

文章编号: 1007-5321(2022)06-0021-10

DOI: 10.13190/j.jbupt.2022-147

人工智能在 6G 空口物理层的潜在应用

廖 勇, 杨植景, 李 雪

(重庆大学 微电子与通信工程学院, 重庆 400044)

摘要: 为充分支持万物互联, 第 6 代移动通信系统(6G)必须满足垂直行业严苛的物理层通信需求, 而人工智能技术是提升物理层通信能力的有力手段。首先介绍了人工智能技术原生理论; 然后归纳了人工智能技术在信道估计、信号检测、无源波束赋形和索引调制技术上的应用; 最后梳理了未来人工智能技术潜在应用面临的技术挑战, 探讨了该领域的研究趋势, 展望了其在 6G 空口物理层中的应用前景。

关键词: 人工智能; 第 6 代移动通信系统; 无线通信; 空口; 物理层

中图分类号: TN929.5

文献标志码: A

Research Progress of Potential Applications of AI in 6G Air Interface Physical Layer

LIAO Yong, YANG Zhijing, LI Xue

(School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

Abstract: The sixth generation of mobile communications system (6G) is expected to fully support the Internet of everything, which must meet the strict physical layer communication requirements of industries, and artificial intelligence (AI) is a powerful means to enhance physical layer communication capabilities. To focus on the development of AI in the 6G air interface physical layer, we first introduce the AI native theory briefly, then summarize the specific applications of AI in channel estimation, signal detection, passive beamforming and index modulation. Finally, we point out the technical challenges of potential applications in the future and discuss the research trends of AI in the 6G physical layer.

Key words: artificial intelligence; the sixth generation of mobile communications system; wireless communication; air interface; physical layer

第 5 代移动通信系统(5G, the fifth generation of mobile communications system)为无线通信技术引入了更多的应用灵活性并提高了信号的传输效率。尽管 5G 已应用于增强移动带宽、超可靠低延迟通信和海量机器类通信三大业务场景, 但离“万物互联”的愿景仍有较大差距, 面临诸多技术挑战^[1]。第 6 代移动通信系统(6G, the sixth generation of mobile communications system)的推进将弥补 5G 的不足。

为了满足应用场景在性能、安全性和成本方面多样化的需求, 超大规模多输入多输出(MIMO, multiple input multiple output)^[2]、全息波束形成、可重构智能表面(RIS, reconfigurable intelligent surface)^[3]、太赫兹通信^[4]等新兴技术广泛应用于移动通信领域。但是, 日益复杂的通信场景将会给无线通信物理层(PHY, physical layer)的设计带来巨大挑战。

近年来, 随着人工智能(AI, artificial intelli-

收稿日期: 2022-06-15

基金项目: 重庆市自然科学基金项目(cstc2019jcyj-msxmX0017)

作者简介: 廖 勇(1982—), 男, 副研究员, 邮箱: liaoy@cqu.edu.cn。

gence)技术的应用和发展,将机器学习(ML, machine learning)和深度学习(DL, deep learning)方法引入PHY可以简化其设计,同时还可以进行资源管理和一些无线电参数估计^[5]。其中,基于DL方法可构建不同的功能模块,对整个通信系统的质量并不会产生很大的影响^[6]。利用AI技术在理论上可以实现整个收发机所有模块的功能。因此,通信PHY的块结构转换到使用DL方法的端到端优化代表了一个根本性的转变,彻底改变和超越了现有的无线通信模式。

鉴于上述研究背景,首先从无线通信的需求出发,指出目前无线通信PHY的发展趋势是利用AI技术对其进行端到端优化;然后,探讨了AI技术的原生理论;接着,总结了AI技术在物理层领域一些最新研究进展,重点分析和归纳了信道估计、信号检测、无源波束赋形和索引调制(IM, index modulation)4部分内容;最后指出了AI技术在未来6G发展过程中可能会面临的挑战和未来的发展趋势。

1 AI技术原生理论

AI技术是一门发展了模拟和扩展人类智能的理论、技术和方法的技术^[7],人们试图利用该技术理解智能的本质并用机器来模拟人脑的信息处理。作为AI技术的典型实现方法,利用ML方法可以计算和预测从数据中获得的经验和知识^[8]。而DL方法本质上是ML方法的一个分支,它使模型能够基于大型数据集进行分类、预测或决策,而无需显式编程。ML方法能从数据中学习并做出决策或预测。根据训练方法,ML方法可以分为有监督学习、无监督学习和强化学习(RL, reinforcement learning)3种方法。

有监督学习通常用于有足够标签数据的场景,这一类的典型算法包括朴素贝叶斯、 k -临近法(KNN, k -nearest neighbor)、随机森林^[9]、神经网络、支持向量机(SVM, support vector machine)、决策树。而无监督学习算法则是被给予一组无标记的输入以正确地推断输出。典型的无监督算法包括 k -means^[10]自组织映射^[11]、隐马尔可夫模型和受限玻尔兹曼机。半监督学习是监督学习和无监督学习的结合。伪标记是半监督学习算法的典型例子^[12]。为了充分利用无标记数据,半监督学习算法通常需要对数据集进行一定的假设,如流形

假设、低密度假设、聚类假设和平滑假设^[13]。用RL方法则是通过试错法来模仿大脑的学习过程^[14],在动态过程中探索最佳行动。RL可分为有模型学习和无模型学习。由于用动态网络难以建立准确的模型,所以基于无模型的RL方法更适用于移动网络^[15]。

DL方法是ML方法的一个分支,可以通过学习数据实现预测、分类或其他决策。与依赖于预定义特征的传统ML方法相比,DL方法可以通过多层非线性处理单元从原始数据中提取基本特征,根据目标进行预测或采取行动^[16]。

2 AI技术使能6G空口物理层的关键处理

AI技术能学习到输入输出的映射关系,因此可以作为下一代无线通信系统的解决方案^[17]。AI技术使能的PHY技术主要包括信道估计、信号检测、调制解调、信道编码和解码、端到端优化、IM和无源波束赋形等。

2.1 信道估计

目前业界常用的正交频分复用(OFDM, orthogonal frequency division multiplexing)信道估计是基于导频辅助的方式,在设计导频时需要系统开销和信道估计性能进行折中。Chun等^[18]提出了一种应用于下行大规模MIMO系统的两阶段的基于深度神经网络(DNN, deep neural network)的信道估计方法。随后,Chun等^[19]将该研究扩展到了上行的多用户MIMO系统中,与文献[18]不同的是,文献[19]中的信道估计跳过了数据辅助估计阶段,直接利用两层神经网络构造了一个导频设计器,并利用DNN进行信道估计。

在高速移动通信中,无线信道的快时变和非平稳特性使信道估计成为具有挑战性的问题。为了跟踪到每个时刻信道的变化状态并挖掘其中的相关性,Pan等^[20]和Liao等^[21]都利用了长短期记忆(LSTM, long short-term memory)网络来跟踪信道的变化。

在毫米波大规模MIMO系统中,射频链的数量远远小于天线的数量,因此信道估计是一个十分复杂的问题。近似消息传递(AMP, approximate message passing)算法是一种强大的稀疏信号恢复迭代算法,可以低复杂度来估计波束空间信道^[22-23]。然而,用AMP算法很难找到最优的收缩参数(通常

使用经验收缩参数代替),限制了其在实践中的信道估计性能的提升。因此,He 等^[24]将具有一定性能保证的传统算法与 DL 方法相结合,提出了一种用于信道估计的基于学习降噪的近似消息传递(LDAMP, learned denoising-based approximate message passing)网络。为了提高稀疏信号恢复的性

能,Zhang 等^[25]在 LDAMP 网络的基础上设计了一种更好的基于卷积神经网络(CNN, convolutional neural network)的去噪网络。
基于 DL 方法的信道估计算法如表 1 所示。可以看到,几乎所有基于 DL 方法的信道估计算法都适用于上行场景。

表 1 基于 DL 方法的信道估计算法

文献	DL 网络结构	基准算法	上行/下行	导频设计	应用系统
[18]	DNN	数据辅助的线性最小均方误差 ^[26]	下行	—	MIMO
[19]	DNN	最小均方误差	上行	—	MIMO
[20]	数据导频辅助的 LSTM	不结合数据导频辅助的 LSTM	—	—	OFDM
[21]	CNN、双向 LSTM	BEM-EKF(basic extra model-extended Kalman filter),BEM-LS(BEM-least squares)	—	块状导频	OFDM
[24]	LDAMP	AMP 变体	上行	—	毫米波大规模 MIMO
[25]	FCDAMP(fully convolutional denoising approximate message passing)	LDAMP,AMP 变体	上行	—	毫米波大规模 MIMO

2.2 信号检测

在大规模 MIMO 系统中,传统算法的计算复杂度较高,因此在检测算法中需要在计算复杂度和误码率性能之间寻找平衡。Samuel 等^[27]采用基于可训练变量的迭代算法设计了检测网络结构。受其启发,He 等^[28]提出模型驱动的 DL 检测器,分别将网络命名为正交近似消息传递网络(OAMP-Net, orthogonal approximate message passing network)^[29]和 OAMP-Net2。该检测器是在 OAMP 算法基础上利用 DL 方法得到的。

与模型驱动相对应的另一种检测算法是基于数据驱动,其原理是将信号检测整体看作一个黑匣子,用神经网络替代。Al-Baidhani 等^[30]提出了一种纯数据驱动的 DNN 体系结构,用于检测在有带宽约束的多径衰落信道中传输的符号。与该网络结构类似的还有文献[31]中所描述的结构,其主要思想是使用小的子 DNN 代替单个大的 DNN。

除了单独使用模型驱动或者数据驱动的检测算法,Jia 等^[32]将基于模型的检测器与传统的检测算法相结合,提出了一个部分学习方案,使用神经网络检测 MIMO 系统中幅度相位调制符号的非线性部分,其余的幅度-相位调制符号由传统的迫零(ZF, zero forcing)进行线性检测。

目前大部分的研究都遵循 DNN 的基本原理,即通过堆叠隐藏层来构建深度网络以提高学习能

力。然而,Jin 等^[33]认为在一定数量的隐藏层之后,深化网络并不能显著提高误码率的性能,因此提出了一个并行检测网络,其中多个 DNN 并行执行,最后选择一个似然函数最大的神经网络,获得分集增益。

基于 DL 方法的检测器中使用的网络也是影响检测性能的一个关键因素。Chen 等^[34]比较了 DNN 和 CNN 的检测器,结果表明,基于 DNN 方法的性能比基于 CNN 方法的性能更优。而 Baek 等^[35]针对不同信道环境的 MIMO 信道选择了基于 CNN、DNN、循环神经网络(RNN, recurrent neural network)的检测器与最大似然检测进行对比。基于 DNN 检测器的性能优于基于 CNN 的体系结构^[34],但在不同环境下性能有所下降^[35],这表明最优的神经网络结构依赖于系统模型和环境。

表 2 所示为基于 DL 方法的信号检测算法。可以看出,大部分研究所用检测的信道模型都是基于完美的信道状态信息(CSI, channel state information),没有从实际出发考虑信道估计所带来的 CSI 误差。

2.3 无源波束赋形

无源波束赋形是下一代无线通信系统 RIS 中的关键技术之一。基于 AI 技术的波束赋形方法能够在降低系统复杂性的同时依然保持 RIS 的完全无源性质,因此在下一代无线通信系统中具有巨大潜力。

表 2 基于 DL 的信号检测算法

文献	DL 网络结构	基准算法	数据驱动/模型驱动	CSI 类型
[27]	DetectionNet	AMP	模型驱动	完美
[28]	OAMP-Net	OAMP	模型驱动	完美
[29]	OAMP-Net2	OAMP, ML	模型驱动	不完美
[30]	DNN	判决反馈均衡、理论瑞利信道	数据驱动	完美
[31]	Sub-DNNs	ML, 普通 DNN	数据驱动	完美
[32]	部分学习的 DNN	ZF, ML, 普通 DNN	部分模型驱动	完美
[33]	并行 DNN	DetectionNet	数据驱动	完美
[34]	DNN, CNN	ZF, ML, DetectionNet	数据驱动	不完美
[35]	DNN, CNN, RNN	ML	数据驱动	完美

如表 3 所示,基于 ML 方法的无源波束赋形算法已得到广泛研究。

在大型 RIS 中,反射波束带来的训练开销难以承受。Taha 等^[36]为 RIS 侧的波束赋形设计提供了多层感知器 (MLP, multilayer perceptron) 框架,所考虑的风险方案使用混合结构,有源和无源元件同时存在,降低了系统开销。Özdoğan 等^[37]使用 DL 方法优化 RIS 侧的相位配置,学习和利用本地传播环境。Sheen 等^[38]提出一种基于 DL 方法的建模方法,用该方法学习周围环境对通信网络的影响,映射 RIS 相位配置与接收机位置的关系,不需要 CSI 而直接映射,大大减少了信道数据。

深度强化学习 (DRL, deep reinforcement learning) 方法具有强大的学习和决策能力,在 RIS 辅助的下一代移动通信系统的物理层中,是一个强有力的候选者。

虽然使用 DL 方法进行相移设计取得了一定成

果,但这种监督式学习方法需要大量的有标签数据,而这些数据很难获得;相反,基于 DRL 的方法不需要训练标签,且拥有在线学习和样本生成的特性,更具存储效率。Feng 等^[39]提出了针对 DL 方法辅助的 RIS 方案和深度确定性策略梯度 (DDPG, deep deterministic policy gradient) 算法,使下行链路的计算信噪比最大化。但是,训练导频开销将导致系统负载、存储需求和硬件成本较高。为了克服多个神经网络带来的计算复杂性和硬件限制,Ge 等^[40]提供了一种深度迁移学习和无监督学习相结合的模式。

DDPG 算法也被 Gong 等^[41]用于优化和加速学习过程,在网络学习阶段搜索每个决策的最佳动作,优化了搜索空间,加快了学习阶段的进程,但是在一定程度上与 DL 方法的无模型性质相矛盾。为了补偿当前 DRL-DDPG 应用的模型依赖, Huang 等^[42]、Feriani 等^[43]和 Taha 等^[44]提出了改进的 DRL 方法,使系统在不断变化的信道条件下具有鲁棒性。通过

表 3 基于 ML 方法的无源波束赋形算法

文献	ML 方法	网络结构	主要贡献
[36]	DL	MLP	提出一种基于 DL 方法的大型智能表面反射矩阵设计方案,降低了开销
[37]	DL	DNN	训练前馈神经网络获得最佳相位矩阵,忽略了传统信道估计的中间步骤
[38]	DL	DNN	使用 DL 方法学习了最佳相位配置和可实现速率之间的直接映射
[39]	DRL	DNN	提出了用于 DL 方法辅助 RIS 方案的 DDPG 算法
[40]	DTL	DNN	提出了一种基于深度迁移学习的算法,降低了硬件复杂度和训练负载
[41]	DRL	DNN	提出了一种新的 DRL 方法,与传统无模型 DRL 方法相比,显著提高了学习效率和奖励性能
[42]	DRL	DNN	提出了一种基于 DRL 方法的发射波束形成和 RIS 相移矩阵的联合设计算法
[43]	DRL	Feedforward NN	使用 DRL 方法增强了系统对噪声和用户移动性的鲁棒性
[44]	DRL	DQN	提出了一种新的 DRL 方法,用于以最小的波束训练开销预测反射矩阵
[45]	DRL	DNN	提出了一种解决具有高分子吸收和衰减的 RIS 辅助太赫兹通信路径损耗优化问题的方法
[46]	DRL	NN	研究了一种基于可实现速率和计算时间性能的设备到设备网络资源分配和相移配置优化方法

这些改进的 DRL 方法,不仅可以学习信道信息,还可以学习信道行为。与传统的 DRL 方法相比,改进的 DRL 方法在噪声信道和移动场景中获得了更高的信噪比。

传播损耗是太赫兹通信的核心研究内容之一。Huang 等^[45]提出一种混合波束赋形方法,以解决 RIS 辅助的太赫兹通信路径损耗优化的问题。与 ZF 和交替波束赋形相比,所提方法的覆盖范围扩展了 50%。

除上述应用,用 DRL 方法还可在 RIS 辅助系统中对传输功率和相移配置进行联合优化。Nguyen 等^[46]提出了一种设备到设备网络执行资源分配优化的方案,能在几乎没有训练开销的情况下学习和调整最佳中继选择。

综合上述研究成果得出结论:将 RIS 与 DL 方法相结合所获得的结果不能充分满足 6G 和更新一代移动通信系统的灵活性和所需性能,需要针对这些问题开展进一步研究。

2.4 索引调制

大规模 MIMO 技术为通信系统带来了更高的通信容量,同时需要具有精确的 CSI,以确保通信性能。为了获取 CSI,大规模 MIMO 系统中每个用户都必须估计大量的信道响应,这会产生巨大的反馈开销。为解决上述大规模 MIMO 的固有问题,IM 是下一代无线通信的关键候选技术。

除了减少对大量射频链的需求,IM 方案中利用通信系统构建模块的索引传输额外的信息比特,提供了高能量和频谱效率^[47]。然而,检测器的复杂度

和误码率间的平衡是 IM 方案的固有问题。采用发射天线选择(TAS, transmit antenna selection)、功率分配和调制与编码策略(MCS, modulation and coding scheme)选择等算法可以进一步提高 IM 方案的误码率,但实现这些算法非常复杂,而使用 DL 方法对提高 IM 系统的效率具有较大作用。

基于 DL 方法的 IM 方案如表 4 所示。Yang 等^[48]考虑 2 种不同的 ML 方法,为解决空间调制多输入多输出(SM-MIMO, spatial modulation multiple input multiple output)系统中的 TAS 和功率分配问题提出了一种新的数据驱动框架。作为最初的研究,在该框架中通过使用 KNN 和 SVM 等有监督学习分类器,相较于传统方法得到的复杂度更低。Arslan 等^[49]通过删除天线选择过程中的重复元素,将计算开销降至最低,与前人所做工作中的网络相比具有更少的隐藏神经元^[48]。

Zhang 等^[50]提出了基于 DNN 和基于梯度提升决策树的 TAS-SM 技术。梯度提升决策树的复杂度比 DNN 的复杂度低,误码性能稍差。Gecgel 等^[51]针对实际信道场景提出了基于 DNN 和基于决策树的 TAS-广义空间调制(TAS-GSM, TAS-generalized spatial modulation)方案。Mohamed 等^[52]提出了另一种 TAS-SM 方案,该方案中基于 DNN 将信道矩阵的模和信道矩阵的相关性组合为特征向量。

Liu 等^[53]针对全双工 SM 系统解决了 TAS 问题。与之前大多数 TAS 方法中使用联合特征向量生成相比,所提的基于主成分分析的特征向量生成提取了信道矩阵的向量特征,降低了误码率。

表 4 基于 DL 方法的 IM 方案

文献	主要贡献	应用
[49]	提出了一种基于 ML 方法的 SM-MIMO 系统的低成本链路自适应新框架	TAS&PA
[50]	利用 DNN 实现了 SM 系统的 TAS,在不涉及 TAS 度量重复部分的情况下减少了处理负载	TAS
[51]	提出了一种基于 DL 方法的新发射天线选择方案	TAS
[52]	提出了一种基于 ML 方法的大规模 MIMO-GSM TAS 方案,与基于欧几里得距离方法相比,具有更优的性能	TAS
[53]	针对 SM-MIMO 系统,提出了基于监督学习分类器的 TAS 方案,具有更低的误码率和更低的复杂度	TAS
[54]	提出了基于 SVM 和 DNN 两种新的 TAS 方法,减少了残余自干扰对全双工空间调制系统性能的影响	TAS
[55]	对于 SM 系统,提出了一种学习方法来预测瞬时信道状态下的符号错误率	MCS
[56]	提出了一种基于 DNN 的动态 SM-MIMO 系统互信息计算方法	MCS
[57]	使用多层前馈神经网络评估了 GSM 链路的容量,降低了计算复杂度	MCS
[58]	提出了一种基于信道特征集和 DNN 的编码速率选择机制	MCS
[59]	提出了一种基于 DL 方法自适应选择 SM 系统中的最佳 MCS	MCS
[60]	提出了一种基于 DNN 的调制顺序选择方案,在系统计算复杂度和误码率间实现有效的平衡	MCS

除了 TAS 和功率分配, MCS 是提高 IM 系统效率的另一方式。Saxena 等^[54]研究了 SM-MIMO 系统中基于 DNN 的码本选择方法, 根据基于 DNN 的符号错误率预测在码本之间的动态切换。Tato 等^[55]提出了一种基于 DNN 的方法, 用于计算动态 SM-MIMO 系统的互信息, 允许动态 MCS 自适应。与传统的 Taylor 和 Jensen 近似方法相比, 基于 DNN 的方法几乎完美地获得了互信息, 其复杂度显著降低。此外, Tato 等^[56]在 SM-MIMO 系统的基础上扩展至 GSM-MIMO, 允许动态自适应, 通过计算得到 GSM-MIMO 系统模型的信道容量。

Tato 等^[57]介绍了基于 DNN 动态码率选择方案的 SM-MIMO 系统, 实现了接近最大的吞吐量, 并且在误码率约束下其性能优于固定码率方案。Tato 等^[58]扩展了模型, 以预测最佳的 MCS, 而不是仅根据相同的输入特征预测编码率。基于 DNN 的 MCS 选择方法接近吞吐量性能的上限, 正如编码速率优化方案, SM-MIMO 系统的效率得到了提高。与之前的研究不同, Twarayisenze 等^[59]提供了一种基于 DNN 的调制顺序选择方案, 不考虑系统的编码率, 与传统的 SM-MIMO 系统相比具有更低的复杂度。

研究发现, 因为在 DL 方法中采用了复杂度极低的算法, 提高了系统效率。IM 方案在未来 6G 及其他通信技术中的潜力已经得到释放。

3 技术挑战

AI 技术为下一代无线通信带来了诸多性能优势的同时, 仍然存在一些待解决的问题。下面列举 4 类与无线通信密切相关的 AI 技术挑战。

1) 可解释性(可靠性)

ML 方法的可解释性是相关学者^[60-62]提出的问题之一, 很多的 DNN 无法完全从人类的角度理解模型的决策。可解释性研究的必要性包括 3 部分。①高可靠性的要求。实践中神经网络经常有难以预测的错误, 这对于要求可靠性较高的系统很危险。②科学的要求。科学研究可以发现新知识, 可解释性正是用以揭示其原理。③伦理/法规的要求。可解释性背后的理论是以人类为中心, 反映的是如何通过解释模型达到人类对模型的信任, 从而产生更加安全可靠的应用, 进而推动整个 AI 技术产业的进步。

2) 计算复杂度

根据麻省理工学院的研究结果^[62], 在 Dennard-scaling 时代, 用 AI 技术计算的功耗几乎遵循摩尔定

律。然而在多核时代, 功耗的增长速度开始超过摩尔定律。如今已经进入 DL 时代, 由于 DL 方法对暴力计算的需求, 功耗的增长远远超过摩尔定律的增长率, 至少达到 10^5 级。

此外, 要将 ML 方法的错误率降低到 5%, 计算成本非常高, 需要 1 000 亿美元和 10.5 亿个程序指令^[63]。因此, 降低计算复杂度成为未来 AI 技术研究的首要任务。即使通过某些技术, 如剪枝、低维压缩等, 可以缓解这个问题, DL 方法的计算危机仍然是未来几十年需要解决的问题。

3) 分布式和实时要求

大多数现有的基于 AI 技术的解决方案都是耗费资源且耗时的, 因此, 由集中式智能计算和分布式边缘智能计算组成移动智能网络至关重要。嵌入在无线网络边缘的分布式轻量级 AI 技术可以显著促进超低延迟服务^[64]。利用边缘智能计算分析本地数据, 可以减少数据传输过程中的成本、安全风险和延迟。然而, 分布式边缘节点可能具有不同的学习能力, 并且数据集的大小和质量可能不同, 如何依靠小数据确保边缘智能计算的可靠性是一个具有挑战性的问题。

4) 可验证性

大多数关于将 ML/DL 方法应用于无线通信的现有研究是通过仿真实验分析、验证其性能的优劣。通常, 在训练和验证中使用的是合成网络数据集, 不是真实环境下的数据, 模拟信道往往不够真实。因此, 模拟环境和真实环境之间存在巨大差异。如实际场景中多样化的动态物理信道比数学模型生成的模拟系统中的信道环境更复杂、更多样化。虽然研究者提出的大多数解决方案在合成网络数据集下的表现良好, 但仍需进一步验证在实际网络环境中的适用性。因此, 来自实际移动通信网络的真实数据集对于研究人员验证和比较新方法的性能非常重要。

4 研究趋势

未来可将 AI 技术应用于超大规模 MIMO 系统、先进波形/调制、RIS 系统和物理层安全 4 个方面。

从智能接收机的角度而言, 现有研究中的大多数检测器需要完美的 CSI 才能成功运行。在超大规模 MIMO 系统中, 由于发射天线数量多, 给信道估计带来巨大挑战, 不可能开发一个具有完美 CSI 假设的系统模型。因此, 基于 ML 方法的接收机框架, 包

括信道估计器和符号检测器,将在未来变得更加常见和更具实用性。此外,在计算机模拟环境中使用通用信道模型评估所提网络模型可能存在一定缺陷,因为现实场景中存在更多的损失,无法清楚地了解这些损失如何影响 ML 方法的性能。

在未来超高速移动场景下,新的波形/调制值得关注。目前,正交时频空调制^[65]正在成为研究热点。在高多普勒频移的情况下,时延多普勒域中信道的稀疏性和低变异性使信道估计和信号检测得以简化^[66]。由于信道表示的特殊性,关于信道估计、导频设计、信号检测等问题的研究还有很大空间。

在大多数 ML 方法的研究中只关注优化性能指标,如误码率和峰均比。但在多载波系统中,要考虑多个关键性能指标。因此,基于 DL 方法的技术联合优化多个性能指标,提高整体性能非常重要。此外,在设计基于 DL 方法的方案时,需要考虑 6G 应用中的具体要求,如增强移动宽带、超高可靠低时延通信、海量物联及可能的组合。因此,基于 ML 方法的多载波波形设计仍然是待解决的问题。大多数基于 ML 方法的解决方案中未考虑真实世界的数据集,为了发挥基于 ML 方法的作用,需要通过实际场景验证。

考虑到 6G 及其他无线通信技术的需求,通过保留 RIS 的无源结构并以低成本实现高性能降低整个系统的复杂性至关重要。为了达到上述目的,需要考虑最佳 RIS 配置。因此,将面临在 ML 方法的辅助下如何有效配置 RIS 的问题。解决了这个问题则可以评估适用的 RIS 配置场景,在用户侧进行有效的信道估计,减少信号开销并优化发射功率。

DL 方法对于提高下行链路非正交多址接入系统的性能和系统在用户和速率方面的整体性能也具有重要意义。通过这种方式可以降低系统的复杂性和功耗,从而在性能上超越 5G。

需要重视新兴的 PHY 安全系统。现有研究结果证明,用 ML 方法对 PHY 的安全性具有积极影响。尽管已经考虑到各种网络或攻击模型,但未针对所有场景测试 ML 方法对安全性的影响,如对 OFDM-IM/OFDM 系统或 RIS 辅助网络保密能力的影响仍然有待研究。

5 结束语

详细介绍了 AI 技术在 6G 空口 PHY 的潜在应用,主要包括信道估计、信号检测、无源波束赋形和

IM 调制。通过与传统方法的对比,AI 技术在 6G 空口 PHY 的优势显而易见。同时,梳理出 AI 技术在无线通信系统应用中所面临的挑战,包括技术挑战和伦理等非技术挑战。尽管如此,AI 技术必将深刻改变下一代通信系统的设计和部署方式。最后探讨了 AI 技术在未来无线通信系统中的研究方向。通信系统将会是智能化的,并将向智慧通信演进。

参考文献:

- [1] HUANG T Y, YANG W, WU J, et al. A survey on green 6G network: architecture and technologies [J]. IEEE Access, 2019, 7: 175758-175768.
- [2] SARIEDDEEN H, ALOUINI M S, AL-NAFFOURI T Y. Terahertz-band ultra-massive spatial modulation MIMO[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(9): 2040-2052.
- [3] ZHOU G, PAN C H, REN H, et al. A framework of robust transmission design for IRS-aided MISO communications with imperfect cascaded channels [J]. IEEE Transactions on Signal Processing, 2020, 68: 5092-5106.
- [4] RAHAMAN M H, BANDYOPADHYAY A, PAL S, et al. Reviewing the scope of THz communication and a technology roadmap for implementation[J]. IETE Technical Review, 2021, 38(5): 465-478.
- [5] QIN Z J, YE H, LI G Y, et al. Deep learning in physical layer communications[J]. IEEE Wireless Communications, 2019, 26(2): 93-99.
- [6] O'SHEA T, HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017, 3(4): 563-575.
- [7] RUSSELL S J, NORVIG P. Artificial intelligence: a modern approach[M]. New York: Pearson, 2019.
- [8] ANDERSON J R, MICHALSKI R S, CARBONELL J G, et al. Machine learning: an artificial intelligence approach[M]. Palo Alto: Tioga Press, 1983.
- [9] KULKARNI V Y, SINHA P K. Pruning of random forest classifiers: a survey and future directions [C] // 2012 International Conference on Data Science & Engineering (ICDSE). Piscataway, NJ: IEEE Press, 2012: 64-68.
- [10] SHI N, LIU X M, GUAN Y. Research on k -means clustering algorithm: an improved k -means clustering algorithm[C] // 2010 Third International Symposium on Intelligent Information Technology and Security Informatics. Piscataway, NJ: IEEE Press, 2010: 63-67.
- [11] KOHONEN T. Self-organized formation of topologically

- correct feature maps[J]. *Biological Cybernetics*, 1982, 43(1): 59-69.
- [12] WU H, PRASAD S. Semi-supervised deep learning using pseudo labels for hyperspectral image classification[J]. *IEEE Transactions on Image Processing*, 2019, 27(3): 1259-1270.
- [13] XIE J F, YU F R, HUANG T, et al. A survey of machine learning techniques applied to software defined networking (SDN): research issues and challenges[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(1): 393-430.
- [14] KIUMARSI B, VAMVOUDAKIS K G, MODARES H, et al. Optimal and autonomous control using reinforcement learning: a survey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(6): 2042-2062.
- [15] ELSAYED M, EROL-KANTARCI M. AI-enabled future wireless networks: challenges, opportunities, and open issues [J]. *IEEE Vehicular Technology Magazine*, 2019, 14(3): 70-77.
- [16] HATCHER W G, YU W. A survey of deep learning: platforms, applications and emerging research trends[J]. *IEEE Access*, 2018, 6: 24411-24432.
- [17] ZHANG P, LI L H, NIU K, et al. An intelligent wireless transmission toward 6G[J]. *Intelligent and Converged Networks*, 2021, 2(3): 244-257.
- [18] CHUN C J, KANG J M, KIM I M. Deep learning-based channel estimation for massive MIMO systems [J]. *IEEE Wireless Communications Letters*, 2019, 8(4): 1228-1231.
- [19] CHUN C J, KANG J M, KIM I M. Deep learning-based joint pilot design and channel estimation for multiuser MIMO channels [J]. *IEEE Communications Letters*, 2019, 23(11): 1999-2003.
- [20] PAN J, SHAN H G, LI R P, et al. Channel estimation based on deep learning in vehicle-to-everything environments [J]. *IEEE Communications Letters*, 2021, 25(6): 1891-1895.
- [21] LIAO Y, HUA Y X, DAI X W, et al. ChanEstNet: a deep learning based channel estimation for high-speed scenarios [C] // ICC 2019. Piscataway, NJ: IEEE Press, 2019: 1-6.
- [22] DONOHO D L, MALEKI A, MONTANARI A. Message passing algorithms for compressed sensing: I. motivation and construction [C] // 2010 IEEE Information Theory Workshop on Information Theory. Piscataway, NJ: IEEE Press, 2010: 1-5.
- [23] ZOU X B, LI F W, FANG J, et al. Computationally efficient sparse Bayesian learning via generalized approximate message passing [C] // 2016 IEEE International Conference on Ubiquitous Wireless Broadband. Piscataway, NJ: IEEE Press, 2016: 1-4.
- [24] HE H T, WEN C K, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems [J]. *IEEE Wireless Communications Letters*, 2018, 7(5): 852-855.
- [25] ZHANG Y H, MU Y F, LIU Y, et al. Deep learning-based beamspace channel estimation in mmWave massive MIMO systems [J]. *IEEE Wireless Communications Letters*, 2020, 9(12): 2212-2215.
- [26] MA J J, PING L. Data-aided channel estimation in large antenna systems [J]. *IEEE Transactions on Signal Processing*, 2014, 62(12): 3111-3124.
- [27] SAMUEL N, DISKIN T, WIESEL A. Deep MIMO detection [C] // 2017 IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications. Piscataway, NJ: IEEE Press, 2017: 1-5.
- [28] HE H T, WEN C K, JIN S, et al. Model-driven deep learning for MIMO detection [J]. *IEEE Transactions on Signal Processing*, 2020, 68: 1702-1715.
- [29] HE H T, WEN C K, JIN S, et al. A model-driven deep learning network for MIMO detection [C] // 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Piscataway, NJ: IEEE Press, 2018: 584-588.
- [30] AL-BAIDHANI A, FAN H H. Learning for detection: a deep learning wireless communication receiver over Rayleigh fading channels [C] // 2019 International Conference on Computing, Networking and Communications (ICNC). Piscataway, NJ: IEEE Press, 2019: 6-10.
- [31] SHAMASUNDAR B, CHOCKALINGAM A. A DNN architecture for the detection of generalized spatial modulation signals [J]. *IEEE Communications Letters*, 2020, 24(12): 2770-2774.
- [32] JIA Z F, CHENG W C, ZHANG H L. A partial learning-based detection scheme for massive MIMO [J]. *IEEE Wireless Communications Letters*, 2019, 8(4): 1137-1140.
- [33] JIN X L, KIM H N. Parallel deep learning detection network in the MIMO channel [J]. *IEEE Communications Letters*, 2020, 24(1): 126-130.
- [34] CHEN Q, ZHANG S Q, XU S G, et al. Efficient MIMO detection with imperfect channel knowledge-A deep learning approach [C] // 2019 IEEE Wireless Communi-

- cations and Networking Conference. Piscataway, NJ: IEEE Press, 2019: 1-6.
- [35] BAEK M S, KWAK S, JUNG J Y, et al. Implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters [J]. IEEE Transactions on Broadcasting, 2019, 65(3): 636-642.
- [36] TAHA A, ALRABEIAH M, ALKHATEEB A. Enabling large intelligent surfaces with compressive sensing and deep learning [J]. IEEE Access, 2021, 9: 44304-44321.
- [37] ÖZDOĞAN Ö, BJÖRNSON E. Deep learning-based phase reconfiguration for intelligent reflecting surfaces [C]//2020 54th Asilomar Conference on Signals, Systems, and Computers. Piscataway, NJ: IEEE Press, 2020: 707-711.
- [38] SHEEN B L, YANG L, FENG X L, et al. A deep learning based modeling of reconfigurable intelligent surface assisted wireless communications for phase shift configuration[J]. IEEE Open Journal of the Communications Society, 2021, 2: 262-272.
- [39] FENG K M, WANG Q S, LI X, et al. Deep reinforcement learning based intelligent reflecting surface optimization for MISO communication systems [J]. IEEE Wireless Communications Letters, 2020, 9(5): 745-749.
- [40] GE Y M, FAN J C. Beamforming optimization for intelligent reflecting surface assisted MISO: a deep transfer learning approach[J]. IEEE Transactions on Vehicular Technology, 2021, 70(4): 3902-3907.
- [41] GONG S M, LIN J Y, ZHANG J B, et al. Optimization-driven machine learning for intelligent reflecting surfaces assisted wireless networks [EB/OL]. (2020-08-29) [2022-05-25]. <https://arxiv.org/abs/2008.12938>.
- [42] HUANG C W, MO R H, YUEN C. Reconfigurable intelligent surface assisted multiuser MISO systems exploiting deep reinforcement learning[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(8): 1839-1850.
- [43] FERIANI A, MEZGHANI A, HOSSAIN E. On the robustness of deep reinforcement learning in IRS-aided wireless communication systems [EB/OL]. (2021-07-26) [2022-05-25]. <https://arxiv.org/abs/2107.08293>.
- [44] TAHA A, ZHANG Y, MISMAR F B, et al. Deep reinforcement learning for intelligent reflecting surfaces: towards standalone operation [C]//2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications. Piscataway, NJ: IEEE Press, 2020: 1-5.
- [45] HUANG C W, YANG Z H, ALEXANDROPOULOS G C, et al. Hybrid beamforming for RIS-empowered multi-hop terahertz communications: a DRL-based method[C]//2020 IEEE Globecom Workshops (GC Wkshps). Piscataway, NJ: IEEE Press, 2020: 1-6.
- [46] NGUYEN K K, MASARACCHIA A, YIN C, et al. Deep reinforcement learning for intelligent reflecting surface-assisted D2D communication [EB/OL]. (2021-08-06) [2022-05-25]. <https://arxiv.org/abs/2108.02892>.
- [47] BASAR E, WEN M W, MESLEH R, et al. IEEE access special section editorial: index modulation techniques for next-generation wireless networks[J]. IEEE Access, 2017, 6: 26452-26456.
- [48] YANG P, XIAO Y, XIAO M, et al. Adaptive spatial modulation MIMO based on machine learning[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(9): 2117-2131.
- [49] ARSLAN İ A, ALTIN G. A novel deep neural network based antenna selection architecture for spatial modulation systems [C]//2021 56th International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST). Piscataway, NJ: IEEE Press, 2021: 141-144.
- [50] ZHANG Y, WANG J T, WANG X S, et al. Efficient selection on spatial modulation antennas: learning or boosting[J]. IEEE Wireless Communications Letters, 2020, 9(8): 1249-1252.
- [51] GECGEL S, GOZTEPE C, KARABULUT KURT G. Transmit antenna selection for large-scale MIMO GSM with machine learning[J]. IEEE Wireless Communications Letters, 2020, 9(1): 113-116.
- [52] MOHAMED A, BAI Z Q, TWARAYISENZE J P, et al. Supervised learning classifier based transmit antenna selection for SM-MIMO system [C]//IWCNC 2021. Piscataway, NJ: IEEE Press, 2021: 110-115.
- [53] LIU H, XIAO Y, YANG P, et al. Transmit antenna selection for full-duplex spatial modulation based on machine learning[J]. IEEE Transactions on Vehicular Technology, 2021, 70(10): 10695-10708.
- [54] SAXENA V, CAVAREC B, JALDEN J, et al. A learning approach for optimal codebook selection in spatial modulation systems [C]//2018 52nd Asilomar Conference on Signals, Systems, and Computers. Piscataway, NJ: IEEE Press, 2018: 1800-1804.
- [55] TATO A, MOSQUERA C, HENAREJOS P, et al. Neu-

- ral network aided computation of mutual information for adaptation of spatial modulation[J]. IEEE Transactions on Communications, 2020, 68(5): 2809-2822.
- [56] TATO A, MOSQUERA C, HENAREJOS P, et al. Neural network aided computation of generalized spatial modulation capacity[C] // 2019 27th European Signal Processing Conference (EUSIPCO). Piscataway, NJ: IEEE Press, 2019: 1-5.
- [57] TATO A, MOSQUERA C. Deep learning assisted rate adaptation in spatial modulation links[C] // 2019 16th International Symposium on Wireless Communication Systems (ISWCS). Piscataway, NJ: IEEE Press, 2019: 176-181.
- [58] TATO A, MOSQUERA C. Spatial modulation link adaptation: a deep learning approach[C] // 2019 53rd Asilomar Conference on Signals, Systems, and Computers. Piscataway, NJ: IEEE Press, 2019: 1801-1805.
- [59] TWARAYISENZE J P, BAI Z Q, MOHAMED A, et al. Artificial neural network based adaptive spatial modulation[C] // 2021 IEEE 6th International Conference on Computer and Communication Systems. Piscataway, NJ: IEEE Press, 2021: 553-557.
- [60] HERLOCKER J L, KONSTAN J A, RIEDL J. Explaining collaborative filtering recommendations[C] // Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work. New York: ACM, 2000: 241-250.
- [61] DOSHI-VELEZ F, KIM B. Towards a rigorous science of interpretable machine learning[EB/OL]. (2017-03-02) [2022-05-25]. <https://arxiv.org/abs/1702.08608>.
- [62] ZHANG Q S, ZHU S C. Visual interpretability for deep learning: a survey[J]. Frontiers of Information Technology and Electronic Engineering, 2018, 19(1): 27-39.
- [63] THOMPSON N C, GREENEWALD K, LEE K, et al. The computing limits of deep learning[EB/OL]. (2020-07-10) [2022-05-25]. <https://arxiv.org/abs/2007.05558>.
- [64] PELTONEN E, BENNIS M, CAPOBIANCO M, et al. 6G white paper on edge intelligence[EB/OL]. (2020-04-30) [2022-05-25]. <https://arxiv.org/abs/2004.14850>.
- [65] XIAO L X, LI S, QIAN Y, et al. An overview of OTFS for Internet of things: concepts, benefits, and challenges[J]. IEEE Internet of Things Journal, 2022, 9(10): 7596-7618.
- [66] HADANI R, RAKIB S, TSATSANIS M, et al. Orthogonal time frequency space modulation[C] // WCNC 2017. Piscataway, NJ: IEEE Press, 2017: 1-6.