



中国移动
China Mobile

研究院
CMRI

6G 物理层 AI 关键技术白皮书

(2022)



中国移动通信有限公司研究院
东南大学、清华大学

目录

| | |
|---------------------------------------|----|
| 1. 前言..... | 1 |
| 2. 物理层 AI 工作原理..... | 2 |
| 2.1 无线通信系统引入 AI 技术的价值..... | 2 |
| 2.2 物理层 AI 技术的定义和基本工作流程..... | 3 |
| 2.3 物理层 AI 在无线通信网络中的作用..... | 4 |
| 3. 基于 AI 的发射机/接收机技术..... | 5 |
| 3.1 基于 AI 的端到端通信链路设计..... | 5 |
| 3.2 基于 AI 的发射机/接收机模块算法设计..... | 6 |
| 3.3 小结..... | 8 |
| 4. 基于 AI 的大规模 MIMO 技术..... | 9 |
| 4.1 基于 AI 的 CSI 反馈..... | 9 |
| 4.2 基于 AI 的信道估计..... | 12 |
| 4.3 基于 AI 的信道状态信息预测..... | 13 |
| 4.4 面向未来的思考：基于 AI 的终极大规模 MIMO 技术..... | 14 |
| 5. 无线 AI 算法评估准则、数据集、与泛化性..... | 14 |
| 5.1 无线 AI 方案的评估指标..... | 15 |
| 5.2 数据集的建立准则..... | 17 |
| 5.3 AI 模型的开放性..... | 18 |
| 5.4 泛化性提升技术..... | 18 |
| 5.5 小结..... | 19 |
| 6. 未来研究与标准化展望..... | 20 |
| 7. 总结..... | 21 |
| 8. 白皮书贡献单位..... | 22 |
| 缩略语列表..... | 24 |
| 参考文献..... | 25 |

1. 前言

加快发展新一代人工智能（Artificial Intelligence, AI）是赢得全球科技竞争主动权的重要战略抓手。面向 2030+，6G 有望在 5G 的基础之上全面实现数字化，推动社会走向“数字孪生，智慧泛在”的愿景。为了实现这个美好愿景，人工智能技术有望发挥重要作用。

现阶段将 AI 技术应用在无线网络中将有助于更精准地预测业务特征、用户移动性、用户行为、信道环境等信息，最终通过智能资源管理与调度机制保证更好的服务质量和用户体验，实现更好的公平性和系统资源利用率，促进无线通信网络的开放与智能。长期来看，基于 AI 的无线网络设计有助于实现通信协议的自动升级，从而有效降低网络部署与运维成本，实现移动通信产业的可持续发展。

目前 AI 技术已经开始在核心网、网管网优、接入网等领域发挥积极作用。基于 AI 的空口传输技术（尤其是物理层 AI 技术）近年来已取得显著进展。大量研究表明，将 AI 技术融入到新型编码调制、多址、波形设计、预编码、信道估计、信号检测等物理层模块设计中，可带来显著的性能增益。以 ITU、3GPP、IMT-2020，IMT-2030 等为代表的多个行业组织已经在数据集构建、评估准则、典型用例等重要课题上开展深入研究，为将来无线 AI 技术的实际应用打下了重要基础。然而，不可否认的是，业界在无线 AI 技术方面的研究仍面临诸多挑战：

- 缺乏科学公开的数据集：不同研究机构采用的数据集并不统一，研究结果难以相互验证；
- 无线 AI 数据和应用具备自己独特的特征，如何将图像与语音处理领域的经典 AI 算法与无线数据以及无线领域专家知识进行有机融合尚不明确；
- 无线通信系统的显著特征之一是通信场景复杂多变（室内、室外、高铁等）与业务形式多样，如何让无线 AI 方案在有限算力前提下适用于多种通信场景与业务形式，是业界目前需要克服的重要挑战；
- 无线 AI 的链路级和系统级性能上界尚不明确，在综合考虑算力、功耗、数据集、信令开销等成本的前提下，AI 方案对比传统基于专家知识的设计是否有性能增益等重要问题还缺乏系统科学的分析与论证，这是无线 AI 未来标

准化和产业化落地的先决条件。

无线 AI 是通信界重点的研究方向之一，在中国移动发布的《2030+愿景与需求白皮书》、《2030+网络架构展望》和《2030+技术趋势》等白皮书的基础上，本白皮书聚焦目前备受关注且颇具挑战的物理层 AI 技术，尝试回答业界普遍关心的 AI 数据集、算法设计、泛化性、未来研究方向和标准化路线图等核心问题，希望能够为业界研究面向 2030+ 的无线 AI 尤其是物理层 AI 提供参考和指引。具体来讲，白皮书在第二章分析了物理层 AI 的基本工作原理，以及在整个无线通信网络中可能发挥的价值；第三章中深入探讨了基于 AI 的发射机与接收机设计，重点指出了模型与数据双驱动的设计思路；第四章讨论了基于 AI 的大规模 MIMO 技术，并展望未来终极 MIMO 的技术特征；第五章针对无线 AI 方案的评估准则和方法进行了分析，提出了一些典型的评估指标、数据集构建原则、提升 AI 方案泛化性的思路；第六章对未来的研究与标准化提供了一些参考建议。第七章对本白皮书进行了总结。

2. 物理层 AI 工作原理

近年来 AI 技术特别是深度学习在计算机视觉、自然语言处理、语音识别等多个领域获得了巨大成功^[1-2]。AI 技术使能的智能无线通信被认为是 6G 发展主流方向之一，其基本思想是通过无线通信技术与 AI 技术的有机融合实现智慧内生，大幅度提升无线通信系统的性能^[3-9]。

2.1 无线通信系统引入 AI 技术的价值

无线通信系统中存在大量传统方法难以进行精确数学建模或者高效率求解的技术问题，例如覆盖增强、干扰消除、时频资源优化分配、波束管理、跨层优化等问题，这推动了近年来 AI 技术在通信系统中的广泛研究与应用。比如：在网管领域，AI 算法可以用来优化系统容量、覆盖、故障率、负载均衡、异常检测等方方面面的性能；在核心网，AI 的应用包括智能业务质量定义与分配、切片状态分析、用户体验分析等；在接入网，AI 的应用包含智能无线资源管理算法、接入控制、调度算法，以及最新的研究热点物理层 AI，包括基于 AI 的编码、调制、多址、多天线、波束管理、无线定位、信道估计/预测、接收机算法等。

近年来，很多国际组织也开始了无线 AI 相关的研究与标准化，例如，ITU

专门成立了机器学习焦点组，研究机器学习在未来网络的应用场景、潜在需求、用于移动网络优化的机器学习算法、支持机器学习的未来网络架构、接口、协议等^[10]。3GPP 也开展了 AI 应用于核心网、网管、接入网的标准化工作^[11-12]，尤其是近期 RAN1 也开始了物理层 AI 的标准化讨论。

经过多年的发展演进，物理层的信道编码、调制、波形、大规模多输入多输出（MIMO）、正交频分复用（OFDM）等技术已日趋成熟。在实际系统中，当发射机获知信道信息后，可以在发送端做各种优化处理，例如自适应编码调制、MIMO 预编码、功率控制等，这些自适应方案可以大幅提升通信系统的性能。然而，在很多情况下，由于信道的快速变化以及小区内和小区间干扰的存在，实现精确的信道估计很困难，再加上不理想的信道反馈等原因，发送端难以获得准确的信道信息。因此，发射端如何通过高效率的方式（低反馈开销、低参考信号开销、低复杂度、低时延）精确获知信道信息，是整个无线通信系统性能提升的关键因素之一。在传统物理层技术的基础上引入 AI，有望更全面的把握无线信道的特征和变化趋势（包括小区内和小区间的干扰），从而有助于提升无线通信物理层的性能。

2.2 物理层 AI 技术的定义和基本工作流程

物理层 AI 设计包含两种主流方法：一是基于 AI 技术的端到端通信链路设计，二是基于 AI 技术的通信模块算法设计。物理层 AI 可以部署在基站侧或终端侧，侧重于对物理信道特征的提取，并针对不同的物理层技术进行相应的 AI 模型选择和训练，很多场合需要基站和终端之间 AI 能力的配合以及信令交互。物理层 AI 的基本工作流程如下：

- 数据采集：基站和终端收集需要的信息，包含信道信息、干扰信息、终端移动速度、终端位置、资源分配、业务信息等；
- 模型训练：基站和终端针对要解决的问题有针对性的进行 AI 模型选择与训练，包含独立 AI 模型和分布式模型训练，并进行模型同步和参数传递；
- 实时 AI 空口增强：基于实际的测量结果和训练好的模型，基站和终端相互配合，实时输出更优的辅助决策信息，供调度器进行更优的调度；

- 智能调度：调度器基于物理层 AI 的输入信息以及其他高层和业务等信息进行全局的资源分配和用户调度，实现系统性能的提升；

2.3 物理层 AI 在无线网络中的作用

如图 1 所示，在具有内生 AI 的无线通信系统中，AI 能力分布在系统不同的功能实体中。接入网 AI 和核心网 AI、网管 AI、以及终端 AI 互相配合，联合优化系统性能。接入网 AI 部署在基站内部，包含中心单元 CU（Centralized Unit）和分布单元 DU（Distributed Unit），CU 与 DU 的 AI 功能需要根据各自的能力和 demand 进行分割与配合。CU 与 DU 之间、接入网 AI 与核心网、网管、甚至应用服务器都有相应的接口用于数据交互。

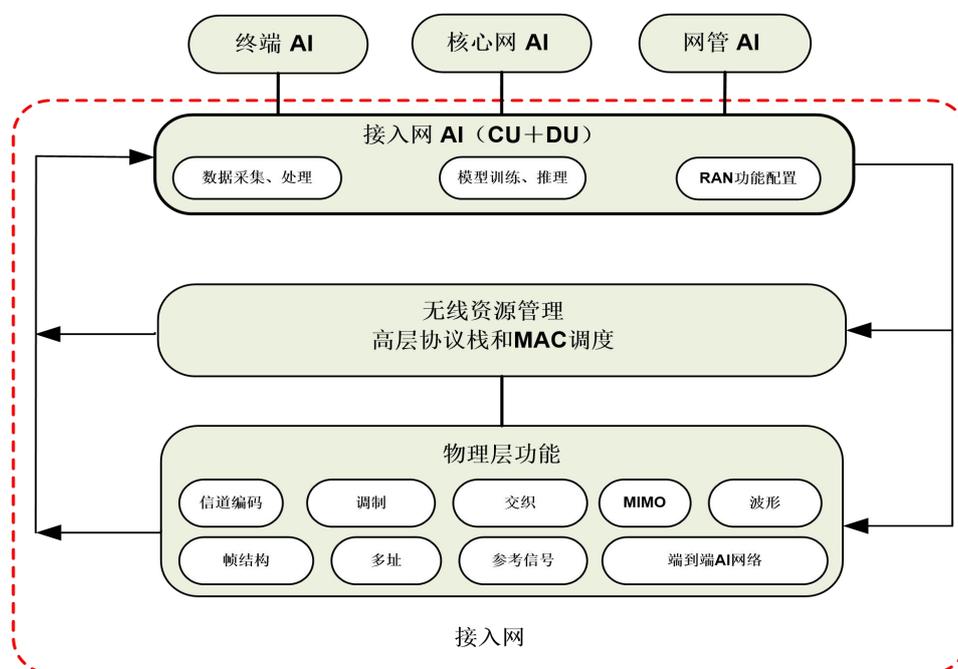


图 1：物理层 AI 在网络中的作用

基于采集的数据，接入网 AI 学习与预测移动业务的特征、用户移动性规律、用户业务行为、信道与干扰情况、业务质量（QoS）、业务体验（QoE）等信息；并酌情把分析的结果通过接口传递到核心网、网管、以及接入网功能（无线资源控制与管理、MAC 层以及高层协议栈、物理层等），支持网络的优化和业务的优化。其中，接入网 AI 可以针对不同的用户或者业务采用最合适的协议栈功能与处理算法，提高资源利用率^[9]。

物理层 AI 是接入网 AI 能力的一部分，主要功能是基于物理信道相关的信息

对于物理层功能（包含信道编码、调制、波形、多址、多天线 MIMO、接收机算法等）进行增强。物理层 AI 的输出信息（例如最优的编码调制方案、信道预测结果、多天线预编码矩阵等）提供给基站媒体接入控制（MAC）调度器，后者结合所有相关的信息进行更加智能的实时业务和资源调度。

为了最大化 AI 对网络潜在的增益，接入网 AI 的算法可以是运营商、设备商、或者第三方设计，并通过接口作用到基站的调度器，推动接入网的开放和智能。

3. 基于 AI 的发射机/接收机技术

典型的无线通信系统由发射机、无线信道、接收机构成。其中，发射机主要包括信源、信源编码、信道编码、调制、波形多址、MIMO 和射频发送等模块；接收机主要包括射频接收、信道估计与信号检测、MIMO、波形多址处理、解调、信道解码、信源解码、信宿等模块。基于 AI 的发射机/接收机技术的工作原理为：以数据（主要为无线信道数据）驱动的方式使用机器学习方法优化发射机/接收机中的单个或多个功能模块，从而实现链路/系统级性能的提升或模块计算复杂度的降低等目标。

按照优化目标涵盖的范围的大小，可以将基于 AI 的发射机/接收机技术分为以下两类：1) 基于 AI 技术的端到端通信链路设计，其原理为使用深度学习联合优化整个端到端通信系统；2) 基于 AI 技术的通信模块算法设计，即针对通信系统中的某一现有模块，或提高通信算法的性能，或降低通信算法的复杂度。

3.1 基于 AI 的端到端通信链路设计

端到端通信^[13,14]是指利用深度学习技术，以最小化消息传输错误概率等为目标，联合优化收发机模块。端到端通信可以打破传统通信系统的模块化壁垒，对发射机和接收机进行联合优化，从而实现通信链路全局最优的误码率性能，其示意图如图 2 所示。

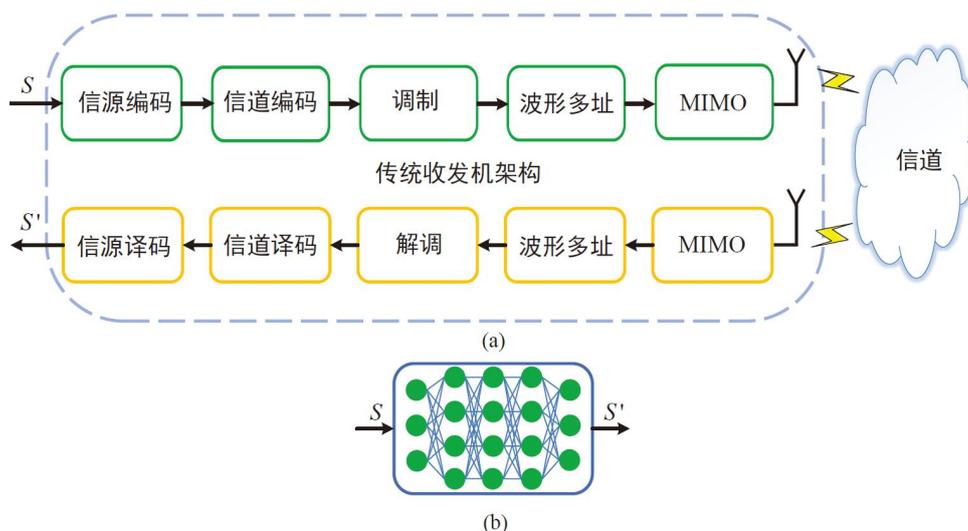


图 2: (a) 经典的无线通信系统架构; (b) 基于深度学习的无线通信系统新架构

端到端通信具有灵活的可拓展性，可以涵盖多种物理层新功能，包括非正交多址、不同的天线波束赋型架构、智能超表面技术等。例如，端到端通信可以将近来新提出的可重构智能超表面技术纳入联合优化范围，从而实现收发转联合优化来最大程度提升超表面部署的期望收益^[15]。此外，通过信源编解码和端到端物理层的联合优化，可以实现以最小化语义错误率为目标的语义通信^[16]。通过使用神经网络学习特定传输内容的语义特征，将其于信道特征加以匹配，更少的通信资源可以实现更大的传输速率。

端到端通信中的发射机/接收机联合设计是实现全局最优的性能保证。但实现发射机/接收机的联合设计需要解决损失函数梯度在无线信道上的传播问题，否则发射机部将难以进行优化。可以考虑采用基于对抗生成网络的梯度回传^[14]等手段使得发射机可以根据接收机反馈的梯度进行相应的更新。

3.2 基于 AI 的发射机/接收机模块算法设计

基于 AI 的发射机/接收机技术使用深度神经网络模型替代传统发射机中的部分模块，以数据驱动的方式训练模型来取得更优的性能和/或更低的复杂度。此类方案中的数据来源一般有两类，即使用传统方案得到的标注数据与端到端的信道数据。相对应的，以传统方案得到的标注数据为学习对象的方案主要目标为以低复杂度实现高性能的传统算法；以端到端的信道数据为学习对象的方案主要目标为优化链路级性能。以下将对两类方法分别举例：

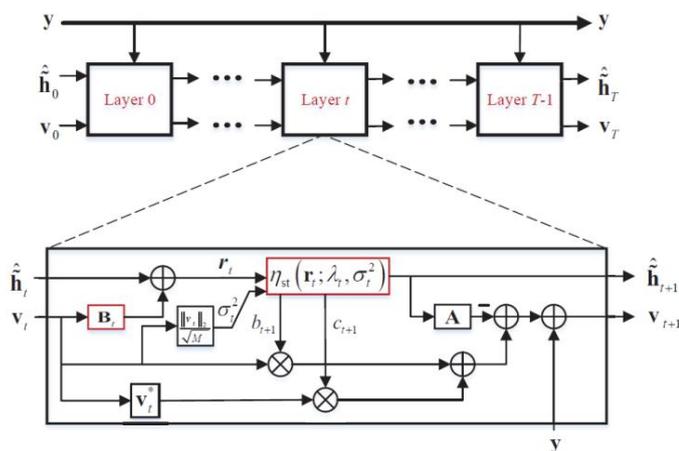


图 3: LAMP 结构示意图

压缩感知技术是一类广泛应用于通信物理层设计中的技术，用来提升解码、信号检测、信道估计算法的精度。然而部分压缩感知算法需要进行多轮迭代，复杂度很高。针对该问题，文献^[17]通过将经典的稀疏信号恢复算法 AMP（Approximate Message Passing，近似消息传递）展开为深度神经网络，得到了一种基于学习的 AMP，即 LAMP 网络，可以用来估计稀疏信道。如图 3 所示，在 LAMP 网络中，每一层网络均与 AMP 算法中的每一次迭代完全对应。特别地，LAMP 网络可以通过网络训练优化 AMP 算法中仅凭经验设定的超参数，从而提高估计精度。文献^[18]和文献^[19]在 LAMP 网络的基础上进一步改进了网络结构。其中文献^[18]借鉴图像降噪的思想，将 LAMP 网络中的收缩函数替换为降噪卷积神经网络（Denoising Convolutional Neural Network, DnCNN）。文献^[19]利用稀疏信道近似服从混合高斯分布这一先验信息，将 LAMP 网络中的收缩函数替换为推导的混合高斯收缩函数。该类基于模型驱动深度学习的信道估计方法已经证明可以在相同的低导频开销下获得优于基于压缩感知方法的估计精度。上述基于 AI 的收发机方案在学习时需要首先使用传统算法生成带标签数据，因此其主要局限在于性能难以突破其标签方案的限制。

信道编解码模块是收发机的重要组成部分，目前大多数信道编码方案都是基于领域专家知识设计，其中 Turbo 码作为一种典型的容量逼近码已经得到广泛研究。然而，Turbo 码会遭遇严重的错误平层和错误传播问题，现有研究表明可以通过基于 AI 的信道编码方案解决上述问题。文献^[20]提出一种 Neural BCJR（Bahl Cocke Jelinek Raviv）方案代替传统的 BCJR 解码算法，解决错误层和

错误传播的问题。文献^[21]将最大化对数最大后验概率（max-log-MAP，max-log-Maximum A Posteriori）算法展开为 TurboNet，并为 TurboNet 引入一些可训练的权重以提高性能并加快收敛速度。仿真结果表明，TurboNet 在高信噪比（SNR, Signal-to-Noise Ratio）状态下具有最佳纠错能力，而 NeuralBCJR 在低 SNR 下具有最佳性能。这些现象表明，当先验知识准确率较低且接收信号干扰较多时，NeuralBCJR 具有更好的应对非理想场景的能力，而当先验更准确且接收信号干扰较少时，TurboNet 具有更好的性能。无论是 Neural BCJR 还是 TurboNet，都需要进行端到端的训练来提升纠错性能，因此属于端到端方案。端到端方案的优势是能够带来性能提升，但不足在于目前无法完全理解神经网络通过何种原理实现这种性能提升。基于 AI 的收发机方案的机理解释是未来一个重要且挑战的方向。

除了上述基于 AI 的信道估计和信道译码，业界还有大量基于 AI 的收发机设计的典型案例，例如基于 AI 的编码和调制方式识别、多用户星座联合设计、波形设计、MIMO 预编码等。此外，基于 AI 能力所提供的发送端精确的信道信息，还可以优化传统物理层技术方案，例如最优的下行大规模 MIMO 预编码方案、最优的编码/调制/交织方案、性能优异的非静态信道下的极化编码^[22]等。

3.3 小结

基于 AI 的发射机/接收机方案主要呈现出两种设计思路：一种基于数据驱动；另一种则基于数据模型双驱动。基于数据驱动的方案将无线通信系统的多个功能块看作为一个未知的黑盒子，利用深度学习网络取而代之。相比之下，基于数据模型双驱动的方案在无线通信系统原有技术的基础上，不改变无线通信系统的模型结构，利用深度学习网络代替某个模块或者训练相关参数以提升某个模块的性能。基于数据驱动的深度学习网络主要依赖海量数据，而基于数据模型双驱动的深度学习网络主要依赖通信模型或者算法模型。

基于数据驱动的深度学习网络通过大量实例学习，吸收了被人类分析员分别标记的大量数据，以生成期望的输出。然而，训练深度学习网络需要大量的标记数据，积累和标记大量信息的过程不但费时而且成本高昂。除了积累标记数据的挑战之外，大多数基于数据驱动的深度学习模型泛化性和鲁棒性较弱，即使网络部分结构发生微小变化，也会导致训练模型准确性大大降低。基于数据模型双驱

动的深度学习网络以物理层已有模型为基础，可以显著减少训练或升级所需的信息量。此外，由于已有的模型具有环境自适应性和泛化性，因此数据模型双驱动深度学习网络也具有这些特性，并且能在原模型基础上进一步提升系统的性能，因此具有广阔的发展前景。

4. 基于 AI 的大规模 MIMO 技术

多天线（Multiple-Input Multiple-Output, MIMO）技术是自 4G LTE 系统与 5G NR 系统中的物理层核心技术之一。随着通信系统的不断演进，MIMO 技术所采用的天线阵列规模在不断增加，从而提供更高的波束赋形精度与分集/复用增益。然而，天线阵列规模的上升也带来了新的问题，尤其是信道状态信息规模的增加导致大规模 MIMO 系统中的信道估计、信道反馈等模块的开销快速上升，已成为目前大规模 MIMO 中的核心挑战之一。

不同于传统 MIMO 方案基于模型设计信号处理方案的思路，基于 AI 的大规模 MIMO 技术是一种数据驱动的方法，能够从大量空口数据中挖掘出先前未知的特征，从而在性能上取得新的增益。从原理上讲，基于 AI 的大规模 MIMO 技术与第三章中讨论的基于 AI 的发射机/接收机技术并无明显差异。但前者在动机与潜力上具备如下突出特点：1) 大规模 MIMO 系统中的高维信道状态信息处理由于其规模庞大的特点，已成为系统中的瓶颈问题；2) 大规模 MIMO 信道在多个维度存在相关性，适于使用机器学习等工具进行处理。因此，基于 AI 的大规模 MIMO 技术自提出以来便蓬勃发展，至今已成为空口 AI 中最重要且最受关注的一类技术，并有望率先在标准化中进行讨论。

本章节将对目前最受关注的基于 AI 的信道状态信息（channel state information, CSI）反馈、基于 AI 的信道估计、以及基于 AI 的信道预测三个方面介绍 AI 的大规模 MIMO 技术的最新进展，并在章节结尾对该方面的研究进行总结与展望。

4.1 基于 AI 的 CSI 反馈

现有 4G LTE 系统与 5G NR 系统使用码本作为 CSI 反馈的基本工具，并针对不同的反馈精度需要定义了 TypeI/II 码本等多套方案。然而，上述码本均针对于均匀排列的天线阵列进行设计，没有针对 3D 天线等特殊天线进行优化，性能

上局限性较为明显。而基于 AI 的 CSI 反馈可以突破上述瓶颈，通过针对特定信道环境的优化来取得更好的反馈性能。

基于 AI 的 CSI 反馈的基本原理为将高维信道信息反馈任务视为端到端的 CSI 图像压缩恢复任务。如图 4 所示，其基本信号流程具有一种类似于自编码器（autoencoder, AE）的结构：1）编码端（一般为终端侧）使用编码器将完整的信道信息经特征提取后压缩为一串满足反馈要求的比特流信息；2）该信息经反馈链路反馈至解码端（一般为基站侧）；3）解码端使用解码器将比特流信息进行解压缩和特征重建，最终恢复出完整的信道信息。上述编码器与解码器在端到端训练过程中进行联合优化从而获得最佳的 CSI 重构性能。在实际部署时，编码器与解码器需要按照训练过程的方式配对使用，即某一编码器输出的压缩后 CSI 需要用对应的解码器进行恢复。

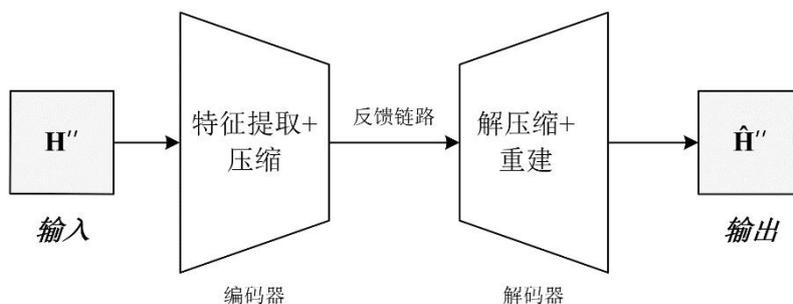


图 4：基于 AI 的全信道信息反馈架构

基于 AI 的 CSI 反馈的基线方案为 CsiNet^[23]。其基本结构如图 5 所示，编码器包括特征提取、特征压缩两个模块，解码器包括特征解压缩和特征恢复两个模块。特征提取与特征恢复均以卷积网络为主要结构，而特征压缩/解压缩部分则使用全连接网络。CsiNet 之后又有大量工作围绕提升信道信息重构精度以及解决时变问题等目标展开。例如，CsiNet-LSTM^[24]将 LSTM 网络与 CsiNet 结合来应对信道信息的时变特性，进一步提高了网络的重建性能。CRNet^[25]则使用多分辨率路径和卷积因子化方法提高了网络的重建性能。ConvCsiNet^[26]使用全卷积自编码器架构替换了原先使用全连接层来压缩的自编码器架构，在提高网络性能的基础上同时能满足适应多种输入 CSI 的尺寸。Attention CsiNet^[27]将 LSTM 网络结构和注意力机制同时引入 CSI 反馈，提高了网络重建性能并降低了时间复杂度。BCsiNet^[28]将二值化神经网络引入 CSI 反馈，在保证性能的同时极大的降低了内

存消耗，提高了运算速度。CsiNet+^[29]提出了一种多速率反馈架构，并对编码器输出的压缩编码进行非均匀量化，生成比特流便于实际传输。表一列举了多种不同的基于 AI 的 CSI 反馈方案的性能比较以供参考。

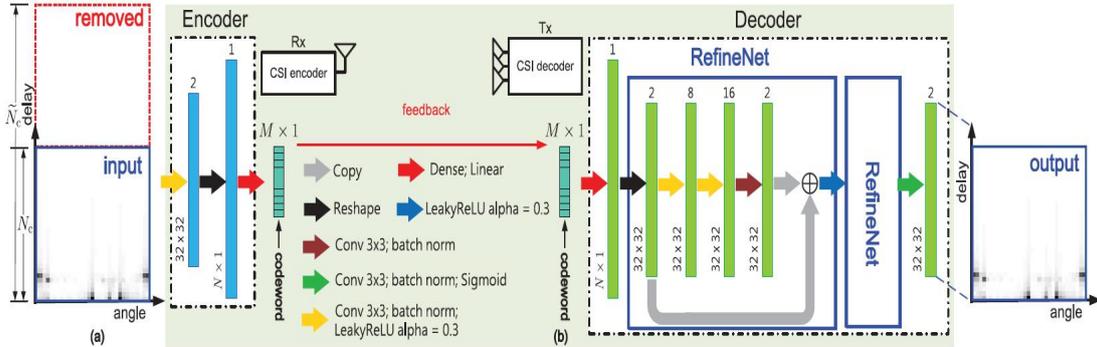


图 5: CsiNet 网络架构

表 1: 不同 CSI 方案的重建性能比较（NMSE 和余弦相似度）

| 压缩率 | 方案 | 室内 | | 室外 | |
|------|----------------------------------|------------|--------|------------|--------|
| | | NMSE (-dB) | ρ | NMSE (-dB) | ρ |
| 1/16 | CsiNet ^[23] | -8.65 | 0.93 | -4.51 | 0.79 |
| | CsiNet-LSTM ^[24] | -23.06 | 0.99 | -9.86 | 0.95 |
| | CRNet ^[25] | -11.35 | 0.95 | -5.44 | 0.80 |
| | ConvCsiNet ^[26] | -13.79 | 0.98 | -6.00 | 0.85 |
| | ShuffleCsiNet ^[26] | -12.14 | 0.97 | -5.00 | 0.82 |
| | Attention CsiNet ^[27] | -10.16 | 0.95 | -6.11 | 0.85 |
| | BCsiNet ^[28] | -10.71 | - | -4.52 | - |
| | CsiNet+ ^[29] | -14.14 | - | -5.73 | - |
| 1/32 | CsiNet | -6.24 | 0.89 | -2.81 | 0.67 |
| | CsiNet-LSTM | -22.33 | 0.99 | -9.18 | 0.94 |
| | CRNet | -8.93 | 0.94 | -3.51 | 0.71 |
| | ConvCsiNet | -10.10 | 0.95 | -5.21 | 0.82 |
| | ShuffleCsiNet | -9.41 | 0.94 | -3.50 | 0.74 |
| | Attention CsiNet | -8.58 | 0.93 | -4.57 | 0.79 |
| | BCsiNet | -7.93 | - | -2.74 | - |
| | CsiNet+ | -10.43 | - | -3.40 | - |

4.2 基于 AI 的信道估计

高精度信道信息是信号判决检测和波束赋形等技术的重要前提。现有系统以基于参考信号辅助的信道估计方法作为主要信道估计手段，其依靠传输具有特定图案且收发端均已知的参考信号来获取部分频带/符号上的信道，然后利用这些信道进一步通过一维或多维的插值获得所有时频空资源上的信道信息。受限于较为一般性的信道模型假设，传统信道估计算法的精度面临一定瓶颈。近几年来，研究发现基于 AI 的信道估计方案通过对信道结构中的先验信息的学习在相同参考信号开销下明显提升信道估计精度。

仍然考虑基于参考信号辅助的信道估计框架，则基于 AI 的信道估计需要学习的是从较少的已知信道信息到完整信道信息的映射，该过程类似于图像处理中的超分辨率插值技术。文献^[30]是基于 AI 的信道估计方向上的开创性工作之一，考虑使用神经网络学习从接收数据到原始信号的恢复过程，其所提框架如图 6 所示。文献^[30]通过仿真对比发现基于 AI 的信道估计相比于传统的 LS 和 MMSE 信道估计方案有明显性能优势。文献^[18]在基于 AI 的信道估计率先提出模型驱动的神经网络结构设计，引入了可学习的去噪近似信息传递网络来解决参考信号较少时的估计精度下降问题，并且所提方案仅需少量数据即可训练，在实际部署中有明显优势。

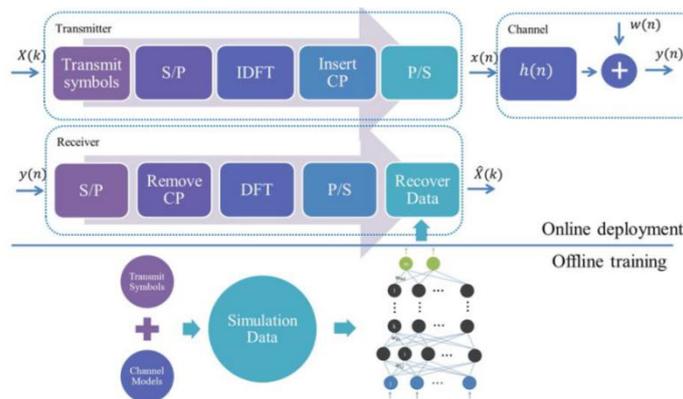


图 6 基于 AI 的信道估计系统框架图^[30]

基于 AI 的信道估计方案仅需在链路的接收端进行部署，因此不存在多模型对齐问题。因为物理层传输过程需要进行大量信道估计，所以对信道估计方案的计算时延有较高要求，这也是目前基于 AI 的信道估计方案需要解决的主要问题之一。此外，用于信道估计的模型需要具备较好的泛化性，在多种不同信噪比、

场景、移动速度下均能满足估计精度要求，否则频繁的模型更新带来的开销将会显得方案整体得不偿失。

4.3 基于 AI 的信道状态信息预测

CSI 预测指以已有 CSI 为基础不增加新的空口资源开销而获得未知时频资源 CSI 的技术。不同时刻/空间等维度的 CSI 虽然不完全相同，但存在一定程度的相关性，使得 CSI 预测成为可能。传统 CSI 预测方案在处理复杂数据上受限于预测精度而难以实用化。基于 AI 的 CSI 预测有望明显提升预测精度，从而有望在实际系统中实现以低开销获取未知 CSI 的目标。

根据数据相关性类别，基于 AI 的 CSI 预测可以分为四类：

1) 第一类考虑时间相关性，即根据前一段时间内的 CSI 来预测下一个时刻或者下一段时间内的 CSI，其主要是应用在随时间变化的信道或者高速移动的场景下。由于循环神经网络架构可以很好地处理时间序列，因此有工作利用 RNN 架构^[31]和 transformer^[32]架构构建了基于 AI 的 CSI 预测网络，通过神经网络来刻画和捕捉信道在时间前后状态信息的变化和相关性，可以根据前几个时间点的 CSI 预测出下一时刻的 CSI。

2) 第二类考虑频率角度的相关性，例如根据 FDD 的上行 CSI 来预测和重建下行 CSI。文献^{[33][34]}将深度学习的方法应用到了 FDD 下行信道的预测和重建问题上，根据环境中的上行信道数据来推测和重建新的环境（频率）中的数据，可以取得良好的预测精度。

3) 第三类考虑空间角度的预测问题。例如，文献^[35]同时考虑了信道在空间和频率上的相关性，并利用这种相关性实现了根据基站部分天线与用户的 CSI 来预测和映射全部天线与用户的 CSI。其主要的方法是引入了一个由全连接构成的信道映射关系学习神经网络，对这些映射关系进行学习。

4) 第四类考虑相邻用户间的信道相关性。对于在同一个场景中并且在同一个基站服务范围内的用户，他们的信道往往也具有很强的相关性，且在不同位置的用户所享有的信道强弱可能不同。因此可以通过部分用户的信道来预测区域所有用户的信道。

4.4 面向未来的思考：基于 AI 的终极大规模 MIMO 技术

MIMO 技术的研究和标准化已经持续了多年，并且在未来一段时间仍然将是标准化讨论的核心议题之一。以用于 CSI 量化反馈的码本为例，3GPP 在 R17 中仍然在进行 MIMO 码本增强的工作，希望进一步降低反馈开销。现有的增强型 type II 码本已经利用了信道的空间稀疏性以及时域稀疏性来达到降低开销的目的，未来还可以进一步考虑如下潜在的方向：1) 现有码本主要基于均匀天线阵列来设计，对一些特殊的天线形态还没有灵活的优化设计；2) FDD 信道上下行信道的部分互异性并没有很好的体现在码本设计理念中；3) 在一些场景中，变换域（例如时延和多普勒域）的信道信息比现有的时频域信道具有更低的反馈开销；4) 不同用户之间信道的相关性也可以用来进一步降低系统的整体反馈开销。然而在目前 3GPP 的码本框架中，想要实现上述功能十分挑战。一个主要原因是未来可考虑的码本优化方向的核心思路为针对具体场景做特定优化，但 3GPP 中码本的使用方法是同一套方案解决所有场景的信道反馈问题。

AI 技术的核心是数据驱动，而数据驱动的方法本身即蕴含针对特定场景做特定优化的思路。因此空口 AI 的引入将带来全新的设计思路。目前的大量研究表明，将 AI 技术引入信道估计、信道状态信息反馈、信道预测等领域均具有明显的性能增益。基于此本白皮书构想基于 AI 的终极大规模 MIMO 技术具有如下的特点：1) 精确的下行信道估计和预测；2) 以最小反馈开销反馈信道信息，充分结合上下行信道部分互异性、用户之间相关性、时频域和其他变换域信道等；3) 下行多用户 MIMO 预编码方案，充分考虑小区内和小区间干扰。上述特点将能够结合一定范围内的无线信道特征进行特定的优化，从而带来全新的性能增益空间。

5. 无线 AI 算法评估准则、数据集与泛化性

目前，业界在无线 AI 的一些关键技术问题，例如数据集建立、泛化性衡量、模型校准、评估准则与评估指标等方面还没有达成共识。3GPP 等标准化组织已有的用于评估无线方案性能的方法体系也不能满足系统性评估无线 AI 方案的需求。评估准则与评估指标是判断无线 AI 算法优劣性的准绳，是无线 AI 未来研究与标准化落地的重要依据；良好的数据集是无线 AI 研究的基础，不同的数据集直接影响 AI 算法设计与性能；基于某种数据集设计的 AI 算法往往在跨场景应用

中存在泛化性不足的问题，需要大力研究泛化性提升技术。所以，数据集、评估准则与评估指标、泛化性等问题紧密耦合在一起，需要联合优化设计。本章首先提出了物理层 AI 的评估准则和一些评估指标，并针对数据集建立和 AI 算法泛化性提升等重要问题阐述其面临的挑战与可选解决方案。

5.1 无线 AI 方案的评估指标

制订无线 AI 方案评估准则的第一步为选取合适的评价指标 KPI（Key Performance Indicators）。所选 KPI 应当能够全面地反应无线 AI 方案的性能与开销，并且方便与传统非 AI 方案进行对比。总体上可以将相关的 KPI 分为性能与开销两类，以下将分别进行讨论：

5.1.1 性能相关 KPI 要根据不同用例选择评估指标

性能相关 KPI 的主要用途为量化无线 AI 方案相比于传统非 AI 方案带来的性能提升。鉴于目前无线 AI 的用例主要集中于对无线网络某些功能的增强，其性能评估 KPI 可以参考使用对应的用于评估传统非 AI 方案性能的 KPI。此外，选取相同 KPI 也可以比较方便地进行性能对比。目前业界各方关于性能相关 KPI 的选择共识较高，基本同意根据不同用例选择不同 KPI 的做法。

以空口 AI 中讨论较多的 FDD 下行信道反馈增强为例，可以选取信道恢复结果与原信道间的归一化均方误差（Normalized mean square error, NMSE）或是余弦相似度作为信道恢复精度的度量 KPI，或者可以选择部分链路级/系统级指标（如误比特率或吞吐量等）作为反映信道反馈精度对系统性能影响的度量 KPI。前者的优点在于评估较为简单，缺点是无法完全反映引入 AI 所带来的开销；相对地，后者优点为能反映出基于 AI 的信道反馈方案对于系统性能的整体影响，缺点为评估步骤更加繁琐。考虑到无线 AI 方案仍在不断演进，不排除未来出现改变无线链路基本框架的方案（如多链路模块联合设计等）的可能，届时可能需要对性能相关 KPI 做不同程度的改动。

5.1.2 开销相关 KPI 要准确量化部署无线 AI 方案时引入的开销

开销相关 KPI 的主要用途为量化部署无线 AI 方案时引入的开销，主要包括：
1) 模型复杂度；2) 数据收集与训练；3) 用例相关的无线资源开销；4) AI 算

法所需的硬件成本和功耗；5）提升泛化性所需开销等。具体如下：

1) 模型复杂度：主要指推理阶段运行模型带来的计算开销，实际部署中主要关注推理计算复杂度对运行时间的影响。然而，影响该指标的因素较多，即使是相同模型在不同硬件环境中部署，其推理时间也会有明显差异，很难直接比较运行时间。因此，一个衡量模型复杂度的指标是模型推理所需的浮点数运算量。

2) 数据收集与训练：第一个指标是因数据采集而产生的相关开销，包含离线开销和在线开销。相比之下，非 AI 方案则不需要数据收集与训练过程，因此出于公平比较的原则应当将该过程的开销计入 AI 方案的成本中。对于在线训练方案来说，训练开销会对方案的时延有明显影响，因此，第二个需要纳入的评估指标是训练时延。

3) 用例相关的无线资源开销：指在具体用例中引入 AI 带来的无线资源开销。以基于 AI 的下行信道压缩反馈为例，其模型需要在终端与基站同时部署，并要求两者保持同步。该过程将涉及到模型本身的传输，因此需要将相关开销纳入考虑之中。但是对于基于 AI 的信道反馈等用例来说，只需在终端或基站侧部署模型，不存在模型传递带来的开销。

4) AI 算法所需的硬件成本和功耗：大规模 AI 算法通常需要昂贵的硬件设备，以及巨大的功耗开销，这些是衡量 AI 算法性能非常重要的指标。

5) 提升泛化性所需开销：指在解决模型泛化性方面付出的开销。模型的泛化性一般指在满足一定性能要求的前提下模型所能适用的范围。因为无线系统中的数据与无线环境密切相关，且无线环境本身存在不稳定性，再加上实际部署中对于模型推理时间的要求，所以在实际系统中使用单个强大而复杂的模型应对所有无线环境的做法将会面对模型训练与推理开销巨大的挑战。无线 AI 模型都将有一定的适用范围，一旦超出这种范围，例如终端由于移动性发生了小区切换，甚至是直接来到另一个城市，则之前使用的模型很可能因出现明显的性能下降甚至不可用的情况。为了克服该挑战而使用的各种方案（包括模型更新等）带来的开销均可视为泛化性相关的开销。泛化性问题是无线 AI，尤其是空口 AI 所面临的主要挑战之一，因此需要在评估指标中明确体现，从而保证模型在实际无线系统中的可用性。

5.2 数据集的建立准则

数据集的选择将会从至少以下三个方面影响无线 AI 方案的评估：1) AI 模型的性能很大程度上取决于其训练数据，如果训练数据集未能充分体现数据特征，则可能导致 AI 模型的测试性能大幅下降，甚至改变最终的评估结论；2) 对 AI 模型泛化能力的评估主要通过调整训练集与测试集之间数据分布的差异来实现，不合理的训练集与测试集可能造成对 AI 模型泛化能力的错误估计；3) 数据来源影响评估工作量与评估质量之间的折衷：虽然仿真数据易于获取，但其与真实数据存在一定差异，相比之下真实数据的获取成本高昂，还需要解决隐私保护等问题。

解决上述问题需要各方在充分沟通的基础上达成共识，形成各方都能接受的统一数据集来提升评估结果的说服力。具体地，针对上述第一个问题，一方面需要保证数据集达到一定规模，另一方面需要保证数据采样的环境足够多样以包含足够丰富的特征。针对上述第二个问题，需要人为在训练集与测试集之间设置一定的差异，且该差异能够体现出实际系统部署时对于模型泛化性能的要求。针对第三点，则要明确评估的目的，从而针对性选择数据来源：如果评估的目的主要是比较无线 AI 方案与传统非 AI 方案的区别，则可以考虑使用仿真模型产生的无线数据；如果评估的目的是比较无线 AI 方案在实际系统中的性能，则需要考虑使用真实环境数据。

业界目前关于良好的无线数据集应当具备哪些特征存在一定争论。从运营商的角度来看，一个优秀的无线数据集应当在满足模型性能需求的前提下具有尽可能低的获取开销。虽然在评估阶段，可以使用大规模的数据集来保证测试结果尽量准确；但在实际网络中，数据集获取的开销远非可以忽略的水平，甚至会占用相当多的无线资源。虽然部分数据采集过程可以与数据传输过程分开，并采取一定的错峰策略（例如选择业务量较小的时候进行数据采集），但上述做法仍可能存在与现有部分无线节能策略冲突的可能性（例如大量的数据采集将占用原本基站关断的时间）。正如在前言中提到，如何保证无线 AI 方法的“绿色节能”是未来业界需要解决的重要问题之一。统一数据集的形成需要进行多轮迭代才能逐渐满足各方需求，在这个过程中需要进行多次试错与调整。

5.3 AI 模型的开放性

在制定全面的评估准则与完备的公开数据集的同时，还需要考虑模型本身的可复现性，从而确保评估结果的可信度。基于上述考虑，业界在后续的评估中需要加强在开源方面的提倡，甚至对一些诸如 3GPP 等的标准组织来说，完全的代码公开（包含模型本身的结构与训练过程）将会成为一个要求，从而让任意参与方可以完整复现其他方面的评估结果。此外，考虑到无线 AI 中的一些用例尚处于研究阶段，模型的充分公开可以方便各方加深对 AI 算法的理解，从而促进各方在后续的讨论中更容易达成共识。

5.4 泛化性提升技术

泛化性问题是无线 AI 评估中的核心问题之一。相关研究发现，无线 AI 方案的性能与适用场景存在一定的折衷关系，同时要求一个模型具备很好的性能与较大的适用场景是十分挑战的目标。因此，在制定模型评估标准时不宜要求过高的泛化性，否则会对评估的可行性造成影响。在实际评估中，可以考虑以基础模型的泛化表现为参考进一步制定明确适中的泛化性指标。

考虑到评估时使用的基础模型需要具备一定的泛化性能，以下将列举一系列可以提升模型泛化性能的技术作为参考：

1) 迁移学习：迁移学习旨在将某领域或某任务中学到的知识应用在其他目标领域或任务中。通过迁移学习，仅使用少量样本就可以快速获得新的模型。

2) 元学习：元学习旨在通过多次学习的经验来改善和加快学习。通过元学习，可以通过少量的训练样本快速学习新的任务。

3) 联邦学习：在联邦学习中，不同的数据持有方分别进行模型训练，之后将模型更新上传至中央节点，由该中央节点将多个模型进行聚合。由于最终的模型是由多个数据持有方的数据共同训练而成，因此模型将具有较好的泛化性。

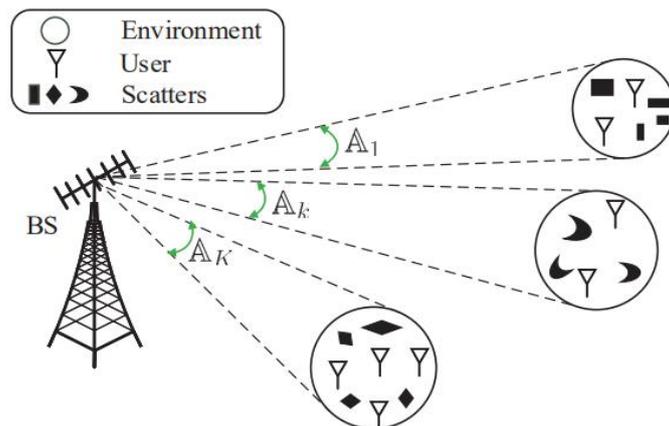


图 7：泛化性提升

以基于深度学习的下行信道预测为例，可以使用一种基于迁移学习和元学习的方法来使用户通过少量样本快速适应新的环境。由图 7 所示，由于共享部分散射簇，相邻用户的信道往往具有相似的特征，在某一小范围的环境中往往可以训练出性能较好的信道预测模型，但将该环境下训练好的信道预测模型应用在其他环境中，信道预测的准确度就会显著下降。对此，采用直接迁移学习和元学习两种方法可以提升性能。在直接迁移学习方法中，模型通过在其它环境中搜集的数据通过传统深度学习方法预先进行学习，然后通过少量数据在新的环境下进行微调，而在元学习方法汇总，通过交替进行模型内部更新和模型间更新来学习一个较好的模型初始化参数，并在此初始化参数基础上在新环境下进行微调。

5.5 小结

本章提出了物理层 AI 的评估准则和一些评估指标：

- 1) 性能相关的指标要根据不同用例进行选择，例如信道压缩反馈相关的 NMSE 和链路级/系统级吞吐量。
- 2) 开销相关指标要准确量化部署无线 AI 方案时引入的开销，包含模型复杂度、数据集、用例相关的无线资源开销、AI 算法所需的硬件成本和功耗、提升泛化性所需开销等。

本章还提出了评估数据集建立的准则以及 AI 算法泛化性提升的一些途径。面向未来，理想的评估数据集和评估用 AI 模型应该具有如下特征：

- 1) 数据集需要最小化实测信道数据的开销，可以考虑主要或者全部基于现

有信道模型产生。业界目前有大量的信道模型来刻画多种多样的通信场景中的信道环境，基于已有的模型，可生成贴近任意实际场景的信道信息，从而为 AI 模型的训练提供了充分的数据集。

2) 训练集与测试集需要明确体现出对模型的泛化性要求与测试方法，从而最大程度地降低实际系统中因模型切换/重训等因素带来的开销。该问题是未来物理层 AI 的一个研究难点。

3) 评估用 AI 模型需要充分公开，包括模型结构与训练过程，便于参与方完整复现方案的评估结果。

6. 未来研究与标准化展望

经过近几年的快速发展，物理层 AI 技术，尤其是部分通信模块的功能增强方面有了长足的进步，涌现了很多优秀的算法。展望未来，在相关研究和标准化方面仍然有很多艰巨的挑战：

- 基于 AI 的物理层链路（发射机与接收机）优化设计：如何根据信道状态和业务需求进行发射与接收神经网络的联合设计面临很多挑战；
- 端到端收发链路的联合设计：发射机如何智能的根据信源的变化进行发射端神经网络的设计，接收端如何根据具体的需求获取有效信息，这种语义通信理论和经典的香农理论有很大不同，需要长期的研究和探索；
- 多域的联合优化：把基于 AI 的物理层技术真正有效的落实到端到端用户体验的提升，还有很长的路要走，用户体验的提升取决于业务提供商、核心网、网管、接入网、终端等各方面的高效配合，相关的接口需要开放，分布式 AI 算法的全局优化设计还有大量的工作；
- 绿色 AI 通信技术：AI 算法通常需要大量的数据集以及训练开销，对系统的成本和功耗有很大的挑战，未来 6G 需求指标相比 5G 会有很大的提升^[36]，对绿色通信技术有迫切的要求^[37,38]。因此，迫切需要低训练开销、低成本、低功耗的 AI 算法实现；
- 基于 AI 的自演进通信标准：移动通信网络面临着业务需求长期高速增长、系统部署费用高、网络运维复杂、通信标准和设备更新频繁等挑战。研究基

于 AI 的新的空口通信协议，使其根据新的系统需求自适应调整 AI 算法，同时 AI 算法的调整在安全严格的人类监管之下，这样就可以大幅度降低系统设备硬件升级成本；

- 基于量子计算的物理层 AI 技术：随着量子计算的快速发展，其巨大的算力为各行各业提供了全新的动能。基于 AI 的物理层和无线通信网络如何与量子计算进行深度的融合，是未来的一个重要课题。

基于上面的分析，未来潜在的国际标准化大体上分为如下几个阶段：

初级智能：物理层 AI 在部分物理层链路的关键技术中得到应用，例如信道估计、压缩、波束管理、无线定位等。这些技术需要相应的基站和终端之间信令流程的升级，对目前的接入网架构不产生显著的影响。在标准化过程中，首先要解决的是数据集的建立方法，基于前面章节的分析，基于现有的信道模型数据生成的数据集可以很好的支持 AI 模型训练。在实际应用中，再结合具体的信道测量数据进行模型选择与更新。此外，也需要制定统一的评估准则来评价 AI 算法的性能与代价。

中级智能：接入网的 AI 模块可以根据接入网、核心网、网管、业务服务器、以及终端的信息进行物理层神经网络的调整以及高层协议的智能实现，并通过智能调度在满足用户业务需求的情况下使得系统资源利用率最大化。难点在于端到端物理层链路基于 AI 方式的实现、基于 AI 的接入网架构设计、以及对于 AI 算法的监管机制。

高级智能：根据用户的业务需求，全网络的 AI 能力（接入网、核心网、网管、业务服务器、以及终端等）的联合优化，使得全网资源（时间、带宽、功率、算力等）实现动态最优分配，最大化体现效率与公平，难点是多个实体之间 AI 功能的分割以及联合优化如何实现。

7. 总结

AI 技术是助力实现未来无线网络智能化的重要使能技术之一。无线 AI 正“自上而下”地与无线网络的各个层面紧密地结合：从核心网、网络管理优化到接入网高层功能，乃至到接入网物理层功能都能够在 AI 技术的赋能下取得更优的性

能。现阶段无线 AI 正经历从理论走向实践的过程，业界不仅关注无线 AI 方案带来的理论上的增益，更关注如何顺利地将无线 AI 在实际网络中用起来。虽然产学研各方围绕该问题已经做了大量工作，但是仍存在一系列挑战需要解决：1) 缺少足够的科学公开的数据集；2) 如何根据无线数据的特点设计适合的 AI 算法；3) 如何克服场景变化带来的泛化性问题；4) 无线 AI 能够带来多少具体的系统级/链路级增益。

本白皮书内容针对上述几个问题进行展开，以目前较为新兴且十分挑战的物理层 AI 技术为用例梳理了相关研究进展。具体来说，围绕基于 AI 的发射机/接收机技术和基于 AI 的大规模 MIMO 技术两项用例介绍了其工作原理、算法设计以及依据现有数据集进行的性能比较结果。随着研究的不断深入，以 3GPP 为代表的行业标准化组织也逐渐开始开展相关的标准化工作。当前阶段各方关注的标准化重点在于如何制订一套系统、科学、公平的评估体系比较基于 AI 的无线方案与传统方案之间的优劣。因此，本白皮书用一章的内容专门讲述无线 AI 方案评估准则和评估指标，并特别强调了模型泛化性能在评估中的重要地位。

物理层以及无线 AI 的标准化将是一个“持久战”式的长期过程，因此不仅需要关注当前的标准化热点，更需要对未来标准化走势进行提前规划与把握，这方面的相关内容集中在第六章中呈现。此外，并非所有的无线 AI 方向都具备在近期标准化中讨论的成熟度，但并不意味着这些方向应该忽视。因此，白皮书列举并强调了一些未来无线 AI 具备潜力的研究方向，尤其是基于 AI 的多模块联合优化、绿色 AI 通信技术与基于 AI 的自演进通信标准等。这些方向未来的研究突破对无线通信系统将具有革命性的意义。

无线 AI，尤其是物理层 AI，迄今为止已有四年左右的研究积累，标准化工作将于明年（2022 年）开始。处在当下的关键节点，本白皮书意在从历史发展的角度回顾过去、展望未来，从科学规划相关研究的角度提出建议，致力于充分发挥无线 AI 的潜力，助力实现 6G 网络“数字孪生、智慧泛在”的美好愿景。受时间精力所限，白皮书中内容难免有疏漏错误之处，恳请诸位同行不吝指出。

8. 白皮书贡献单位

在白皮书中，中国移动主要负责物理层 AI 工作原理、无线 AI 算法评估准则

与泛化性提升技术、未来研究和标准化展望等内容，东南大学和清华大学主要负责基于 AI 的发射机/接收机技术以及基于 AI 的大规模 MIMO 技术部分。白皮书主要贡献人员如下：

中国移动通信有限公司研究院：韩双锋、谢天、刘志明、王启星

东南大学：张静、郭佳佳、金石

清华大学：蒋浩、魏秀红、陆宇、戴凌龙

缩略语列表

| 缩略语 | 英文全名 | 中文解释 |
|-------|--|-----------|
| AI | Artificial Intelligence | 人工智能 |
| OFDM | Orthogonal Frequency Division Multiplexing | 正交频分复用 |
| CU | Centralized Unit | 中心单元 |
| DU | Distributed Unit | 分布单元 |
| AMP | Approximate Message Passing | 近似消息传递 |
| DnCNN | Denoising Convolutional Neural Network | 降噪卷积神经网络 |
| 3GPP | 3rd Generation Partnership Project | 第三代合作伙伴计划 |
| ITU | International Telecommunication Union | 国际电信联盟 |
| SNR | Signal-to-Noise Ratio | 信噪比 |
| MIMO | Multiple-Input Multiple-Output | 多天线技术 |
| CSI | channel state information | 信道状态信息 |
| AE | autoencoder | 自编码器 |
| KPI | Key Performance Indicators | 关键性能指标 |
| NMSE | Normalized mean square error | 归一化均方误差 |
| QoS | Quality of Service | 业务质量 |
| QoE | Quality of Experience | 体验质量 |
| LTE | Long Term Evolution | 长期演进技术 |
| FDD | Frequency Division Duplexing | 频分双工 |
| MAC | Media Access Control | 媒体接入控制 |

参考文献

- [1] D. Silver et al., “Mastering the game of GO without human knowledge,” *Nature*, vol. 550, no. 7676, pp. 354-359, 2017.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” in *Proc. Adv. Neural Inf. Process. Syst.*, pp. 1097-1105, 2012.
- [3] M. Chen et al., “Artificial neural networks-based machine learning for wireless networks: A tutorial,” *IEEE Commun. Surveys & Tuts.*, vol. 21, no. 4, pp. 2029-2071, 4th Quarter 2019.
- [4] N. C. Luong et al., “Applications of deep reinforcement learning in communications and networking: A survey,” *IEEE Commun. Surveys & Tuts.*, vol. 21, no. 4, pp. 3133-3174, 4th Quarter 2019.
- [5] K. B. Letaief et al., “The Roadmap to 6G: AI empowered wireless networks,” *IEEE Commun. Mag.*, vol. 57, no. 8, pp. 84-90, Aug. 2019.
- [6] L. Dai, R. Jiao, F. Adachi, H. V. Poor, and L. Hanzo, “Deep learning for wireless communications: An emerging interdisciplinary paradigm,” *IEEE Wireless Commun.*, vol. 27, no. 4, pp. 133-139, Aug. 2020.
- [7] S. Han, C.-L. I, G. Li, S. Wang, and Q. Sun, “Big data enabled mobile network design for 5G and beyond,” *IEEE Commun. Mag.*, vol. 55, no. 9, pp. 150-157, Sep. 2017.
- [8] C.-L. I, Q. Sun, S. Zhang, Z. Liu, and S. Han, “The big-data-driven intelligent wireless network: Architecture, use cases, solutions, and future trends,” *IEEE Veh. Technol. Mag.*, pp. 20-29, Dec. 2017.
- [9] S. Han, T. Xie, C.-L. I, L. Chai, Z. Liu, Y. Yuan, and C. Cui, “Artificial intelligence enabled air interface for 6G: solutions, challenges, and standardization impact,” *IEEE Commun. Mag.*, vol. 58, no. 10, pp. 73-79, Oct. 2020.
- [10] ITU-T. FG-ML5G Technical Specification: Unified Architecture for Machine Learning in 5G and Future Network; ITU-T: Paris, France, 2019.
- [11] Study of Enablers for Network Automation for 5G, document S2-173827, 3GPP, Sophia Antipolis, France, May 2017.

- [12] Study on RAN-Centric Data Collection and Utilization for LTE and NR, document RP-182105, 3GPP, Sophia Antipolis, France, Sep. 2018.
- [13] T. O' Shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Trans. Cogn. Commun. Netw.*, vol. 3, no. 4, pp. 563 – 575, Dec. 2017.
- [14] H. Jiang and L. Dai, "End-to-end learning of communication system without known channel," in *Proc. IEEE Int. Conf. Commun. (ICC)*, Montreal, Canada, Jun. 2021.
- [15] L. Dai, et al., "Reconfigurable intelligent surface-based wireless communication: Antenna design, prototyping and experimental results," *IEEE Access*, vol. 8, pp. 45913-45923, Mar. 2020.
- [16] E. Bourtsoulatze, D. B. Kurka, D. Gündüz. "Deep joint source-channel coding for wireless image transmission," *IEEE Trans. Cogn. Commun. Netw.*, vol. 5, no. 3, pp. 567-579, Sep. 2019.
- [17] M. Borgerding, P. Schniter, and S. Rangan, "AMP-inspired deep networks for sparse linear inverse problems," *IEEE Trans. on Signal Process.*, vol. 65, no. 16, pp. 4293 – 4308, Aug. 2017.
- [18] H. He, C. K. Wen, S. Jin, and G. Y. Li, "Deep learning-based channel estimation for beamspace mmWave massive MIMO systems," *IEEE Commun. Lett.*, vol. 7, no. 5, pp. 852-855, Oct. 2018.
- [19] X. Wei, C. Hu and L. Dai, "Deep learning for beamspace channel estimation in millimeter-wave massive MIMO systems," *IEEE Trans. Commun.*, vol. 69, no. 1, pp. 182-193, Jan. 2021.
- [20] H. Kim, S. Oh, and P. Viswanath, "Physical layer communication via deep learning," *IEEE J. Sel. Areas Inf. Theory*, vol. 1, no. 1, pp. 5 – 18, May 2020.
- [21] Y. He, J. Zhang, S. Jin, C.-K. Wen, and G. Y. Li, "Model-driven DNN decoder for turbo codes: Design, simulation, and experimental results," *IEEE Trans. Commun.*, vol. 68, no. 10, pp. 6127 – 6140, Oct. 2020.
- [22] H. MahdaviFar, "Polar coding for non-stationary channels," *IEEE Transactions on Information Theory*, vol. 66, no. 11, pp. 6920-6938, Nov. 2020.

- [23] C. Wen, W. Shih and S. Jin, “Deep Learning for Massive MIMO CSI Feedback,” *IEEE Commun. Lett.*, vol. 7, no. 5, pp. 748-751, Oct. 2018.
- [24] T. Wang, C. Wen, S. Jin and G. Y. Li, “Deep Learning-Based CSI Feedback Approach for Time-Varying Massive MIMO Channels,” *IEEE Wireless Commun. Lett.*, vol. 8, no. 2, pp. 416-419, April 2019.
- [25] Z. Lu, J. Wang and J. Song, “Multi-resolution CSI Feedback with Deep Learning in Massive MIMO System,” in *Proc. IEEE Int. Conf. Commun. (ICC)*, 2021, pp. 1-6.
- [26] Z. Cao, W. -T. Shih, J. Guo, C. -K. Wen and S. Jin, “Lightweight Convolutional Neural Networks for CSI Feedback in Massive MIMO,” *IEEE Commun. Lett.*, vol. 25, no. 8, pp. 2624-2628, Aug. 2021.
- [27] Q. Cai, C. Dong and K. Niu, “Attention Model for Massive MIMO CSI Compression Feedback and Recovery,” in *Proc. IEEE Wireless Commun. Netw. Conf. (WCNC)*, 2019, pp. 1-5.
- [28] Z. Lu, J. Wang and J. Song, “Binary Neural Network Aided CSI Feedback in Massive MIMO System,” *IEEE Wireless Commun. Lett.*, vol. 10, no. 6, pp. 1305-1308, June 2021.
- [29] J. Guo, C. Wen, S. Jin and G. Y. Li, “Convolutional Neural Network-Based Multiple-Rate Compressive Sensing for Massive MIMO CSI Feedback: Design, Simulation, and Analysis,” *IEEE Trans. Wireless Commun.*, vol. 19, no. 4, pp.2827-2840, April 2020.
- [30] H. Ye, G. Y. Li and B. Juang, “Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems,” *IEEE Wireless Commun. Lett.*, vol. 7, no. 1, pp. 114-117, Feb. 2018.
- [31] W. Jiang and H. D. Schotten, “Neural Network-Based Channel Prediction and Its Performance in Multi-Antenna Systems,” in *Proc. IEEE Veh. Tech. Conf. (VTC-Fall)*, Aug. 2018, pp. 1 - 6.
- [32] H. Jiang, M. Cui, and L. Dai, “Accurate channel prediction for mobile millimeter-wave massive MIMO,” *IEEE Trans. Commun.*, 2021.

- [33] Y. Yang, F. Gao, Z. Zhong, B. Ai and A. Alkhateeb, “Deep Transfer Learning-Based Downlink Channel Prediction for FDD Massive MIMO Systems,” *IEEE Wireless Commun.*, vol. 68, no. 12, pp. 7485-7497, Dec. 2020.
- [34] Y. Han, M. Li, S. Jin, C. Wen, X. Ma, “Deep Learning-Based FDD Non-Stationary Massive MIMO Downlink Channel Reconstruction,” *IEEE J. Sel. Areas Commun.*, vol. 38, no. 9, pp. 1980-1993 Sep. 2020.
- [35] M. Alrabeiah and A. Alkhateeb, “Deep Learning for TDD and FDD Massive MIMO: Mapping Channels in Space and Frequency,” *Proc. Asilomar Conference on Signals, Systems and Computers*, May 2019.
- [36] G. Liu, Y. Huang, N. Li, J. Dong, J. Jin, Q. Wang, and N. Li, “Vision, requirements and network architecture of 6G mobile network beyond 2030,” *IEEE/CIC China Commun.*, vol. 18, no. 7, pp. 1-9, Aug. 2020.
- [37] C.-L. I, C. Rowell, S. Han, Z. Xu, G. Li, and Z. Pan, “Towards Green & Soft: A 5G Perspective,” *IEEE Commun. Mag.*, vol. 52, no. 2, pp.66-73, Feb. 2014.
- [38] C.-L. I, S. Han, and S. Bian, “Energy-efficient 5G for a greener future,” *Nature Electronics*, no.3, pp.182-184, Ap. 2020.



数字孪生 智慧泛在