,6G 无线通信网络将从 1G~5G 的地面通信网络扩展到包括卫星、无人机、地面超密集网络(UDN)、地下通信、海上通信和水声通信在内的空-空-地-海一体化网络。为了提供更高的数据速率,将充分利用所有频谱,包括低于 6GHz、毫米波、太赫兹和光学无线频段。借助 AI 和大数据技术,将关键技术和应用高度融合,赋能全应用。此外,AI 还可以实现网络、缓存和计算资源的动态协调,以提高网络性能。最后但并非最不重要,6G 的发展趋势是在开发时实现强大或内置的网络安全,包括物理层和网络层安全。这与 1G~5G 的发展策略截然不同,1G~5G 的发展策略是先让网络运转起来,再考虑网络是否安全,如何提高网络安全。

支持 6G 的技术旨在大幅提高总容量,该总容量近似为 HetNets 上不同类型信道的香农链路容量的总和(考虑干扰),可以通过增加信号带宽、信号功率、空间/时间/频率域中的信道数量、HetNet 或覆盖的数量,以及减少干扰和噪声来增加总容量,从而增加信号干扰噪声比。

为了利用这些新趋势和使能技术实现 6G 网络,需要深入研究 6G 无线信道,因为无线信道是 6G 网络的系统设计、网络优化和性能评估的基础。

6G 无线信道存在于多个频段和多个场景中。每个单独通道的通道探测器和通道特性显示出很大的差异。在这里,通过在所有频谱、全球覆盖场景和全应用场景下对 6G 信道进行分组,对不同类型的 6G 信道进行了全面调查。6G 信道测量结果和特性总结如表 3.1 所示,同时,图 3.11 展示了不同类型的 6G 无线信道^[75]。



表 3.1 6G 信道测量结果和特性总结

无线信道	主要频段	信道特征
毫米波/太赫兹信道	26/28, 32, 38/39, 60, 主要在 380~780nm	大带宽,高方向性;路径损失严重;阻塞效应
光无线信道	主要在 380~780nm	依赖 LoS 信道;主要在室内应用
卫星通信信道	C,S,L,X,Ku 等频段	受天气影响严重;超大多普勒频移和多普勒扩散;覆盖范围大
无人机信道	2,2.4 以及 5.8GHz	3D 随机轨道(仰角大、高移动性、高机动性、机身阴影等)
海上通信信道	2.4、5.8GHz	稀疏度高,时间不平稳,受海上气候影响大
水下通信信道	2~32kHz	信号传输损耗大,多径效应严重
车联网信道	Sub 6GHz,毫米波频段	多普勒频移和多普勒扩散严重;非平稳性;受车辆速度影响
工业互联网信道	Sub 6GHz	LoS 损耗大,NLoS 效果不好




图 3.11 不同类型的 6G 无线信道

首先是毫米波/太赫兹信道。一般来说,毫米波指的是 30~300GHz 频段,太赫兹指的是 0.1~10THz 频段。因此,100~300GHz 波段与毫米波和太赫兹波段具有一些共同的特点,如大带宽、高方向性、大路径损耗、阻塞效应、大气吸收和更多的漫射散射。虽然毫米波被应用于以几千兆赫兹带宽实现高达几百米的千兆字节每秒级传输数据速率,但已知太赫兹信道以几十千兆赫兹带宽实现了高达几十米的千兆字节每秒级传输数据速率。太赫兹波段比毫米波波段表现出更严重的路径损耗、大气吸收和漫射/散射。毫米波信道在一些典型的频段,如 26/28-、32-、38/39-、60-、73GHz,已经得到很好的研究,尽管毫米波信道的测量仍



然需要 MIMO 天线、高动态(如 V2V)和室外环境。图 3.12 显示了实测的 28GHz 毫米波 V2V 信道,它是从实际信道测量中获得的^[31]。LoS 功率和总功率在 2000 张快照中变化,这验证了信道的非平稳性。但毫米波信道测深仪和测量未来依旧充满挑战。目前大多数太赫兹信道测量都在 300GHz 频段附近。300GHz 以上的信道特性尚不清楚,需要未来进行广泛的信道测量。




图 3.12 28GHz 波段的毫米波 V2V 通道变化(见彩插)

其次是光无线通信。光无线波段是指载频为红外、可见光和紫外的电磁光谱,分别对应 780~106nm、380~780nm 和 10~380nm 范围的波长。它们可用于室内、室外、地下和 underwater 场景的无线通信。光无线信道表现出一些独特的信道特性,如对不同材料的复杂散射特性、发射/接收端的非线性光电特性、背景噪声效应等。信道场景可进一步分类为有向 LoS、无向 LoS、无向 NLoS、跟踪等。光无线与传统频段的主要区别在于没有多径衰落、多普勒效应和带宽调节。测量的信道参数包括信道冲激响应/信道传递函数、路径损耗、阴影衰落、RMS 时延扩展等。

卫星通信以其可行的服务和较低的成本成为无线通信系统的研究热点。一般来说,卫星通信轨道可分为地球同步轨道和非地球静止轨道。圆形地球同步轨道(GEO)位于地球赤道上空 35786km 处,遵循地球自转的方向。根据卫星与地球的距离,非地球静止轨道可进一步分为低地球轨道(LEO)、中地球轨道(MEO)和高地球轨道(HEO)。通常应用的频带是 Ku(12~18GHz)、K(18~26.5GHz)、Ka(26.5~40GHz)和 V(40~75GHz)频带。卫星通信信道很大程度上受到天气动态的影响,包括雨、云、雾、雪等。雨是衰减的主要来源,尤其在 10GHz 以上的频段。此外,卫星通信信道还表现出极大的多普勒频移和多普勒扩展、频率依赖性、覆盖范围大、通信距离远等特点。由于距离很长,信道可以看作视距传输,多径效应可以忽略不计。同时,需要高发射功率和高天线增益来对抗长距离和高频段造成的高路径损耗。

同时,无人机在民用和军用方面的应用越来越多。无人机信道具有三维展开、高机动性、时空非平稳性、机体遮蔽等独特的信道特性。一般来说,无人机信道可分为空对空和空对地两种。两种类型的飞行器用于航道测量,即小型/中型有人驾驶飞机和无人机。第一种



信道测量是昂贵的,第二种信道测量可大大降低成本。我们进行了窄带和宽带信道的测量,其中大部分在 2-GHz、2.4-GHz 和 5.8-GHz 频段。所测量的环境包括城市、郊区、农村和开阔地带。测量的信道参数包括路径损耗、阴影衰落、RMS 时延扩展、K 因子、幅度概率密度函数(PDF)/累积分布函数(CDF)等。

V2V/HST 通道同样值得关注。以往的 HST 通信系统主要是面向移动通信铁路的全球系统和面向铁路的长期演进系统。5G 网络应用于 HST,可提高服务质量。未来,超 HST 的速度有望超过 500km/h,由此产生切换频繁快速、多普勒扩展大等问题。毫米波/太赫兹和 Massive MIMO 是 HST 通信系统中潜在的关键技术。学术界和工业界的多个团队和研究人员已经进行了一些初步的 HST 环境信道测量,包括开放空间、丘陵地形、高架桥、隧道、路堑、车站和车内车载网络是面向 uRLLC 场景的 5G/6G 典型行业垂直应用。这些通道包括 V2V、车辆到基础设施和车辆到行人通道,通常被称为车辆到一切。亚 6-GHz 频段的 V2V 信道得到广泛的研究,而毫米波的 V2V 信道需要更多的测量。文献[33]给出了目前毫米波 V2V 通道测量的概况。总之,在 28-GHz、38-GHz、60-GHz、73-GHz 和 77-GHz 波段测量了 V2V 通道。它们都在两侧配置了单个天线。所测量的环境包括高速公路、城市街道、空旷地带、大学校园、停车场等。具有高移动性的毫米波、V2V MIMO 甚至 Massive MIMO 信道测量是未来的发展方向。如何以有效和低成本的方式衡量这些仍然是一个开放的问题。

最后是工业互联网信道。在工业物联网环境中,各种机器人、传感器和机械设备需要以健壮和高效的方式进行大规模连接。工业物联网信道表现出许多新的信道特性,如变化的路径损耗、随机波动、非视距传播、大量散射体和多移动性等。在工业物联网环境中,只有很少的信道测量是在当前的物联网标准中进行的,这些环境主要在 Sub-6GHz 频段。然而,在工业物联网环境中,对于未来具有高传输数据速率的大规模连接来说,毫米波段的信道测量也是有希望的。

3.1.2 信道估计

1. 深度学习信道估计

由于大规模 MIMO 的各种理论增益的实现很大程度上依赖于信道状态信息(CSI)的质量,因此信道估计是实际大规模多输入多输出(MIMO)系统中的关键问题之一。在现有的信道估计中,最小二乘(LS)和最小均方误差(MMSE)是两种最常用的信道估计方法。LS 相对简单,易于实现,但其性能并不令人满意。另外,如果有准确的信道相关矩阵(CCM),MMSE 可以对 LS 估计进行改进。然而,由于矩阵求逆运算,MMSE 估计的复杂度远高于 LS 估计。为了降低硬件和能源成本,在实际的大规模 MIMO 系统中通常采用混合模拟-数字(HAD)结构,即多天线阵列通过模拟域的移相器仅连接到有限数量的射频(RF)链。使用 HAD,信道估计变得更加困难,因为在 BS 处接收的信号只是原始信号的几个线性组合。如果使用 LS,由于 RF 链的数量有限,一次只能估计天线的部分信道,因此需要多次估计,二者本身的局限性放在如今的通信系统中难免显得有些乏力。

由于深度学习(DL)在在线预测过程中具有良好的性能和较低的复杂度,因此它已经被应用于许多无线通信问题,如频谱感知、资源管理、波束形成、信号检测、信道估计等。例如,



文献[211]中定制的 DNN 在频谱感知中显著优于能量检测;文献[212]提出一种用于资源管理的 DNN,它的性能与迭代优化算法相当;文献[213]提出一种基于无监督学习的波束形成网络,用于智能可重构曲面辅助 Massive MIMO 系统;正交频分复用系统中的信道估计和信号检测已经由 DNN 联合执行等。

基于 DL 的大规模 MIMO 信道估计方法大致分为两种。在第一类中,“深度展开”方法展开了各种迭代优化算法,并通过插入可学习参数提高它们的估计性能。AMP 算法被展开为用于毫米波信道估计的级联神经网络,其中去噪器由 DNN 学习。由于 DL 的强大功能,该方法可优于一系列传统的基于降噪放大器的算法。文献[214]将迭代收缩阈值算法应用于求解稀疏线性逆问题,并以 Massive MIMO 信道估计为例进行了研究。然而,“展开”仅适用于结构简单的迭代算法,计算复杂度也较高。在第二类中,DL 用于直接学习从可用的信道相关信息到 CSI 的映射,以提高性能或降低复杂度。文献[215]提出一种 DNN 来改进 HAD Massive MIMO 系统的粗估计,利用频域和时域的信道相关性进一步提高性能。在下行 Massive MIMO 系统中,通过将导频信号和信道估计器与自动编码器联合训练,进一步提高了估计性能。在文献[29]中,图神经网络已经被用于 Massive MIMO 信道跟踪。

尽管 DL 取得了巨大的成功,但 DNN 嵌入式无线通信系统通常被认为是信号发送/接收的黑匣子。目前只有数值和实验研究表明 DL 在学习无线系统关键功能部件方面具有强大的能力,而对于 DL 方法应用于通信领域的优劣几乎没有分析解释。为了进一步提高性能并扩展到不同的环境,需要理解为什么 DL 方法能在广泛的任务中获得惊人的性能。此外,DL 方法对无线通信系统的限制对于更好地理解哪些场景适合 DL 嵌入式通信系统也是非常重要的。另一个重要的问题是,在无线通信领域,新出现的数据驱动的 DL 方法与传统的专家设计的算法相比有什么优点。此外,DL 方法颠覆了传统的信号处理方法,在缺乏专家知识的情况下仍然可以获得令人满意的性能。到目前为止,关于 DL 方法如何从数据中学习以及专家知识的缺乏如何影响 DL 嵌入式通信系统的研究还很少。

目前已有大量文献论述了 DL 方法很适用于信道估计工作,在通信系统中部署 RELU DNN 已经变得越来越普遍。RELU DNNs 在实际应用中的成功要求全面了解它们在信道估计中的行为,为进一步开发基于 DL 的估计理论提供指导和启发。接下来以一个例子说明建立在 RELU DNN 上的 DL 估计的性能,并与传统 LS 方法及 LMMSE 方法进行比较。

2. 信号模型

这里考虑一个在基站(BS)有 D 根天线,在用户侧有单根天线的 SIMO 通信系统。假设上行链路信道具有块衰落,即信道参数在块内是固定的,但因块而异。在基站估计信道的传统方法是使用上行链路导频。设 τ 为 $|\tau|^2 = 1$ 的发射导频符号。在 BS 处接收的符号可以由下面的 $d \times 1$ 向量表示:

$$\mathbf{X} = \tau \mathbf{h} + \mathbf{n} \quad (3.1.1)$$

其中, $\mathbf{h}$ 表示用户和 BS 之间的 $d \times 1$ 随机信道向量, $\mathbf{n}$ 是具有零均值和元素方差 σ_n^2 的 $d \times 1$ 高斯白噪声向量。假定信道向量 $\mathbf{H}$ 均值为零,协方差矩阵 $\boldsymbol{\zeta} = \mathbb{E}\{\mathbf{h}\mathbf{h}^T\}$ 。

3. 传统信道估计

信道估计的目标是尽可能准确地从接收信号向量 $\mathbf{x}$ 中提取信道向量 $\mathbf{h}$ 。传统的估计方法都是基于 3.1.1 节中的信号模型。其中,使用最小二乘算法估计 $\mathbf{h}$ 可表示为



$$\mathbf{h}_{\text{LS}} = \frac{1}{\tau} \mathbf{x} = \mathbf{h} + \frac{1}{\tau} \mathbf{n} \quad (3.1.2)$$

对应的均方误差(MSE)可表示为

$$J_{\text{LS}} = \mathbb{E} \{ \|\mathbf{h} - \mathbf{h}_{\text{LS}}\|_2^2 \} = \frac{d}{1/\sigma_n^2} \quad (3.1.3)$$

如 MSE 表达式所示,LS 估计器的性能与定义为 $1/\sigma_n^2$ 的信噪比成反比。

使用线性最小均方误差(LMMSE)估计 $\mathbf{h}$ 可表示为

$$\mathbf{h}_{\text{LMMSE}} = \mathbf{\Xi} \left(\mathbf{\Xi} + \frac{\sigma_n^2}{\tau^2} \mathbf{I}_d \right)^{-1} \mathbf{h}_{\text{LS}} \quad (3.1.4)$$

对应的 MSE 可表示为

$$J_{\text{LMMSE}} = \text{tr} \left\{ \mathbf{\Xi} \left(\mathbf{I}_d + \frac{1}{\sigma_n^2} \mathbf{\Xi} \right)^{-1} \right\} \leq J_{\text{LS}} \quad (3.1.5)$$

顺带一提,MMSE 估计 $\mathbf{h}$ 可表示为

$$\mathbf{h}_{\text{MMSE}} = \mathbb{E} \{ \mathbf{h} \mid \mathbf{x} \} \quad (3.1.6)$$

通常,MMSE 估计器不同于 LMMSE 估计器。只有在某些特殊情况下,当 $\mathbf{x}$ 和 $\mathbf{h}$ 是线性模型的联合高斯分布时,才有 $\mathbf{h}_{\text{MMSE}} = \mathbf{h}_{\text{LMMSE}}$ 。因此,LS 和 LMMSE 估计器可以很好地解决线性模型的信道估计。然而,由于 LS 和 LMMSE 估计量都是线性的,所以它们对非线性模型的估计性能明显下降。LMMSE 估计器利用信道统计信息可以提高估计精度,但对信道统计信息的不完备性很敏感。相反,LS 估计器由于对信道统计量没有先验要求而易于实现,但这种简单性是以相对较低的精度为代价的。

4. DL 信道估计

近年来,DL 估计器已成为无线通信系统中解决信道估计问题的一种很有前途的替代方法。DL 估计器优良的泛化能力和强大的学习能力使其成为不完善和干扰破坏系统中信道估计的有力工具。下面以一个 Attention-Aided 深度学习信道估计框架进行介绍。

现有的基于 DL 的信道估计方法很少能充分利用信道的分布特性。在实践中,基站通常位于较高的高度,周围散射很少,因此每个用户在基站的入射信号的角扩展很窄。因此,在整个角度空间中对不同用户的信道的全局分布可以被看作许多局部分布的组成,其中每个局部分布代表小角度区域内的信道。由于窄的角分布,以及通道路径的角范围有限,某一个角区域包含的通道情况比整个角空间少得多,使得局部分布比全局分布简单得多。另外,如果将整个角空间分割成不同的角区域,则不同的局部分布可以很好地区分开。在这种情况下,经典的“分而治之”策略,即通过解决一个复杂的主问题的一系列简化的子问题来解决它,是非常合适的。具体而言,整个角空间的信道估计可视为主要问题,不同小角区域的信道估计可视为不同的子问题。Attention-Aided 深度学习信道估计框架就是基于此进行研究的。它有以下几个特点:

针对 Massive MIMO 系统,提出一种基于注意力辅助 DL 的信道估计框架,仿真结果表明,该框架比无注意力的信道估计框架具有更好的性能。据作者所知,这是首次将注意力机制引入基于 DL 的信道估计中,同时是首次将 Attention-Aided 这一机制引入基于 DL 的信道估计中。

文献[216]将上述框架扩展到具有 HAD 的场景,并提出一种嵌入方法,将注意力机制



有效地集成到全连通神经网络(FNN)中,扩大了该方法的应用范围。

根据结果,Attention-Aided 的性能增益主要来自信道的窄角扩展特性。因此,只要信道分布具有一定的可分离性,该方法就可以推广到除信道估计外的许多其他问题,如多用户波束形成、FDD 下行信道预测等。

5. 系统模型

考虑一个单小区 Massive MIMO 系统,其中基站配置一个 N 天线均匀线阵(ULA), K 个单天线用户随机分布在相应基站的小区中,如图 3.13 所示。




图 3.13 大规模 MIMO 系统

6. 信号模型

从用户 k 到 BS 的上行链路信道可以表示为

$$\mathbf{h}_k = \frac{1}{\sqrt{N_p}} \sum_{i=1}^{N_p} \alpha_{ki} \mathbf{a}(\theta_{ki}), \mathbf{h}_k \in \mathbb{C}^{N \times 1} \quad (3.1.7)$$

其中 N_p 是路径数, α_{ki} 和 θ_{ki} 分别是来自第 k 个用户的第 i 条路径的 BS 处的复增益和到达角(AOA)。为了更好地理解这种信道特性,可通过以下步骤将原始信道转换为角域:

$$\mathbf{x}_k = \mathbf{f} \mathbf{h}_k \in \mathbb{C}^{N \times 1} \quad (3.1.8)$$

其中 $\mathbf{x}_k$ 表示用户 k 的角域通道, $\mathbf{f} \in \mathbb{C}^{N \times 1}$ 是移位型离散傅里叶变换矩阵,其中第 n 行由以下公式给出:

$$\mathbf{f}_n = \frac{1}{\sqrt{N}} [1, e^{-j\pi\eta_n}, \dots, e^{-j\pi\eta_n(N-1)}] \quad (3.1.9)$$

由于窄角扩展假设,角域信道表现出空间聚类稀疏结构,具体如图 3.13 右半部分所示, $\mathbf{x}_k$ 只有几个重要元素出现在一个簇中。如果利用得当,这种稀疏结构可以提高估计性能,减少估计开销。

在上行链路训练过程中,不同用户发送正交导频序列。将第 k 个用户的导频序列表示为 $\mathbf{p}_k \in \mathbb{C}^{1 \times L_p}$, 其中 $L_p \geq k$ 为导频序列的长度。注意,由于 L_p 相对较小,导频训练阶段的信道被假定为不变,因此在 BS 处的叠加接收信号可表示为

$$\mathbf{Y} = \sum_{k=1}^K \mathbf{h}_k \mathbf{p}_k + \mathbf{N}, \mathbf{Y} \in \mathbb{C}^{N \times L_p} \quad (3.1.10)$$

其中, $\mathbf{N}$ 表示方差 σ^2 的零均值加性高斯白噪声。在不丧失通用性的前提下,将导频序



列的功率固定为单位,通过改变噪声方差调整发射信噪比。同时, $\mathbf{P}_i \mathbf{P}_j^H = 0$ (i 不等于 j), $\mathbf{P}_i \mathbf{P}_i^H = \mathbf{I}$ (i 等于 j)。利用导频序列的正交性,可以得到用户 k 信道的 LS 估计:

$$\hat{\mathbf{h}}_k = \mathbf{Y} \mathbf{p}_k^H = \mathbf{h}_k + \tilde{\mathbf{n}}_k \in \mathbb{C}^{N \times 1} \quad (3.1.11)$$

其中:

$$\tilde{\mathbf{n}}_k \triangleq \mathbf{N} \mathbf{p}_k^H \quad (3.1.12)$$

它表示用户 k 的有效噪声。

上面提到过,传统方法要么精度低要么开销大,因此这里我们考虑 DL 的方法进行信道估计。

7. Attention-Aided 信道估计框架

由于信道参数可以在角域内规范地表示,因此在该框架中,网络的输入和输出都在角域内。在仿真中,我们发现更稀疏的角域输入和输出可以得到比原来更好的信道估计性能。一旦获得角域信道估计,就可以很容易地恢复原始信道估计。此外,由于现有的 DL 库还不能很好地支持复杂的训练,所以实部和虚部必须分开处理。为了提高训练效率,我们还对输入进行了标准的归一化预处理。

Attention-Aided 信道估计框架如图 3.14 所示,Conv1D 层的输入被组织为 (F, C) 维特征矩阵,其中 C 表示信道的数目, F 表示每个信道中的特征数目。然后,卷积运算在输入特征矩阵上以一定的步幅滑动 C 滤波器,以获得输出特征矩阵,即下一层的输入。




图 3.14 Attention-Aided 信道估计框架

具体地,每个滤波器包含 (L, C) 维可训练权重矩阵和标量偏置项,其中 L 表示滤波器大小。当滤波器位于特征矩阵的某一位置时,计算特征矩阵的相应块与滤波器的权重矩阵之间的互相关,并添加偏置以获得该位置的卷积输出。在所提出的信道估计网络中,使用 NB 卷积块和输出 Conv1D 层细化 LS 粗信道估计。如图 3.14 所示,在每个卷积块中,在 Conv1D 层之后插入用于防止梯度爆炸或消失的批归一化(BN)层和 ReLU 激活函数。此外,在第一块中的 Conv1D 层具有 F 个尺寸为 L_1 的滤波器,并且在接下来的 $N_b - 1$ 块中的 Conv1D 层有 F 个尺寸为 L_b 的滤波器。通过仿真可以确定 N_b 和 F 的最佳值。最后,输出 Conv1D 层具有大小为 L_o 的 2 个滤波器,分别对应信道预测的实部和虚部。步幅设置为 S ,所有 Conv1D 层填充零,以保持特征矩阵的维数 n 不变。

为了有效地利用信道的分布特性,在网络结构设计中引入了注意力机制。在最初的 CNN 中,所有的特征都被用于具有同等重要性的所有数据样本。然而,在实际应用中,某些特征对某些数据样本来说肯定比其他特征更重要或更有信息量,尤其对于像窄角扩展信道这样高度可分离的数据。例如,关键特征只用于处理特定角度区域的信道分布,而对于距离较远的另一个区域的信道估计可能是无用的,甚至是破坏性的。

如图 3.15 所示,将原始特征矩阵乘以通道式的关注图,得到关注模块中的重新加权的



特征矩阵,对当前数据样本更重要或更有信息量的特征给予更多的 attention。在注意力映射的学习过程中,首先对原始特征矩阵 $\mathbf{Z}_O$ 进行全局平均池化,将全局信息嵌入 $(1,c)$ 维压缩特征矩阵 $\mathbf{Z}$ 中。




图 3.15 Attention-Aided 信道估计框架结构

具体来说, $\mathbf{Z}$ 的第 c 个元素由以下公式给出:

$$z_c = \sum_{f=1}^F [\mathbf{Z}_O]_{f,c} / F \quad (3.1.13)$$

然后,由基于 $\mathbf{Z}$ 的专用注意力网络预测 $(1,c)$ 维注意力图 m 。注意,网络包含两个完全连接的(FC)层。第一层含有 C/R 神经元的 FC 层,随后是 ReLU 激活。第二层含有 C 神经元,经过 Sigmoid 函数激活,它将 m 的元素限制在 $0 \sim 1$ 。

$$f_{\text{Sigmoid}}(x) = 1 / (1 + e^{-x}) \quad (3.1.14)$$

随后进行网络训练。为了训练所设计的网络,使用真实角域信道 x 和预测角域信道 x 之间的 MSE 作为损失函数,该损失函数可以通过下式给出,其中下标 i 表示一个小批处理中的第 i 个数据样本, $n=500$ 是该小批处理的大小。

$$\text{MSE}_{\text{Loss}} = \frac{1}{n} \sum_{i=1}^n \|\hat{\mathbf{x}}_i - \mathbf{x}_i\|^2 \quad (3.1.15)$$

为了平衡训练复杂度和测试性能,根据所采用的信道和传输模型生成总共 20 万个数据样本。然后,将生成的数据集按 3 : 1 : 1 的比例拆分为训练集、验证集和测试集。为了加快训练开始时的损失收敛速度,减少训练结束时的损失振荡,如果在连续 10 个历元内验证损失不减小,则学习速率将衰减至 1/10。此外,为了防止过拟合和加快训练过程,采用了 25 个周期的早期停止。

接下来进行复杂度分析。用两个指标度量复杂度,即所需的浮点操作数和参数总数。简洁起见,计算浮点操作数时只考虑乘法运算,一次复数乘法计算为四次实数乘法;计算参数时忽略 BN 层的权重和偏差,一个复数参数计算为两个实数参数。在分析神经网络的复杂度时,由于网络训练只需执行一次,且实际中 BS 通常具有足够的计算能力,因此忽略了离线训练阶段,而将重点放在在线测试阶段。使用 Attention-Aided 信道估计框架,Conv1D 层和第 L 层 FC 的浮点操作数分别为 LFCC 和 $N_{L-1} N_L$,其中 N_L 表示第 L 层 FC 中的神经元数量。CNN 的浮点操作总数可计算为 $(2L_1 F + 2L_0 F + L_H F^2 (N_B - 1))n$ 。至于参数的总数,Conv1D 层和第 1 层 FC 层分别包含 LCC 和 N_{L-1} 个 N_L 参数,CNN 总共包含 $2(L_1 + L_0)F + L_H (N_B - 1)F^2$ 个参数,注意力模块的附加参数个数为 $N_B F^2$ 。

接下来对所提出方法进行仿真,同时,将与以下几个基线算法进行比较: MMSE 算法、



FNN、没有 attention 的 CNN。

$$\hat{\mathbf{h}}_{\text{MMSE}} = \mathbf{R}_{hh} (\mathbf{R}_{hh} + \mathbf{I}/\text{SNR})^{-1} \hat{\mathbf{h}}_{\text{LS}} \quad (3.1.16)$$

MMSE 将整个角空间分割成多个 3° 角区域,并仅用平均 AOAS 在该区域内的信道样本估计每个区域的专用信道相关矩阵(CCM)。在一个信道样本的测试过程中,首先估计其所属的角度区域,然后选择相应的 CCM 进行信道细化。与对所有信道样本使用单个 CCM 相比,使用多个 CCM 匹配不同的角度区域可以有效利用信道的窄角扩展特性,显著提高性能。实际上可以看作“分而治之”政策的人工实施,即信道样本按其角度区域“分割”,由不同的对应 CCM“征服”。

FNN 结构由 3 个 FC 层组成,分别有 512、1024 和 256 个神经元,每两个 FC 层之间插入一个 BN 层。前两个 FC 层的激活功能是 ReLU,最后一个 FC 层不使用激活。

没有 attention 的 CNN 具有同样的 CNN 结构,但去掉了所有的注意力模块。

仿真参数如表 3.2 所示。

表 3.2 仿真参数

参数	值	参数	值
N	128	Δ_θ	5°
M	32	α_i	$CN(0,1)$
N_p	20	SNR	20dB
θ_i	$u[0, 2\pi]$		

如图 3.16 所示,CNN 的结构主要由卷积块数 N_B 和每个 Conv1D 层的滤波器数 F 决定,注意可以提高不同卷积块数和滤波器数的 CNNs 的性能,两层注意辅助 CNN 的性能甚至优于无注意的四层 CNN,说明了注意机制的优越性。一般来说,卷积块越多,能力越强,网络的性能越好。然而,在有足够的滤波器的情况下,如果滤波器数量不断增加,注意力辅助 CNN 的性能提高是微乎其微的,有时甚至会对没有注意力的 CNN 造成损害。此外,更深更广的 CNNs 也有更重的计算和存储负担。为了在性能和复杂度之间取得平衡,我们选择为每个 Conv1D 层使用四个卷积块和 96 个滤波器。




图 3.16 网络参数 F 对 MSE 的影响



如图 3.17 所示,所有基于 DL 的方法都可以细化和提高 LS 粗估计的信道质量。随着信噪比的增加,模糊神经网络的性能改善程度降低,而 CNN 由于利用了输入数据的局部相关性,在各种信噪比下的性能明显优于 LS。然后,在注意的辅助下,CNN 的 MSE 进一步适度降低。此外,注意机制的性能增益随信噪比的增加而增加。当信噪比为 0 dB 时,CNN 的 MSE 为不注意 CNN 的 89.55%,当信噪比为 20 dB 时,其 MSE 下降到 71.83%。其原因是角域信道的窄角扩展特性更加暴露,更容易被利用,噪声更小,从而放大了注意力的好处。对于 MMSE,MMSE 单机的性能提高不大,而 MMSE 3°由于充分利用了信道的窄角扩展特性,性能提高得更好。然而,所提出的注意辅助 CNN 仍略微优于 MMSE 3°,显示出其优越性。




图 3.17 SNR 对 MSE 的影响

如图 3.18 所示,attention CNN 的性能接近 MMSE 3°,并在不同角度扩展下持续显著优于 LS。随着角扩展的增加,在这两种情况下,由于信道估计问题变得更加复杂,所以所有算法的性能都在下降,角域信道的稀疏性较小。此外,由于渠道分布的不可分离性,注意力的性能增益也会下降,这使得注意力机制更难实现“分而治之”的策略。




图 3.18 角度扩展对 MSE 的影响



如图 3.19 所示,所有算法的性能都随着 n 的增加而提高。由于角域信道的功率泄漏与天线数成反比,因此更多天线引起的信道稀疏性增加可以简化信道估计。attention CNN 的性能接近 MMSE 3° ,而更稀疏的信道可以放大注意力的性能增益。




图 3.19 天线数目和射频链比对 MSE 的影响

在不同信噪比的情况下,本模型的整体性能如图 3.20 所示。




图 3.20 不同信噪比下的整体性能

4. RIS 辅助无线通信系统信道估计

如今,5G 依旧大规模商用,6G 技术处于开始探讨之际,实现超可靠无线通信的根本挑战来自于用户移动性而产生的定时无线信道。解决这一难题的传统方法要么通过利用各种调制、编码和分集技术补偿信道衰落,要么通过自适应功率/速率控制和波束形成技术来适应信道衰落。然而,它们不仅需要额外的开销,而且对大量随机无线信道的控制有限,从而使实现大容量和超可靠无线通信的最终障碍无法克服。

在此背景下,智能反射面/智能超表面(IRS/RIS)成为 5G/6G 无线通信系统中实现智能和可重构无线信道/无线传播环境的一种新范式^[34]。一般来说,IRS 是一个由大量无源反射元件组成的平面,每个无源反射元件能独立地对入射信号产生可控的幅度和/或相位变化。通过在无线网络中密集部署 IRS,并巧妙地协调它们的反射,可以灵活地重新配置发射机和