



深度学习赋能波束管理：现状、挑战与机遇*

王昭诚, 马可

清华大学电子工程系, 北京 100084

摘要: 随着载波频率的不断提高和大规模天线阵列的广泛部署, 基于模拟移相器的波束赋形成为下一代无线通信的标志性技术之一。此时, 波束管理被用于获取和维护基站和用户端具有最大接收功率的最优波束对, 以保障可靠的无线通信服务。传统波束管理方法往往依赖于海量搜索。同时, 传统数学模型无法全面的、准确刻画非线性的波束的内在关联和高维无线环境特征, 因而难以取得令人满意的波束增益性能。近年来, 得益于深度学习强大的自适应拟合能力, 深度学习赋能波束管理得到了国内外广泛关注。本文总结了深度学习赋能波束管理的研究进展, 并展望了未来的研究方向。首先, 阐述了深度学习应用于波束管理的典型场景和潜在优势; 随后, 从空/时/频域切入, 讨论当前深度学习赋能波束管理的主要研究路线和代表性工作; 最后, 面向更大规模的无线网络、更多元的波束管理功能和更鲁棒的深度学习模型, 阐述未来的研究挑战与机遇。

关键词: 深度学习; 波束管理; 空域; 时域; 频域

中图分类号: TN929.5 **文献标志码:** A **文章编号:** 2097-0137(2025)01-0040-11

Deep learning empowered beam management: State-of-the-art, challenges and opportunities

WANG Zhaocheng, MA Ke

Department of Electronic Engineering, Tsinghua University, Beijing 100084, China

Abstract: With the increase of carrier frequencies and the widespread deployment of large-scale antenna arrays, the analog phase shifter based beamforming has become one of the key technologies for the next-generation wireless communications. To ensure reliable wireless services, beam management is usually adopted to acquire and maintain the optimal beam pair with the maximum received power between the base station and the user equipment. However, traditional beam management methods generally rely on large-scale searching, which could bring huge overhead. Additionally, traditional mathematical models cannot comprehensively and accurately model the nonlinear intrinsic characteristics in the received signals from the beam and the high-dimensional features of wireless environments, making it difficult to achieve satisfactory beamforming gain performance. Thanks to its strong adaptive fitting capabilities, deep learning empowered beam management has drawn much attention recently. To this end, this paper reviews the state-of-the-art literatures of deep learning empowered beam management and discusses future research directions. Firstly, the typical scenarios and advantages of applying deep learning to beam management are

* 收稿日期: 2024-06-27 录用日期: 2024-08-15 网络首发日期: 2024-09-29

基金项目: 国家自然科学基金联合基金(U22B2057)

作者简介: 王昭诚(1968年生), 男; 研究方向: 无线通信; E-mail: zewang@tsinghua.edu.cn

通信作者: 马可(1998年生), 男; 研究方向: 无线通信、人工智能;

E-mail: make15@tsinghua.org.cn

全文阅读



ZR20240214

elucidated. Subsequently, the main techniques and representative works in current deep learning empowered beam management are summarized from space/time/frequency domains. Finally, this paper addresses future research challenges and opportunities from the perspective of larger-scale wireless networks, more diverse beam management functions, and more robust deep learning models.

Key words: deep learning; beam management; space domain; time domain; frequency domain

随着人类社会向更高层次的数字化、智能化逐渐迈进, 物联网、车联网、人工智能等新兴应用的蓬勃发展亟需更高吞吐量、可靠的无线通信作为基础性的数据桥梁支撑。然而, 在过去40余年的无线通信技术发展过程中, 载波频率在6 GHz以下的Sub-6G频段已被大量占用, 下一代无线通信需要开辟更高的频段、更丰富的带宽资源以支持日益增长的无线数据通信需求。鉴于此, 工信部率先划分6425-7125 MHz作为国内第六代无线通信(6G, sixth generation)的核心频段之一。同时, 美国、日本、韩国等对中心频率位于24-100 GHz的毫米波频段开展了商业化部署的初步探索。近年来, 更高频段的太赫兹通信受到了学术界的广泛关注(Chen et al., 2019)。

尽管具有海量的带宽资源, 但迈向更高频段的无线通信面临更加显著的传播衰减。具体而言, 无线信号的自由空间传播损耗和大气分子吸收衰减将会随着载波频率的升高而增加(Rappaport et al., 2013); 同时, 波长变短导致无线信号易被建筑、树木等障碍物遮挡(Xiao et al., 2017), 上述因素显著制约了更高频段无线通信的覆盖范围。幸运的是, 由于天线间隔通常和波长成正比, 在高频段大量天线易于集成在有限的空间, 实现大规模天线阵列部署(Heath et al., 2016)。但是, 射频链路的成本随载波频率和带宽升高而显著增加, 传统的Sub-6G频段每根天线配备一个射频链路的数字波束赋形难以在高频段有效实施(Uwaechia et al., 2020)。针对这一问题, 高频段大规模天线阵列通常采用基于移相器的模拟波束赋形结构, 通过调整每根天线发射信号的相位实现波束赋形, 定向传输无线信号(Roh et al., 2014)。在实际通信系统中, 为降低波束赋形复杂度, 通常从预定义的码本中选择备选波束(Kutty et al., 2015)。波束管理致力于获取和维护基站(BS, base station)和用户

端具有最大接收功率的最优波束对, 实现高可靠的无线通信服务。然而, 传统波束管理方法往往依赖于海量搜索, 当备选波束数目较多时将带来较大训练开销(Jeong et al., 2015)。

近年来, 得益于数据驱动的自适应拟合范式和海量参数赋予的强大拟合能力, 深度学习被认为是6G移动通信的核心使能技术之一。作为物理层的三个典型应用场景之一, 第三代合作伙伴计划(3GPP, third generation partnership project)已针对波束管理开展标准化讨论。相比于传统波束管理方法, 深度学习具有两方面的显著优势。首先, 传统方法采用的数学模型往往依赖于理想化假设, 当真实场景与模型假设不一致时, 性能会严重恶化。而深度学习以数据驱动的形式自适应地提取真实场景的内在特征, 能够准确反映实际信道的特性。其次, 传统方法难以全面地对非线性的波束内在关联和高维无线环境特征进行刻画, 性能通常受限。相比之下, 深度学习能够基于海量的可学习参数建模上述复杂特征, 实现高效的波束管理。

鉴于此, 本文总结了深度学习赋能波束管理的现有研究工作, 并讨论未来的研究挑战和机遇。首先, 阐述深度学习应用于波束管理的典型应用场景和相比传统方法的潜在优势; 随后, 从空/时/频域切入, 综述当前深度学习赋能波束管理的研究路线和代表性工作; 最后, 基于更大规模的无线网络、更多元的波束管理功能和更鲁棒的深度学习模型三个视角, 讨论未来的研究挑战与机遇。

1 应用场景和优势

为了充分利用深度学习在自适应拟合非线性高维特征上的优势, 首先阐述其在波束管理中的应用场景。图1展示了深度学习赋能波束管理的典型应用场景。



图1 深度学习赋能波束管理的典型应用场景

Fig. 1 Typical scenarios of deep learning empowered beam management

1.1 深度学习赋能波束管理的应用场景

1.1.1 非线性特征提取 在实际场景中,波束管理面临着多种多样的非线性因素,传统的数学方法通常忽略这些复杂的非线性因素带来的负面影响。相比之下,深度学习能够准确建模这些复杂的非线性特征,并利用它们辅助高效的波束管理。通过深度学习进行非线性特征提取,主要原因如下:

(1) 波束管理在空间角度域具有非线性特征。具体来说,波束通常由模拟移相器生成,其单位幅度约束导致了非线性的波束形状,这被称为功率泄漏效应(Xie et al., 2019)。如图1所示,实现高增益波束赋形需要极其精确的角度对准。一旦发生失准,部分波束功率会泄漏到旁瓣,造成最优波束的接收功率降低。但是,这一特性使得我们能够利用深度学习基于波束训练接收信号估计主导径的到达角(AoA, angle-of-arrival)和离开角(AoD, angle-of-departure),降低波束训练开销。

(2) 波束管理在用户移动场景具有非线性特征。考虑图1左侧所示的视距(LOS, line-of-sight)场景,当用户靠近基站时,LOS径的角度变化速度随着用户和基站间的距离降低而加快,反之亦然。此外,用户的运动速度和方向也是随时间动态变化的。这种用户运动与角度变化之间的非线

性关系使得准确跟踪波束方向变得更加困难,尤其是在高速场景下。幸运的是,深度学习为精确建模上述用户非线性运动特征、高效跟踪最优波束提供了一种切实可行的思路。

1.1.2 高维度环境建模 无线环境包含具有不同位置、大小和形状的大量散射体,这些散射体形成高维度特征空间,并共同决定了最优波束方向。得益于海量的可学习参数,深度学习能够准确建模这些复杂的散射特征。具体来说,AoA和AoD从本质上表征了基站发射信号和用户周围传播环境之间的交互过程。因此,收集得到的训练数据使得深度学习模型可以刻画最优波束方向与特定环境之间的复杂关联,实现面向特定环境的高效波束管理。

此外,由于用户和散射体的移动性,信道遮挡往往会动态地出现和消失。如图1所示,当一辆公交车在车站停靠并遮挡LOS径时,波束需要切换到与最强非视距(NLOS, non line-of-sight)径对准的方向。此时,波束管理需要感知环境变化并确定新的最优波束方向。传统波束管理方法通常通过接收功率阈值检测遮挡,并重新进行波束搜索,导致较大开销。将深度学习应用于波束管理的优势在于其自适应环境动态变化的能力。当深度学习模型经过充分训练后,可以激活持续的在

线学习, 不断收集训练数据并根据环境变化更新模型参数, 实现对动态无线环境的鲁棒性。

1.2 深度学习赋能波束管理的优势

本节选择基于搜索的方法、基于模型的方法和传统机器学习方法等传统波束管理方法, 阐述深度学习应用于波束管理的潜在优势。

1.2.1 基于搜索的方法 由于基站和用户端的备选波束数量往往是有限的, 一种寻找最优波束对的直观方法是穷举搜索, 即扫描所有备选波束对并选择具有最大接收功率的最优波束对。然而, 这种方法可能会带来巨大开销。为解决这个问题, 基于分层多分辨率码本的低开销波束搜索方法被广泛采用, 其中第一层搜索的目标是找到最优宽波束, 随后第二层搜索在选定的宽波束范围内确定最优窄波束方向(Wei et al., 2017)。另一种低开销搜索方法是交互式波束搜索, 其中备选发射和接收波束被分别搜索(Kim et al., 2014)。然而, 这些传统的波束搜索方法没有建模波束训练接收信号内在的非线性关联, 仍然会导致较大开销。相比之下, 深度学习能够提取这些内在关联的非线性特征, 通过只测量少数波束对来预测最优波束对, 从而有效地降低搜索开销。

1.2.2 基于模型的方法 通常来说, 最优波束

需要对准最强径的 AoA 和 AoD 以获得最大接收功率。基于信道模型的统计特性, 寻找最优波束对可以被建模为角度估计问题。例如, 压缩感知被广泛用于根据无线信道的角度稀疏性来估计 AoA 和 AoD(Choi, 2015)。然而, 这些基于模型的方法通常依赖于先验假设, 当这些假设与实际场景不一致时性能会严重恶化。相对而言, 深度学习作为一种端到端的方法, 不需要模型先验假设。基于反向传播算法, 深度学习模型参数能以数据驱动的形式自适应优化, 以应对特定的动态无线场景。

1.2.3 传统机器学习方法 机器学习被广泛用于从收集得到的训练数据中挖掘面向特定环境的知识, 其中传统机器学习方法主要依赖于相对简单的模型。例如, 考虑到备选波束对的数量有限, 寻找最优波束对可被建模为一个分类任务, 从而支持向量机被用于实现分类器(Long et al., 2018)。与这些传统的机器学习方法相比, 得益于其多层隐藏层结构包含的大量可学习参数, 深度学习在面对受高维度无线环境特征支配的复杂波束管理问题时, 具有更强大的拟合能力。

将深度学习与三种传统波束管理方法进行对比, 总结深度学习赋能波束管理的主要优势。结果如表1所示。

表1 深度学习与传统波束管理方法的对比

Table 1 Comparison between deep learning and the conventional beam management methods

波束管理方法	核心特征	优势	缺点
基于搜索的方法	搜索备选波束, 选择接收功率最大的波束作为最优波束	实现简单	搜索开销较大
基于模型的方法	根据信道模型估计最优波束方向	利用信道数学建模减小开销	依赖于先验假设, 当实际场景和假设不符合时性能显著降低
传统机器学习方法	利用传统机器学习方法提取面向特定数据的特征	基于数据自适应, 通常能够取得更优性能	模型相对简单, 拟合能力有限
深度学习方法	利用深度学习提取非线性特征和动态适应无线环境	(1) 端到端学习, 无需显式的先验假设 (2) 海量可学习参数带来的强大拟合能力	计算开销较大

2 深度学习赋能波束管理

实现更高的波束赋形增益和降低波束搜索开销是波束管理的基本目标, 本文从空/时/频域不同视角讨论深度学习赋能的波束管理。首先, 深度

学习可以提取空间角度域的非线性特征实现波束预测, 在保障高波束赋形增益的同时减少波束搜索开销; 其次, 面向用户高速运动场景, 深度学习可以从时域建模用户的运动特征, 实现低开销、

高精度的自适应波束跟踪；最后，面向在第五代无线通信(5G, fifth generation)得到广泛部署的非独立组网(NSA, non-standalone)和异构网场景，深度学习可以根据低频段信道状态信息(CSI, channel state information)感知无线环境，辅助高频段的波束管理。

2.1 深度学习赋能空域超分辨率波束预测

如图2(a)所示，在基于模拟移相器的波束赋形系统中，非线性的功率泄漏效应为我们利用波束训练接收信号估计主导径的AoA和AoD提供了可行性。然而，使用传统估计方法解决该问题面临两个挑战。首先，上述波束内在的非线性关系难以准确建模；其次，复杂的多径分量可能严重干扰角度估计。为解决这些问题，深度学习被用于建模非线性功率泄漏和复杂多径干扰，从而准确估计AoA/AoD。由于最优波束方向通常与主导径的AoA/AoD对准，波束预测可以看作是在备选波束方向上估计相应的量化AoA/AoD，基于低分辨率波束搜索来预测最优高分辨率波束方向，从而降低训练开销。

一种直观的减少波束训练开销的方法是仅测量具有固定角度间隔的少量波束，并利用其接收信号来预测最优波束，称为基于等角度间隔波束的深度学习方法，如图2(b)所示(Ma et al., 2020)。具体而言，由于备选波束的数量有限，该预测被建模为一个分类任务。卷积神经网络(CNN,

convolutional neural network)被用于实现分类，随后采用Softmax函数将输出转换为概率，并选择具有最大预测概率的波束作为最优波束。然而，当主导径的AoA和AoD不位于任何测量波束主瓣内时，其性能可能由于低信噪比(SNR, signal-to-noise ratio)而显著恶化。

为了完全覆盖整个角度空间，Echigo et al. (2021)提出了一种基于宽波束的最优窄波束预测方法，称为基于宽波束的深度学习方法。如图2(c)所示，宽波束和窄波束可以被自然地视为低分辨率和高分辨率波束。该工作将超分辨率波束预测类比为超分辨率图像恢复问题，并采用CNN实现预测。

如图2(a)所示，远离主导径AoA和AoD的波束泄漏功率通常较小。由于SNR较低，从相应接收信号中提取有效信息较为困难。基于此，Ma et al.(2021a)提出仅考虑具有高SNR的宽波束子集合，并利用其接收信号预测最优窄波束，从而进一步减少宽波束训练开销，称为基于高SNR宽波束的深度学习方法。具体而言，该工作利用长短时记忆网络(LSTM, long short-term memory)建模AoA和AoD的时域变化，如图2(d)所示。在当前时隙，该模型不仅预测该时隙的最优窄波束，还预测下一时隙的最优宽波束，以选择下一次宽波束训练的高SNR宽波束备选集合。

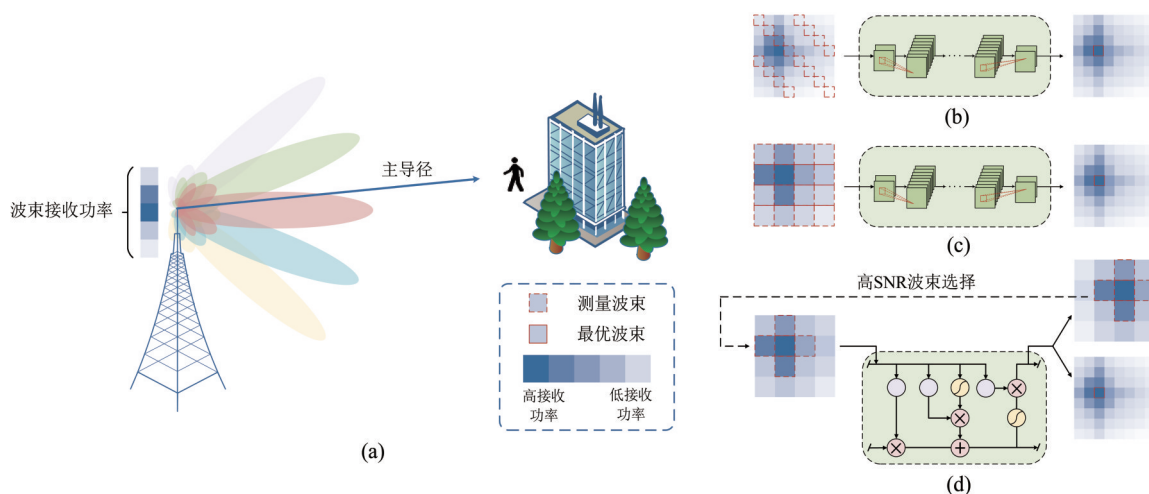


图2 深度学习赋能空域超分辨率波束预测

Fig. 2 Illustration of deep learning empowered space-domain super-resolution beam prediction

图 3 对比了几种深度学习方法和传统超分辨率波束预测方法的有效频谱效率性能, 该指标同时考虑了波束训练开销。仿真参数设置如表 2 所示。信道模型采用 COST 2100 模型(Liu et al., 2012)。传统超分辨率波束预测方法基于最优宽波束和相邻宽波束之间的波束赋形增益比值估计最优窄波束方向, 并忽略噪声影响(Luo et al., 2019)。可以看到, 由于波束训练开销降低, 有效频谱效率一开始随着波束训练周期的增加而增加, 但较长的波束训练周期会降低有效频谱效率, 因为在移动场景中, 较长的数据传输期间更有可能发生波束失准。相比传统方法, 基于深度学习的方法能够取得更优异的性能, 因为其能更加准确建模非线性功率泄漏特征。此外, 得益于较低的训练开销, 基于高 SNR 宽波束选择的深度学习方法具有最高的有效频谱效率, 尤其是在较短的波束训练周期场景中。

表 2 空域超分辨率波束预测的仿真参数
Table 2 Simulation parameters of space-domain super-resolution beam prediction

参数	取值
中心频率/GHz	28
总通信时间/ms	1 000
单个波束测量时间/ms	0.1
基站天线数目	64
备选窄波束数目	64
备选宽波束数目	16
固定角度间隔窄波束数目	16
高 SNR 宽波束选择数目	7
用户运动速度/($\text{m}\cdot\text{s}^{-1}$)	10~50

2.2 深度学习赋能时域自适应波束跟踪

在波束管理中, 另一类典型的非线性特征来自于用户的移动性。然而, 传统的基于扩展卡尔曼滤波的波束跟踪方法通常假设固定的 AoA/AoD 变化模型, 难以处理用户运动与角度变化之间的非线性关系, 尤其是在高速场景下。为解决该问题, 深度学习被用于建模上述非线性特征, 以提高波束跟踪的准确性。

一方面, 深度学习能够与传统波束跟踪流程融合, 从而在更小的跟踪开销下提高波束增益性




图 3 不同空域超分辨率波束预测方法的有效频谱效率对比

Fig. 3 Effective spectral efficiency comparison of different space-domain super-resolution beam prediction methods

能。具体而言, Kaya et al.(2021)提出采用 LSTM 根据历史波束跟踪接收信号预测未来最优波束, 并选择预测概率最高的数个波束进行测量。同时, 用户动态变化的运动速度和方向是影响波束跟踪的另一个关键挑战。当运动速度较高时, 波束跟踪范围需要随之增加, 反之亦然。为了适应用户的不同运动速度, Ma et al.(2022)提出了和概率准则, 选择预测概率之和大于预定义阈值的最高概率波束集合进行跟踪, 从而能够根据预测置信度分布自适应地调整跟踪范围, 在不同移动性下均能够稳定地保障较高的波束赋形增益。此外, Zhang et al.(2020)提出使用深度强化学习(DRL, deep reinforcement learning)自适应地调整波束跟踪范围。在该方法中, 波束跟踪动作由初始波束索引和跟踪波束集合的大小共同决定。所提出的深度 Q 网络与环境交互, 采用有效数据吞吐量反馈调整跟踪范围, 在跟踪开销和准确率之间实现灵活折中。

为了进一步提高波束跟踪性能, Lim et al.(2021)将传统波束跟踪方法与深度学习深度融合。在每次波束跟踪中, 首先利用长短时记忆网络融合历史 CSI 估计和传感器测量结果提取用户的运动特征, 以预测先验角度分布。基于此分布, 该方法预测并测量未来的最优波束; 随后, 通过序贯贝叶斯估计, 根据先验 CSI 构建更准确的后验估计结果。该方法将传统数学模型的专业知识与深度

学习的自适应拟合能力有机结合, 相比于仅依赖训练数据的传统深度学习方法, 实现了更低的跟踪误差。

另一方面, 深度学习能够根据历史的波束训练接收信号估计用户运动特征, 以进行预测性的波束切换, 无需任何额外的波束测量过程。Echigo et al.(2021)的文献中, 在每次波束训练之后, 传统 LSTM 根据历史的波束训练接收信号预测当前和下一次波束训练中间时刻的最优波束, 从而将波束训练开销减半。

但是, 在实际物理场景中波束失准可能随时发生。当波束失准造成无线通信链路质量降低时, 需要及时恢复链路的可靠性, 这带来了设计连续时间尺度波束预测框架的研究目标。然而, LSTM 等传统循环神经网络 (RNN, recurrent neural network) 的内部状态仅对应离散的时刻, 无法建模连续的时间概念。为解决该问题, Ma et al.(2021b)采用了离散近似连续的思路, 预测两次波束训练之间多个均匀采样时刻的最优波束, 并选择最接近目标时间的预测结果进行近似。相应地, 该工作设计了共享参数的级联 LSTM 结构, 以实现从单次波束训练接收信号到多个均匀采样时刻预测输出的拟合过程。为了进一步实现精确的连续时间拟合能力, Ma et al.(2023a)提出将 LSTM 与常微分方程 (ODE, ordinary differential equation) 融合的 ODE-LSTM 架构, 将传统 LSTM 学习时间状态的差分扩展为学习时间状态的导数, 进而采用数值积分方法在时域求解任意时刻的最优波束结果。

图 4 比较了几种基于深度学习的预测性波束切换方法与传统扩展卡尔曼滤波方法在不同归一化预测时刻下的归一化波束增益性能, 仿真参数设置如表 3 所示, 信道数据采用由光线跟踪软件生成的 DeepMIMO 数据集 (Alkhateeb, 2019)。归一化预测时刻指当前波束训练之后、下一次波束训练之前相对于波束训练周期的归一化时刻, 归一化波束增益计算为预测最优波束和实际最优波束的功率比值, 归一化波束增益越高, 波束预测越准确。可以看到, 深度学习方法的性能显著优于传统扩展卡尔曼滤波方法, 因为深度学习能够更加准确地建模非线性的用户运动特征。传统 LSTM 表

表 3 时域波束跟踪的仿真参数

Table 3 Simulation parameters of time-domain beam tracking

参数	取值
中心频率/GHz	28
总通信时间/ms	1 600
基站天线数目	64
备选波束数目	64
波束训练周期/ms	160
用户运动速度/($\text{m}\cdot\text{s}^{-1}$)	20

现出明显的单峰性能, 这是因为传统 LSTM 只能预测与输入周期同步的单个时刻最优波束结果, 因此其趋向于预测中间时刻的最优波束, 使得平均性能最佳。级联 LSTM 和 ODE-LSTM 模型都能够达到稳定的高波束增益性能, 其中 ODE-LSTM 模型性能最优, 因为它内在地实现了连续时间尺度的准确波束预测。




图 4 不同时间域波束跟踪方法的归一化波束增益对比

Fig. 4 Normalized beamforming gain comparison of different time-domain beam tracking methods

2.3 深度学习赋能低频辅助波束管理

无线信道本质上表征了发射信号与基站和用户周围散射环境的交互过程。为实现高效波束管理, 采用辅助信息精确感知无线环境发挥着至关重要的作用。得益于较低的获取成本和可靠的辅助能力, 低频辅助高频段波束管理成为近年来的重要研究方向。

具体而言, 高频段能够提供丰富的带宽资源以支持更大的数据吞吐量, 但由于其信号衰减较大且易受障碍物遮挡, 使用高频段实现稳定的大

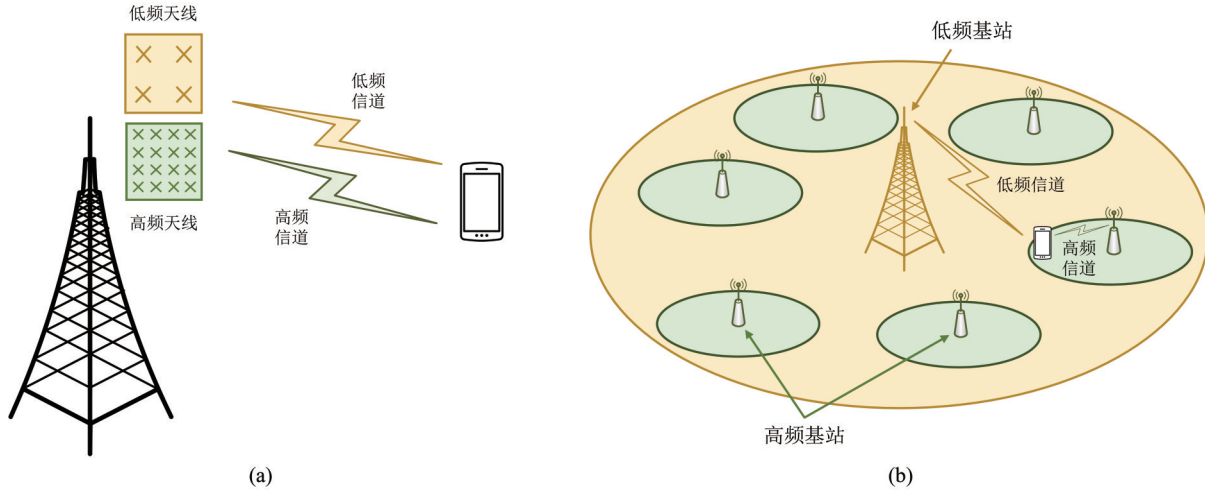


图 5 低频辅助波束管理的典型场景

Fig. 5 Typical scenarios of low-frequency assisted beam management

范围覆盖非常困难, 尤其是在高频段无线通信网络商业化部署的初期阶段。为解决该问题, 高低频混合部署的非独立组网在 5G 移动通信得到了广泛应用。如图 5(a) 所示, 在非独立组网中, 为节省硬件开销, 高频天线通常部署在低频基站上, 形成共址场景。此时, 用户支持双连接(DC, dual connection)功能, 即同时接入上述两个频段。为充分利用双频段的优势, 低频链路往往致力于保障基本的数据传输能力, 用户在具有高速数据传输需求、且高频信道质量较好时接入高频链路, 从而有效改善通信服务体验。在该共址场景中, 高低频信道共享相同的无线环境, 两者信道特征具有一致性。具体而言, 高低频各径的角度、延时和相对强度趋于一致 (Hashemi et al., 2017; Ali et al., 2017)。由于最优波束通常对准主导径, 低频 CSI 可以被用于辅助高频段波束管理, 从而有效降低高频波束搜索开销。但是, 双频段信道的关联性依赖于无线环境中众多散射体的具体性质, 难以被传统数学模型全面建模。因此, 深度学习被用于以数据驱动的形式实现可靠的跨频段波束预测。

基于上述分析, Alrabeiah et al. (2020) 设计了根据低频 CSI 预测高频最优波束的全连接深度神经网络, 其中 Softmax 函数将输出转换为概率。随后, 该工作提出测量预测概率最高的备选波束子集合, 并选择接收功率最大的波束作为最优波束, 从而在较小的额外训练开销下取得更精确的波束

对准。面向用户运动场景, Ma et al. (2021b) 进一步提出采用 LSTM 根据历史的低频 CSI 预测未来的高频最优波束。由于低频链路需要周期性进行 CSI 估计以满足自身通信需求, 该方法不会带来额外的低频开销。但是, Gao et al. (2021) 指出, 由于低频天线数目较少, 仅利用低频 CSI 进行预测难以取得良好性能。因此, 该文献提出了一种基于低频 CSI 和少量高频 CSI 的双频融合预测方法, 并采用深度学习自适应地选择最优的高频天线进行 CSI 测量。

然而, 非独立组网的应用场景存在一定的局限性。具体而言, 由于高频信号衰减较大, 高频小区的半径往往小于低频小区, 共址场景通常只能服务低频基站附近的用户。随着高频基站的进一步密集部署, 共址场景自然地扩展为包含少量低频基站和密集高频基站的异构网, 如图 5(b) 所示。在这种非共址场景下, 高低频基站共享无线环境, 两者信道仍然具有关联性。但是, 相比共址场景, 非共址场景的高低频信道关联性较弱, 仅采用低频 CSI 直接预测高频最优基站和波束的性能通常较差。为解决该问题, Ma et al. (2023b) 提出采用深度学习融合低频 CSI 和高频低开销测量信息, 提高预测性能。具体地, 由于异构网中低频基站覆盖范围较大, 为了获取可靠的高频段信道信息, 需要采用低频 CSI 预测对准用户的少量高频波束进行测量, 以提高接收 SNR。此外, 仅采用低频 CSI 预测得到的结果往往不准确, 为了在较低

的高频段测量开销下覆盖较大的不确定区域,应当优先测量覆盖能力更强的宽波束。因此,该工作提出采用低频 CSI 预测少量对准用户的高频宽波束作为高频段低开销测量信息,并基于注意力机制与低频 CSI 进一步融合以预测高频最优窄波束。随后, Zhao et al.(2024)将异构网双频融合的思想进一步扩展到时域波束跟踪场景,采用 LSTM 实现更加准确的波束预测。此外, Huang et al.(2024)将多基站之间的波束干扰考虑在内,采用图神经网络(GNN, graph neural network)实现低频 CSI 辅助的波束调度。

3 研究挑战和机遇

尽管学术界和工业界针对深度学习赋能波束管理已经开展了一些研究工作,该领域仍有诸多挑战和机遇值得进一步探索和挖掘。

3.1 多模态信道高维特征建模

无线信道本质上表征了电磁信号与周围散射体的交互过程。对基站周围数目庞大、种类繁多的散射体所构成的信道高维特征进行全面准确建模,有助于简洁、精准地刻画无线信道所反映的电磁传播过程,为降低波束管理开销、保障通信服务质量提供了重要契机。6G 移动通信不可避免迈向大数据时代,包括城市环境、用户位置、运动速度、传感器数据、视觉图像在内的多模态信息能够从不同角度刻画周边复杂无线环境。如何对这些多模态信息进行高效鲁棒融合并构建不同基站周边无线环境的统一表征,是精确建模信道高维特征的基础。基于深度学习的自编码器模型能够建立“模态-低维嵌入-信道”的映射结构,并保证相似信道下多模态对应低维嵌入的一致性,有望实现精确高维信道表征,具有重要的研究价值。

3.2 面向多任务的波束功能扩展

现实世界里,包含无线定位、波束管理、信道估计和反馈在内的物理层多任务本质上都由无线环境所决定。一方面,其它任务的信息能够用于辅助波束管理。例如,在 LOS 场景下,准确获取用户位置有助于快速估计最优波束方向。另一方面,波束信息也能够改善其它任务的性能。例

如, 3GPP 定义的 Type-II 码本基于角度-延时域稀疏性,测量最强的数个波束以估计信道状态信息。因此,面向物理层多任务扩展波束管理功能,构建统一的深度学习模型能够充分利用不同任务之间的关联性,从而改善整体性能,并降低模型部署开销。

3.3 面向超大规模网络的灵活波束协调

随着 6G 超大规模无线网络的部署,多基站、多用户之间的高效协同对于保障高质量的无线通信服务至关重要,而突发性的波束干扰是高频段无线通信的关键挑战之一。具体而言,当相邻小区的波束指向本小区用户时,该用户会受到严重的小区间干扰。随着用户运动速度的提升,多用户高速移动场景更容易导致频繁的基站和波束切换,需要高度灵活的跨基站波束协调框架。作为一种潜在的解决方法,基于 GNN 的图上强化学习能天然匹配无线网络的拓扑结构,根据用户移动性对接入关系进行动态调整,可以被用于多基站动态场景下的小区间干扰管理。

3.4 深度学习模型高效训练和迁移

现有深度学习赋能波束管理工作主要基于有监督学习,通过大量标签数据训练深度学习模型。尽管该方法通常能够取得良好的性能,但在实际场景中收集这些标签数据往往会带来巨大开销。鉴于此,以迁移学习、元学习为代表的小样本学习方法能够基于少量样本高效训练深度学习模型,在波束管理中具有较大的应用潜力。其次,最优波束标签通常采用传统波束训练方法收集,开销较大。为解决该问题,可以进一步考虑面向半监督学习的训练方法。其中只收集少量样本的最优波束标签,并基于半监督学习和数据增强技术,充分融合有限的标签数据与大量无标签数据,以提高训练性能。最后,由于计算复杂度较高,深度学习赋能波束管理方法可能会导致较大的功耗开销。鉴于此,以剪枝、量化、知识蒸馏等技术为代表的轻量级模型设计在波束管理中值得进一步的深思与探讨。

4 结 论

随着高频段的天线阵列规模不断扩大,模拟

波束赋形成为下一代移动通信的标志性技术之一, 如何以较低的开销实现高增益的波束对准成为波束管理的核心挑战。近年来, 得益于深度学习强大的自适应拟合能力, 深度学习赋能波束管理得到了国内外的广泛关注。一方面, 深度学习被用于精确拟合波束管理在空域和时域的非线性特征, 实现超分辨率波束预测和自适应波束跟踪。另一

方面, 在非独立组网和异构网场景中, 深度学习能够根据低频信道感知无线环境特征, 辅助高频段波束管理。在此基础上, 本文探讨了深度学习赋能波束管理的挑战和机遇, 包括基于多模态的信道高维特征建模、面向多任务的波束功能扩展、面向超大规模网络的灵活波束协调以及深度学习模型高效训练和迁移等。

参考文献:

- ALI A, GONZÁLEZ-PRELCIC N, HEATH R W, 2017. Millimeter wave beam-selection using out-of-band spatial information [J]. *IEEE Trans Wirel Commun*, 17(2): 1038-1052.
- ALKHATEEB A, 2019. DeepMIMO: A generic deep learning dataset for millimeter wave and massive MIMO applications [C]//*IEEE Information Theory and Applications Workshop(ITA)*. Bahia Resort, San Diego, USA:IEEE: 1-8.
- ALRABEIAH M, ALKHATEEB A, 2020. Deep learning for mm wave beam and blockage prediction using sub-6 GHz channels [J]. *IEEE Trans Commun*, 68(9): 5504-5518.
- CHEN Z, MA X, ZHANG B, et al, 2019. A survey on terahertz communications [J]. *China Commun*, 16(2): 1-35.
- CHOI J, 2015. Beam selection in mm-wave multiuser MIMO systems using compressive sensing [J]. *IEEE Trans Commun*, 63(8): 2936-2947.
- ECHIGO H, CAO Y, BOUAZIZI M, et al, 2021. A deep learning-based low overhead beam selection in mm wave communications [J]. *IEEE Trans Veh Technol*, 70(1): 682-691.
- GAO F, LIN B, BIN C, et al, 2021. FusionNet: Enhanced beam prediction for mm wave communications using sub-6GHz channel and a few pilots [J]. *IEEE Trans Commun*, 69(12): 8488-8500.
- HASHEMI M, KOKSAL C E, SHROFF N B, 2017. Out-of-band millimeter wave beamforming and communications to achieve low latency and high energy efficiency in 5G systems [J]. *IEEE Trans Commun*, 66(2): 875-888.
- HEATH R W, GONZALEZ-PRELCIC N, RANGAN S, et al, 2016. An overview of signal processing techniques for millimeter wave MIMO systems [J]. *IEEE J Sel Top Signal Process*, 10(3): 436-453.
- HUANG Z, WANG Z, CHEN S, 2024. Sub-6GHz assisted mm wave hybrid beamforming with heterogeneous graph neural network [J]. *IEEE Trans Commun*, 99: 1.
- JEONG C, PARK J, YU H, 2015. Random access in millimeter-wave beamforming cellular networks: Issues and approaches [J]. *IEEE Commun Mag*, 53(1): 180-185.
- KAYA A Ö, VISWANATHAN H, 2021. Deep learning-based predictive beam management for 5G mm wave systems [C]//*IEEE Wireless Communications and Networking Conference(WCNC)*. Nanjing, China:IEEE: 1-7.
- KIM J, MOLISCH A F, 2014. Fast millimeter-wave beam training with receive beamforming [J]. *J Commun Netw*, 16(5): 512-522.
- KUTTY S, SEN D, 2015. Beamforming for millimeter wave communications: An inclusive survey [J]. *IEEE Commun Surv Tutor*, 18(2): 949-973.
- LIM S H, KIM S, SHIM B, et al, 2021. Deep learning-based beam tracking for millimeter-wave communications under mobility [J]. *IEEE Trans Commun*, 69(11): 7458-7469.
- LIU L, OESTGES C, POUTANEN J, et al, 2012. The COST 2100 MIMO channel model [J]. *IEEE Wirel Commun*, 19(6): 92-99.
- LONG Y, CHEN Z, FANG J, et al, 2018. Data-driven-based analog beam selection for hybrid beamforming under mm-wave channels [J]. *IEEE J Sel Top Signal Process*, 12(2): 340-352.
- LUO X, LIU W, WANG Z, 2019. Calibrated beam training for millimeter-wave massive MIMO systems [C]//*IEEE 90th Vehicular Technology Conference (VTC2019-Fall)*. Honolulu, Hawaii, USA:IEEE: 1-5.
- MA K, HE D, SUN H, et al, 2021a. Deep learning assisted calibrated beam training for millimeter-wave communication systems [J]. *IEEE Trans Commun*, 69

- (10): 6706–6721.
- MA K, HE D, SUN H, et al, 2021b. Deep learning assisted mm wave beam prediction with prior low-frequency information [C]//IEEE International Conference on Communications (ICC). Montreal, QC, Canada: IEEE: 1–6.
- MA K, ZOU H, SUN C, et al, 2022. Deep learning assisted adaptive mm wave beam tracking: A sum-probability oriented methodology [C]// IEEE Global Communications Conference (GLOBECOM). Rio de Janeiro, Brazil: IEEE: 573–578.
- MA K, ZHANG F, TIAN W, et al, 2023a. Continuous-time mm wave beam prediction with ODE-LSTM learning architecture [J]. IEEE Wirel Commun Lett, 12 (1) : 187–191.
- MA K, DU S, ZOU H, et al, 2023b. Deep learning assisted mm wave beam prediction for heterogeneous networks: A dual-band fusion approach [J]. IEEE Trans Commun, 71 (1): 115–130.
- MA W, QI C, LI G Y, et al, 2020. Machine learning for beam alignment in millimeter wave massive MIMO [J]. IEEE Wirel Commun Lett, 9(6) : 875–878.
- RAPPAPORT T S, SUN S, MAYZUS R et al, 2013. Millimeter wave mobile communications for 5G cellular: It will work! [J]. IEEE Access, 1: 335–349.
- ROH W, SEOL J Y, PARK J, et al, 2014. Millimeter-wave beamforming as an enabling technology for 5G cellular communications: Theoretical feasibility and prototype results [J]. IEEE Commun Mag, 52(2): 106–113.
- UWAECHIA A N, MAHYUDDIN N M, 2020. A comprehensive survey on millimeter wave communications for fifth-generation wireless networks: Feasibility and challenges [J]. IEEE Access, 8: 62367–62414.
- WEI L, LI Q, WU G, 2017. Exhaustive, iterative and hybrid initial access techniques in mm wave communications [C]//IEEE Wireless Communications and Networking Conference (WCNC). San Francisco, CA, USA: IEEE: 1–6.
- XIAO M, MUMTAZ S, HUANG Y, et al, 2017. Millimeter wave communications for future mobile networks [J]. IEEE J Sel Area Commun, 35(9) : 1909–1935.
- XIE T, DAI L, NG D W K, et al, 2019. On the power leakage problem in millimeter-wave massive MIMO with lens antenna arrays [J]. IEEE Trans Signal Process, 67 (18): 4730–4744.
- ZHANG J, HUANG Y, WANG J, et al, 2020. Intelligent interactive beam training for millimeter wave communications [J]. IEEE Trans Wirel Commun, 20(3) : 2034–2048.
- ZHAO Y, ZHANG X, GAO X, et al, 2024. LSTM-based predictive mm wave beam tracking via sub-6GHz channels for V2I communications [J]. IEEE Trans Commun, 99: 1.

(责任编辑 王海蓉)