面向 6G 的人工智能驱动信道状态信息（CSI）外推：现状、挑战与未来研究

Yuan Gao、Zichen Lu、Xinyi Wu、Wenjun Yu、Shengli Liu、Jianbo Du、Yanliang Jin、Shunqing Zhang、Xiaoli Chu、Shugong Xu

摘要——**信道状态信息（CSI）外推是获取信道状态信息（CSI）的有效方法，而 CSI 对优化第六代（6G）通信系统的性能至关重要。随着高移动性、超大规模多输入多输出（EL-MIMO）和多频段系统的兴起，开销激增，传统信道估计方法面临可扩展性挑战。信道状态信息外推技术利用部分 CSI 推断完整 CSI，从而显著降低开销。尽管人们对这一领域的兴趣日益浓厚，目前仍缺乏对最先进（SOTA）信道状态信息外推技术的全面综述。本文首次全面回顾信道状态信息外推的现状、挑战与未来方向，以弥补这一空白。首先，我们分析了 6G 信道状态信息外推特有的性能指标，包括外推精度、对动态场景的适应能力以及算法成本。随后，我们回顾了面向时间、频率、天线和多域信道状态信息外推的模型驱动和人工智能（AI）驱动方法，并总结了这些方法的关键见解与要点。鉴于人工智能驱动方法有望满足性能要求，我们还考察了可用于训练高性能人工智能驱动信道状态信息外推模型的开源信道数据集和仿真器。最后，我们讨论现有研究面临的关键挑战，并提出具有前瞻性的研究机遇。**

索引词—**信道状态信息外推，6G，人工智能，Surv ey.**

I. 引言

第六代（6G）移动网络有望在连接能力和性能方面实现变革性飞跃，预计将在 2030 [1]–[5]左右部署。6G预计将通过采用超大规模多输入多输出（EL-MIMO） [6]，以应对广泛的高移动性通信场景 [7], [8] 以及更高频段超越毫米波（mmWave）频谱 [9]–[12]。获取准确的信道状态信息（CSI）一直是确保移动网络性能的关键因素，对于实现 6G 愿景也日益重要 [13]。然而，6G 面临的一大挑战是在保持较低信道估计开销的同时获取准确的信道状态信息 [14], [15]。传统信道估计依赖于传输导频符号来测量信道响应，随后采用插值或压缩感知等技术重建信道状态信息[16], [17]。虽然这些方法在 5G大规模MIMO 中效果显著，但由于可扩展性差，在 6G 的 EL-MIMO 和更高频率场景中表现不佳，导致开销高得难以承受 [18], [19]。由此催生了信道状态信息外推这一研究领域。它是现代无线通信系统中的一项重要技术，在即将到来的 6G时代 尤其如此 [20]。

A. 信道状态信息外推概述

信道状态信息外推技术旨在利用部分信道状态信息（主要通过基于导频的信道估计获得）推断完整 CSI，从而降低开销 [21]–[24]。根据应用场景，信道状态信息外推可分为多种类型，包括时域、频域和天线域外推。

- 在车联网（V2X）和无人机网络等高速 6G 环境中，由于高移动性，信道变化迅速。传统方法往往难以在这些动态环境中保持信道状态信息的准确性，因此需要频繁发送导频或更新反馈，导致开销大幅增加[22], [25]。利用信道状态的时间特性，时域信道状态信息外推通过根据历史数据预测未来的信道状态信息来解决这一问题，从而减少频繁进行信道估计的需求和开销。当前研究主要针对时分双工（TDD）系统 [26]。

- 频域 CSI 外推对于频分双工（FDD）和多频段系统至关重要 [27], [28]。在 FDD系统中可观察到部分互易性：上行链路和下行链路的时延与角度几乎相同，而下行链路与上行链路之间的复增益则不同 [29]。频域 CSI 外推可用于利用这种部分互易性，并根据下行链路外推上行信道

本研究部分获得上海市自然科学基金项目（编号：25ZR1402148）的资助，部分获得上海市科学技术委员会6G科技创新与未来产业培育专项项目（编号：24DP1501001）的资助。（通讯作者：Yanliang Jin、Shugong Xu）

Yuan Gao、Zichen Lu、Xinyi Wu、Wenjun Yu、Shengli Liu、Yanliang Jin和Shunqing Zhang均供职于中国上海大学通信与信息工程学院，电子邮箱：gaoyuan-sie@shu.edu.cn、luzichen@shu.edu.cn、wu xinyi0312 @shu.edu.cn、yuwen-jun@shu.edu.cn、victoryliu@shu.edu.cn、jinyanliang@staff.shu.edu.cn和shunqing@shu.edu.cn。

Jianbo Du 就职于中国西安的西安邮电大学通信与信息工程学院，电子邮箱：dujianboo@163.com。

Xiaoli Chu 就职于英国谢菲尔德大学电子与电气工程系，电子邮箱：x.chu@sheffield.ac.uk。

Shugong Xu 任职于中国苏州的西交利物浦大学，电子邮箱：shugong.xu@xjtlu.edu.cn。

表一 按字母顺序排列的缩略语列表

缩略语	释义
1G	第一代
2D	二维
3D	三维
3GPP	第三代合作伙伴计划
5G	第五代
6G	第六代
ADEN	天线域外推网络
AGMAE	非对称图掩码自编码器
AI	人工智能
AoA	到达角
AoD	离开角
AR	自回归
ASN	天线选择网络
BEE	基扩展外推
BEM	基扩展建模
BER	误码率
BS	基站
CCM	信道相关性度量
CDL	簇化延迟线
CENet	信道状态信息外推网络
CFR	信道频率响应
CIR	信道冲激响应
CNN	卷积神经网络
条件生成对抗网络	条件生成对抗网络
CSI	信道状态信息
CT	信道Transformer
CVNN	复值神经网络
D2D	设备到设备
DFT	离散傅里叶变换
DL	下行链路
DNN	深度神经网络
EM	外推度量
ESPRIT	旋转不变技术信号参数估计 旋转不变技术
FDD	频分双工
FIT	一阶泰勒展开
FNN	全神经网络
GA	地空
GAI	生成式人工智能
GAN	生成对抗网络
GRU	门控循环单元
HRPE	高分辨率参数估计
I2O	室内到室外
IENet	干扰消除网络
IIoT	工业物联网
IoT	物联网
ITU	国际电信联盟
联合信道预测与天线选择	联合信道预测与天线选择
KF	卡尔曼滤波器
LB	下界
LEO	低地球轨道
线性最小均方误差	线性最小均方误差
LoS	视距
LS	最小二乘
LSTM	长短期记忆网络
LTE	长期演进
MCGP	蒙特卡洛高斯过程
MDMP	多维矩阵铅笔
mDRUNet	改进型深度残差U形网络
MICP	移动性诱导信道预测
MIMO	多输入多输出
MLP	多层感知机
MMSE	最小均方误差
毫米波	毫米波
MPC	多径分量
MSE	均方误差
MUSIC	多重信号分类
NLoS	非视距
NMSE	归一化均方误差
NR	新空口
O2I	室外到室内
O2O	室外到室外
ODE	常微分方程
QoS	服务质量
RIS	可重构智能表面
RMa	农村宏蜂窝
RMSE	均方根误差
RNN	循环神经网络
RSSI	接收信号强度指示器
稀疏复值神经网络	稀疏复值神经网络
SCP	空间一致性属性
SE	频谱效率
SISO	单输入单输出
SNR	信噪比
SVR	支持向量回归
TAS	发射天线选择
TDD	时分双工
TDL	抽头延迟线
TDoA	到达时间差
THz	太赫兹
TL	迁移学习
TR	技术报告
UAV	无人驾驶飞行器
UCB	上置信界
UE	用户设备
uGP	不确定高斯过程
UL	上行链路
UMa	城市宏小区
UMi	城市微小区
UT	用户终端
V2V	车对车
V2X	车对万物
VSS	矢量空间特征
WTMP	波前变换矩阵铅笔

信道，反之亦然 [30]。多频段系统通常使用多个频谱频段，例如 6 GHz 以下频段以及毫米波或太赫兹频段。毫米波和太赫兹频段具有独特的传播特性，例如更高的路径损耗和更强的方向性，因此信道更加稀疏 [31]。频域 CSI 外推可以捕捉这些稀疏特征，并利用已观测频段外推未观测频段的 CSI。

- EL-MIMO系统的庞大规模大幅增加了需要估计的信道状态信息数量，也显著提高了每根天线进行信道状态信息估计的需求。传统做法是为每根天线分配一个导频符号，但随着天线数量增加，这种做法的效率会降低，并消耗大量时频资源[32]。天线域CSI外推提出利用部分天线的信道状态信息来预测其他天线的信道状态信息，从而利用信道状态之间的空间相关性 [33]。

除单域外推之外，6G场景日益增加的复杂性（例如由 EL-MIMO 系统提供服务的超高速通信）要求进行多域信道状态信息外推 [34], [35]。多域联合 CSI 外推基于已知 CSI，推断时间、频率和天线多个维度上的未知 CSI，并利用不同域之间 CSI 的相关性来提高信道估计的精度 [36], [37]。

表 II 与信道状态信息外推相关的现有综述和杂志汇总。 ●、 ○和 ◐分别表示该主题已充分覆盖、部分覆盖和未覆盖。

论文	Year	时间域-域	频率域-域	Ant-领域	多域领域	数据集	关键见解与局限性
[38]	2024	●	○	○	○	○	主要回顾基于RNN系列的信道状态信息外推方法 时域，忽略模型驱动和先进的基于人工智能的方法。
[39]	2025	●	○	○	○	○	回顾基于模型和基于人工智能的信道状态信息外推方法, 时域方法，不深入讨论生成式人工智能，也不涉及 其他域。
[21]	2021	○	●	●	○	○	阐述频率域和天线域信道状态信息 外推的原理，重点介绍卷积神经网络和深度神经网络的变体，不回顾 先进的人工智能模型。
[30]	2023	●	●	●	○	○	讨论时域、频域和天线域信道状态信息 外推，重点关注基于人工智能的模型，不回顾多域 信道状态信息外推。
[40]	2023	●	○	○	○	◐	使用以下数据比较基于人工智能的时域信道状态信息外推方法: 在所提出的测试平台中测得的信道数据，不涉及其他域。
[41]	2023	◐	○	○	○	○	主要回顾模型驱动和基于RNN系列的信道状态信息外推 时域方法，未涉及先进的基于人工智能的方法以及 其他领域。
[42]	2019	●	●	○	○	○	回顾基础的基于人工智能的信道状态信息外推方法（例如，深度神经网络和卷积神经网络） 时域和频域方法、先进的基于人工智能的方法以及 未涵盖的其他领域。
本文		●	●	●	●	●	全面综述基于模型和基于人工智能的信道状态信息外推方法 ，涵盖时间、频率、天线和多域方面，并深入 讨论其优缺点。综述现有可用的数据集 和信道仿真器，并探讨面临的挑战及未来研究方向。

B. 信道状态信息外推相关综述

目前已有多篇关于信道状态信息外推的综述，重点关注单域信道状态信息外推 [38], [39], [43]。[38] 聚焦于在标准化的第三代合作伙伴计划（3GPP）抽头延迟线（TDL）-A模型下，利用数据驱动的神经网络（NNs）进行时域信道预测。该文从预测精度、对信道老化的鲁棒性和计算复杂度等方面，对五种神经网络架构进行了严格比较，包括多层感知机（MLP） [44],卷积神经网络（CNN） [45], 长短期记忆网络（LSTM） [46],门控循环单元（GRU） [47], 和 Transformer [48], 。 [39] 提出了一个更广泛的基于人工智能（AI）的信道预测框架，将相关方法分为时域信道预测（例如自回归（AR）模型、卡尔曼滤波器和神经网络）以及环境适应（例如迁移学习、元学习和数据增强）。上述综述主要讨论时域信道，未涉及频域、天线域或联合多域信道状态信息外推。 [43]在移动通信领域，尤其是大规模多输入多输出系统中，为天线域信道生成与外推作出了重要贡献。该文引入条件扩散模型（DM）这一新型生成式人工智能框架，以应对高维天线域信道估计、外推和反馈所面临的挑战。

有几篇论文回顾了多个域中的信道状态信息外推。 [21]回顾了用于天线域和频域信道状态信息外推的深度学习（DL）解决方案，例如深度神经网络（DNN）和基于卷积神经网络的模型。 [30]系统地探讨了时间、频率和天线域中的信道状态信息外推技术，以应对 6G 系统中的开销挑战。对于时域外推，作者强调了高移动性场景中的信道，并提出基于生成对抗网络（GAN）的网络来处理非线性 CSI 演变。在频域外推方面，作者区分了 FDD 上行（UL）到下行（DL）映射与多频段共存（例如，从 6 GHz 以下到毫米波），并利用部分互易性和衍射现象进行参数级推断。在天线域外推方面，作者引入了一种新颖的信道 Transformer，通过自注意力机制应对 EL-MIMO 中的空间非平稳性，并利用时域预训练进行迁移学习以增强性能。[41] 回顾了基于人工智能的信道质量预测技术，强调其在降低 6G网络导频信号开销方面的作用。论文将相关方法分为时域、频域和天线域方法。时域预测采用循环神经网络（RNN）利用时间相干性，而频域方法则使用深度神经网络来映射上行链路/下行链路相关性。天线域信道状态信息外推通过采用 K 近邻（KNN）和卷积神经网络进行无线电地图补全来实现；基于网络相关性的预测则引入了一种深度神经网络框架，根据参考节点测量值推断直接的设备到设备（D2D）信道。然而，该研究忽略了 Transformer 模型或混合域融合策略等先进技术。 [42] 对自适应无线通信系统中基于循环神经网络的信道预测技术进行了深入分析。论文首先批判了传统的基于模型的方法，例如参数模型和 AR 模型，并指出它们在计算复杂度（参数模型）和易受噪声影响（AR 模型）方面的局限性。随后，作者将循环神经网络作为一种数据驱动的替代方案加以介绍，强调其利用衰落信道中的时间相关性的能力。论文概述了循环神经网络的架构和训练方法，包括时间反向传播，并将其应用扩展到

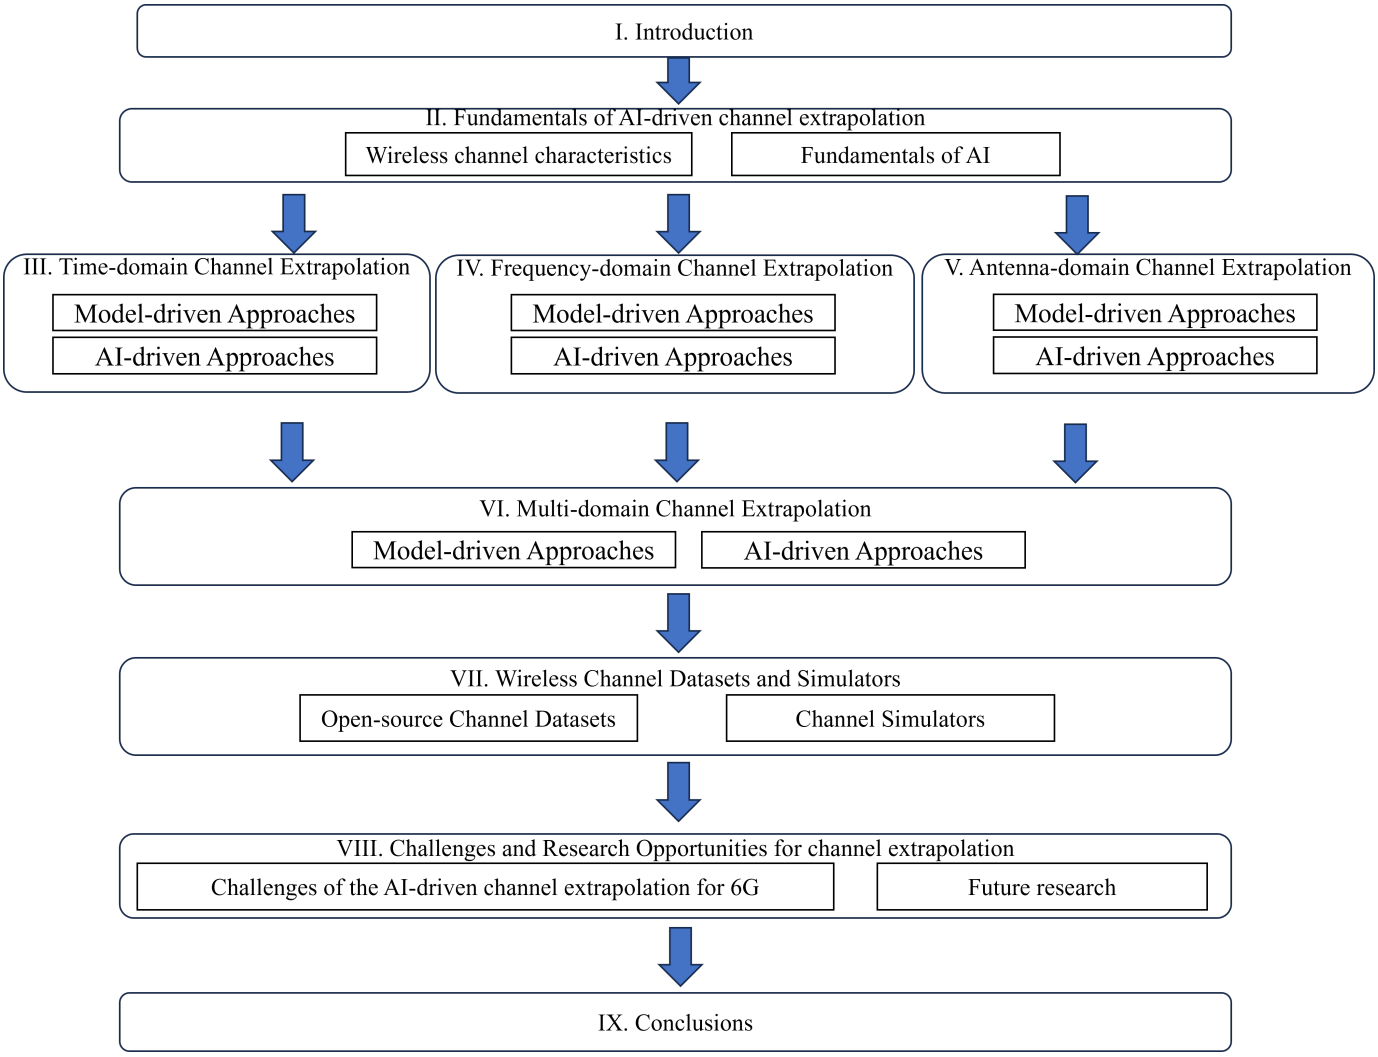


图 1. 本文概述。

平坦衰落和频率选择性 MIMO-OFDM 系统。

然而，上述综述存在以下局限性：

- 上述综述对信道状态信息外推技术进行了宏观概述，但缺乏对不同外推技术的系统比较，也未评估它们的优势、劣势以及对各种场景的适用性。

- 上述综述侧重于特定域中的信道状态信息外推，例如时域或频域外推，例如 [38], [39]仅考虑时域外推，而 [43] 仅关注天线域外推。然而，上述综述均未回顾多域信道状态信息外推的研究现状。

- 上述综述主要关注基于人工智能的信道状态信息外推方案，而忽略了对可用数据集和仿真器的讨论。众所周知，高质量数据集对于训练高性能的基于人工智能的模型起着关键作用。

C. 范围与组织结构

本文旨在全面讨论信道状态信息外推的现状、挑战和解决方案。据我们所知，这是首篇深入分析时间、频率、天线和多域信道状态信息外推的综述。本文的创新点和贡献可概括如下：

- **人工智能驱动的信道状态信息外推基础**：我们全面回顾信道状态信息外推和人工智能技术的基础知识。对于信道状态信息外推，我们系统地阐述其问题，并分析第五代和第六代中在时间、频率、天线和多域方面的典型用例。在人工智能方面，我们从原理、在信道状态信息外推中的应用以及计算复杂度等方面回顾具有代表性的人工智能模型。

- **信道状态信息外推方案的综合综述**：不同于现有仅提供高层次概述的综述，本文对信道状态信息外推技术进行了详细比较，全面考察了

模型驱动方案和人工智能驱动方案，突出分析了各自的优势与不足。我们全面综述了多域信道状态信息外推，强调了与单域外推相比其独特的挑战。据我们所知，这是首篇如此详细研究多域外推的综述。

- **可用的数据集和信道仿真器**：为支持人工智能驱动模型的有效训练，我们全面调研了与信道状态信息外推相关的可获取开源无线数据集和信道仿真器。我们分析了这些数据集/仿真器用于信道状态信息外推时的关键特征、优势和不足。这一方面在以往的调研和综述论文中基本未受到关注。

- **挑战与未来方向**：我们讨论了人工智能驱动的信道状态信息外推在时间、频率、天线和多域方面面临的主要挑战。此外，我们还提出了相应的未来研究方向，包括高效且可靠的数据集构建、全面的性能评估指标、先进的模型设计，以及与新兴技术的融合。

本文的组织结构如下。第二节讨论了面向6G的信道状态信息外推性能指标，包括外推精度、泛化能力和计算复杂度。第三、四、五和六节分别综述了时间、频率、天线和多域信道状态信息外推的最新模型驱动方法和人工智能驱动方法。我们总结了当前时间、频率、天线和多域信道状态信息外推研究的关键见解和要点。由于人工智能驱动方法有望满足信道状态信息外推的性能要求，我们在第七节综述了可用于训练高性能人工智能模型进行信道状态信息外推的无线信道数据集和仿真器。最后，在第八节中，我们讨论了若干关键研究挑战，并提出了解决每项挑战的潜在研究方向。

II. 人工智能驱动的信道状态信息外推基础

本节详细介绍信道状态信息外推的应用与用例，以及典型人工智能模型的基础知识。

A. 无线信道特性

为说明无线信道特性，我们考虑一个采用正交频分复用（OFDM）的多输入多输出系统。基站第 i根天线与用户设备第 j根天线之间的无线信道，在频率f 处、时刻 t 可表示为：

$$h_{i,j}(f,t)=\sum_{l=1}^{L}\alpha_{i,j,l}(f,t)e^{j\eta_{i,j,l}(f,t)}e^{-j2\pi f_l(t)\tau_l(t)}, \tag{1}$$

其中，$\alpha_{i,j,l}(f,t)$ 和 $\eta_{i,j,l}(f,t)$ 分别表示频率 f 、时刻的基站第 i 根天线与用户设备第 j 根天线之间第 l 条路径的幅度和相位 t，分别如此。 L 表示路径总数。 $f_l(t)$ 和$\tau_l(t)$ 分别表示第 l 条路径的接收频率和传输时延。频率 f 、时刻 t 的完整信道矩阵 $\mathbf{H}(f,t)$ 可表示为：

$$\mathbf{H}(f,t)=\begin{bmatrix} h_{1,1}(f,t) & \dots & h_{1,j}(f,t) & \dots & h_{1,J}(f,t) \\ \dots & \dots & \dots & \dots & \dots \\ h_{i,1}(f,t) & \dots & h_{i,j}(f,t) & \dots & h_{i,J}(f,t) \\ \dots & \dots & \dots & \dots & \dots \\ h_{I,1}(f,t) & \dots & h_{I,j}(f,t) & \dots & h_{I,J}(f,t) \end{bmatrix}, \tag{2}$$

其中， I 和 J 分别为基站和用户设备的天线数量。

1）时域：在第五代之前的传统通信系统中，由于用户设备的移动性有限，信道在时域变化缓慢，在一段时间内可视为不变；这段时间即相干时间，在数学上可表示为：

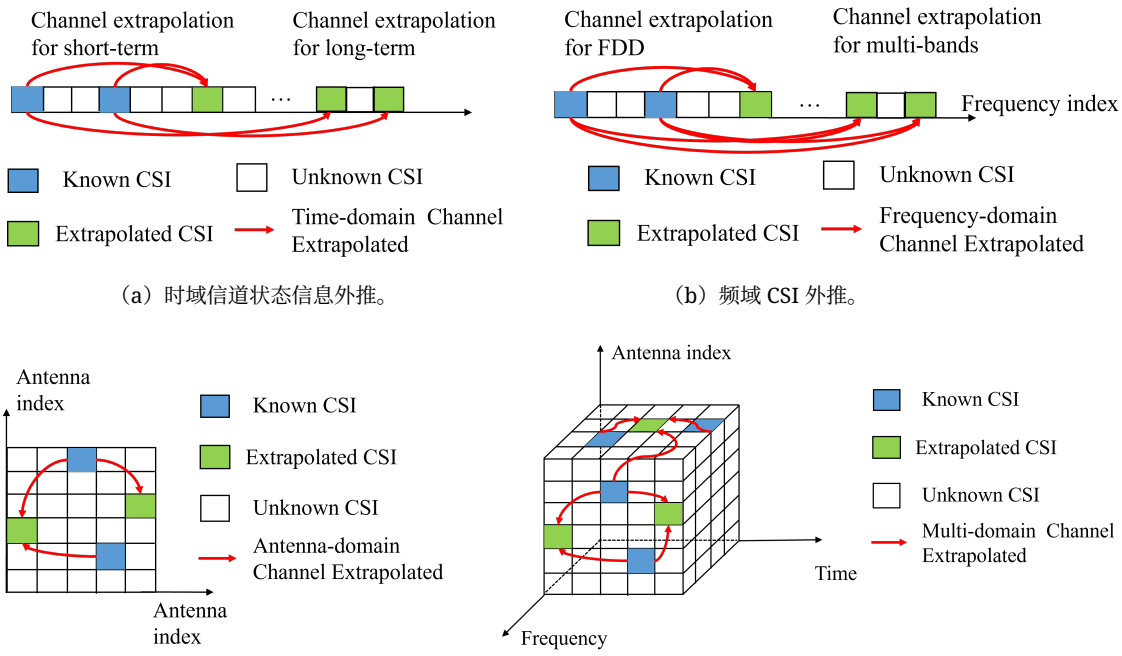
$$h_{i,j}(f,t+\Delta t)\approx h_{i,j}(f,t),\forall i,j,f, \tag{3}$$

其中 Δt 表示信道样本之间的时间差。若时间差 Δt 小于相干时间 t_{C}，即 $\Delta t<t_{\mathrm{C}}$，则式（3）成立。值得注意的是，相干时间 t_{C} 与基站和用户设备之间的相对移动性呈负相关，也就是说，用户设备移动得越慢，相干时间就越长。为保障蜂窝系统的性能，必须在每个相干时间内获取信道状态信息（主要通过基于导频的信道估计）。这意味着相干时间越长，执行信道获取的频率越低，产生的开销也越小。然而，预计 6G 将支持广泛的高速通信场景，例如车联网和无人机网络，此时相干时间会大幅缩短。这意味着获取的信道状态信息很快就会过时，这种现象称为信道老化或信道陈旧。因此，需要更频繁地执行传统的基于导频的信道估计，进而产生过多开销。

时域信道变化的本质源于以下两个方面：

- **移动引起的多普勒频移**：基站与用户设备之间的相对运动会导致多普勒频移，其大小与二者之间的径向速度成正比。这意味着每条路径的频率 $f_l(t)$ 都会发生变化，从而导致式1所示的无线信道发生变化。多普勒频移越显著，在一定时间内无线信道的变化就越大。从这一角度来看，面向第六代的时域信道状态信息外推比面向第五代的更具挑战性，因为预计第六代将支持超过 1000 km/h 的移动速度，远高于第五代的 500 km/h。

- **BS 与 UE 之间的相对位置变化**：BS 与 UE 之间的相对移动会改变幅度 $\alpha_{i,\ j,\ l}(f_{\mathrm{C}}t)$ 和相位 $\eta_{i,\ j,\ l}(f_{\mathrm{C}}t)$，从而改变第$l$条路径的无线信道；这必然会改变公式 1中给出的无线信道。位置变化更大时，总路径数 L 也更有可能发生变化。因此



（a）时域信道状态信息外推。 （b）频域 CSI 外推。

（c）天线域CSI外推。 （d）多域信道状态信息外推。

图 2. 信道状态信息外推示意图。

表 III 第五代和第六代在重要性、应用与挑战方面的时域、频域、天线域和多域信道状态信息外推比较。

	5G	6G
时间域	短期：高速引起的多普勒频移； 长期：多普勒频移和位置变化。	短期：超高速引起的多普勒频移； 长期：多普勒频移和位置变化。
频率域	频分双工：部分信道互易性； 多频段： 6 GHz 以下频段与毫米波之间的信道特性，涉及其对视距、大气吸收等因素的依赖。	频分双工：部分信道互易性； 多频段：6 GHz 以下频段之间的信道特性（毫米波）和太赫兹频段，在对视距的依赖、大气吸收、散射、绕射等方面。
天线-域	远场：天线的位置变化	新兴多输入多输出系统：除了位置变化之外，还有 EL-MIMO 中的空间非平稳性，流体天线系统中天线位置的灵活性，以及可重构智能表面中的相位控制。
多域	多个域之间的信道相关性耦合域。	多个域之间的信道相关性耦合域，单一域中的信道外推挑战也随之增加

UE 移动得越快，在特定时间段内无线信道的变化往往越大。

如图 2(a)所示，为了在高移动性场景中获取信道状态信息，提出了利用历史信道状态信息进行时域信道状态信息外推的方法，如下所示：

$$[h_{i,j}(f,t),\ldots,h_{i,j}(f,t+t_{M-1})] \tag{4}$$

$$=\mathbb{F}_{\mathrm{T}}\left([h_{i,j}(f,t-t_1),\ldots,h_{i,j}(f,t-t_N))\right], \tag{5}$$

其中，$[t,\ldots,t+t_{M-1}]$ 和 $[t-t_1,\ldots,t-t_N]$ 分别是外推信道状态信息的 M时刻以及历史数据的 N 时刻。$\mathbb{F}_{\mathrm{T}}$ 是时域信道状态信息外推。这项技术对移动通信尤为关键，尤其是在信道快速变化的场景中（例如高移动性用户），准确的信道状态信息预测能够优化资源分配、波束成形和预编码设计。短时间周期的时域外推所面临的挑战源于多普勒频移；而对于长时间周期的时域外推，则需要同时考虑多普勒频移和位置变化。

2）频域：FDD和多频段系统有望满足6G对时延和容量的严格要求。具体而言，与时分双工相比，FDD系统能够同时支持上行链路和下行链路通信。通过避免时分双工中因上行链路切换至下行链路或下行链路切换至上行链路而导致的传输中断，可以最大限度地降低时延。提出采用更高频段（如毫米波频段和太赫兹频段）来提升蜂窝系统的容量。对于FDD或多频段系统，传统的基于导频的信道估计不可避免地会增加开销，从而降低网络性能。

时域中的信道变化本质上源于以下两个方面：

• **FDD系统**：在FDD中，上行链路和下行链路频段彼此分离，下行链路$f_{\text{下行链路}}$与上行链路$f_{\text{上行链路}}$之间的双工间隔几乎总是远大于信道相干带宽f_{C}，即$|f_{\text{下行链路}} - f_{\text{上行链路}}| > f_{\text{C}}$。因此，信道互易性不成立：

$$h_{i,j}(f_{\text{UL}}, t) \neq h_{i,j}(f_{\text{DL}}, t), \forall i, j, t. \tag{6}$$

研究发现，在某些情况下，下行链路和上行链路信道之间唯一的差异是每条传播路径的复增益，而两者的时延和角度与频率无关

t

[29]。这种部分信道互易性使得可以利用上行信道推断下行信道，反之亦然。

•**多频段系统**：对于同时工作在 6 GHz以下频段和毫米波（太赫兹）频段的系统，这两个频段的信道特性截然不同。具体而言，与 6 GHz以下频段相比，毫米波（太赫兹）频段更容易受到遮挡影响。此外，毫米波和太赫兹频段具有独特的传播特性。毫米波在视距条件下可支持数百米范围内的可靠链路，在非视距条件下则可通过绕射和反射支持有限距离的链路，同时氧气吸收和雨衰程度适中。相比之下，太赫兹频段的大气吸收极强、绕射可忽略、散射严重，并且几乎完全依赖视距传播，因此实际无线传输距离仅为数米或更短。不同频段之间的上述传播特性使跨频段信道状态信息外推极具挑战性。

如图2(b)所示，提出了频域 CSI 外推，以利用一个频段中已知的 CSI 来获取另一个频段中的 CSI，如下所示：

$$[h_{i,j}(f'_1, t), ..., f'_M, t)] \tag{7}$$
$$= \mathbb{F}_{\text{F}}\left([h_{i,j}(f_1, t), ..., h_{i,j}(f_N, t))\right], \tag{8}$$

其中，$[f'_1, ..., f'_M]$和$[f_1, ..., f_N]$分别是目标频谱频段的M采样频点，以及已知 CSI 的频谱频段的N采样频点。$\mathbb{F}_{\text{F}}$是频域 CSI 外推。这种方法在 FDD 和多频段系统等场景中尤为重要，因为这些场景需要降低反馈开销并提高频谱效率。FDD系统可利用部分信道互易性进行频域 CSI 外推。频域外推面临的挑战源于多个频谱频段之间信道特性的差异。

3）天线域：蜂窝网络演进中一个前所未有的趋势是天线数量急剧增加，从 4G 的 4 根天线增至 6G 的 1024 根以上。传统上，多输入多输出系统通过为每个收发对分配专用导频来获取 CSI，这对于 4G 来说成本可接受。然而，这种方案不适用于 6G，否则将导致过高的开销。天线域中的信道变化本质上是指不同收发对之间的信道变化，其成因主要有以下两个方面：

•**远场**：在第五代中，基站与用户设备之间的距离远大于瑞利距离，因此传统的远场假设成立，这简化了无线传播过程，其假设空间平稳，即多条路径的数量和角度均相同。这表明，不同发射端—接收端对之间的信道变化是由天线的位置造成的。

• **新兴天线系统**：对于 EL-MIMO 系统，远场假设不再成立，空间非平稳性变得显著，这可能导致某些传播路径仅对大规模天线阵列中的部分天线可见 [49], [50]。在这种情况下，天线位置间距越大，不同信道在路径数方面的差异就越大 L，进而在幅度$\alpha_{i,\ j,\ l}(f,\ t)$、相位$\eta_{i,\ j,\ l}(f,\ t)$和传输时延$\tau_l(t)$方面也会产生差异。其他类型的可编程天线（如流体天线、可重构智能表面等）通过改变天线单元的位置和相位，为优化无线信道提供了更灵活的方法，也为天线域CSI外推带来了新的挑战。

如图所示 2(c)，提出了天线域CSI外推方法，以利用已知的部分天线CSI来获取所有天线的CSI：

$$h_{\{i,j\}_{\text{I}}}(f, t) = \mathbb{F}_{\text{A}}(h_{\{i,j\}_{\text{K}}}(f, t)), \tag{9}$$

其中，$\{i, j\}_{\text{I}}$和$h_{\{i,j\}_{\text{K}}}(f,\ t)$分别表示感兴趣的收发对集合和已知CSI的收发对集合。需要注意的是，为了尽可能减少开销，感兴趣的收发对数量通常远大于已知CSI的收发对数量，即$\|\{i, j\}_{\text{I}}\| \gg \|\{i, j\}_{\text{K}}\|$。$\mathbb{F}_{\text{A}}$是天线域CSI外推，旨在利用部分天线的CSI推断同一面板上未测量天线的CSI，从而减少下行训练和反馈开销。对于远场天线域CSI外推，挑战可能源于不同天线位置的变化。近场天线域CSI外推则更具挑战性，因为传播路径可能因天线而异。在这种情况下，应联合设计CSI外推算法和天线选择方案。

4）多域：现有大多数关于信道状态信息外推的研究都聚焦于上述单一域，即时域、频域或天线域。然而，随着6G时代的到来，图中所示的多域联合信道状态信息外推2(d) 已不可避免 [51]。例如，6G通常需要联合频率-天线域信道状态信息外推，因为所利用的频谱越高，为补偿传播损耗并实现定向波束成形，所需的MIMO系统规模就越大。多域联合信道状态信息外推的挑战源于这样一个事实：单一域中的信道相关性通常是耦合的。例如，式$\alpha_{i,\ j,\ l}(f,\ t)$中的幅度$\eta_{i,\ j,\ l}(f,\ t)$、相位 $\tau_l(t)$ 和传输时延1 ，都会受到载波频率和天线位置的影响。此外，在采用超大规模MIMO为高速用户设备提供服务的车联网场景中，需要进行联合时域-天线域CSI外推，以较低开销获取CSI。在虚拟现实（VR）场景中，用户设备使用多个频段的超大规模MIMO获得服务，以实现高

表 IV 不同模型的复杂度比较

模型	每层复杂度
MLP	$\mathcal{O}(d^{out}_{MLP} d^{in}_{MLP})$
RNN	$\mathcal{O}(T \times h \times (h + d^{in}_{RNN}))$
LSTM	$\mathcal{O}(T \times 4 \times h \times (h + d^{in}_{LSTM}))$
GRU	$\mathcal{O}(T \times 3 \times h \times (h + d^{in}_{GRU}))$
CNN	$\mathcal{O}(H_{out} \times W_{out} \times C_{in} \times C_{out} \times H_k \times W_k)$
GNN	$\mathcal{O}(K_s N_s F + N_s F^2)$
Transformer	$\mathcal{O}(T^2 d_{Trans})$

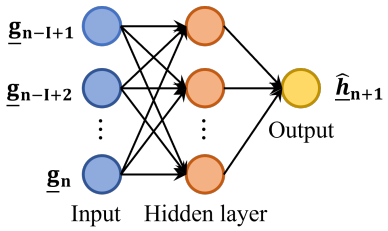


图3. 多层感知机示意图。

吞吐量；联合频率-天线域CSI外推有助于最大限度地降低信道状态信息获取的开销。

表 III 总结了第五代和 6G 中时域、频域、天线域和多域信道状态信息外推在重要性、应用和挑战方面的比较。

B. 人工智能基础

人工智能模型在信道状态信息外推中发挥着关键作用，下面将详细介绍典型人工智能模型在信道状态信息外推中的应用。

1）多层感知机（*MLP*）：如图3所示，MLP 是一种经典的前馈神经网络架构，由输入层、输出层和至少一个隐藏层组成。设 d^{in}_{MLP}和 d^{out}_{MLP} 分别表示输入神经元和输出神经元的数量。MLP 层的计算复杂度为$\mathcal{O}$（$d^{out}_{MLP} dn^{in}_{MLP}$）。MLP 广泛应用于多个领域，包括无线通信系统中的信道估计和信道预测任务。通过多层非线性变换，MLP 能够学习输入与输出之间复杂的映射关系，因此适用于信道状态信息外推等回归问题。MLP 的结构通常由输入层、多个全连接隐藏层和输出层组成。每个隐藏层包含多个神经元，每个神经元先对其输入进行线性加权求和，再通过非线性激活函数输出。MLP 的核心原理是通过多层非线性变换，从输入数据中逐步提取高层特征，从而逼近复杂的函数关系。在信道预测任务中，MLP 的输入通常是经过预处理的接收信号向量，输出则是预测的未来信道向量。具体而言，MLP 的输入输出关系可表示为 [52]:

$$\underline{\hat{h}}_{n+1} = f_{\Pi}(\underline{\mathbf{g}}_{n-I+1}, \cdots, \underline{\mathbf{g}}_{n}), \tag{10}$$

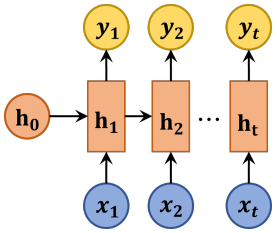


图4. 循环神经网络示意图。

其中，Π表示 MLP 的参数集，I 表示用于平衡模型复杂度和预测性能的输入阶数，而 g_n 则是经过线性最小均方误差（LMMSE）预处理的接收信号向量，以增强模型对噪声的鲁棒性。在 MLP 的训练阶段，输入为经过预处理的信道向量序列（$\mathbf{g}^{n}_{n-I+1}, \cdots, \mathbf{g}^{n}$），输出则是后续时间步的信道向量 $\hat{h}_{n+1}$。为适应实值神经网络架构，通常将复数输入分解为实部和虚部。隐藏层采用 L个全连接层，每层包含 f_l 个神经元。输出层对应于预测信道向量的实部和虚部，随后通过重构层将二者合并为复数形式的预测信道向量。训练时使用 ADAM 作为优化器，损失函数定义为预测信道与预处理信道之间的均方误差：

$$C_{\text{loss}} = \frac{1}{N_{\text{train}}} \sum_{n=I}^{N_{\text{train}}} \left\| \underline{\hat{\mathbf{h}}}_{n+1} - \underline{\mathbf{g}}_{n+1} \right\|^2, \tag{11}$$

其中，N_{train} 表示训练样本的数量。在信道状态信息外推任务中，多层感知机学习历史信道数据中的时间相关性，以预测未来的信道状态。其优势在于训练完成后，预测阶段的计算复杂度较低，因此适用于对实时性能要求较高的通信场景。然而，多层感知机训练需要大量样本数据，且对输入阶数和网络架构较为敏感。需要根据用户移动性等因素进行适当配置，以平衡性能和计算复杂度。

2) 基于*RNN*的模型：如图4所示，循环神经网络是一种专门用于处理序列数据的神经网络架构，能够通过内部状态捕捉时间序列中的动态特征。在无线通信领域，得益于对时间依赖关系的建模能力，循环神经网络已成为时变信道预测的重要工具。RNN的核心在于其循环结构，该结构通过共享参数和隐藏状态在不同时间步之间传递信息。在每个时间步，RNN接收当前输入和前一时间步的隐藏状态，并计算当前输出和更新后的隐藏状态。这种循环计算使每层的时间复杂度为 $\mathcal{O}(T \times h \times (h + d^{in}_{RNN}))$，其中 T 为序列长度，h 为隐藏状态大小，

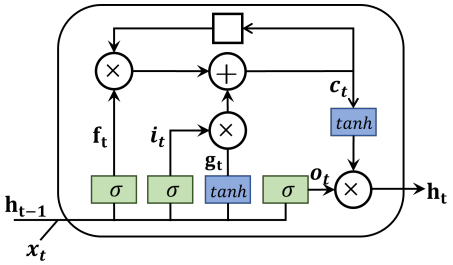


图 5. 长短期记忆网络示意图。

且 d_{RNN}^{in} 为输入维度。这种机制使RNN能够有效处理具有时间相关性的信道数据。

在信道预测任务中，循环神经网络的基本计算过程可表示如下 [53]:

隐藏状态更新如下:

$$\mathbf{h}_t = \sigma(\mathbf{W}_{hh}\mathbf{h}_{t-1} + \mathbf{W}_{xh}\mathbf{x}_t + \mathbf{b}_h), \tag{12}$$

输出的计算方式如下:

$$\mathbf{y}_t = \mathbf{W}_{hy}\mathbf{h}_t + \mathbf{b}_y, \tag{13}$$

其中， h_t 表示当前时间步的隐藏状态，x_t 表示当前输入，y_t 表示当前输出。 W_{hh}、 W_{xh}和 W_{hy} 为权重矩阵， b_h 和 by 为偏置向量， σ 为激活函数。与传统自回归模型相比，基于循环神经网络的信道预测方法能够更好地捕捉信道变化的非线性特征，在时变环境中表现出较强的适应性。循环神经网络的循环结构能够自然地对信道的时间相关性进行建模，从而实现更准确的预测。

然而，传统循环神经网络在处理长序列时会面临梯度消失或梯度爆炸问题，从而限制其在长期信道预测中的性能。此外，循环神经网络的训练过程相对复杂，需要仔细进行超参数调优以确保收敛。

如图所示5，LSTM网络是一种特殊类型的循环神经网络，通过引入门控机制和细胞状态，解决传统RNN在长序列训练过程中遇到的梯度消失问题。凭借其对时间序列数据强大的建模能力，LSTM在无线通信领域的信道预测任务中表现出色。LSTM的核心创新在于其门控架构和细胞状态设计。一个LSTM单元包含三种关键门控结构：遗忘门控制历史信息的保留，输入门调节新信息的引入，输出门决定当前状态的输出比例。细胞状态作为长期记忆的载体，在整个序列处理过程中维持信息流。然而，这种复杂的设计也增加了计算需求，使每层的时间复杂度达到 $\mathcal{O}(T \times 4 \times h \times (h + d_{LSTM}^{in}))$，其中 T、 h和 d_{LSTM}^{in} 分别表示序列长度、隐藏状态大小和输入维度。在信道预测中，

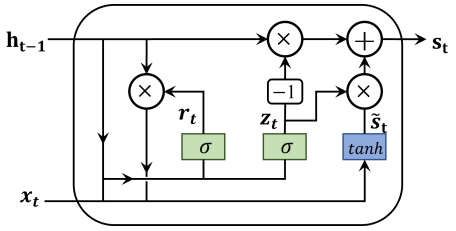


图 6. GRU 示意图。

LSTM的主要计算步骤包括 [54]: 遗忘门决定从先前的细胞状态中丢弃哪些信息:

$$f_t = \sigma(W_f x_t + R_f h_{t-1} + b_f). \tag{14}$$

s 新信息添加的输入门控制计算如下:

$$\begin{aligned} i_t &= \sigma(W_i x_t + R_i h_{t-1} + b_i), \\ g_t &= \tanh(W_g x_t + R_g h_{t-1} + b_g). \end{aligned} \tag{15}$$

单元状态更新如下:

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t. \tag{16}$$

输出门确定最终输出如下:

$$\begin{aligned} o_t &= \sigma(W_o x_t + R_o h_{t-1} + b_o), \\ h_t &= o_t \odot \tanh(c_t), \end{aligned} \tag{17}$$

其中， W_f、 W_i 和 W_g 分别表示从输入 xt 到遗忘门、输入门和候选状态的权重矩阵。 R_i、 R_g 和 R_f 表示相应的循环权重矩阵，以及从隐藏状态 h_{t-1} 到遗忘门的循环权重矩阵。 W_o、 R_o 和 b_o 是输出门的权重和偏置参数，而 b_i、b_g 和 b_f 表示遗忘门的偏置向量。 σ 是 Sigmoid 激活函数， $\odot$ 表示逐元素乘法，从而实现选择性信息更新。

如图 6所示，GRU 是一种基于循环神经网络架构的增强模型，通过引入门控机制，解决了传统 RNN 在处理长序列时遇到的梯度消失问题。得益于其简化的结构和出色的时间序列建模能力，GRU 在无线通信领域的信道预测任务中展现出显著优势。

门控循环单元的核心创新在于其门控机制设计，通过两种关键门结构——更新门和重置门——调节信息流和记忆状态更新。与长短期记忆网络相比，门控循环单元将长期状态和短期状态合并为一个隐藏状态，并减少了参数数量，从而在保持性能的同时提升计算效率。这种结构简化使其每层的时间复杂度降低至 $\mathcal{O}(T \times 3 \times h \times (h + d_{LSTM}^{in}))$，其中 T、 h和 d_{GRU}^{in}分别表示序列长度、隐藏状态大小和输入维度。因此，门控循环单元的计算效率高于长短期记忆网络。

在信道预测任务中，GRU 的计算过程可表示为 [55]:

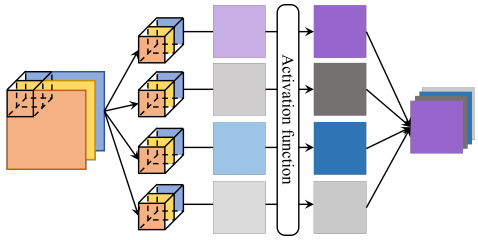


图 7. 卷积神经网络示意图。

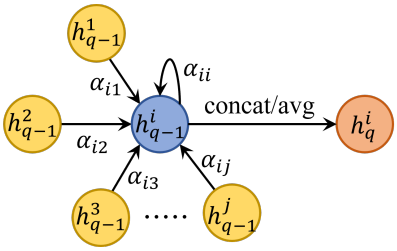


图 8. 图神经网络示意图。

更新门的计算公式为：

$$\mathbf{z}_t = \sigma_g(\mathbf{W}_z\mathbf{x}_t + \mathbf{U}_z\mathbf{s}_{t-1} + \mathbf{b}_z). \tag{18}$$

重置门的计算方式如下：

$$\mathbf{r}_t = \sigma_g(\mathbf{W}_r\mathbf{x}_t + \mathbf{U}_r\mathbf{s}_{t-1} + \mathbf{b}_r). \tag{19}$$

候选隐藏状态的生成方式如下：

$$\tilde{s}_t = \sigma_h\left(\mathbf{W}_s\mathbf{x}_t + \mathbf{U}_s\left(\mathbf{r}_t \otimes \mathbf{s}_{t-1}\right) + \mathbf{b}_s\right). \tag{20}$$

最终隐藏状态的更新方式如下：

$$\mathbf{s}_t = (1 - \mathbf{z}_t) \otimes \mathbf{s}_{t-1} + \mathbf{z}_t \otimes \tilde{\mathbf{s}}_t, \tag{21}$$

其中，σ_g 表示 Sigmoid 激活函数，σ_h 表示双曲正切函数，W 和 U 为权重矩阵，b 为偏置向量，$\otimes$ 表示逐元素乘法。

在多天线系统的信道预测应用中，门控循环单元通过其门控机制有效捕获信道的时间相关性。更新门控制当前状态保留多少历史信道信息，而重置门决定如何将新的信道观测与前一状态相结合。这种机制使门控循环单元能够自适应地平衡长期依赖关系与短期变化，从而在快速变化的信道环境中保持稳定的预测性能。

然而，门控循环单元的性能仍受网络深度和训练数据质量的影响。在深层网络架构中，需要仔细进行超参数调优，以避免过拟合问题。同时，充足的训练数据对于充分发挥门控循环单元在信道预测中的潜力至关重要。

3) 卷积神经网络：卷积神经网络是一种具有卷积操作和深层结构的前馈神经网络，广泛应用于图像处理。如图7所示，在卷积神经网络中，卷积操作将一组共享权重（卷积核）应用于输入特征图，以生成输出特征图。数学上，第（i，j，k）层 h处输出特征图的值可表示为：

$$y_{i,j,k}^{h+1} = g\left(\boldsymbol{w}_k^{h\,T}\boldsymbol{x}_{i,j}^h + b_k^h\right), \tag{22}$$

其中，$\boldsymbol{x}_{i,j}^h$是输入特征图在位置（i,j）处的局部感受野，$\boldsymbol{w}_k^h$是第 k 个输出特征图的卷积核，b_k^h是偏置项，而$y_{i\ k,j,}^{h+1}$是输出特征图在位置（i,j,k）处的值。

输出特征图的尺寸由输入特征图的尺寸、核大小、步幅和填充决定：

$$H_{out} = \left\lfloor \frac{H_{in} + 2P - H_K}{S} \right\rfloor + 1, \tag{23}$$

$$W_{out} = \left\lfloor \frac{W_{in} + 2P - W_K}{S} \right\rfloor + 1, \tag{24}$$

其中，H_{in} 和 W_{in} 分别为输入特征图的高度和宽度，H_K 和 W_K 分别为卷积核的高度和宽度，P 为填充大小，S 为步幅。卷积层的计算复杂度主要由卷积操作本身决定，可表示为 $\mathcal{O}(H_{out} \times W_{out} \times C_{in} \times C_{out} \times H_k \times W_k)$，其中$C_{in}$ 和 C_{out} 分别表示输入通道数和输出通道数。

卷积神经网络通过卷积层擅长提取局部特征，并利用平移不变性确保特征表示高效且准确。与全连接神经网络相比，卷积神经网络通过在空间位置间共享权重来减少参数数量，因此在处理高维数据时计算效率更高 [56]。然而，由于卷积神经网络侧重于局部区域，因此在建模全局关系方面存在固有的困难，尤其是在细粒度层面上。这一局限促使人们将注意力机制或全局池化层等互补技术融入其中，以增强其捕获长程依赖关系的能力。

4) 图神经网络：如图 8所示，图神经网络是一种专门用于处理图结构数据的深度学习架构，能够有效捕捉节点之间的拓扑关系和局部依赖关系。在无线通信领域，图神经网络凭借其建模空间相关性和局部扩散机制的固有能力，已成为信道状态信息外推任务的重要工具。图神经网络的核心在于通过基于图的消息传递机制聚合邻域信息，从而更新节点表示。在流体天线系统的信道状态信息外推中，每个天线端口都可视为图中的一个节点，节点之间的边则根据端口间的空间邻近关系构建。图神经网络通过多层图注意力网络模块，逐步扩散并重建信道特征。图注意力网络模块中每一层的计算过程

如下：

$$
\begin{aligned}
e\left(\mathbf{h}_{q-1}^{i}, \mathbf{h}_{q-1}^{j}\right) &= \mathbf{a}^{\top} \cdot \mathrm{LReLU}\left(\mathbf{W}_{e}\left[\mathbf{h}_{q-1}^{i} \,\|\, \mathbf{h}_{q-1}^{j}\right]\right), \\
\alpha_{ij} &= \frac{\exp\left(e\left(\mathbf{h}_{q-1}^{i}, \mathbf{h}_{q-1}^{j}\right)\right)}{\sum_{j' \in \mathcal{N}_i} \exp\left(e\left(\mathbf{h}_{q-1}^{i}, \mathbf{h}_{q-1}^{j'}\right)\right)}, \\
\mathbf{h}_{q}^{i} &= \sigma\left(\sum_{j \in \mathcal{N}_i} \alpha_{ij} \cdot \mathbf{W}_{a} \mathbf{h}_{q-1}^{j}\right),
\end{aligned}
\tag{25}
$$

此处， h_{q-1}^{i} 表示第$q-1$层第 i个端口的特征向量， a、W_e和 W_a 表示可学习的线性变换矩阵，LReLU为非线性激活函数， $\|$ 表示向量拼接， α_{ij} 为归一化的注意力权重，反映邻近节点 j 对中心节点 i的重要性。通过多层堆叠，图神经网络逐步融合远距离端口之间的信道信息，从而有效外推未知端口的信道。

在 AGMAE 框架中，图神经网络充当解码器组件，负责通过局部扩散机制重建所有未知端口的信道状态[57]。该过程基于编码器生成的基向量和已知端口信道状态信息进行。本质上，这一过程是学习基向量的组合系数，从而在保留空间平滑性和局部相关性的同时，重建整个信道矩阵。图神经网络的优势在于其复杂度相对于节点数量呈线性增长，具体而言

$$
\mathcal{O}(K_s N_s F + N_s F^2), \tag{26}
$$

其中， K_s 表示邻居的数量， N_s 表示端口总数， F 表示特征维度。这使得图神经网络特别适用于高分辨率流体天线系统中的大规模信道状态信息外推任务。

然而，图神经网络的性能高度依赖于所构建图的质量以及节点之间的实际相关性。如果图结构未能准确反映信道之间的真实依赖关系，外推精度可能会受到限制。此外，图神经网络对训练数据的分布较为敏感，其在动态信道环境中的泛化能力仍需进一步优化。

5）Transformer：如图9所示，Transformer 是完全基于注意力机制构建的突破性神经网络架构，已在多个领域彻底革新了人工智能。其统一的编码器-解码器结构和多模态能力使其具有高度的通用性和适应性。Transformer 主要由 N_e 级联编码器和 N_d 级联解码器构成。Transformer 的核心是自注意力机制，它为输入序列的不同部分动态分配权重，使模型能够聚焦于最相关的特征。自注意力机制使每层的时间复杂度为$\mathcal{O}(T^2 d_{Trans})$，其中 T是序列长度， d_{Trans}是特征维度。数学上，位置 i 处的自注意力输出可写为

$$
\mathrm{Attention}_i = \mathrm{softmax}\left(\frac{(q_i W^Q)(K W^K)^{\top}}{\sqrt{d_k}}\right)(V W^V), \tag{27}
$$

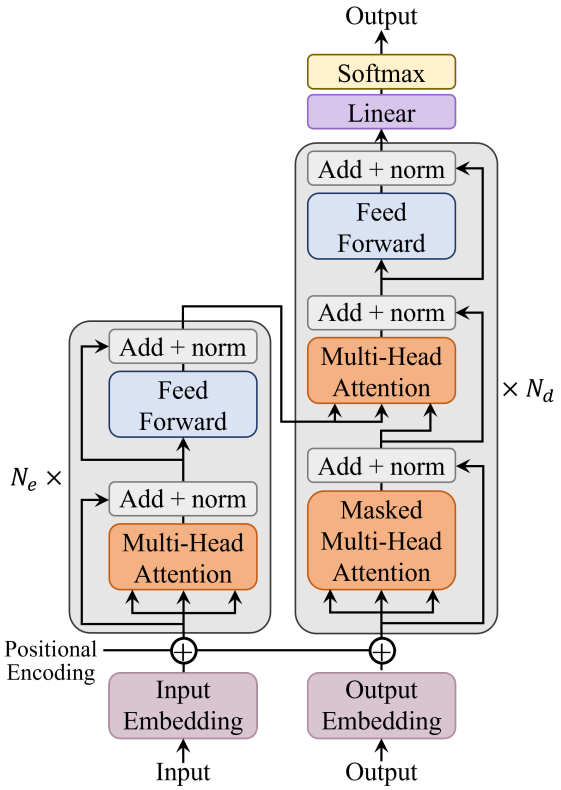


图9. Transformer示意图。

其中， q_i、 K和 V 是查询、键和值表示； W^Q、 W^K和 W^V 是投影矩阵； d_k 是缩放因子；softmax 是 softmax函数。

Transformer通过统一的架构简化了特征处理，但其注意力机制的 O（n^2）计算复杂度会带来较高的资源需求，尤其是在处理长序列时。此外，Transformer依赖大型数据集进行训练，这可能会降低其在较小数据集或简单任务上的效率；在这些场景中，卷积神经网络等模型可能表现更好。

上述模型的计算复杂度对比如表IV所示。

III. 时域信道状态信息外推

如图所示：2(a)时域信道状态信息外推利用历史信道状态信息序列获取未来信道状态信息序列，这对高速通信场景尤为有益。本节全面回顾了最先进的时域信道状态信息外推方案。最先进时域信道状态信息外推方案的全面综述如图所示：10。

A. 模型驱动方法

模型驱动方案依赖信道的时间相关性，使用数学模型描述信道随时间的变化。其核心假设是信道具有一定程度的连续性，因此可以通过数学关系从历史信道状态信息推导出未来的信道状态信息。

Method	Schemes	Principles	Strengths	Weaknesses
Model-based	AR-based	Future channel modeled as a linear combination of the historical channel with additive stochastic noise.	• Easy implementation; • Computational efficient.	• Unfit for channel with strong channel aging effect.
	Parametric channel-based	Channel modeled mathematically regarding multipath components, Doppler frequency shift, etc., future channel calculated using the estimated parameters.	• Consider the physical properties of the channel, i.e., strong interpretability; • High accuracy if model fits the channel.	• Limit to quasi-static channel with time-invariant or slowly varying channel parameters; • Computation-intense for high accuracy parameter estimation.
AI-based	MLP	An MLP is a multilayer-perceptron model trained to fit the complex nonlinear dynamics of the channel in time domain.	• Enable complex nonlinear relationships.	• Dependent on large datasets; • Difficult to train; • Low parameter efficiency.
	RNN-series	Model the time-domain channel extrapolation as a sequence-to-sequence problem, process the input CSI sequence serially.	• Designed to process sequential data, effectively capture the time-series correlations inherent in communication channels; • Variable sequence length handling.	• Error accumulation due to sequential extrapolation; • Sequential extrapolation induced long-latency for large historical CSI sequence, unfit for high-speed communication.
	Transformer-based	Model the time-domain channel extrapolation as a sequence-to-sequence problem, process the input CSI sequence parallelly.	• Capture complex features and long-range temporal dependencies of the input historical CSI sequences using multi-head self-attention mechanisms; • Parallel computation effectively mitigate channel aging in high-mobility scenarios.	• Computation-intense for training and inference; • Positional encoding need improvements for time-series channel.
	Hybrid-AI schemes	Incorporating multiple AI models to capture the temporal correlation of historical CSI and extrapolate future CSI series.	• ConvLSTM enhances its spatio-temporal feature extraction abilities by substituting all fully-connected network in LSTM by CNN. • CNN-Transformer enhances its ability to extract spatial information of XL-MIMO by adding a CNN at the beginning of the Transformer encoder.	• Weaknesses of multiple AI models; • Difficult design to balance local and temporal features.

图 10. 时域 CSI 外推方案的最新进展综述。

这种方法依赖预先建立的信道动态模型，可分为以下几类：

1）基于 *AR* 的方法：AR 模型假设，当前 CSI 是先前时刻的 CSI 值与加性随机噪声的线性组合。这是一种经典的时间序列预测方法，具有简单易实现的特点。为捕捉时间相关性，研究人员提出了多种方案 [52]，[58]–[70]。 [67] 提出了一种用于信道状态信息外推的两阶段部分在线优化方案。具体而言，第一阶段利用前面 L 个时隙的 CSI 预测下一时隙的 CSI，并通过在线优化 AR 模型参数来适应不同的移动速度。第二阶段则利用第一阶段预测的 CSI 和前面 m 个时隙的实际 CSI，通过插值操作预测未引导时隙的 CSI。在已知时间相关性的情况下，研究人员提出了基于卡尔曼滤波器（KF）的预测器[52], [59], [66]以及基于维纳滤波器的预测器 [60]–[62] 。例如， [52]提出了一种基于一阶多项式的外推方法，用于外推时变信道。该方法利用最近两个时间点的信道估计值，外推下一个时间点的信道。与直接使用过时信道相比，该方法能够更好地捕捉信道的时变特性，从而提升外推性能。 [62] 提出了用于时域信道预测的维纳滤波。该方案利用导频来预测当前时刻的信道状态序列。

基于 AR 的模型假设信道模型具有明确的线性形式，易于理解，也便于进行理论分析。基于 AR 的模型易于实现，因此适用于实时应用和资源受限设备。在对线性动态信道进行信道状态信息外推时，基于 AR 的模型表现良好。然而，在非线性或复杂环境中（例如多径效应显著或具有高移动性的场景），基于 AR 的模型表现较差。这一缺点促使人们开发更复杂的时域信道状态信息外推方案。

2）基于参数化信道的方法：基于参数化无线信道模型的方法根据准静态假设进行时域信道状态信息外推，即无线信道的关键参数（例如复振幅、时延和多普勒频移）在外推期间保持时变或缓慢变化 [71]–[83]。根据参数估计技术的不同，基于参数化无线信道模型的方法包括变分模态分解 [73]、基于最大似然的方法 [74], [80]，、基于子空间的方法（例如多重信号分类（MUSIC）） [75], [76]，、基于压缩感知的方法 [77], [78], 以及基于旋转不变技术的信号参数估计（ESPRIT） [75]，[79]。

基于参数化信道的方法基于考虑物理特性的信道模型，这些物理特性具有明确的物理含义和很强的可解释性。这类

方法在信道模型与信道场景相匹配时尤其有效。然而，当信道处于动态变化状态，即准静态假设不成立时，这些方法的性能会显著下降。此外，高精度估计关键参数通常计算复杂度较高，因此在计算资源受限且有实时要求的场景中适用性有限。

B. 人工智能驱动方法

遗憾的是，由于多径效应和多普勒效应，实际信道通常会随时间复杂地演变，这使得模型驱动方法难以与实际信道相匹配。基于人工智能的方案采用机器学习或深度学习技术，有望从历史CSI数据中学习信道变化的复杂模式和长期依赖关系，从而实现高精度的时域信道状态信息外推。与模型驱动方案不同，这些方案不依赖预定义的数学模型，而是通过数据驱动方法提取特征和模式。下一节将全面综述最先进的人工智能驱动时域信道状态信息外推方法。

1) 基于*MLP*的方案：多层感知机（MLP）采用全连接架构，是首个被提出用于外推未来信道状态信息序列的深度学习模型，它根据从历史信道状态信息序列中学习到的信道特性进行外推 [52]。然而，时域外推的MLP输入通常包含大量信道信息，因此这类模型很难训练。

2）基于循环神经网络（*RNN*）系列的方法：时域信道状态信息外推可建模为从历史信道状态信息到未来信道状态信息的序列到序列转换，这可通过基于RNN的模型实现 [42], [52]–[55], [84]–[95]。在 [84], 中，提出了一种基于实值权重RNN的信道预测方法，其在计算复杂度更低、预测精度更高方面优于复值加权RNN模型。此外，还提出了适用于多输入多输出系统的基于RNN的时域信道状态信息外推模型 [42], [85], ，与基于AR的模型相比，该模型在计算复杂度适中的情况下，对噪声和插值误差具有更强的鲁棒性。

然而，基于RNN的模型在捕捉信道信息的长期依赖关系方面仍然表现不佳。为此，RNN 的演进模型——LSTM [53], [54], [96], [97] 和 GRU [55], [95],[98],应运而生。研究 [91] 表明，与基线RNN相比，基于LSTM的模型能够更好地学习时间序列数据中的长期和短期依赖关系，并且在时域信道状态信息外推方面表现更佳。此外，在低轨卫星系统中，基于LSTM的模型优于传统的卡尔曼模型和RNN模型 [92]。 [93] 提出了一种基于LSTM网络的深度学习信道状态信息外推模型，该模型擅长捕捉时间序列数据中的相关性，因此能够有效预测未来的信道参数，并优于传统AR积分移动平均和支持向量回归（SVR）方法。 [94]观察到，在多天线衰落信道中，基于LSTM和GRU的模型在计算复杂度和预测精度方面均优于RNN。

基于RNN系列的方法直观地适用于时域信道状态信息外推，因为它们能够进行序列到序列的转换，并捕捉序列中的时间依赖关系。此外，基于RNN系列的方法能够处理长度可变的输入序列，因此可以灵活应对历史信道状态信息数量的变化。然而，基于RNN的模型按顺序进行信道状态信息外推，前几个时间步中的外推误差会在后续时间步中累积。此外，对于较长的历史信道状态信息序列，按顺序进行外推会导致较长的时延，这不利于高速通信。

3）基于*Transformer*的方法：随着6G的兴起，通信场景日益复杂，传统的基于人工智能的模型难以实现理想的性能。凭借卓越的长程特征提取能力，Transformer已被用于时域信道状态信息外推。自注意力机制被用于提取时域信道状态信息中的深层隐含关系 [22], [38], [99], [100], [100]–[103]。 [99]提出了一种基于Transformer的并行信道状态信息外推方案，以解决移动毫米波大规模MIMO系统中的信道老化问题。具体而言，该论文将信道状态信息外推问题转化为并行信道映射问题，从而避免传统顺序外推方法中的误差传播问题。与现有的顺序信道状态信息外推方法（如LSTM、RNN等）相比，所提出的框架在具有不同移动性的移动场景中，具有更优的归一化均方误差性能和吞吐量性能。 [22] 通过移除位置编码进一步改进了时域信道状态信息外推。在时域信道状态信息外推中，时序CSI序列通常缺乏内在语义，其主要目标是对一组连续CSI值的时间变化进行建模。因此，时序CSI中的序列顺序对于准确理解CSI序列的时间相关性至关重要。向CSI序列添加位置编码可能会导致原始序列信息或位置上下文丢失，最终降低外推性能。

总而言之，基于Transformer的方法擅长捕捉复杂的时间特征，因此特别适用于复杂场景下的时域信道状态信息外推。Transformer能够捕捉长期时间相关性，即相隔多个时间步的CSI之间的关系。Transformer的并行计算能够有效缓解高移动性场景中的信道老化。然而，这类方法需要大型数据集和大量计算资源进行训练。此外，这些模型的推理过程也十分耗费计算资源，因此难以保证实时进行时域信道状态信息外推。此外，位置编码带来的置换不变性并不完全适合处理时域CSI序列。

4）混合人工智能方案：除了上述单一的基于模型的时域信道状态信息外推方案外，人们还提出了融合多个AI模型的混合方案。为提升复杂场景下时域信道状态信息外推的性能，一个主要趋势是

利用CNN卓越的特征提取能力，并将其与其他AI模型结合，以实现序列到序列转换 [104]–[110]。CNN最初与RNN结合 [109], , 随后又与LSTM结合 [106]–[108]。卷积长短期记忆网络（ConvLSTM）是一种经典的序列到序列转换模型，例如可用于降水临近预报。在该模型中，LSTM的所有全连接层都由CNN替代 [111], , 并且它已针对时域信道状态信息外推进行了调整。具体而言，ConvLSTM中的CNN模型增强了传统的基于LSTM的方法提取时空特征的能力，从而提升了时域信道状态信息外推的性能 [112], [113]。此外，CNN-Transformer通过在Transformer编码器的开头添加CNN，增强了提取XL-MIMO空间信息的能力 [104]。

尽管混合方案可以发挥多种人工智能模型的优势，但设计这类方案并非易事。以基于 ConVLSTM 的方案为例，对于相干时间不断变化的信道（例如，在高移动性场景中相干时间较短），如何设计 CNN 卷积核以捕捉时间局部模式，同时不改变 LSTM 的序列长度，是一项棘手的任务。在短相干时间场景中，CNN 需要关注时间局部模式（例如，高多普勒导致的快速相位偏移），但过度下采样或使用较大的卷积核会模糊这些模式。在长相干时间场景中，CNN 必须避免过分强调短期噪声，而 LSTM 则需要较长的序列来捕捉稳定趋势。此外，基于 ConVLSTM 的方案仍存在 LSTM 在序列外推方面的缺陷，需要加以解决。

IV. 频域 CSI 外推

如图2(b)所示，频域 CSI 外推利用其他频点的 CSI，获取感兴趣频点处的 CSI，这对频分双工和多频段通信场景尤其有利。本节全面回顾了最先进的频域 CSI 外推方案。图11总结了模型驱动方法与人工智能驱动方法在频域 CSI 外推方面的全面比较。

A. 模型驱动方法

FDD系统中传统的信道状态信息外推方法是基于参数化无线信道模型的方法。这类方法利用多径分量等物理属性对信道建模，从而实现跨频率的信道状态信息外推 [114]。这些方法通过估计路径损耗或时延扩展等参数来重建信道响应，通常会用到最大似然估计或子空间技术等工具 [115], [116]。文献 [117]指出，当频率间隔小于信道相干带宽的一半时，外推误差较小；但超过这一范围后，误差会迅速增大。 [118] 提出了一种基于外推矩阵（EM）的频域信道状态信息外推方法，与现有的最小二乘法（LS）或基于最小均方误差（MMSE）的方法相比，该方法大幅降低了计算复杂度。 [119]提出利用上行信道角度散射函数的频率不变性估计下行信道协方差矩阵，无需额外的下行信道训练开销，即可根据上行信道参数估计下行信道协方差矩阵。与基于压缩感知或字典学习的方法不同，该方法无需假设信道具有离散且稀疏的角度特性。

为进一步提高CSI外推精度，基于高分辨率参数估计（HRPE）的外推方法已广泛应用于频域 [120]–[122]。HRPE方法利用信道的多径结构，实现更大范围的频域外推，为FDD大规模MIMO系统中的低反馈开销解决方案提供了重要参考。 [123] 指出，可采用空间交替广义期望（SAGE）估计器等HRPE方法来提升CSI外推性能。与传统的LS和线性最小均方误差（LMMSE）外推方法相比，所提出的基于HRPE的外推方法能够实现更大的外推范围。与压缩感知等其他外推算法相比，基于HRPE的外推算法在频域外推性能方面表现更好。 [124]利用SAGE算法提取多径信道参数，包括幅度、时延和角度信息。

基于参数化信道的方法依赖于预定义的频率响应模型，这些模型易于理解和验证。当模型与场景匹配时，其性能良好。然而，在6G宽带系统中普遍存在的复杂多径场景下，这类方法难以应对模型失配问题，因为很难对多径特征进行全面建模。此外，参数估计的高计算复杂度也是基于参数化信道的方法面临的另一项主要问题。

B. 人工智能驱动方法

1) 多层感知机： 针对频分双工系统中的频域信道状态信息外推，研究者提出了基于多层感知机的模型 [125], [126]。这类模型经过训练，可学习子信道之间的频率相关性，并进一步用于外推未知子信道的信道状态信息。在 [127], 中，研究者提出了一种基于多层感知机架构训练的信道预测器，该预测器显著降低了训练开销，且性能明显优于以往基于机器学习的宽带信道预测方法。为进一步提升信道状态信息外推的性能， [128] 提出了一种基于稀疏复值神经网络的下行链路信道状态信息外推方法，该方法学习从上行链路到下行链路的确定性映射关系，可基于上行链路信道状态信息直接映射得到下行链路信道状态信息，无需下行训练和上行链路反馈。为加速信道状态信息外推， [129] 提出了一种轻量级机器学习模型，用于生成高质量的初始猜测值，再通过高效的优化框架加以改进，从而实现外推

Method	Schemes	Principles	Strengths	Weaknesses
Model-based	Parametric channel-based	Channel modeled mathematically using physical properties, such as multipath components, etc., CSI across frequencies points are extrapolated using the estimated parameters.	• Consider the physical properties of the channel, i.e., strong interpretability; • High accuracy if model fits the channel.	• Poor performance if the channel model mismatches with the scenarios,; • Computation-intense for high accuracy parameter estimation.
AI-based	MLP-based	Trained to learn the frequency correlation between subchannels, and are further used to extrapolate the unknown CSI of sub-channels	• Effective in learning complex mappings between frequency bands, potentially capturing non-linear frequency-selective characteristics.	• Low parameter-efficiency of MLP results in the large parameter volume of MLP and limits its scalability in multi-band systems.
	RNN-series	Modeling sequential patterns across frequency bands, potentially capturing correlations of CSIs across frequencies.	• Temporal information of CSI is utilized to improve the performance of frequency-domain channel extrapolation.	• CSIs across frequencies are not strictly sequential, reducing their effectiveness; • Error accumulation due to sequential extrapolation.
	CNN	Perform frequency-domain channel extrapolation using the frequency-domain correlation capture by the kernels in CNN.	• Efficiently capturing local correlations among CSIs, showing high-performance for FDD systems.	• Limited long-range feature capturing, not suitable for frequency-domain channel extrapolation across wide frequency separation, such as multi-band systems.
	Transformer-based	Capture the correlation between CSI in frequency-domain using self-attention module, and perform sequence-to-sequence transformation.	• Ability to capture long-range feature across frequencies, promising for frequency-domain channel extrapolation in multi-band systems.	• Computation-intense for training and inference.
	Hybrid-AI schemes	A spatial attention module integrated into the CNN-based models to effectively extract internal connections among spatial features to improve CSI extrapolation.	• Focusing on the spatial features of the greatest importance, thereby improving performance of frequency-domain channel extrapolation; • Easy integration between spatial attention module and CNN-based models.	• Relying on the assumption of input CSI spanning uniformly across frequencies.

图 11. 对当前最先进的频域信道状态信息外推方案的全面综述。

其精度可与基准模型相当；一种基于多层感知机的方法能够快速、高效地进行跨频段信道预测。

多层感知机能够学习不同频段之间的复杂映射，有望捕捉非线性频率选择性特征。然而，多层感知机的参数效率较低，导致其参数量庞大，并限制了其在多频段系统中的可扩展性。这意味着多层感知机需要大量数据，才能在不同频段和场景之间实现泛化，从而给实时部署带来挑战。

2）RNN 系列方法：利用信道状态信息的时域信息，通过循环神经网络和长短期记忆网络提升频域信道状态信息外推的性能。在 [130],针对宽带 MIMO-OFDM 系统中的频率选择性信道，提出了一种基于循环神经网络的频域外推方法。该模型处理过去信道状态信息序列，以预测未来状态，同时考虑衰落动态。与传统卡尔曼滤波预测器相比，该循环神经网络频域信道预测方法在频率选择性信道上的性能更佳，并具有更高的灵活性和预测能力。长短期记忆网络通过解决梯度消失问题对循环神经网络进行了改进，从而提升了训练性能[131], [132]。在 [133], 中，介绍了一种基于长短期记忆网络的频域信道状态信息外推方法，用于预测路径损耗。与采用最新观测数据的传统方法相比，该方法使均方根误差（RMSE）性能提升了1 dB以上，并且在包括高频段在内的任何频率下都能保持较高的预测精度

频段。 [134] 提出了一种基于长短期记忆网络的方法，用于在真实的车载通信环境中预测信道特性。作者首先使用商用车载单元和频谱分析仪开展测量活动，从 IEEE 802.11p 帧中提取信道状态信息；随后收集了不同车对车（V2V）驾驶场景下的真实无线接入车载环境通信数据集；最后构建并评估了一种深度学习方法，用于预测这些车载环境中的子载波级信道状态信息以及帧级接收信号强度指示（RSSI）。 [135] 指出，基于人工智能的方法，尤其是长短期记忆网络和循环神经网络，被视为一种很有前景的信道状态信息预测技术。作者表示，通过优化长短期记忆循环神经网络的两个参数，即输入特征数量和隐藏层数量，可以进一步提升预测性能。与传统的基于估计的方法、自回归（AR）和自回归滑动平均（ARMA）建模方法以及二阶统计建模方法相比，基于长短期记忆循环神经网络的方法具有更好的预测性能。 [136] 提出了一种名为 SatCP 的基于深度学习的频域信道状态信息外推方法，该方法使用深度神经网络直接根据观测到的上行链路信道状态信息预测未来的下行链路信道状态信息，从而避免下行链路信道估计。与需要进行下行链路信道估计的传统方法相比，SatCP 方法能够有效解决低轨卫星大规模 MIMO系统获取有效下行链路信道状态信息的难题。

RNN 系列模型能够对跨频段的序列模式进行建模，有望捕捉

跨频率的信道状态信息相关性。此外，利用信道状态信息的时域信息可以提升频域信道状态信息外推的性能。然而，对于频域信道状态信息而言，这种方法不够直观，因为频率相关性并非严格按序排列，因此其效果不如其他模型。此外，基于RNN的模型以序列方式进行信道状态信息外推，在宽带信道状态信息外推中会产生误差累积。

3）基于卷积神经网络的方法：由于能够捕捉子载波之间的关系，卷积神经网络被用于频域信道状态信息外推。[137] 提出了一种基于卷积神经网络的方法，利用上行链路信道状态信息预测下行链路信道状态信息，以解决频分双工大规模多输入多输出系统中下行链路信道状态信息反馈开销过高的问题。该方法无需依赖信道稀疏性假设，利用神经网络在没有任何先验知识的情况下，仅使用观测到的测量数据学习上行链路和下行链路频段之间的物理联系。[138] 提出了一种基于路径增益系数的神经网络方法，通过从上行链路和下行链路信道中提取共同的路径增益系数来训练神经网络。所提出的方法大幅降低了神经网络的输入和输出维度，简化了训练过程，并且即使在高速移动期间也能保持良好的性能。

基于卷积神经网络的模型利用局部频率相关性，这与其在图像中捕捉局部模式的方式类似，因此适合处理频率选择性衰落。因此，基于卷积神经网络的模型在FDD系统中表现良好。然而，由于模型设计的限制，基于卷积神经网络的模型难以捕捉宽带系统中信道状态信息之间的相关性。它需要进行复杂的设计（例如滤波器尺寸）来处理频域数据的特定结构，尤其是宽带信道。

4）基于*Transformer*的方法：[139] 提出了一种面向FDD系统的、基于Transformer的信道状态信息外推方法。与先进行上行信道估计、再以逐步方式进行下行链路信道预测的方法不同，[139]实现了一个端到端框架，直接将基站接收的上行链路导频作为网络输入，以获取下行链路信道状态信息。该方法提出了一种基于Transformer编码器并采用非因果注意力机制的混合特征提取模块，以有效捕获下行链路信道特征，并展示出优异的信道状态信息外推性能。[140]提出了一种基于Transformer的频域信道状态信息外推方法。该网络旨在估计RIS辅助OFDM系统中的频率选择性衰落信道，并利用部分RIS反射单元的反射模式来降低频率传导开销。所提方法能够通过单个训练模型应对不同的信噪比，从而降低离线训练开销和硬件成本；同时，它在应对不同噪声水平的同时还能减少导频开销，因此可为RIS辅助OFDM系统提供有效的信道估计。

基于Transformer的方法擅长捕捉频域中的复杂特征，因此特别适用于复杂场景下的频域 CSI 外推。Transformer 能够捕捉频域中的 CSI 校正，即频率相距较远的 CSI 之间的关系。这使 Transformer 成为多频段系统中进行 CSI 外推的有前景方法。不过，这类方法需要大型数据集和大量计算资源进行训练。此外，模型训练和推理都需要大量计算资源，因此不适用于资源受限场景。

5）混合人工智能方案：除上述单一基于模型的时域 CSI 外推方案外，研究人员还提出了融合多个人工智能模型的混合方案 [141]。为通过融合信道信息有效提取空间特征之间的内在联系，基于卷积神经网络的模型中集成了空间注意力模块 [142]。该空间注意力模块经过轻量化设计，几乎不会增加计算复杂度。

频域信道状态信息在不同子载波上的衰落特性存在显著差异，尤其是在时延扩展较大的信道中。空间注意力机制使网络能够动态关注对目标子载波外推贡献最大的已观测子载波（例如路径时延相近或功率较高的子载波），从而显著提高外推子载波的幅度和相位估计精度。此外，只需在基于卷积神经网络的架构中插入一个或两个空间注意力模块，即可在仅需少量结构修改、实现开销较低的情况下显著提升性能。然而，空间注意力机制默认已观测子载波均匀分布或随机分布。当采用特定的稀疏采样模式（例如嵌套采样或互质采样）时，该注意力机制可能产生次优权重，导致其性能不如针对给定采样方案专门设计的卷积神经网络架构。

V. 天线域信道状态信息外推

如图2(c)所示，天线域信道状态信息外推利用未观测天线的信道状态信息，获取感兴趣天线的信道状态信息，这对于多输入多输出通信场景尤其有益。本节全面综述了最先进的天线域信道状态信息外推方案。图12总结了天线域信道状态信息外推中模型驱动方法与人工智能驱动方法的全面比较。

A. 模型驱动方法

模型驱动方法通常利用信道的物理特性（例如空间相关性或到达角），预测同一面板内未观测天线的信道状态信息。这种方法在大规模多输入多输出系统中尤为重要，因为它能减少训练和反馈开销。模型驱动方案利用信道的物理属性进行外推，主要依赖以下两个关键属性：

- 空间一致性属性：相邻天线之间的信道响应通常具有很高的相关性，从而能够预测未测量天线的信道状态信息

Method	Schemes	Principles	Strengths	Weaknesses
Model-based	Interpolation Method	Assuming spatial continuity or smoothness of CSIs in antenna-domain.	• Easy implementation; • High performance spatially smooth channels.	• Unfit for dynamic channel environments; • Limit to strong antenna correlation.
	Parametric channel-based	Channel modeled mathematically with multipath components regarding antenna array geometry, such as the amplitude, delay, AOA, etc., CSI of interest calculated using the estimated parameters.	• Consider the physical properties of the channel, i.e., strong interpretability; • High accuracy if model fits the channel.	• Poor performance in multipath-rich scenarios, where the characteristics of all paths are challenging to acquire; • Limit to strong spatial correlation, where the spacing between adjacent antennas is desirable.
AI-based	MLP-based	Learning a nonlinear mapping from CSI of partial antenna to the CSI of the entire antenna array.	• Simple to implement due to the simple structure of MLP.	• Difficult to capture spatial structures of CSI in antenna domain; • The parameter-efficiency of MLP is low, resulting in the large parameter volume and limiting their scalability in ultra-massive MIMO.
	CNN-based	CNNs treat CSI in antenna-domain as a two-dimensional image and use convolutional layers to capture local correlations of CSIs between antennas.	• Efficiently capturing local spatial correlations for grid-like antenna arrays; • Strong spatial-feature capturing capabilities.	• Spatial-feature capturing restricted to local due to limited receptive fields, not suitable for ultra-massive MIMO; • Less effective for non-uniform arrays, such as fluid antenna systems.
	GNN-Based	GNNs model the antenna array as a graph, with antennas as nodes and spatial relationships as edges.	• Adapt to various antenna layouts makes them particularly appealing for antenna-domain channel extrapolation with irregular antenna layouts; • Capturing long-range dependencies for large-spacing arrays.	• Difficult to construct the graph of the antennas, errors or oversimplifications in the graph can compromise extrapolation accuracy; • Computational cost scales dramatically with the number of antennas.
	Transformer-based	The known CSI and CSI of interest in antenna domain transformed into sequence via positional encoding, sequence-to-sequence performance by Transformer.	• Learns long-range dependencies; • High flexibility for dynamic channels and extrapolation; • 2D positional encoding effective to model the relative position of the antennas.	• Computation-intense for training and inference.
	Hybrid-AI schemes	Incorporating AI model and mathematical model to effectively capture the correlation of CSI In antenna domain.	• Ordinary differential equation (ODE) utilized to describe the latent relation between different data layers, speeding the convergence and learning performance of CNN-based schemes; • The antenna-domain CSI exhibits approximately linear phase variation along the array axis, which can be approximated by a first-order or second-order ODE.	• High computational complexity of solving ODE, unsuitable for latency-sensitive scenarios; • ODE approximation invalid for ultra-massive systems, performance tends to degrade dramatically.

图12。天线域信道状态信息外推方案的前沿研究综合综述。

基于已知的天线 CSI。这一属性对于毫米波大规模 MIMO至关重要，尤其是在非平稳信道条件下 [143]。

- 角度域稀疏性：信道在角度域中通常具有稀疏性，这意味着只有少数多径分量的角度（例如到达角、AoA）主导信道响应，因此可以利用这些参数重构整个天线阵列的信道状态信息。在频分双工多用户大规模 MIMO 系统中的研究表明，可利用角度域稀疏性进行压缩感知估计 [144]。

1）基于插值的方法：基于插值的方法假设信道具有空间连续性或平滑性，通过对已知 CSI 进行数学插值来估计未测量的天线 CSI，而不依赖特定的物理参数 [145]。在线性插值中，通过对相邻天线的 CSI 进行线性插值，实现天线域 CSI 外推。这种方法简单，但精度有限。样条插值使用三次样条函数拟合已知 CSI，从而为渐变信道提供更平滑的估计。克里金插值是一种统计方法，利用协方差模型（如高斯过程）进行最优无偏估计，以提高 CSI 外推精度[146]。有研究提出利用信道的空间协方差矩阵进行 CSI 外推，该方法在统计特性稳定的场景中表现出色，例如室内环境或慢衰落信道 [147]。

插值方法易于理解，也易于实现。这些模型计算效率高，在空间平滑的信道中表现有效。然而，如果不同天线的CSI并非平滑变化，例如在超大规模MIMO系统中，插值方法便无法实现高精度的天线域CSI外推。

2）基于参数化信道的方法：基于参数化无线信道模型的方案用于天线域CSI外推，通过从物理信道模型中提取多径参数（例如幅度、时延、到达角（AoA）），以外推未测量天线的CSI [148]。通过利用阵列几何结构和空间相关性，研究者提出了向量空间特征模型（VSS），用于提取多径参数以进行CSI外推 [120]。通过估计AoA并将其与阵列响应向量结合，可实现CSI外推。为进一步提高CSI外推精度，采用高分辨率参数估计算法（如SAGE）从接收信号中分解多径分量，该方法适用于宽带多输入多输出系统 [117]。 [149] 提出了一种双极化CSI外推方法：首先利用一个极化方向上的大量导频估计与极化无关的参数，然后在另一个方向上重新估计这些参数，从而降低导频开销。对于具有明显角度域稀疏性的毫米波或超大规模MIMO系统，研究者提出利用压缩感知（CS）从部分测量中外推完整CSI [81]。

基于参数化信道的方法依赖显式物理模型，并取决于包括幅度、时延、到达角等在内的关键参数。这些方法易于理解和验证，尤其在信道模型符合信道场景时效果显著。与用于信道状态信息外推的基于参数化信道的方法类似，要高精度地估计关键参数通常需要较高的计算复杂度。此外，在真实环境中，信道可能因遮挡或多径效应而呈现空间非平稳性，导致模型假设失效。在多径丰富的场景中，模型可能无法准确捕捉所有路径特征，基于参数化信道的方法的性能会大幅下降。如果信道处于动态变化中，即准静态假设不成立，这些方法的性能也会大幅下降。相邻天线间距增大时，空间相关性会减弱，从而导致显著的外推误差。

B. 人工智能驱动方法

随着多输入多输出技术朝着超大规模、可移动和可编程方向发展，显式物理模型已无法捕捉新兴多输入多输出信道的特性。为此，人工智能驱动方法利用机器学习或深度学习，根据已知信道状态信息学习天线之间的空间关系，并在天线域外推未知信道状态信息。这种方法不依赖显式物理模型，而是采用数据驱动方法来捕捉复杂的信道特性。下一节将全面回顾最先进的人工智能驱动时域信道状态信息外推方法。

1）基于 *MLP* 的方法：多层感知机是多层全连接网络，能够学习从部分天线信道状态信息向量（通常展平为实数或复数张量）到完整阵列信道状态信息的非线性映射。训练采用监督学习，并使用均方误差（MSE）或归一化均方误差（NMSE）等损失函数，通过反向传播优化权重 [21], [33], [150]。例如， [150] 描述了一种方法该方法基于阵列模型来外推空间信道，假设天线位置差异可通过相位偏移建模，同时保持功率、到达角和离开角不变。该方法通过增加外推距离，优于静态信道估计。 [151] 提出了一种适用于可重构方向图大规模多输入多输出系统的基于深度神经网络的信道状态信息外推方法，通过按辐射方向图对天线分组，以极低开销进行信道估计。

多层感知机的结构简单，因此易于实现。通过改变输入和输出维度，多层感知机能够灵活地对包含不同数量天线单元的信道状态信息进行外推。然而，多层感知机的结构使其难以捕捉信道状态信息在天线域中的空间结构。此外，多层感知机的参数效率较低，导致其参数量庞大，限制了其在超大规模MIMO中的可扩展性。由于参数效率低下，多层感知机需要利用大量天线域信道状态信息数据进行训练，才能近似天线域相关性。

2）基于卷积神经网络的方法：卷积神经网络将信道状态信息视为二维图像，并利用卷积层捕捉天线之间的局部相关性，从而外推缺失的信道状态信息部分 [21], [152], [153]。 [154]提出了一种利用卷积神经网络进行天线域信道预测的方法，以预测信道的统计特性。该方法提出了更优的数据采集规则，在预测精度方面显著优于以往方法。 [21]提出了一种基于深度学习的方案，用于实现天线域信道状态信息外推；与传统方法相比，该方案提高了系统效率和适应性。 [155] 提出了 FadeNet，用于大规模信道衰落预测；该方法通过直接从数据中学习、无需人工调优，展现出准确且快速的预测能力。 [156] 实现了两个基于卷积神经网络的网络 IENet 和 CENet，并通过联合训练优化其在降低可重构智能表面系统中组内干扰方面的性能。

基于卷积神经网络的方法天然适用于网格状天线阵列，能够通过卷积滤波器有效捕捉空间相关性。然而，对于不规则天线配置（如流体天线系统）或非平稳空间特性，这类方法可能难以应对，因此需要采用基于图的方法等改进方案。此外，卷积神经网络在捕捉长程依赖关系方面效果较差；长程依赖关系指的是相距较远的天线单元之间的信道状态信息关系。这一弱点限制了其在超大规模MIMO中的性能。

3）基于图神经网络（*GNN*）的方法：图神经网络将天线面板建模为图结构，并学习天线之间的依赖关系，因此特别适用于不规则天线阵列。 [57] 提出了一种用于天线域CSI外推的非对称图掩码自编码器（AGMAE）架构。具体而言，编码器部分采用Transformer注意力机制，解码器部分采用图注意力网络，并通过非对称设计整个架构来平衡计算复杂度。该方法支持不同数量的CSI输入，并且只需使用一个固定尺寸的阵列进行训练，就能外推到不同尺寸的阵列，这

提供了良好的灵活性和泛化能力。与压缩感知和线性插值等传统外推方法相比，AGMAE方法在灵活性、计算复杂度和泛化能力方面具有明显优势。

图神经网络通过在基于图的框架中利用空间关系，为天线域CSI外推提供了一种前景广阔的方法。它们能够对复杂依赖关系进行建模，并适应各种天线布局，因此在不规则天线布局或大间距阵列下进行天线域CSI外推时尤其具有吸引力。然而，要取得成功，仍需克服图设计、计算需求和数据可用性等挑战。图神经网络的有效性很大程度上取决于图能否准确反映天线之间的真实关系。图中的错误或过度简化可能会损害外推精度。要充分发挥其在这一应用中的潜力，可能需要谨慎实施，并考虑将其与领域知识或其他技术相结合。图神经网络需要在相连节点之间进行消息传递；尽管原则上具有可扩展性，但在大型天线阵列中，这一过程仍可能带来高昂的计算开销。

4）基于*Transformer*的方法：目前，Transformer也已应用于天线域CSI外推 [23], [157], [158]。文献 [30] 的作者尝试使用线性回归和支持向量回归等机器学习算法进行天线域CSI外推。尽管取得了一些成果，但由于存在明显的空间非平稳性，传统机器学习方法难以适应大规模天线阵列。为此，作者提出了一种基于自注意力机制的信道Transformer（CT）模型，用于建立不同天线位置之间的相关性；位置嵌入则保留了天线之间的位置关系，从而解决空间非光滑问题。与卷积神经网络和循环神经网络等方法相比，CT利用自注意力机制，能够更好地处理超大规模多输入多输出系统中远距离天线的CSI信息。此外，通过迁移学习策略，CT能够针对不同传播环境训练自适应AI模型，从而提高外推精度。 [159]采用基于参考的变分自编码器，估计混合RIS辅助毫米波系统中的完整天线域信道，从而提升信道估计性能。 [158]提出了一种基于双向Transformer编码器表示（BERT）和掩码语言模型的空间CSI外推方法，无需额外的导频输入，即可根据部分观测高效推断完整CSI，优于传统CSI方法。

基于 Transformer 的方法能够学习为未见过的天线配置生成信道状态，并有望适应新的空间布局。然而，这类方法复杂度高、数据需求大，且在训练数据不足时可能无法捕捉细粒度的空间相关性，从而给实时应用带来挑战。模型训练和推理需要大量计算资源，因此不适用于资源受限场景。

5）混合人工智能方案：为改进特征提取，卷积神经网络（CNN），常微分方程（ODE） [160]被应用于[161] 可重构智能表面（RIS）辅助通信系统中的信道状态信息外推方法，以根据部分信道状态信息外推完整的信道状态信息。所提出的 ODE-CNN 结构引入了跨层连接和线性计算，相较于级联 CNN 方法，能够实现更快的收敛速度和更优的性能。然而，神经常微分方程需要对底层 ODE 系统进行数值积分，通常采用自适应或定步长求解器，例如高阶龙格-库塔方法或 Dormand-Prince 方法积分器 [162], [163]。这种计算开销的增加可能成为超低时延应用中的关键瓶颈，例如第五代 5G-Advanced 和 6G 系统中的 URLLC 场景 [164]。此外，在远场和视距（或单一主导路径）条件下，天线域信道状态信息沿阵列流形呈现近似线性的相位递变，可通过低阶（一阶或二阶）连续时间动态模型有效建模。然而，在近场区域或具有显著多径分量的丰富散射环境中，信道的空间演变与简单的线性常微分方程假设存在显著偏差。因此，在此类复杂传播条件下，纯神经常微分方程方法的外推精度往往会大幅下降 [165]。

VI. 多域信道状态信息外推

如图 2(d)所示，多域信道状态信息外推可视为时间、频率和天线域外推的整合。 [34] 指出，尽管与单域 CSI 外推相比，多域联合 CSI 外推能够提供更高精度的信道估计、更强的鲁棒性并降低开销，但其复杂度也高于单域 CSI 外推；此外，多域数据更难以同步和校准，且需要更高分辨率的先验信息。目前，关于多域信道状态信息外推的现有研究可分为模型驱动方案和人工智能驱动方案。

A. 模型驱动方案

与前文讨论的单域信道状态信息外推类似，模型驱动方案主要聚焦于基于参数化信道的方法。现有方法主要利用多径信道模型（如 Saleh-Valenzuela信道模型） [22], [166], 作为起点，其中关键参数包括路径数量、时延、到达角、方向角、多普勒频移以及每条路径的复增益，并据此建立各个域中的相关性 [122], [167]。

[34]提出了一种适用于频分双工多输入多输出系统的两阶段时频天线域信道状态信息外推方案。该工作假设子载波和天线之间分别存在相移线性变化，以此对频域和天线域相关性进行建模。假设用户设备低速移动，则每帧内的关键参数（即参数估计周期内）保持不变。下一帧的信道参数由当前帧的信道参数与

Schemes	Principles	Strengths	Weaknesses
MLP-based	Integrating with assumption on wireless channel to capture effective correlations between CSI in multi-domain.	• Easy implementation to learn the mapping between the known CSI to the CSI of interest.	• Low parameter-efficiency of MLP results in the large parameter volume of MLP; • Poor performance if the assumption on wireless channel mismatch the scenario of interest.
CNN	3D convolutional kernels in CNN are effective to capture the correlation of the CSI in the temporal, antenna, and frequency domain.	• Excel at extracting coupled CSI correlations in multi-domain, making them well-suited for multi-domain CSI extrapolation tasks.	• Limited to local feature capturing, which restricts their applicability in joint high-speed, EL-MIMO and wideband systems, etc.
Transformer-based	Capture the correlation between CSI in multi-domain using self-attention modules and multi-dimensional positioning coding.	• Scaling-law utilized for effective multi-domain CSI correlation extraction.	• Computation-intense for training and inference; • The efficiency of the baseline Transformer architecture to capture the joint correlation of CSI in multi-domains is in doubt.
Hybrid-AI schemes	Incorporating multiple AI models for effective CSI channel extrapolation.	• GAN used to generate synthetic channel data to enrich the training dataset, thereby enhancing the performance of CSI extrapolation module.	• Difficult to generate synthetic channel samples with specific scenario attributes, thereby limiting the generalization of the CSI extrapolation model in multi-domain.

图 13. 对当前最先进的人工智能驱动的多域信道状态信息外推方案的全面综述。

随机项相加得到。基于上述相关性，可估计关键参数，以进行多域信道状态信息外推。[168] 提出了一种基于3GPP/WINNER II SCM模型、适用于极化窄带多输入多输出的参数化预测方法。该方法利用时域、天线域和极化域的信息，通过多维ESPRIT联合估计多径信号的到达角、离开角、多普勒频移和复极化权重。与仅利用时域信息的一维ESPRIT方法相比，该方法能够更准确地估计信道参数，因此在所有预测时间尺度上都表现出较低的归一化均方误差。 [169] 提出了一种基于波前变换矩阵铅笔的信道预测方法。该方法设计了一个矩阵，可将球面波前变换为更接近平面波的新波前，从而减轻超大规模天线阵列在移动场景中由近场效应造成的性能损失。 [170] 提出了一种基于校准散射体表面粗糙度参数的信道状态信息外推方法。该方法实现了频域与天线域之间信道相关矩阵的外推，并展现出良好的性能。从频域信道相关性度量外推至天线域信道相关性度量，可将变化部分的预测误差降低约50%。从天线域信道相关性度量外推至频域信道相关性度量，也可将变化部分的预测误差降低约50%，其效果与采用频域信道相关性度量外推所得结果相当。

对于多域信道状态信息外推，基于参数化信道的方法以显式物理模型为基础，这些模型基于特定假设推导而来，或采用常用信道模型。与前文讨论的单域信道状态信息外推方法类似，第一阶段会估计路径数、复增益、时延、到达角等关键参数，并将其用于信道状态信息外推。这些方法易于理解和验证；如果信道模型与信道场景相符，则尤其有效。然而，常用的高精度参数估计算法通常计算复杂，例如 MUSIC、ESPRIT 或其改进版本。此外，全面建立信道模型颇具挑战，例如，在多径丰富场景中很难准确捕捉所有路径特征，基于参数化信道的方法的性能也会因此下降。此外，现有研究分别对时间、频率和天线域之间的相关性进行建模。然而，已有研究指出，不同域之间的信道相关性存在耦合，例如，高速场景下时域与频域的信道相关性相互耦合 {v1}。

通常用于高精度参数估计的算法计算复杂，例如 MUSIC、ESPRIT 或其改进版本。此外，全面建立信道模型颇具挑战，例如，在多径丰富场景中很难准确捕捉所有路径特征，基于参数化信道的方法的性能也会因此下降。此外，现有研究分别对时间、频率和天线域之间的相关性进行建模。然而，已有研究指出，不同域之间的信道相关性存在耦合，例如，高速场景下时域与频域的信道相关性相互耦合 [171]。

B. 人工智能驱动方法

随着 6G 的到来，多域联合信道状态信息外推已不可避免，其复杂程度远高于单域信道状态信息外推。为此，人们开发了复杂的人工智能驱动方法，本节将全面综述当前最先进的方案。图 13 总结了多域信道状态信息外推人工智能驱动方法的全面比较。

1）基于 *MLP* 的方法： MLP 已应用于多域信道状态信息外推。 [35]提出了一种基于交错学习的信道映射方法，该方法设计了一种复数域 MLP 混合器模型，分别学习天线域和频域中的信道特性，然后通过交错学习捕获两个域之间的相关性。这种设计大幅减轻了学习负担，并在信道映射性能方面展现出高效率。利用宽带大规模 MIMO 系统的高角度-时延分辨率， [36] 提出了一种通过利用角度-时延域中的信道特性来实现多域信道状态信息外推的方法。该方法采用基于深度学习的监督学习方法，使用复值神经网络（CVNN）预测角度-时延域中的信道元素。

由于 MLP 结构简单，基于 MLP 的方法易于实现。然而，

MLP 难以有效捕捉多域中的耦合信道相关性。为此，现有研究基于对特定物理信道特性的先验假设，提出了复杂的基于 MLP 的网络。这种方法可视为基于参数化信道的方法与 MLP 的结合。因此，直观而言，基于 MLP 的方法的性能取决于对信道特性的假设是否与所关注的场景相匹配。

2）基于卷积神经网络的方法：鉴于卷积神经网络具有强大的特征提取能力，研究人员提出了将其用于多域信道状态信息外推。 [172]，作者提出了一种基于三维卷积神经网络的深度学习框架，用于外推未来的下行链路信道状态信息。该框架利用三维卷积核捕捉信道在时间、空间和频率维度上的相关性，从而准确外推目标信道状态信息。[37]提出了一种知识驱动与数据驱动相结合的空频网络。该方法利用最小二乘估计器进行粗略信道估计，并结合空频信道状态信息外推，以减少空间域和频域中的导频开销。作者提出了一种基于注意力机制的子单元外推模块，并采用渐近外推架构，以提高空频信道状态信息外推的准确性。[173]提出了一种基于深度残差U形网络的信道状态信息外推方法，用于估计可重构智能表面级联OFDM系统的信道特性。为进一步提升外推性能，该方法将噪声方差作为额外输入，以提高不同信噪比下的信道估计性能；同时利用跳跃连接增强网络的学习能力，并通过单一训练模型适应不同信噪比，从而显著减少训练数据量和训练时间。[174] 提出了一种基于深度学习的方案，将空间外推与时间预测相结合，以高效估计快速变化的级联信道。所提出的时空卷积网络能够并行处理大量时空数据，无需存储大量隐藏状态，因此兼具高性能与高效计算能力。为进一步提升深度学习模型的效率，作者采用了结构化概率剪枝，其外推效果优于均匀剪枝和随机剪枝。

卷积神经网络擅长提取多域中的耦合信道相关性，因此非常适合多域信道状态信息外推任务。然而，由于卷积神经网络侧重于局部特征提取，与单域信道状态信息外推的基于卷积神经网络的方法类似，它们只能耦合局部信道相关性，这限制了其在联合高速、EL-MIMO和宽带系统中的适用性。此外，基于卷积神经网络的方法属于计算密集型，可能给实时实现或在资源受限设备上的部署带来挑战。

3）基于*Transformer*的方法：随着移动网络日益复杂，深度学习信道状态信息外推模型的泛化能力面临巨大挑战。新兴的Transformer有望解决复杂通信场景中的信道状态信息外推问题 [51]。[139] 提出了一种基于Transformer的端到端深度学习信道预测神经网络E2ENet。该网络利用上行链路导频信号直接预测下行链路信道，避免了上行链路信道估计误差的累积，从而提高下行链路信道预测的精度。E2ENet采用混合特征提取模块（HFEM），同时对时域、空域和频域特征进行建模，以更好地捕捉上行链路导频频率与下行链路信道之间的关系。与传统两步法相比，所提出的E2ENet性能显著更优；此外，它还能同时预测上行链路和下行链路信道，并降低存储开销。 [175]提出了一种基于大语言模型的信道预测方法LLM4CP，通过微调预训练的生成式预训练Transformer（GPT）-2模型，预测MIMO-OFDM系统未来的下行链路信道状态信息序列；该方法可同时应用于时分双工和频分双工系统。与现有的模型驱动方法和深度学习方法相比，在不同用户速率下，LLM4CP的归一化均方误差显著优于其他基准方法，且预测精度更高。此外，LLM4CP对信道状态信息噪声的鲁棒性更强，在归一化均方误差性能方面也优于其他方法。在零样本学习场景中（仅使用10%的训练数据），LLM4CP的优势更加明显，体现出强大的零样本学习能力。此外，在频谱效率和误码率等通信性能指标方面，LLM4CP也优于其他方法。

生成式人工智能方法（例如采用生成模型或大语言模型的方法）旨在应对复杂多样的通信场景，具有更强的泛化能力。生成式人工智能模型，尤其是涉及大语言模型或复杂生成架构的模型，需要大量计算资源，从而增加训练和部署成本。尽管一些生成式人工智能方法减少了对导频数据的需求，但要实现有效训练，它们仍可能需要大量数据集，尤其是在多种场景下。与较简单的方法相比，生成式人工智能模型的可解释性可能较差，因此难以理解或调试其预测结果，这可能会妨碍实际部署。

4）混合人工智能方案：由于多域信道状态信息外推复杂且具有挑战性，混合人工智能方案因能够整合各类人工智能模型的能力而受到广泛关注。一种很有前景的方法是生成信道数据，以提升多域信道状态信息外推的性能。[182], 中提出了一种用于6G信道状态信息外推的GAN-LSTM框架。该框架使用生成对抗网络生成合成信道数据，以丰富训练数据集；同时利用长短期记忆网络进行序列预测，从而预测未来的信道特性。通过结合生成对抗网络和长短期记忆网络，该方法有效应对了数据集不足这一挑战，大幅提升了所需信道数据的质量和多样性，并且其参数生成效率优于传统信道建模方法。然而，生成对抗网络难以控制，无法轻易生成具有特定场景属性的数据，这限制了合成信道样本的可变性，也可能限制信道状态信息外推模型在信道特性变化较大的不同或多个场景中的性能。

表 V 适用于信道状态信息外推研究的开源无线信道数据集概览。TR 和 M 分别是射线追踪和测量的缩写。

名称（采集/生成）	场景	频段（带宽）	适用性	局限性	优势
工业无线电（测量）[176]	工业环境	3.7–3.8 GHz (80 MHz)	时域	低移动性不适用于高移动性场景。	1 kHz 的高测量频率用于细粒度时域信道状态信息外推的高测量频率 1 kHz
DICHASUS（测量）[177]	工业环境	1.272 GHz (50.056 MHz)	时间-频率-天线域	较大的测量间隔 32根天线的48毫秒多输入多输出	带内1024个正交频分复用子载波的信道状态信息频域 CSI 外推。
Wireless Intelligence（M）[1]	室外校园	2.565吉赫兹（20兆赫兹）	时间-频率-天线域	4个发射端和2个接收端的多输入多输出每个站点的静态测量	用于高测量频率 1 kHz 的细粒度时域信道状态信息外推
WARI-D（射线追踪）[178]	室外	2.6、6、28, 60、100 吉赫兹	频率-天线-域	静态信道	6 和 28 吉赫兹下的 64 和 384 根天线涵盖 6 GHz 以下和毫米波频谱频段
DeepMIMO（RT）[179]	室外, 室内	3.4、3.5、60 吉赫兹	频率-天线-域	静态信道	覆盖 6 GHz 以下、毫米波频谱频段可配置的天线数量有利于频域 CSI 外推
DataAI-6G（射线追踪）[50]	室外, 室内	3.5、6.5, 28 吉赫兹	时频-天线域	多输入多输出规模较小，用户设备朝单一方向移动	考虑了多普勒频移考虑了空间非平稳性，前景可期用于近场信道状态信息外推。
RENEW（测量）[180], [181]	室外	2.4、5 GHz	时间-频率-天线域	每个站点的静态测量局限于 6 GHz 以下频谱	多达 96 根天线有利于天线-域信道状态信息外推

表 VI 实测数据集和基于射线追踪的数据集的优势与局限性

方面	实测数据集	基于射线追踪的数据集
真实性	高：捕捉真实传播现象、硬件缺陷、噪声和未建模效应	合成数据；其真实性取决于.....的准确性三维场景模型和射线追踪引擎
频率覆盖范围	通常仅限于一个或两个频段（主要为 6 GHz 以下）	范围极广——可轻松覆盖 6 GHz 以下、毫米波，甚至亚太赫兹频段（在 WARI-D [178] 中最高可达 100 吉赫兹）
天线阵列 size	固定且通常规模适中（RENEW 中最多 96 根天线，DICHASUS 中为 32 根 [177]）	高度可扩展——从几根天线到数百根/数千根（DeepMIMO [179],WARI-D [178]最多 384 根）
移动性	极为罕见；几乎全为静态或准静态	几乎总是静态，DataAI-6G [50] 除外
采样率（时域）	变化极大：可能非常高（1 kHz），也可能非常低（48 ms，见 DICHASUS [177]）	没有真实的时间采样；用户必须自行生成轨迹（DataAI-6G [50] 除外）
数据量/可配置性	受测量活动工作量限制；场景固定且位置固定	几乎不受限制且完全可配置（几何结构，天线、轨迹、参数
子载波粒度	由硬件固定	易于配置；可生成数千个子载波如有需要
成本与可重复性	采集成本高且耗时；难以复现完全	场景构建完成后成本较低；可完美复现且可共享
主要优势	真实世界保真度，包含实际因素，适用于模型验证	参数覆盖范围广、规模庞大，涵盖毫米波/太赫兹和近场效应
主要局限性	频率/天线/移动性覆盖范围狭窄，数据量有限，大多数情况下为静态或低移动性	真实性受场景准确性的限制，通常缺乏真实的移动性/多普勒（少数情况除外，例如 DataAI-6G [50]），没有真实的硬件损伤

VII. 无线信道数据集与仿真器

机器学习和深度学习有望实现信道状态信息外推，因此高质量的信道状态信息数据集对模型训练至关重要。信道状态信息数据集既可以通过测量采集，也可以通过仿真生成。本节将全面综述开源数据集和仿真器。

A. 开源信道数据集

移动网络的信道测量颇具挑战，原因在于硬件成本较高；此外，运营商出于政策和数据价值方面的考虑，不会公开信道数据。值得庆幸的是，一些机构和研究团队在信道测量方面付出了宝贵努力，相关信道数据集汇总于表 V。当前用于评估无线通信中人工智能/机器学习的数据集可分为仿真数据集和实测数据集，下面将分别进行综述：

- 工业无线电数据集 [176]通过真实世界测量采集，测量在工业工厂环境中使用基于USRP的软件定义无线电进行，工作频段为 3.7–3.8 GHz，带宽为 80 MHz。该数据集提供以 1 kHz 采样的高时间分辨率信道状态信息，是少数能够捕捉极快速信道变化的公开数据集之一。该数据集尤其适用于时域信道状态信息外推和预测任务，但移动性非常有限（大多为准静态或低速场景），因此无法代表高速移动的车辆或无人机信道。

- DICHASUS [177] 是一个在工业大厅中以1.272 GHz中心频率、约50 MHz带宽采集的真实世界测量大规模多输入多输出数据集。该数据集包含一个32天线基站，并为1024个正交频分复用子载波提供完整的信道状态信息矩阵，记录间隔为48 ms。得益于大量的子载波和天线，它非常适合用于频域和天线域（空间）信道状态信息外推研究。然而，其极低的测量速率（约20.8 Hz）

使其不适合用于研究快速时变信道或多普勒效应。

- Wireless Intelligence[1] 是一个通过真实测量获得的数据集，采集地点为室外大学校园，使用 2.565吉赫兹频率和 20兆赫兹带宽，并采用 4×2 MIMO配置。与 Industrial Radio数据集类似，它提供了 1 kHz 的高采样率，能够在时域进行细粒度分析和外推。测量在静态位置进行，接收机固定在各个站点，因此该数据集捕获了丰富的小尺度衰落特征，但不包含显著的移动性或多普勒特征。

- WARI-D [178] 是一个大规模射线追踪（RT）生成的数据集，专注于室外场景，覆盖极宽的频率范围：2.6 吉赫兹、6 吉赫兹、28 吉赫兹、60 吉赫兹和 100 吉赫兹。它包含大规模天线阵列（较低频段为 64 个阵元，28 吉赫兹频段最多为 384 个阵元），因此适用于 6 GHz 以下、毫米波和亚太赫兹频段之间的频率域和天线域外推。由于该数据集完全静态（没有用户移动），因此不包含时间或多普勒信息。
- DeepMIMO [179]是应用最广泛的基于射线追踪的合成数据集之一，支持室外（“O1”场景）和室内（“I1”）环境。该数据集提供 3.5 吉赫兹和 60 吉赫兹频率下的信道矩阵（也可扩展至其他频段），并且完全可配置：用户可以任意设置基站/用户设备天线数量、阵列几何结构和位置。这种灵活性使其非常适合天线和频域外推研究，以及为机器学习模型生成几乎无限量的训练数据。与大多数基于射线追踪的数据集一样，除非用户手动创建轨迹，否则信道是静态的。

- DataAI-6G [50] 是一个基于射线追踪生成的数据集，专为动态和近场场景设计，涵盖 3.5 吉赫兹、6.5 吉赫兹和 28 吉赫兹频率下的室外和室内环境。与大多数其他基于射线追踪的数据集不同，它包含真实的用户移动性（用户设备沿直线朝基站移动）及相应的多普勒频移，并明确对空间非平稳性进行建模，这对近场外推和超大规模 MIMO研究至关重要。其主要缺点是 MIMO 配置非常小（1 个发射端 × 4 接收端天线），且移动方向有限。

- RENEW [180], [181]是一个在加利福尼亚大学圣迭戈分校校园内采集的真实世界测量数据集，使用运行于 2.4 吉赫兹和 5 吉赫兹的大规模可编程软件定义无线电平台进行采集。该数据集包含来自八个室内视距、十六个室内非视距、四个室外视距和二十一个室外非视距移动节点位置的测量数据。它支持基站最多配备 96 根天线，提供丰富的空间信息，非常适合用于天线域CSI外推以及大规模/超大规模多输入多输出研究。测量均在静态位置进行，因此该数据集不包含显著的移动性或高多普勒分量，并且仅限于 6 GHz以下频段。

表VI全面比较了实测数据集与基于射线追踪的信道数据集。具体而言，实测数据集具有无与伦比的真实世界保真度，因为它们能够自然捕捉复杂的物理现象，而这些现象仍极难准确建模，包括粗糙表面或植被造成的漫散射、移动人员或机械设备引起的动态遮挡和反射、超大规模阵列中的近场球面波前、天线互耦、非理想辐射方向图、极化混合，以及各种硬件/RF损伤，例如相位噪声、IQ不平衡、ADC削波和同步误差等。尽管真实性出众，实测数据集仍受到严重的实际限制。大多数公开可用的数据集仅涵盖 6 GHz 以下频段，且阵列规模不超过 128 根天线，并且测量方式为静态或准静态。测量一旦完成，频段、阵列规模和场景便固定下来；若要将数据集扩展到新的频段或数百根天线，则需要重新开展成本高昂的测量工作。

基于射线追踪的数据集几乎消除了实际测量所受的所有限制。只需构建一个完善的三维场景，即可即时生成从 6 GHz 以下直至 300 GHz 及更高频段的信道，支持由少数到数千个阵元、几何形状任意的天线阵列（平面、圆柱形、球形、共形、可重构智能表面等），并提供从数十 MHz 到数 GHz 的带宽。不过，基于射线追踪的数据集的真实性，根本上受限于底层三维场景和材料参数的准确性。对象缺失、介电常数或电导率取值错误，或过度简化的植被模型，都可能在某些时延或角度分箱中引入系统性误差，尤其是在密集的室内和城市环境中。除 DataAI-6G 这一显著例外外，几乎所有公开的基于射线追踪的数据集都只提供静态快照或简单的脚本化轨迹；它们缺少真实散射体（行人、车辆）丰富而随机的运动，而这种运动会产生持续变化的多普勒谱。最后，基于射线追踪的数据集完全干净，也就是说，其中不含相位噪声、定时偏移、非线性失真或校准误差。

B. 信道仿真器

除开源数据集外，学术界和工业界也为仿真信道CSI付出了巨大努力。表 VII 对信道仿真器进行了全面综述。

SEU-PML-6GPCS [183], [184] 是一种6G泛在信道模型，采用统一几何随机信道建模框架，并融合了6G全频段、全场景信道特性。该模型支持多用户、跨频段信道建模，并符合多项3GPP和ITU标准化文件。它利用测量数据校准信道模型。目前，该仿真器可实现大量场景，包括卫星、无人机 [196],地面通信等。此外，在配置模块中，SEU-PML-6GPCS为6G信道参数提供菜单驱动配置选项，用户可自定义选择频率

[1]https://wireless-intelligence.com/#/dataSet?id=2c92185c7e3f1aa4017e3f2 b9d6e0000

表 VII 信道仿真器在关键特征、是否经过测量校准、是否免费/开源、支持的频段和场景方面的比较。

仿真器	关键特征	校准所依据的测量?	免费/开源来源?	频段	场景
SEU-PML-6GPCS [183], [184]	一种普适的 GBSM信道模型覆盖 6G全频段全场景信道特性。	是的，关键统计特性，例如时延/多普勒/遮挡校准并与测量信道数据进行对照。	是/否	6 GHz 以下至光学	22 个标准化的 6G 使用案例，涵盖陆地/海事/无人机/低地球轨道
BUPTCMG-6G [185]–[188]	兼容GBSM信道模型与标准信道模型例如 ITU-R M.2412、3GPP TR 38.900/901、TR 36.777、TR 36.873 以及 TR 37.885。	是，正在进行校准，并且与 3GPP TR 38.901 进行验证，包括关键的信道参数例如到达方位角扩展，出发天顶角扩展等。	是/否	0.5 至 330 吉赫兹	近场、SnS，可重构智能表面、非地面网络等。
NYUSIM [189]	一种经过测量校准的统计模型，支持 MATLAB 和 Python，已集成至 ns-3 仿真器。	是的，使用大量真实世界测量数据校准参数包括路径损耗指数、时延扩展、簇的数量、阴影衰落等。	是/是	0.5–150 吉赫兹	UMi/UMa/农村宏蜂窝/室内热点/InF
Sionna RT [189], [190]	基于图形处理器加速的信道仿真器基于 TensorFlow；具有独特的可微性特征，使得能够计算信道冲激响应、系统及环境相关参数的梯度；并进一步集成到 Omniverse 中，用于构建数字孪生。	是的，通过一种新颖的可微使用信道测量来校准材料属性、散射行为，以及天线方向图。	是/是	0.5–300 吉赫兹	3GPP（UMa、农村宏蜂窝，室内热点）、自定义场景
QuaDRiGa [191], [192]	准确定性信道生成器，具有确定性的大尺度路径，随机特性，兼容 3GPP TR 36.873、TR 37.885, TR 38.901 TDL ，CDL信道模型。可通过图形处理器加速。	是的，已根据 3GPP 进行校准信道模型，如 3GPP-3D使用大量信道柏林的测量数据。	是/是	0.5–100 吉赫兹	城市/农村/卫星/车联网/高速列车
WiThRay [193]	针对……优化的高保真三维射线追踪可重构智能表面和智能环境；精确的反射/绕射/可编程超表面上的散射电磁建模。	是，散射射线校准以实现精确的电磁波传播。	是/是	6 GHz 以下，毫米波，亚太赫兹频率频段	超大规模 MIMO 高移动性
NirvaWave [194]	一种近场信道仿真器，基于标量衍射理论和傅里叶原理，可提供精确的波传播响应，适用于复杂的无线介质，在自定义用户定义的传输电磁信号。	No	No		采用可重构智能表面的近场。
KUCG [195]	一种能够生成信道冲激响应的统计信道模型适用于毫米波和亚太赫兹频段。	是，关键统计参数已通过信道测量进行校准。	是/是	60, 95, 105 GHz	室内

频段、场景、天线阵列尺寸，以及收发器和散射簇的任意运动轨迹。随后，在仿真模块中，SEU-PML-6GPCS可保存信道的全域统计特性，包括时域、频域、空间域、时延域、多普勒域和角度域。

BUPTCMCCCMG-IMT2030 [185]–[188] 是一款面向6G无线通信的链路级信道模型仿真器。该仿真器能够为各种场景、频段和不同的天线阵列生成准确的大尺度参数、小尺度参数和信道系数。它正式发布，作为对国际电信联盟（ITU）-R M.2412、3GPP TR 36.873 和 3GPP TR 38.901 等广受认可的标准的实现。它使用测量数据校准信道模型。目前，它能够实现标准5G信道、RIS辅助信道、工业物联网信道和非地面网络信道的仿真。此外，BUPTCMCCCMG-IMT2030采用面向过程的框架实现，包含三个模块：配置、仿真和分析。在模块 I（配置模块）中，将定义场景、中心频率、带宽等系统参数。接下来，在模块 II（仿真模块）中，BUPTCMCCCMG-IMT2030根据模块 I 中定义的配置执行仿真，并生成一系列信道参数。最后，在模块 III（分析模块）中，对仿真结果进行简单分析，并以数值和图形形式呈现。

由 NYU WIRELESS 开发的 NYUSIM 是一种广泛采用的开源统计信道模型（提供 MATLAB 和 Python 版本），已集成到 ns-3 网络仿真器中 [189], [190]。该模型利用多个频段的真实测量活动进行了广泛校准，能够准确地刻画路径损耗指数、时延与角度扩展、簇数量以及阴影衰落特性。从技术上说，NYUSIM 采用时间簇与空间瓣方法来耦合时间域与空间域，并根据用户轨迹生成相关的全向和定向功率时延剖面。4.0 版本新增了每次投放的多极化支持（最多四种配置：V-V、H-H、V-H、H-V）、适用于所有 3GPP 场景（UMi、UMa、RMa、InH、InF）的基于投放的仿真，以及通过四状态马尔可夫模型实现的空间一致性

，用于动态人体遮挡。频率支持范围为 0.5–150 吉赫兹，场景覆盖包括 3GPP UMi、UMa、RMa、InH 和 InF 环境。该模型完全开源。与 ns-3 集成后，可实现端到端毫米波/亚太赫兹网络仿真；通过重构 API 和基于文件获取参数的方式，提升了计算效率。

英伟达的 Sionna RT 是一款基于 Python 构建、由图形处理器加速且可微分的射线追踪引擎 [197]。其独特的可微分特性支持针对环境参数、天线方向图和材料属性，对信道冲激响应进行基于梯度的优化。全新的测量驱动校准框架通过结合发射与反弹射线法（SBR）和镜像法来处理镜面反射，并采用基于哈希的重复项消除，确保高度的物理保真度。该引擎支持镜面反射和漫反射、一阶绕射，并通过启发式或穷举式路径搜索来计算信道冲激响应或无线电地图（例如路径增益、接收信号强度、信干噪比网格）。它与 NVIDIA Omniverse 集成，可支持数字孪生应用。它支持 0.5–300 GHz，以及标准 3GPP 场景（UMa、农村宏蜂窝、室内热点）和完全可自定义的环境。它完全开源。1.0 版全面升级，借助 Dr.Jit 即时编译器将速度提升至最高 100 倍，并提高内存效率，从而支持面向通感一体化、可重构智能表面和基于机器学习的收发器进行端到端优化，同时计算阵列几何结构、物体位置等参数的梯度。

QuaDRiGa [191], [192] 由弗劳恩霍夫海因里希·赫兹研究所开发，用于移动无线电网络的系统级仿真。其支持的标准文档包括 3GPP TR 36.873、3GPP TR 37.885 和 3GPP TR 38.901。该工具使用测量数据进行了校准，确保其在表征真实世界传播特性时的准确性和可靠性。此外，QuaDRiGa 支持多种应用场景，包括室内办公环境、室内工业环境、UMa、农村宏蜂窝、UMi、车联网和卫星。除了是一个功能完备的三维几何基础随机信道模型外，QuaDRiGa 还集成了一系列特性，可提供多域特性，以便在不断变化的环境中对接收机移动进行准确定性多链路跟踪。

WiThRay 是一款高保真三维射线追踪仿真器，专为可重构智能表面辅助和超表面增强环境优化 [193]。它能够对可编程超表面上的反射、绕射和散射进行符合物理规律的精确电磁建模，并提供针对 6 GHz 以下、毫米波和亚太赫兹频段校准的散射射线。其关键技术创新包括用于高效路径识别的边缘旁路（BE）算法、通过基于测量的波瓣方向图进行散射校准，以及用于信道冲激响应计算的几何参数评估（例如极化、时延、出发角/到达角）。它既能生成连续信道冲激响应，也能生成离散时间信道数据，并支持可重构智能表面相位重配置和粗糙表面散射。尤其适用于超大规模 MIMO 系统和高移动性场景。完全开源。该仿真器的电磁方程集成确保路径增益与理论值的偏差 ¡1 dB，从而能够在智能环境中评估波束成形、定位和信道估计，并可在数秒内处理多达 10^6 条射线。

NirvaWave 是一款专用的近场信道仿真器以标量衍射理论和傅里叶光学原理为基础 [194]。它能够在用户任意定义的发射电磁信号作用下，精确计算复杂介质中的波传播，并原生支持近场可重构智能表面场景。从技术上看，它通过二维基于傅里叶变换的传播核对波前演化（例如艾里光束/贝塞尔光束）进行建模，并纳入可重构智能表面相移和粗糙散射，以模拟遮挡/反射效应。其核心算法在用户定义的网格上求解波动方程，支持自定义发射端天线相位配置，并生成太赫兹/亚太赫兹频段的覆盖图。与大多数其他工具不同，它目前缺乏明确的基于测量的校准功能，也不开源。其采用麻省理工学院许可证的实现（含评估版）相比完整的麦克斯韦方程求解器，运行效率提升数个数量级，从而有助于在扩展近场区域大规模生成模型驱动机器学习技术所需的数据。

KUCG 是一种统计信道模型，专注于毫米波和亚太赫兹室内环境，支持 60 吉赫兹、95吉赫兹和 105 GHz 频段 [195]。其关键统计参数经过室内测量数据校准。该模型采用基于簇的随机建模生成链路级信道冲激响应，路径损耗、时延扩展和角度扩展等参数均根据传播测量得出。算法包括全向发射端天线假设（不生成离开角），以及为无线个域网/无线局域网/蜂窝网络兼容性而进行的统计统一。该模型完全开源。1.0版评估版侧重于短距离室内场景，支持毫米波/亚太赫兹应用。

VIII. 挑战与研究机遇

人工智能驱动的信道状态信息外推为 6G 带来了重大挑战与令人振奋的机遇。本节将详细阐述这一领域的关键挑战和潜在机遇。

A. 面向 *6G* 的人工智能驱动信道状态信息外推的挑战

尽管针对面向 6G 的人工智能驱动信道状态信息外推已有大量研究，但现有研究仍存在显著局限性，概述如下：

1）时域：时域信道状态信息外推传统上侧重于短期预测时域 [38]。在此类情况下，空间平稳性基本得以保持，而用户设备移动引起的多普勒频移主导着信道变化。对于5G前系统而言，这一假设是适用的，因为用户设备的速度很少超过每小时几十公里。然而，随着5G-Advanced和6G的出现，预计将支持用户设备速度高达每小时1000公里的场景（例如高速列车）。在这些条件下，长期外推会变得困难得多：信道的变化不再仅仅由多普勒效应造成，用户设备还会实际移动到散射几何结构和传播环境完全不同的区域。

长期外推面临两大根本障碍。首先，现有数据集仍然极为有限。基于随机几何的信道模型能够再现运动引起的多普勒诱发的衰落，但难以

表示大尺度位置变化，以及信道特性对特定传播场景的强烈依赖。3GPP定义的传统TDL和簇延迟线（CDL）模型假设短时间间隔内的统计特性准平稳；而RTtools擅长特定位置的信道重建，却难以纳入连续的UE轨迹。现实世界的测量活动能够捕捉移动性和位置相关效应，但大规模采集并标注此类数据的成本高得令人望而却步。

其次，几乎所有现有仿真环境都将传播环境视为静态。这些环境忽略了突发的环境动态变化，例如移动的车辆、城市峡谷中的临时遮挡或摇曳的树叶，也忽略了相位噪声和振荡器漂移等硬件损伤。因此，现有研究中的外推精度往往过于乐观。在实际部署中，这些未建模的时间变化会导致预测精度迅速下降。

2）频域：先前大多数关于频域信道状态信息外推的研究，都针对工作于同一宽频谱频段（通常为 6 GHz 以下）的 FDD系统。在这些配置中，上行链路和下行链路的载波频率足够接近，因此仍能保持部分信道互易性：上行链路与下行链路之间的主要差异在于复数值。这种有限的差异大大简化了 FDD系统的信道状态信息外推。

相比之下，在相距较远的频段之间进行信道状态信息外推，例如在 6 GHz 以下与毫米波之间，或在不同的毫米波频段之间进行外推，挑战要大得多。路径损耗指数、多径丰富度和散射机制等都会随频率显著变化。因此，单频段外推技术无法直接应用。由于远距离频率上的信道响应之间存在内在的非线性关系，且这种关系因频段而异，因此很难建立准确的双向映射。从源频段进行外推时引入的误差，在反向处理或扩展到更多频段时往往会迅速累积，导致性能显著下降。

3）天线域：大多数关于天线域信道状态信息外推的研究，都集中在远场区域运行的传统多输入多输出系统上。在这类设置中，波前在整个天线阵列上基本呈平面，因此，每一对收发天线经历的传播路径几乎相同，且仅由角度决定。XL-MIMO、RIS 和 FAS 等新兴范式部分或完全运行于近场区域。在此区域，球面波前的影响变得显著，各条散射路径在阵列上的可见性也各不相同：某些多径分量可能只照射到部分天线单元。这种空间非平稳性从根本上增加了天线域外推的复杂性。

该领域的进展受到两大主要障碍的限制。首先，获取真实的近场信道数据集仍然极其困难。要通过测量活动捕捉大孔径阵列上的完整球面波效应，成本高、耗时长，而且要求对发射端和接收端进行精确定位。迄今为止，还没有广泛可用的信道仿真器能够以足够的保真度准确重现这些近场现象，以用于训练或评估。其次，由于发射端-接收端对之间的路径可见性会发生变化，近场信道具有固有的非平稳性，因此难以建模和预测。现有的外推方法通常假设空间相关性平滑，难以跟踪这些不连续变化，导致性能迅速下降。

4）多域：多域信道状态信息外推同时跨越时间、频率和天线域，进一步加剧了前文所述的局限性。在单一域中尚可容忍的误差和简化假设，不再彼此独立，而会跨域相互作用并放大，从而导致与现实情况的偏差大幅增加。

即使是 QuaDRiGa 或 Sionna 等先进的信道仿真器，也只能部分应对这一挑战。尽管它们能够在受控条件下对某些跨域相关性进行建模，但仍依赖理想化的传播假设，无法捕捉真实场景的全部复杂性。例如，在 EL-MIMO 系统（如搭载于无人机或低地球轨道卫星链路上的系统）中，高速移动性与大频率间隔的紧密耦合作用；又如天气相关散射（例如雨致衰减和去极化）对时间、频谱和空间信道特性的同时影响。因此，仅基于仿真数据训练或评估的外推模型，往往在单个域中表现出看似优异的性能，但部署到实际环境中时，却会遭遇严重的联合预测误差。

这一差距凸显了对混合数据集的迫切需求，这类数据集应有策略地结合高保真射线追踪或随机仿真与有针对性的测量活动。只有这类复合数据集才能提供多样且符合物理规律的多域样本，以训练稳健且具备良好泛化能力的外推框架。

B. 未来研究

基于对现有信道状态信息外推研究局限性的分析，我们提出以下未来研究方向。

1) 构建有效且可靠的数据集：大规模、高质量的数据集对于人工智能驱动的信道状态信息外推至关重要。为克服高质量数据集匮乏的问题，可考虑以下未来研究方向。

- **利用现有数据集**：
  有效利用现有数据集，是解决信道状态信息外推任务中高质量数据稀缺问题的关键途径。然而，无线信道研究中现有的数据集主要基于仿真，真实世界的测量数据十分稀缺。此外，不同来源的数据集在格式、场景和参数配置方面往往存在差异，限制了它们在信道状态信息外推中的直接适用性。*a)* 数据集对齐技术可以通过统一频率、带宽和天线配置等关键参数，对这些数据集进行标准化，从而提升其

可复用性 [198]。具体而言，一种可行的方案是开发开源数据处理框架，集成数据清洗、格式转换和参数对齐功能 [199], [200]。该框架可将异构信道数据集（例如由射线追踪生成或通过测量获得的数据）统一为标准化格式。通过自动校正频偏和天线配置差异，并结合统计验证模块，预计能够确保数据一致性。*b*) 此外，生成合成数据集也是一个很有前景的方向。利用生成对抗网络等生成模型 [182], [201]以及扩散模型 [202]，，可以生成具有多样性和代表性的合成信道数据，以扩充有限的真实世界数据集。具体而言，条件生成对抗网络有望根据频率、距离和移动速度等参数，以及现有数据集的统计特征，生成特定场景的信道数据。这些合成数据集必须经过严格的统计验证（例如路径损耗、多普勒扩展），以确保其分布特征与实际信道环境相符，从而支持信道状态信息外推模型的训练和评估。

- **制定有效的信道测量**：
开发经济高效的信道测量平台，是解决高质量数据集短缺问题的根本方案。传统信道测量设备（如矢量网络分析仪或专用信道探测仪）价格昂贵且操作复杂，因此难以进行大规模数据采集。*a*) 一种很有前景的方案是开发基于软件定义无线电（SDR）（如 USRP 或 HackRF ）的低成本测量平台，采用商用现货（ COTS）硬件和 MATLAB 或 GNU Radio 等开源软件进行信号处理和信道参数提取 [203]，[204]。这类平台还应进一步扩展，以支持多个频段（例如 6 GHz 以下、毫米波或太赫兹）的测量，并实现多天线信道参数提取。此外，还应开发用户友好型界面，以降低操作复杂度。*b*) 低成本无人机已用于灵活开展信道测量 [205], [206]，，而机器学习驱动的测量策略可通过预测信道参数的空间分布、指导测量点的最优选择来减少冗余并最大限度地扩大场景覆盖，从而进一步提升数据采集的效率和质量。具体而言，可利用强化学习算法开发用于测量的自适应路径规划工具。通过利用环境信息和历史数据，这些工具能够预测信道变化并优化无人机轨迹，从而最大限度地扩大场景覆盖和参数多样性。

- **改进信道仿真器**：
开发先进的信道仿真器，是提高信道状态信息外推研究中数据可用性的重要策略。当前的仿真器，例如基于几何的仿真器（如射线追踪）或统计模型，往往无法捕捉复杂无线信道的非平稳特性或高阶统计特性。未来的研究可以聚焦于混合信道仿真器，将基于几何的模型（如射线追踪）与数据驱动方法（如神经网络）相结合，以更准确地复现无线信道的动态行为。*a*) 例如， [50], 中提出了一种混合仿真器，可根据射线追踪的仿真结果对近场效应和多普勒频移进行建模。未来研究还应着重纳入更多 6 G 相关因素，例如可重构智能表面、流体天线系统、毫米波、太赫兹频段和无人机 [207], 等。*b*) 此外，信道仿真器的实时能力和可扩展性也是至关重要的开发方向。一种可行的解决方案是在云平台（如 AWS 或 Azure）上构建分布式信道仿真系统，并利用 GPU 加速实时生成大规模 MIMO 或太赫兹信道数据。该平台应提供 API 接口，以便集成到信道状态信息外推算法的开发流程中。

2）综合性能评估：

- **泛化性能**：
信道状态信息外推模型的泛化能力是评估其实际部署性能的一项关键指标，尤其是在动态且未见过的场景中。此外，测量设置存在显著差异，包括校准流程、天线极化、发射功率、采集时长和局部散射环境等；若直接合并不同测量活动中采集的数据集，往往会导致严重的分布偏移。这种偏移可能造成对真实泛化性能的高估或低估。如何公平地评估泛化性能仍是一个尚未解决的问题，以下总结了潜在的未来研究方向：*a*) 场景异质性指数：针对关键场景参数（中心频率、带宽、阵列孔径、环境类型、移动性等）计算统计距离（例如 KL散度），以量化源域与目标域之间的差异。*b*) 遮挡/异常预测得分：针对动态遮挡或异常事件（例如车辆或行人突然造成遮挡）的专用指标，综合考虑 F1分数、预测提前时间和虚警率。*c*) 可迁移性比率：目标域上的零样本性能与少样本微调性能之比；该值越接近 1，表明内在泛化能力越强。

- **特定领域信道状态信息外推所需的数据集规模**：

人工智能驱动的信道状态信息外推面临的一个基本问题是：在每个域中，需要多大规模的数据集才能达到理想的性能。直观而言，所需的数据集规模取决于 AI模型、场景的复杂性和动态特征。例如，与监督学习相比，自监督学习通常所需的数据少得多 [157]，，而且需要更多数据

非视距场景所需的数据多于视距场景 [51]。然而，无线通信领域对此主题的研究有限，尤其缺乏有关各域所需数据集规模的定量结果。*a*) [22] 观察发现，由于基于 Transformer 的模型能够捕捉长期时间相关性，较长的历史信道状态信息输入序列有助于提升时域信道状态信息外推性能；而历史信道状态信息输入序列的长度对基于长短期记忆网络/门控循环单元的模型影响则小得多。[57] 观察发现，增加输入信道状态信息的数量可以提升天线域信道状态信息外推性能，但达到一定输入数量后，性能便趋于饱和。然而，以上研究均为定性研究，缺少定量分析。此外，现有信道状态信息外推研究的仿真设置通常各不相同，因此难以通过文献综述得出确切结论。为此，我们建议建立一个公共数据集，如同计算机视觉领域的 ImageNet，以此作为基准，定量评估历史信息与预测时域之间的平衡。3GPP 已率先着手建立此类数据集，但仍需整个社区投入更多努力。*b*) 受人工智能领域启发，确定最小数据集规模的一种有前景的方法是主动学习：依据不确定性和多样性指标，选择最有助于模型训练的数据集 [208]。不确定性用于量化数据样本对下游任务而言有多难，而多样性则衡量数据样本与已用于训练的数据集相比有多大差异。然而，由于信道数据维度很高，要为其计算类似指标难度很大，其中涉及场景特征、载波频率、速度、天线间距等。

- **计算高效的模型设计：**
基于人工智能的信道状态信息外推模型的计算复杂度，是其部署于边缘设备等资源受限环境或实时 6G 应用中的关键因素，但现有评估指标往往忽视了这一方面 [209]。高复杂度模型（如 Transformer 或深层卷积神经网络）可能具有更高的外推精度，但会带来显著的计算开销，因此不适用于车联网通信等时延敏感场景。*a*) 稀疏注意力 Transformer 通过将传统自注意力机制的二次计算复杂度降低至近线性或对数级别，为低复杂度信道状态信息外推带来了显著优势，因而适用于在 6G网络等实时应用中处理高维信道状态信息 [209], [210]。Routing Transformer 或 Performer 等技术利用稀疏注意力模式（如局部注意力或线性化注意力），将计算资源集中于相关的信道状态信息特征（如空间相关性或多普勒频移），从而在提升外推精度的同时，最大限度地降低时延和内存使用量。这种高效性对于大规模MIMO或毫米波场景尤为有益，因为这类场景中的信道状态信息序列既长又复杂，可在不同环境（如城市、车载环境）中实现鲁棒预测。*b*) MobileNetV2 或 EfficientNet 等轻量级卷积神经网络通过采用深度可分离卷积、模型剪枝和量化等技术，最大限度地降低计算成本和内存占用，为低复杂度信道状态信息外推提供了颇具吸引力的解决方案 [211], [212]。这类模型非常适合物联网节点或移动终端等资源受限设备，能够高效处理信道状态信息，从而预测车载或无人机网络等动态环境中的信道响应 [213]–[215]。与传统卷积神经网络相比，它们以更少的参数捕获信道状态信息中的空间—频率相关性，在满足 6G 应用低时延要求的同时，确保较高的外推精度。通过从较大模型进行知识蒸馏，还能进一步提升其性能，使其适用于边缘计算。然而，研究挑战包括：与更深层架构相比，轻量级卷积神经网络的表达能力有限，可能难以建模复杂的信道动态（如非平稳衰落）。要设计能够适用于多种信道场景的轻量级卷积神经网络，需要仔细进行架构优化并制定数据增强策略。

3）高级模型设计：

- **模型驱动的信道状态信息外推：**
无线通信系统中人工智能算法的鲁棒性常常受到信道环境中噪声以及动态性和复杂性的挑战。模型驱动方法将特定领域的物理模型与数据驱动技术相结合，在增强信道状态信息外推模型的鲁棒性和泛化能力方面展现出巨大潜力 [216], [217]。这些方法利用无线信道特性的先验知识（如路径损耗、多径衰落和多普勒效应）指导学习过程，从而减少对大量标注数据集的依赖。具体而言，物理信息神经网络可以将物理信道模型（例如Saleh-Valenzuela模型）嵌入深度神经网络的损失函数中，并在从数据中学习的同时优化路径损耗和时延扩展等信道参数，从而确保在不同频段和环境下实现稳健的外推。未来研究应重点关注如何无缝融合模型驱动范式与数据驱动范式，以构建混合框架 [218]。例如，可将传统上用于信道建模的迭代参数估计算法重新表述为深度神经网络，并将物理信道参数（例如到达角、时延扩展）嵌入为可学习特征。该方法扩展了模型的参数空间，同时支持通过数据驱动优化进行微调，从而显著提升不同噪声水平下的外推精度和鲁棒性。

- **新颖的架构设计：**基于 Transformer 的架构在人工智能驱动的信道状态信息外推中的变革潜力日益凸显，使其成为

未来模型开发的基石 [219],[220]。然而，其计算复杂度和资源需求给在无线系统中的实际部署带来了挑战。为此，稀疏注意力机制和混合专家（MoE）架构为提升外推精度、泛化能力和计算效率提供了颇具前景的解决方案。Routing Transformer [209]或层次化注意力模型 [221], 等采用的稀疏注意力技术，通过聚焦于相关特征交互，降低了自注意力的二次复杂度，使其适用于处理长序列或高维信道数据。同样，Switch Transformers [222] 和 GShard [223], 所展示的混合专家架构，通过选择性地激活部分专家，在前馈层中引入稀疏性，从而支持可扩展且高效的大规模模型。

•**多模态辅助的信道状态信息外推：**融合多模态数据已成为克服仅依赖信道状态信息进行外推所固有局限性的一种最有效策略。无线信道特性受多种因素影响，包括环境几何结构、用户移动性和突发遮挡等，而单一数据模态（例如信道状态信息）无法全面捕捉这些因素。多模态学习通过融合互补的传感器数据和数据流来弥补这一不足，包括摄像头图像 [224], [225],毫米波雷达点云 [226],WiGig/Wi-Fi感知侧信息 [227], [228],，甚至是公开可用的地图和天气数据流。当这些信息源得到恰当整合时，便能提供丰富的传播环境信息 [229] ；这些信息在接收信号中往往隐含存在，甚至完全缺失，从而显著提升在密集城市峡谷、室内工厂或高移动性室外场景等复杂环境中的时空预测精度。多模态信道状态信息外推的一项关键挑战，是设计能够有效融合异构数据、同时缓解模态错位或数据匮乏等问题的融合机制。可以采用跨模态注意力或图神经网络等先进技术，对不同模态之间的关系进行建模，使模型能够学习稳健且具有良好泛化能力的信道表征。

4) 与新兴技术集成：信道状态信息外推能够以较低开销获取信道状态信息，因此有望提升新兴技术在 6G 中的性能。本节将详细阐述信道状态信息外推与新兴技术集成所带来的机遇和挑战，并探讨未来可能的研究方向。

•**新兴MIMO系统：** 先进天线技术、XL-MIMO、RIS和FAS正在从根本上重塑无线系统，并对信道状态信息外推方法提出前所未有的要求 [230]–[232]。在XL-MIMO中，空间非平稳性意味着孔径的不同部分会观测到不同的散射路径集合，阵列各处的路径数量、增益、相位和时延均存在显著差异 [49]。RIS和FAS进一步引入了可控但快速时变的信道：RIS通过可编程反射系数实现，FAS则通过动态端口重定位实现。这些特性大幅增加了信道的维度和时间波动性，使实时外推变得更加困难，尤其是在功耗或计算能力受限的用户设备上 [232], [233]。设计能够在这些条件下保持准确运行、同时满足严格时延和能耗约束的人工智能模型，仍然是一项尚未解决的挑战。能够充分捕捉这些新兴技术物理特性的公开标准化数据集，对于加速该领域的研究同样至关重要。

- **新兴多址接入技术：**
新兴多址接入技术，尤其是非正交多址接入（NOMA） [234] 和速率分割多址接入（RSMA），已成为实现 6G 网络频谱效率和海量连接目标的基石 [235], [236]。与正交方案不同，这两种方法都会有意在用户之间引入受控干扰，因此对信道状态信息外推的准确性和及时性提出了更高要求。*a)* 在NOMA 中，多个用户通过功率域或码域复用共享相同的时频资源。接收端能否成功解码，以及发射端能否进行最优功率分配，都高度依赖于对瞬时用户间信道条件的准确了解。当无法获得完美的信道状态信息时，外推误差会直接转化为残余干扰、连续干扰消除性能下降以及吞吐量降低。在车联网等高度动态的环境中，这一问题尤为突出；基于人工智能的时域信道外推必须在保持低时延的同时，预测信道的快速变化。*b)* RSMA 进一步增加了复杂性，它将每个用户的消息拆分为公共流（由多个接收机解码）和私有流（被其他用户视为噪声）。由此形成的干扰格局兼具广播和单播特征，因此外推框架需要同时跟踪两种流的信道响应及其相互依赖关系。人工智能驱动的外推可通过联合建模公共流和私有流的信道响应来应对这一问题，并利用多任务学习捕捉它们之间的相互依赖关系。

- **卫星通信：**卫星通信为信道状态信息外推带来了独特挑战，推动了人们对长期鲁棒预测技术的研究兴趣日益增长 [14], [92], [96], [97], [103],[107], [237]。造成困难的两个主要因素是：用户移动性极高，尤其是在低地球轨道（LEO）星座以及高速航空或海上平台中；往返时延则从几十毫秒到数百毫秒不等。这些条件要求外推时域远超地面系统的典型范围，往往需要在多普勒效应、多径和遮挡动态快速变化的情况下，准确预测数百毫秒后的状态 [238]。处理

资源受限终端上的长预测序列对模型复杂度和功耗提出了严格限制。公开可用的高保真卫星信道数据集仍极为稀缺，研究人员因此不得不依赖简化的几何随机模型，或基于地面数据集进行领域适配迁移学习。最后，受轨道运动、仰角变化和大气湍流影响，信道具有高度非平稳性，使得传统指标难以胜任。一种颇有前景的解决方案是利用卫星系统中易于获取的多模态输入，例如精确的卫星星历、用户轨迹预测，以及实时电离层或对流层闪烁指数，以改进信道状态信息外推 [239]。

IX. 结论

信道状态信息外推技术在现代无线通信系统中发挥着至关重要的作用，尤其是在即将到来的 6G 时代。随着通信需求迅速增长，以及对高频谱效率和低时延的要求不断提高，传统信道估计方法已无法应对高维数据处理和新兴技术带来的挑战。信道状态信息外推技术利用部分 CSI 推断完整 CSI，从而有效减少频繁反馈和传输开销，并提高系统资源利用率。

然而，目前仍缺乏对信道状态信息外推领域现有研究的全面综述。为此，本文对信道状态信息外推研究进行了深入回顾。具体而言，我们首先介绍时间、频率、天线和多域信道状态信息外推的基础知识，以及具有代表性的人工智能模型。随后，我们全面回顾时间、频率、天线和多域信道状态信息外推的现有研究，涵盖主要技术的原理及其优缺点。作为人工智能时代的关键资源，我们总结了开源信道状态信息数据集和信道仿真器。为应对时间、频率、天线和多域信道状态信息外推面临的挑战，我们还提出了富有前景的未来研究方向，涉及数据集构建、性能评估、模型设计以及与 6G 新兴技术的融合。

总而言之，信道状态信息外推技术已成为未来无线通信系统不可或缺的一部分，其研究与发展不仅有助于提升通信系统的性能，还将为实现6G网络愿景奠定坚实基础。

参考文献

[1] M. Banafaa, I. Shayea, J. Din, M. H. Azmi, A. Alashbi, Y. I. Daradkeh, and A. Alhammadi, “6G移动通信技术：需求、目标、应用、挑战、优势与机遇，”《亚历山大工程学报》，第64卷，第245–274页，2023年。[2] S. Xu, J. Jiang, W. Yu, Y. Gao, G. Pan, S. Mu, Z. Ai, Y. Gao, P. Jiang, and C.-X. Wang, “基于实际缺陷的增强型指纹定位：基于深度学习的方法，” *IEEE Wirel. Commun.*，第1–1页，2025年10月，早期访问，doi:10.1109/MWC.2025. 3600205，。

[3] M. W. Akhtar, S. A. Hassan, R. Ghaffar, H. Jung, S. Garg, and M. S. Hossain，“向6G通信转型：愿景与需求”，《以人为中心的计算与信息科学》，第10卷，第27期，2020年，1页。[4] Y. Gao, H. Du, Z. Jiang, H. Hu, J. Zhang, S. Zhang, J. Du, F. R. Yu, and S. Xu，“面向定位与通信一体化系统的随机几何分析框架”，IEEE物联网期刊，2025年。[5] Y. Gao, H. Hu, J. Zhang, Y. Jin, S. Xu, and X. Chu，“定位与通信一体化系统的性能分析：一种分析框架”，IEEE车辆技术汇刊，第73卷，第7期，第10 845–10 849页，2024年。[6] H. Tataria, M. Shafi, A. F. Molisch, M. Dohler, H. Sj¨oland, and F. Tufvesson，“6G无线系统：愿景、需求、挑战、见解与机遇”，IEEE会刊，第109卷，第7期，第1166–1199页，2021年。[7] V. Dala Pegorara Souto, P. S. Dester, M. Soares Pereira Facina, D. Gomes Silva, F. A. P. de Figueiredo, G. Rodrigues de Lima Tejerina, J. C. Silveira Santos Filho, J. Silveira Ferreira, L. L. Mendes, R. D. Souza 等，“面向6G网络的新兴MIMO技术”，Sensors，第23卷，第4期，第1921页，2023年。[8] Y. Huo, X. Lin, B. Di, H. Zhang, F. J. L. Hernando, A. S. Tan, S. Mumtaz, ¨O. T. Demir, and K. Chen-Hu，“面向6G的大规模MIMO技术趋势”，Sensors，第23卷，第13期，第6062页，2023年。[9] T. S. Rappaport, Y. Xing, G. R. MacCartney, A. F. Molisch, E. Mellios, and J. Zhang，“第五代（5G）无线网络的毫米波通信概述——聚焦传播模型”，IEEE天线与传播汇刊，第65卷，第12期，第6213–6230页，2017年。[10] K. Tekbıyık, A. R. Ekti, G. K. Kurt, and A. G¨orcin，“太赫兹频段通信系统：挑战、新进展与标准化工作”，《物理通信》，第35卷，第100700页，2019年。[11] C.-X. Wang, J. Huang, H. Wang, X. Gao, X. You, and Y. Hao，“6G无线信道测量与模型：趋势与挑战”，IEEE车辆技术杂志，第15卷，第4期，第22–32页，2020。[12] S. Ahearne, N. O’Mahony, N. Boujnah, S. Ghafoor, A. Davy, L. G. Guerrero, and C. Renaud，“在数据中心网络中集成太赫兹无线通信链路”，载于2019年IEEE第二届5G世界论坛（5GWF）。IEEE，2019年，第393–398页。[13] J. Jiang, W. Yu, Y. Li, Y. Gao, and S. Xu，“基于CIR-CSI一致性的MIMO无线信道基础模型”，arXiv预印本 arXiv:2502.11965，2025年。[14] Y. Gao, X. Xu, B. Hu, J. Du, W. Yang, and Y. Jin，“MIMO-OTFS卫星通信的信道估计：一种基于深度学习的方法”，载于2024年第33届国际计算机通信与网络会议（ICCCN）。IEEE，2024年，第1–6页。[15] Y. Gao, X. Xu, Y. Jin, W. Yuan, J. Zhang, and S. Xu，“OTFS系统的联合信道估计与数据检测：采用新型数据增强方法的轻量级深度学习框架”，IEEE物联网期刊，2025年。[16] B. Lim, W. J. Yun, J. Kim, and Y.-C. Ko，“硬件损伤条件下基于深度残差学习的多小区大规模MIMO联合导频设计与信道估计”，IEEE车辆技术汇刊，第71卷，第7期，第7599–7612页，2022年。[17] H. Chen, R. Zhang, W. Zhai, X. Liang, and G. Song，“基于零相关区序列的无干扰导频设计与信道估计：适用于基于MIMO-OFDM的C-V2X通信”，中国通信，第15卷，第7期，第47–54页，2018年。[18] Z. Chen, H. Shin, and A. Nallanathan，“基于生成式扩散模型的MIMO信道变分推断”，IEEE通信汇刊，2025年。[19] R. Zhang, G. Chen, L. Cheng, X. Guan, Q. Wu, W. Wu, and R. Zhang，“动态超表面天线极大规模MIMO-OFDM的基于张量的信道估计”，IEEE无线通信汇刊，2025年。[20] Y. Gao, X. Wu, Y. Gao, and S. Xu，“C2S：一种基于Transformer的框架，用于从通信信道外推感知信道”，载于2024年IEEE第100届车辆技术会议（VTC2024-Fall）。IEEE，2024年，第1–5页。[21] S. Zhang, Y. Liu, F. Gao, C. Xing, J. An, and O. A. Dobre，“大规模天线系统的基于深度学习的信道外推：机遇、挑战与解决方案”，IEEE《无线通信》，第28卷，第6期，第160–167页，2021年。[22] Y. Jin, Y. Wu, Y. Gao, S. Zhang, S. Xu, and C.-X. Wang，“Linformer：一种面向时间感知MIMO信道预测的基于线性变换的轻量级Transformer架构”，IEEE无线通信汇刊，2025年。

[23] Y. Jin, R. Yu, Y. Gao, S. Liu, X. Chu, K.-K. Wong, and C.-B. Chae, “面向流体天线系统中鲁棒信道外推的上下文感知深度学习”，arXiv预印本 arXiv:2507.04435，2025年。[24] J. Jiang, Y. Gao, X. Wu, and S. Xu, “迈向信道基础模型（CFM）：研究动机、方法与机遇”，arXiv预印本 arXiv:2507.13637，2025年。[25] M. Mizmizi, D. Tagliaferri, D. Badini, C. Mazzucco, and U. Spagnolini, “利用多车辆学习进行6G车联网混合系统的信道估计”，IEEE Access，第9卷，第95 775–95 790页，2021年。[26] S. Zhang, S. Zhang, J. Ma, T. Liu, and O. A. Dobre, “混合毫米波大规模MIMO的基于深度学习的天线-时间域信道外推”，IEEE车辆技术汇刊，第71卷，第12期，第13 398–13 402页，2022年。[27] M. Alrabeiah and A. Alkhateeb, “TDD和FDD大规模MIMO的深度学习：空间与频率域的信道映射”，载于2019年第53届阿西洛马会议：信号、系统与计算机。IEEE，2019年，第1465–1470页。[28] A. Ali, N. Gonzalez-Prelcic, and R. W. Heath, “利用带外信息估计毫米波混合系统的空间协方差”，IEEE无线通信汇刊，第18卷，第12期，第5471–5485页，2019年。[29] Y. Han, T.-H. Hsu, C.-K. Wen, K.-K. Wong, and S. Jin, “FDD多天线系统的高效下行信道重构”，IEEE无线通信汇刊，第18卷，第6期，第3161–3176页，2019年。[30] Z. Zhang, J. Zhang, Y. Zhang, L. Yu, and G. Liu, “面向6G的基于人工智能的时域、频域和空域信道外推：机遇与挑战”，IEEE车辆技术杂志，第18卷，第1期，第29–39页，2023年。[31] L. Mucchi, S. Shahabuddin, M. A. Albreem, S. Abdallah, S. Caputo, E. Panayirci, and M. Juntti, “面向6G的信号处理技术”，《信号处理系统杂志》，第95卷，第457期，2023年，第4卷，第435页。[32] R. Chataut and R. Akl, “面向5G及后续网络的大规模MIMO系统——概述、近期趋势、挑战与未来研究方向”，Sensors，第20卷，第10期，第2753页，2020。[33] B. Lin, F. Gao, S. Zhang, T. Zhou, and A. Alkhateeb, “大规模MIMO系统中基于深度学习的天线选择与信道状态信息外推”，IEEE无线通信汇刊，第20卷，第11期，第7669–7681页，2021年。[34] Y. Han, S. Jin, X. Li, C.-K. Wen, and T. Q. Quek, “FDD大规模MIMO系统的多域信道外推”，IEEE通信汇刊，第69卷，第12期，第8534–8550页，2021年。[35] Z. Chen, Z. Zhang, Z. Yang, and L. Liu, “基于复数域MLP-Mixer和交错学习的信道映射”，IEEE无线通信快报，2024年。[36] C. Wu, X. Yi, Y. Zhu, W. Wang, L. You, and X. Gao, “高移动性大规模MIMO中的信道预测：从时空自回归到深度学习”，IEEE通信领域精选期刊，第39卷，第7期，第1915–1930页，2021年。[37] B. Zhou, X. Yang, S. Ma, F. Gao, and G. Yang, “高移动性场景下TDD毫米波大规模MIMO系统的低开销信道估计：基于三维外推的方法”，arXiv预印本 arXiv:2406 08887，2024年。[38] O. Stenhammar, G. Fodor, and C. Fischione, “无线信道预测神经网络的比较”，IEEE《无线通信》，2024年。[39] H. Kim, J. Choi, and D. J. Love, “面向未来无线通信的机器学习：信道预测视角”，arXiv预印本 arXiv:2502.18196，2025年。[40] F. Pasic, N. Di Cicco, M. Skocaj, M. Tornatore, S. Schwarz, C. F. Mecklenbr¨auker, and V. Oegli-Esposti, “用于基于深度学习的动态信道预测与仿真的多频段测量”，IEEE通信杂志，第61卷，第9期，第98–104页，2023年。[41] Z. Becvar, D. Gesbert, P. Mach, and M. Najla, “基于机器学习的6G移动网络信道质量预测”，IEEE通信杂志，第61卷，第7期，第106–112页，2023年。[42] W. Jiang and H. D. Schotten, “基于神经网络的衰落信道预测：全面综述”，IEEE Access，第7卷，第118 112–118 124页，2019年。[43] X. Xu, X. Mu, Y. Liu, H. Xing, Y. Liu, and A. Nallanathan, “面向移动通信的生成式人工智能：扩散模型视角”，IEEE通信杂志，2024年。[44] G. E. Hinton, “学习多层表征”，《认知科学趋势》，第11卷，第10期，第428–434页，2007年。

[45] J. Wu, 《卷积神经网络简介》，新型软件技术国家重点实验室，南京大学，中国，第5卷，第23期，第495页，2017年。[46] A. Graves和A. Graves, 《长短期记忆网络》，《基于循环神经网络的监督序列标注》，第37–45页，2012年。[47] R. Dey和F. M. Salem, 《门控循环单元（GRU）神经网络的门控变体》，载于《2017年第60届IEEE国际中西部电路与系统研讨会》（MWSCAS）。IEEE，2017年，第1597–1600页。[48] A. Vaswani、N. Shazeer、N. Parmar、J. Uszkoreit、L. Jones、A. N. Gomez、Ł. Kaiser和I. Polosukhin, 《Attention is All You Need》，《神经信息处理系统进展》，第30卷，2017年。[49] J. Li、B. Ai、R. He、M. Yang、Z. Zhong、Y. Hao和G. Shi, 《大规模MIMO信道测量中的三维空间非平稳性与球面波前》，载于《2018年第十届无线通信与信号处理国际会议》（WCSP）。IEEE，2018年，第1–6页。[50] Z. Shen、L. Yu、Y. Zhang、J. Zhang、Z. Zhang、X. Hu、S. Han、J. Jin和G. Liu, 《DataAI-6G：一种系统参数可配置的AI-6G研究信道数据集》，载于《2023年IEEE Globecom研讨会》（GC Wkshps）。IEEE，2023年，第1910–1915页。[51] Y. Gao、Z. Lu、Y. Wu、Y. Jin、S. Zhang、X. Chu、S. Xu和C.- X. Wang, 《通过多域信道外推实现6G：生成式人工智能的机遇与挑战》，《IEEE通信杂志》，2025年10月，提前在线发表，doi:10.1109/ MCOM.001.2500246,.[52] H. Kim、S. Kim、H. Lee、C. Jang、Y. Choi和J. Choi, 《大规模MIMO信道预测：卡尔曼滤波与机器学习的比较》，《IEEE通信汇刊》，第69卷，528，2020 1，518第.期，页–。[53] W. Xu、J. An、Y. Xu、C. Huang、L. Gan和C. Yuen, 《基于深度学习的RIS辅助MU-MISO网络时变信道预测》，《IEEE认知通信与网络汇刊》，第8卷，第4期，第1802–1815页，2022年。[54] W.-S. Son和D. S. Han, 《基于深度学习的方法的信道预测精度分析》，载于《2021年人工智能与信息通信国际会议》（ICAIIC）。IEEE，2021年，第140–143页。[55] W. Jiang和H. D. Schotten, 《一种用于预测多天线系统中衰落信道的深度学习方法》，载于《2020年IEEE第91届车辆技术会议》（VTC2020-Spring）。IEEE，2020年，第1–5页。[56] Z. Li、F. Liu、W. Yang、S. Peng和J. Zhou, 《卷积神经网络综述：分析、应用与展望》，《IEEE神经网络与学习系统汇刊》，第33卷，第12期，第6999–7019页，2022年。[57] H. Zhang、J. Wang、C. Wang、C.-C. Wang、K.-K. Wong、B. Wang和C.-B. Chae, 《利用非对称图掩码自编码器进行流体天线系统的学习驱动信道外推》，《IEEE无线通信快报》，2024年。[58] W. Liu、Z. Chen和X. Gao, 《利用张量分解和自回归模型预测真实传播环境中的大规模MIMO信道》，载于《2022年IEEE第33届个人、室内和移动无线电通信国际研讨会》（PIMRC）。IEEE，2022年，第849–855页。[59] S. Kashyap、C. Moll´en、E. Bj¨ornson和E. G. Larsson, 《采用卡尔曼信道预测的时分双工大规模MIMO性能分析》，载于《2017年IEEE声学、语音与信号处理国际会议》（ICASSP）。IEEE，2017年，第3554–3558页。[60] N. Palleit和T. Weber, 《多天线系统中的信道预测》，载于《2012年ITG智能天线国际研讨会》（WSA）。IEEE，2012年，第1–7页。[61] S. Prakash和I. McLoughlin, 《瑞利衰落下信道预测对采用最大比合并的发射天线选择的影响》，《IEEE车辆技术汇刊》，第60卷，第6期，第2555–2568页，2011年。[62] T. Yang、R. Zhang、X. Cheng和L. Yang, 《不完美信道状态信息下的安全大规模MIMO：性能分析与信道预测》，《IEEE信息取证与安全汇刊》，第14卷，第6期，第1610–1623页，2018年。[63] K. E. Baddour和N. C. Beaulieu, 《时变瑞利信道未知参数的改进导频辅助预测》，载于《2006年IEEE国际通信会议》，第11卷。IEEE，2006年，第5192–5199页。[64] H. Yin、H. Wang、Y. Liu和D. Gesbert, 《利用基于Prony方法的角度-时延域信道预测应对大规模MIMO中的移动性诅咒》，《IEEE通信领域精选期刊》

，第 38 卷，第 12 期，第 2903–2917 页，2020。

[65] J.-Y. Wu 和 W.-M. Lee，《存在信道估计误差时 LTE-A 上行链路的最优线性信道预测》，IEEE车辆技术汇刊，第 62 卷，第 8 期，第 4135–4142 页，2013 年。[66] P. Pedrosa、D. Castanheira、A. Silva、R. Dinis 和 A. Gameiro，《采用 SC-FDE 方案实现车联网通信的高效联合信道均衡与跟踪》，IEEE Access，第 8 卷，第 55 158–55 169 页，2020 年。[67] P. Wang、J. Li、A. Zhang、B. Ning、B. Sun 和 P. Sun，《面向高移动性大规模 MIMO 的两阶段部分在线优化信道预测》，IEEE Communications Letters，2024 年。[68] W. Peng、M. Zou 和 T. Jiang，《时变大规模 MIMO 环境中的信道预测》，IEEE Access，第 5 卷，23 946，2017 年 23 938页。– 。[69] W. Li、H. Yin、Z. Qin、Y. Cao 和 M. Debbah，《一种面向移动场景大规模 MIMO 的多维矩阵铅笔信道预测方法》，IEEE无线通信汇刊，第 22 卷，第 4 期，第 2215–2230 页，2022年。[70] Y. Zhang、X. Zhu、Y. Liu、Y. Jiang、R. Yin、Y. L. Guan 和 D. Gonz´alez，《基于基扩展外推的下行链路信道预测及其在 TDD MIMO-OTFS 系统中的上行信道估计应用》，载于 ICC 2023-IEEE国际通信会议。IEEE，2023年，第 2270–2275 页。[71] F. Peng、S. Zhang、Z. Jiang、X. Wang 和 W. Chen，《一种面向车载通信的新型移动性诱导信道预测机制》，IEEE无线通信汇刊，第 22 卷，第 5 期，第 3488–3502 页，2022年。[72] X. Ren、W. Chen 和 M. Tao，《高移动性 OFDM 系统中基于位置的压缩信道估计与导频设计》，IEEE车辆技术汇刊，第 64 卷，1929，2014 年 5，1918 第。页 – 。[73] G. Liu、L. Wang、Z. Hu 和 J. Xue，《基于变分模态分解的大规模 MIMO 系统信道预测》，载于 2022 IEEE/CIC中国通信国际会议（ICCC）。IEEE，2022年，第 214–219 页。[74] B. H. Fleury、M. Tschudin、R. Heddergott、D. Dahlhaus 和 K. I. Pedersen，《使用 SAGE算法在移动无线电环境中进行信道参数估计》，IEEE Journal on selected areas in communications，第 17 卷，第 3 期，第 434–450 页，1999年。[75] D. Sun 和 Y. Li，《一种结合信道矩阵加倍与时空平滑的信道预测方案》，Wireless Personal Communications，第 122 卷，第 3 期，第 2045–2055 页，2022 年。[76] Z. Guo 、 X. Wang 和 W. Heng，《基于二维波束空间MUSIC方法的毫米波信道估计》，IEEE无线通信汇刊，第 16 卷，第 8 期，第 5384–5394 页，2017年。[77] S. Uehashi、Y. Ogawa、T. Nishimura 和 T. Ohgane，《基于压缩感知到达方向估计的时变多用户 MIMO 信道预测》，IEEE车辆技术汇刊，第 68 卷，第 1 期，第 565–577 页，2018年。[78] Y. Shi、X. Wang 和 Z. Jiang，《基于非均匀导频模式的移动大规模 MIMO 场景信道预测》，Journal of Communications and Networks，第 25 卷，第 4 期，第 456–468 页，2023年。[79] J. Vanderpypen 和 L. Schumacher，《基于 ESPRIT 技术的 MIMO 信道预测》，载于 2007年 IEEE 第 18 届个人、室内和移动无线电通信国际研讨会。IEEE，2007年，第 1–5 页。[80] W. Peng、W. Li、W. Wang、X. Wei 和 T. Jiang，《时变 FDD大规模MIMO系统的下行信道预测》，IEEE Journal of Selected Topics in Signal Processing，第 13 卷，第 5 期，第 1090–1102 页，2019年。[81] X. Xu、S. Zhang、F. Gao 和 J. Wang，《基于稀疏贝叶斯学习的 RIS 辅助 MIMO-OFDM 信道外推》，IEEE通信汇刊，第 70 卷，第 8 期，第 5498–5513 页，2022年。[82] Z. Xiao、J. Sun、Z. Zhang 和 Y. Liu，《MU-MIMO 信道预测的非参数回归：从 K近邻到局部线性回归》，IEEE无线通信汇刊，2023年。[83] K. He、T. X. Vu、S. Chatzinotas 和 B. Ottersten，《基于学习的部分 CSI 大规模 MIMO 联合信道预测与天线选择》，载于 2022 IEEE Globecom研讨会（GC Wkshps）。IEEE，2022年，第 178–183 页。[84] W. Jiang 和 H. D. Schotten，《人工智能赋能的多天线衰落信道预测》，载于 2018年 IEEE第88届车辆技术会议（VTC-Fall）。IEEE，2018年，第 1–6 页。[85] M. K. Shehzad、L. Rose、S. Wesemann 和 M. Assaad，《基于机器学习的大规模 MIMO 信道预测：能否应用于真实世界数据？》，IEEE无线通信快报，第 11 卷，815，2022 年 4，811第。页 – 。[86] W. Jiang、M. Strufe 和 H. D. Schotten，《利用循环神经网络进行长距离 MIMO 信道预测

消费者通信与网络会议（CCNC）。IEEE，2020，页码1–6。[87] W. Jiang 和 H. D. Schotten，“无线信道预测器比较：人工智能与卡尔曼滤波器”，载于 ICC 2019-2019 IEEE国际通信会议（ICC）。IEEE，2019，页码1–6。[88] ——，“基于神经网络的信道预测及其在多天线系统中的性能”，载于2018年IEEE第88届车辆技术会议（VTC-Fall）。IEEE，2018年，页码1–6。[89] Z. Xiao、Z. Zhang、Z. Chen、Z. Yang 和 R. Jin，“采用 ODE-RNN 的移动多输入多输出信道预测：一种受物理启发的自适应方法”，载于2022年IEEE第33届个人、室内和移动无线电通信国际研讨会（PIMRC）。IEEE，2022年，页码1301–1307。[90] Y. Zhu、X. Dong 和 T. Lu，“一种用于无线信道预测的自适应无参数循环神经结构”，IEEE通信汇刊，第67卷，第11期，页码8086–8096，2019年。[91] T. Peng、R. Zhang、X. Cheng 和 L. Yang，“不完美信道状态信息下用于安全大规模MIMO通信的基于LSTM的信道预测”，载于 ICC 2020-2020 IEEE国际通信会议（ICC）。IEEE，2020，页码1–6。[92] Y. Zhang、Y. Wu、A. Liu、X. Xia、T. Pan 和 X. Liu，“用于低地球轨道卫星大规模MIMO通信系统的基于深度学习的信道预测”，IEEE无线通信快报，第10卷，第8期，页码1835–1839，2021年。[93] G. Liu、Y. Xu、Z. He、Y. Rao、J. Xia 和 L. Fan，“面向智能网联汽车的边缘计算网络基于深度学习的信道预测”，IEEE Access，第7卷，页码114 487–114 495，2019年。[94] W. Jiang 和 H. D. Schotten，“用于衰落信道预测的深度学习”，IEEE Open Journal of the Communications Society，第1卷，页码320–332，2020。[95] ——，“用于衰落信道预测的长短期记忆循环神经网络”，载于2020年IEEE第91届车辆技术会议（VTC2020-Spring）。IEEE，2020，页码1–5。[96] F. Minani、M. Kobayashi、T. Fujihashi、M. A. Alim、S. Saruwatari、M. Nishi 和 T. Watanabe，“采用LSTM和深度强化学习进行非地面网络上行链路的信道预测与公平资源分配”，IEEE无线通信汇刊，2025年。[97] O. Abbasi 和 G. Kaddoum，“卫星通信中信道老化感知的基于LSTM的信道预测”，IEEE网络快报，2024年。[98] L. Yuan、F. Zhou、Q. Wu 和 D. W. K. Ng，“通过信道预测增强动态频谱共享网络的智能资源分配”，载于 ICC 2024-IEEE国际通信会议。IEEE，2024，页码2767–2772。[99] H. Jiang、M. Cui、D. W. K. Ng 和 L. Dai，“基于Transformer的精准信道预测：让移动性变得可忽略”，IEEE通信领域精选期刊，第40卷，第9期，页码2717–2732，2022年。[100] V. Rizzello、B. Bock、M. Joham 和 W. Utschick，“用于基于注意力机制的信道预测的逆序技术”，IEEE信号处理开放期刊，2023年。[101] T. Zhou、X. Liu、Z. Xiang、H. Zhang、B. Ai、L. Liu 和 X. Jing，“基于Transformer网络的信道预测，用于增强AI原生空口中的信道状态信息反馈”，IEEE无线通信汇刊，第23卷，第9期，页码11 154–11 167，2024年。[102] S. Lu、Y. Lu、B. Su、S. Xu 和 M. You，“通过混合注意力并行同步Transformer进行信道预测”，电子信息通信学会通信汇刊，2025年。[103] D. Yan、M. Jia、Q. Guo 和 D. Niyato，“低地球轨道卫星通信系统的时频域信道预测：一种新型TFformer结构”，IEEE无线通信汇刊，2025年。[104] C. Cao、M. Chen、Y. Zhang、Y. Pan、Y. Cang 和 Z. Zhan，“面向超大规模MIMO系统的深度学习增强信道预测”，IEEE无线通信快报，2025年。[105] Y. Sang、K. Ma、Z. Wang 和 S. Chen，“高移动性MIMO系统中的双频超分辨率信道预测”，IEEE通信汇刊，2024年。[106] X. Liu、W. Yu、C. Qian、D. Griffith 和 N. Golmie，“用于车联网信道状态信息预测的深度强化学习”，载于2024年IEEE第21届消费者通信与网络会议（CCNC）。IEEE，2024，页码388–391。[107] M. Ying、X. Chen、Q. Qi 和 W. Gerstacker，“用于低地球轨道卫星物联网的基于深度学习的联合信道预测与多波束预编码”，IEEE无线通信汇刊，第23卷

,” 于 *2020*年*IEEE*第*17*届年度

，第 10 期，第 13 卷，页码 946–13960 ，2024年。

[108] C. Luo、J. Ji、Q. Wang、X. Chen 和 P. Li，《面向第五代无线通信的信道状态信息预测：一种深度学习方法》，IEEE 网络科学与工程汇刊，第 7 卷，第 1 期，第 227–236 页，2018年。[109] J. Yuan、H. Q. Ngo 和 M. Matthaiou，《考虑信道老化的大规模MIMO机器学习信道预测》，IEEE无线通信汇刊，第 19 卷，第 5 期，第 2960–2973 页，2020。[110] C. Eom 和 C. Lee，《基于混合神经网络的衰落信道预测与链路自适应》，IEEE Access，第 9 卷，第 117 257–117 266 页，2021年。[111] X. Shi、Z. Chen、H. Wang、D.-Y. Yeung、W.-K. Wong 和 W.-c. Woo，《卷积长短期记忆网络：一种用于降水临近预报的机器学习方法》，神经信息处理系统进展，第 28 卷，2015年。[112] M. Meliha、P. Charg´e、Y. Wang、S. E. Bouzid、C. Henry、C. Bourny、H. Tomaz 和 Y. Chen，《基于深度学习的信道预测与路径提取》，IEEE无线通信快报，2025年。[113] G. Liu、Z. Hu、L. Wang、J. Xue、H. Yin 和 D. Gesbert，《用于大规模 MIMO-OFDM 系统信道预测的时空神经网络》，IEEE通信汇刊，第 70 卷，第 12 期，第 8003–8016 页，2022年。[114] L. Yao、K. Ma、Y. Ming 和 Z. Wang，《通过损失函数融合提升基于学习的信道状态信息外推》，IEEE无线通信快报，2024年。[115] Y. Wan、A. Liu 和 T. Q. Quek，《5G NR 系统中用于信道外推的多用户导频模式优化》，IEEE无线通信汇刊，2025年。[116] Y. Wang、Y. Wang、H. Y. Park、M. Lee、W. Liu 和 M. Jing，《基于多模态异频信道外推（M-HCE）的 NR FDD 大规模 MIMO 系统信道状态信息重建》，载于 GLOBECOM 2023-2023 IEEE 全球通信大会。IEEE，2023年，第 7182–7187 页。[117] N. Jalden、H. Asplund 和 J. Medbo，《基于宽带 MIMO 测量的信道外推》，载于 2012年第六届欧洲天线与传播会议（EUCAP）。IEEE，2012年，第 442–446 页。[118] A. A. Tahat，《适用于 4G MIMO OFDM 系统的外推与插值矩阵方案》，载于 2010年 IEEE 第72届秋季车辆技术会议。IEEE，2010年，第 1–5 页。[119] M. B. Khalilsarai、S. Haghighatshoar、X. Yi 和 G. Caire，《通过上行/下行信道协方差外推和主动信道稀疏化实现 FDD大规模 MIMO》，IEEE无线通信汇刊，第 18 卷，第 1 期，第 121–135 页，2018年。[120] T. Choi、F. Rottenberg、J. Gomez-Ponce、A. Ramesh、P. Luo、C. J. Zhang 和 A. F. Molisch，《针对零反馈 FDD 的大规模 MIMO 频域信道外推实验研究》，IEEE无线通信汇刊，第 20 卷，第 1 期，第 710–725 页，2020。[121] F. Rottenberg、R. Wang、J. Zhang 和 A. F. Molisch，《FDD大规模MIMO中的信道外推：理论分析与数值验证》，载于 2019年 IEEE 全球通信大会（GLOBECOM）。IEEE，2019年，第 1–7 页。[122] Y. Wan 和 A. Liu，《面向 TDD 5G NR 系统的两阶段二维信道外推方案》，IEEE无线通信汇刊，2024年。[123] F. Rottenberg、T. Choi、P. Luo、C. J. Zhang 和 A. F. Molisch，《FDD大规模MIMO系统中信道外推的性能分析》，IEEE无线通信汇刊，第 19 卷，第 4 期，第 2728–2741 页，2020。[124] T. Choi、F. Rottenberg、J. Gomez-Ponce、A. Ramesh、P. Luo、J. Zhang 和 A. F. Molisch，《FDD大规模MIMO的信道外推：流程与实验结果》，载于 2019 年 IEEE 第 90 届车辆技术会议（ VTC2019-Fall ）。IEEE，2019 年，第 1–6 页。[125] O. W. Bhatti、N. Ambasana 和 M. Swaminathan，《设计空间与频率外推：神经网络的应用》，IEEE 微波杂志，第 22 卷，第 10 期，第 22–36 页，2021年。[126] Y. Yang、F. Gao、Z. Zhong、B. Ai 和 A. Alkhateeb，《基于深度迁移学习的FDD大规模MIMO系统下行信道预测》，IEEE通信汇刊，第 68 卷，第 12 期，第 7485–7497 页，2020。[127] B. Ko、H. Kim 和 J. Choi，《利用频率相关性的宽带大规模 MIMO 系统机器学习信道预测》，载于 2021年国际信息与通信技术融合会议（ICTC）。IEEE，2021年，第 1069–1071 页。

[128] Y. Yang, F. Gao, G. Y. Li, and M. Jian, “基于深度学习的下行链路信道预测，适用于FDD大规模MIMO系统,” IEEE通信快报，第23卷，第11期，第1994–1998页，2019年。 [129] A. Bakshi, Y. Mao, K. Srinivasan, and S. Parthasarathy, “利用机器学习进行快速高效的跨频段信道预测,” 载于第25届移动计算与网络年度国际会议，2019年，第1–16页。 [130] W. Jiang and H. D. Schotten, “基于循环神经网络的宽带通信频域信道预测,” 载于2019 IEEE第89届车辆技术会议（ VTC2019-Spring）。IEEE，2019年，第1–6页。 [131] S.-H. Noh, “循环神经网络梯度消失分析及性能比较,” Information，第12卷，第11期，第442页，2021年。 [132] P. Le and W. Zuidema, “量化递归神经网络和递归长短期记忆网络中的消失梯度与长距离依赖问题,” arXiv预印本 arXiv:1603.00423，2016年。 [133] M. Sasaki, N. Kuno, T. Nakahira, M. Inomata, W. Yamada, and T. Moriyama, “利用长短期记忆网络在2–26 GHz频段进行基于深度学习的信道预测,” 载于2021年第15届欧洲天线与传播会议（EuCAP）。IEEE，2021年，第1–5页。 [134] J. Joo, M. C. Park, D. S. Han, and V. Pejovic, “真实车载通信中的基于深度学习的信道预测,” IEEE Access，第7卷，第27 846–27 858页，2019年。 [135] M. Soszka, “面向第五代和第六代移动通信系统的衰落信道预测,” International Journal of Electronics and Telecommunications，第68卷，第1期，2022年。[136] Y. Zhang, A. Liu, P. Li, and S. Jiang, “基于深度学习（DL）的信道预测与混合波束成形，适用于低轨卫星大规模MIMO系统,” IEEE物联网期刊，第9卷，第23期，第23 705–23 715页，2022年。 [137] M. Arnold, S. D¨orner, S. Cammerer, S. Yan, J. Hoydis, and S. t. Brink, “通过基于深度学习的信道预测实现FDD大规模MIMO,” arXiv预印本 arXiv:1901.03664, 2019年。 [138] H. Choi and J. Choi, “利用提取的上行链路路径增益，通过神经网络对FDD多天线系统进行下行链路外推,” IEEE Access，第8卷，第67 100–67 111页，2020年。 [139] S. Fan, H. Li, X. Liang, Z. Liu, X. Gu, and L. Zhang, “E2ENet：一种基于上行导频、适用于FDD系统的端到端信道预测神经网络,” IEEE无线通信快报，第13卷，第5期，第1285–1289页，2024年。 [140] Y. Wang, Z. Gao, S. Chen, C. Hu, and D. Zheng, “混合场信道下，面向可重构智能表面辅助太赫兹大规模MIMO系统的基于深度学习的信道外推与多用户波束成形,” Intelligent Computing，第3卷，第0065页，2024年。 [141] M. Neuman, D. Burghal, and A. F. Molisch, “信道与系统参数对机器学习频率外推性能评估的影响,” IEEE Open Journal of the Communications Society, 2025年。 [142] X. Fan, Y. Zou, and L. Zhai, “智能反射面辅助毫米波多用户多输入单输出系统中的基于空间注意力的信道估计,” IEEE物联网期刊，第11卷，第6期，第9801–9813页，2023年。 [143] M. Robaei and R. Akl, “考察5G-NR中毫米波大规模MIMO信道估计的空间一致性,” 载于 2020 IEEE 国际消费电子会议（ ICCE ）。IEEE，2020 年，第 1–6页。 [144] A. C. Gurbuz, V. Cevher, and J. H. Mcclellan, “利用压缩感知和空间稀疏性进行方位估计,” IEEE Transactions on Aerospace and Electronic Systems，第48卷，第2期，第1358–1369页，2012年。 [145] S.-C. Lin, K. Chuang, C.-W. Chang, and J.-H. Chen, “ 面向无线通信与信号处理应用的高效插值方法,” IEEE Transactions on Microwave Theory and Techniques，第69卷，第5期，第2753–2761页，2021年。 [146] Y. Gao and T. Fujii, “威胁环境下基于克里金法的无线电环境地图构建与信道估计系统,” IEEE Access，第11卷，第38 136–38 148页，2023年。 [147] R. Hu, J. Tong, J. Xi, Q. Guo, and Y. Yu, “混合MIMO毫米波通信系统中基于降维的信道协方差矩阵估计,” Sensors，第19卷，第15期，第3368页，2019年。 [148] L. S. Muppirisetty, T. Svensson, and H. Wymeersch, “位置不确定条件下的空间无线信道预测,” IEEE无线通信汇刊，第15卷，第2期，第1031–1044页，2015年。 [149] Z. Gu, Y. Han, Q. Liu, C.-K. Wen, and S. Jin, “MIMO双极化信道外推：从理论到实验,” 载于2021 IEEE无线通信与网络会议（WCNC）。IEEE，2021年

，第1–6页。

[150] Y. Yang、S. Zhang、F. Gao、C. Xu、J. Ma 和 O. A. Dobre，“基于深度学习的天线选择：用于FDD大规模MIMO中的信道外推”，载于《2020年国际无线通信与信号处理会议》（WCSP）。IEEE，2020，页182–187。[151] M. Liang 和 A. Li，“用于可重构方向图大规模MIMO的基于深度学习的信道外推”，《IEEE车辆技术汇刊》，2023年。[152] X. Bao、W. Feng、J. Zheng 和 J. Li，“用于毫米波大规模MIMO系统的深度卷积神经网络与等效信道混合预编码”，《IEEE Access》，第8卷，页19 327–19 335，2020年。[153] J. Jiang、L. Lian、T. Yu、Q. Shi、S. Zhang、X. Chen 和 V. K. Lau，“一种面向空间非平稳衰落环境的新型双驱动信道估计方案”，《IEEE无线通信汇刊》，第23卷，第7期，页7027–7042，2023年。[154] L. Bai、C.-X. Wang、J. Huang、Q. Xu、Y. Yang、G. Goussetis、J. Sun 和 W. Zhang，“使用机器学习算法预测无线毫米波大规模MIMO信道特性”，《无线通信与移动计算》，第2018卷，第1期，第9783863页，2018年。[155] V. V. Ratnam、H. Chen、S. Pawar、B. Zhang、C. J. Zhang、Y.-J. Kim、S. Lee、M. Cho 和 S.-R. Yoon，“FadeNet：基于深度学习的毫米波大尺度信道衰落预测及其应用”，《IEEE Access》，第9卷，页3278–3290，2020年。[156] S. Zhang、S. Zhang、F. Gao、J. Ma 和 O. A. Dobre，“结合单元分组的基于深度学习的RIS信道外推”，《IEEE无线通信快报》，第10卷，第12期，页2644–2648，2021年。[157] Y. Gao、Y. Liu、R. Yu、S. Liu、Y. Jin、S. Zhang、S. Xu 和 X. Chu，“SSNet：由自监督学习框架支持的流体天线系统灵活且稳健的信道外推”，《IEEE通信领域精选期刊》，2025年10月，提前出版，doi:10.1109/JSAC.2025.3619472。[158] X. Wu、H. Zhang、C.-C. Wang 和 Z. Li，“基于掩码语言模型的流体天线系统信道状态信息外推”，载于《2024年IEEE国际通信会议研讨会》（ICC研讨会）。IEEE，2024年，页1383–1388。[159] T. Gong、S. Zhang、F. Gao、Z. Li 和 M. Di Renzo，“低分辨率模数转换器混合RIS辅助毫米波系统的基于深度学习的信道外推”，《IEEE无线通信汇刊》，2024年。[160] P. Hartman，《常微分方程》。SIAM，2002年。[161] M. Xu、S. Zhang、C. Zhong、J. Ma 和 O. A. Dobre，“用于RIS辅助通信信道外推的基于常微分方程的卷积神经网络”，《IEEE通信快报》，第25卷，第6期，页1921–1925，2021年。[162] R. T. Chen、Y. Rubanova、J. Bettencourt 和 D. K. Duvenaud，“神经常微分方程”，《神经信息处理系统进展》，第31卷，2018年。[163] J. R. Dormand 和 P. J. Prince，“ 一类嵌入式龙格 - 库塔公式 ”，《计算与应用数学杂志》，第6卷，第1期，页19–26，1980年。[164] L. Wang、G. Liu、J. Xue 和 K.-K. Wong，“利用常微分方程进行MIMO系统信道预测”，《IEEE车辆技术汇刊》，第72卷，第2期，页2111–2119，2022年。[165] H. Lu、Y. Zeng、C. You、Y. Han、J. Zhang、Z. Wang、Z. Dong、S. Jin、C.-X. Wang、T. Jiang等，“面向6G的近场超大规模MIMO通信教程”，《IEEE通信调查与教程》，第26卷，第4期，页2213–2257，2024年。[166] Y. Gao、Z. Zhang、H. Hu、X. Wang、Y. Jin 和 X. Chu，“基于含禁配对的匹配框架实现NR-U与WiGig网络间公平且高效的共存”，《IEEE车辆技术汇刊》，第72卷，第9期，页11 814–11 827，2023年。[167] L. Liu、H. Feng、T. Yang 和 B. Hu，“利用时空相关性进行MIMO-OFDM无线信道预测”，《IEEE无线通信汇刊》，第13卷，319，2013年1，310第期。[168] R. O. Adeogun、P. D. Teal 和 P. A. Dmochowski，“使用极化天线阵列进行窄带MIMO系统的参数化信道预测”，载于《2014年第79届IEEE车辆技术会议》（VTC春季会议）。IEEE，2014年，页1–5。[169] W. Li、H. Yin、Z. Qin 和 M. Debbah，“面向具有移动性的超大规模天线阵列的基于波前变换的近场信道预测”，《IEEE无线通信汇刊》，2024年。[170] H. Zhang、X. Zhang、X. Zhong 和 S. Zhou，“基于散射体粗糙度校准的信道相关矩阵外推”，arXiv预印本 arXiv:2409.10900，2024年。[171] X. Wang、Y. Wu、J.-Y. Chouinard、S. Lu 和 B. Caron，“一种使用频域导频、时域IEEE汇刊，第49卷，第4期，第949–957页，2003年。[172] Y. Zhang、A. Alkhateeb、P. Madadi、J. Jeon、J. Cho和C. Zhang，“面向高速移动大规模MIMO系统的未来信道状态信息反馈预测”，arXiv预印本 arXiv:2202.02492，2022年。[173] M. A. Khan、H. Kang、M. Awais和Y. H. Kim，“面向智能反射面辅助OFDM系统的深度去噪信道外推”，载于2023年第14届信息与通信技术融合国际会议（ICTC）。IEEE，2023年，第723–725页。[174] T. Gong、S. Zhang、M. Xu、Z. Li和O. A. Dobre，“基于轻量级时序卷积网络的RIS辅助通信时空信道外推”，IEEE车辆技术汇刊，2024年。[175] B. Liu、X. Liu、S. Gao、X. Cheng和L. Yang，“LLM4CP：将大语言模型用于信道预测”，arXiv预印本 arXiv:2406.14440，2024年。[176] F. Burmeister和N. Schwarzenberg，“时变环境下时变工业无线电信道数据集”，在线，2023年。

[177] [ ] 10 21227 87 在线。可访问：0 https://dx.doi.org/ 。 /htgs-jp F. Euchner和M. Gauger，“信道状态信息数据集 dichasus-cf x：工业环境中的分布式天线设置，第1天”，在线，2022年。 [在线]。可访问：https://doi.org/doi: 10 18419 2854 。 /darus- Y.

[178] Huangfu、J. Wang、S. Dai、R. Li、J. Wang、C. Huang和Z. Zhang，“WAIR-D：无线人工智能研究数据集”，arXiv预印本 arXiv:2212.02159，2022年。[179] A. Alkhateeb，“DeepMIMO：用于毫米波和大规模MIMO应用的通用深度学习数据集”，载于信息论与应用研讨会（ITA）论文集，美国加利福尼亚州圣迭戈，2019年2月，第1–8页。[180] X. Zhang、L. Zhong和A. Sabharwal，“面向FDD大规模MIMO的定向训练”，IEEE无线通信汇刊，第17卷，第8期，第5183–5197页，2018年。[181] X. Du和A. Sabharwal，“具有用户间角度相关性的大规模MIMO信道：开放访问数据集、分析与基于测量的验证”，IEEE车辆技术汇刊，第1 1页，2021 – 。[182] Z. Li、C.-X. Wang、J. Huang、W. Zhou和C. Huang，“用于6G无线信道预测的GAN-LSTM人工智能框架”，载于2022年IEEE第95届车辆技术会议：（VTC2022-Spring）。IEEE，2022年，第1–5页。[183] C.-X. Wang、Z. Lv、X. Gao、X. You、Y. Hao和H. Haas，“泛在无线信道建模理论及其在适用于所有频段和所有场景的6G几何基础随机模型中的应用”，IEEE车辆技术汇刊，第71卷，第9期，第9159–9173页，2022年。[184] C.-X. Wang、Z. Lv、Y. Chen和H. Haas，“6G泛在信道模型空时频统计特性的全面研究”，IEEE通信汇刊，2023年。[185] T. Lei和Z. Jian-hua，“IMT-2020信道模型标准概述”，北京邮电大学学报，第41卷，第5期，第62页，2018年。[186] J. Zhang、Z. Zhou、Y. Zhang、L. Tian、Z. Yuan和T. Jiang，“亚太赫兹频段RIS辅助通信的确定性信道建模方法”，将发表于2023年第17届欧洲天线与传播会议（EUCAP），2023年。[187] J. Zhang、Y. Zhang、Y. Yu、R. Xu、Q. Zheng和P. Zhang，“三维MIMO：从信道测量结果来看，它在多大程度上符合我们的预期？”，IEEE通信领域精选主题汇刊，第35卷，第8期，第1887–1903页，2017年。[188] H. Gong、J. Zhang、Y. Zhang、Z. Zhou和G. Liu，“如何将三维几何基础随机模型扩展至非理想相位调制的RIS级联信道？”，IEEE无线通信快报，2023年。[189] H. Poddar、S. Ju、D. Shakya和T. S. Rappaport，“NYUSIM教程：面向第五代、第六代及后续通信的亚太赫兹与毫米波信道仿真器”，IEEE通信调查与教程，第26卷，第2期，第824–857页，2023年。[190] F. A. Aoudia、J. Hoydis、M. Nimier-David、S. Cammerer和A. Keller，“Sionna RT：技术报告”，arXiv预印本 arXiv:2504.21719，2025年。[191] S. Jaeckel、L. Raschkowski、K. B¨orner和L. Thiele，“QuaDRiGa：具有时间演化功能、可用于虚拟现场试验的三维多小区信道模型”，IEEE天线与传播汇刊，第62卷，第6期，第3242–3256页，2014年。[192] F. Burkhardt、S. Jaeckel、E. Eberlein和R. Prieto-Cerdeira，“QuaDRiGa：用于陆地移动卫星的MIMO信道模型”，载于第8届欧洲天线与传播会议（EUCAP 2014）。IEEE，2014年，第1274–1278页。[193] H. Choi、J. Oh、J. Chung、G. C. Alexandropoulos和J. Choi，“WiTh-Ray：面向智能无线环境的多功能射线追踪仿真器”，IEEE Access，第11卷，第56 822–56 845页，2023年。

[194] V. Yazdnian和Y. Ghasempour，“NirvaWave：面向6G及后续通信的高精度、高效率近场波传播仿真器”，载于2025年IEEE无线通信与网络会议（WCNC）。IEEE，2025年，第1–7页。[195] Y. Koda和H. Harada，“基于京都大学信道生成器进行亚太赫兹链路级评估的用户指南”，Authorea预印本，2025年。[196] J. Jiang、W. Yu、Y. Gao和S. Xu，“MTCA：无线通信多任务信道分析”，arXiv预印本 arXiv:2502 18766，2025年。[197] J. Hoydis、F. Aït Aoudia、S. Cammerer、M. Nimier-David、N. Binder、G. Marcus和A. Keller，“Sionna RT：用于无线电传播建模的可微射线追踪”，载于2023年IEEE Globecom研讨会（GC Wkshps）。IEEE，2023年，第317–321页。[198] F. Z. Rozony、M. N. A. Aktar、M. Ashrafuzzaman和A. Islam，“异构数据源大数据集成的挑战与解决方案：系统综述”，《商业管理、创新与可持续发展学术期刊》，第4卷，第04期，第1–18页，2024年。[199] G. Kumar、S. Basri、A. A. Imam、S. A. Khowaja、L. F. Capretz和A. O. Balogun，“异构数据集的数据协调：系统性文献综述”，《应用科学》，第11卷，8275，2021年17，第。页。[200] C. Yang、Y. Xiao、Y. Zhang、Y. Sun和J. Han，“异构网络表示学习：包含综述与基准测试的统一框架”，IEEE知识与数据工程汇刊，第34卷，第10期，第4854–4873页，2020年。[201] N. Van Huynh、J. Wang、H. Du、D. T. Hoang、D. Niyato、D. N. Nguyen、D. I. Kim和K. B. Letaief，“面向物理层通信的生成式人工智能：综述”，IEEE认知通信与网络汇刊，2024年。[202] S. Bengesi、H. El-Sayed、M. K. Sarker、Y. Houkpati、J. Irungu和T. Oladunni，“生成式人工智能的进展：对生成对抗网络、GPT、自动编码器、扩散模型和Transformer的全面综述。”IEEE Access，2024年。[203] N. Pandeya、A. Haj-Omar、A. Dhananjay和M. Zappe，“在FR1和FR3频段基于USRP软件定义无线电实现的5G ORAN O-RU仿真器”，载于MILCOM 2024-2024 IEEE军事通信会议（MILCOM）。IEEE，2024年，第684–685页。[204] S. Seven、P. Rothana、S. Channareth、S. Sreypov、T. Brospov、T. Tevy、U. Sokoeun、R. Vannak和N. Sros，“使用USRP N210、GNU Radio和Raspberry Pi 5实现的低成本软件定义无线电频谱分析仪和无线电接收机”，载于2024年电气工程与计算机科学国际会议（ICECOS）。IEEE，2024年，第7–12页。[205] K. Mao、Q. Zhu、C.-X. Wang、X. Ye、J. Gomez-Ponce、X. Cai、Y. Miao、Z. Cui、Q. Wu和W. Fan，“无人机辅助通信的信道探测技术与测量综述”，IEEE仪器与测量汇刊，2024年。[206] Y. Qiu、X. Chen、K. Mao、X. Ye、H. Li、F. Ali、Y. Huang和Q. Zhu，“基于无人机辅助信道测量系统的信道知识图构建”，《Drones》，第8卷，191，2024年5，第。期。[207] K. Huang、S. Mu、J. Jiang、Y. Gao和S. Xu，“虚幻引擎即所需的一切：仅用一个引擎进行多模态通感一体化数据仿真”，arXiv预印本 arXiv:2507.08716，2025年。[208] Y. Liang、F. Huang、Z. Qiu、X. Shu、Q. Liu和D. Yuan，“基于不确定性与多样性的无人机跟踪主动学习”，《神经计算》，第130265页，2025年。[209] A. Roy、M. Saffar、A. Vaswani和D. Grangier，“通过路由Transformer实现高效的基于内容的稀疏注意力”，《计算语言学协会汇刊》，第9卷，第53–68页，2021年。[210] K. Choromanski、V. Likhosherstov、D. Dohan、X. Song、A. Gane、T. Sarlos、P. Hawkins、J. Davis、A. Mohiuddin、L. Kaiser等，“重新思考Performer中的注意力机制”，arXiv预印本 arXiv:2009 14794，2020年。[211] M. Sandler、A. Howard、M. Zhu、A. Zhmoginov和L.-C. Chen，“MobileNetV2：倒置残差与线性瓶颈”，载于IEEE计算机视觉与模式识别会议论文集，2018年，第4510–4520页。[212] M. Tan和Q. Le，“EfficientNet：重新思考卷积神经网络的模型缩放”，载于国际机器学习会议。PMLR，2019年，第6105–6114页。[213] Z. Lu、X. Wu、Y. Liu、Y. Gao、S. Zhang和S. Xu，“无人机对地通信中的联合信道外推与视距/非视距识别：一种多任务学习方法”，载于2025年IEEE/CIC中国通信国际会议（ICCC研讨会）。IEEE，2025年，第1–6页。[214] J. Du, H. Yan, A. Sun, C. Wang, Y. Gao, Z. Liu, 和 X. Chu, 《空天地一体化网络中公平性保证的联合接入控制、三维无人机轨迹规划与任务调度》，IEEE车辆技术汇刊，2025年。[215] B. Hu, W. Zhang, Y. Gao, J. Du, 和 X. Chu, 《面向通感一体化辅助的6G车联网的多智能体深度确定性策略梯度计算卸载与资源分配》，IEEE物联网期刊，2024年。[216] W. Jin, J. Zhang, C.-K. Wen, 和 S. Jin, 《毫米波MU-MIMO系统混合预编码的模型驱动深度学习》，IEEE通信汇刊，2023年。[217] J. Zhang, C.-K. Wen, L. Liang, 和 S. Jin, 《面向多输入多输出收发器设计的通用模型驱动深度学习》，IEEE通信杂志，2023年。[218] G. Li, H. Zhang, C. Wang, 和 B. Wang, 《大规模流体天线的模型驱动信道外推》，载于2024年IEEE国际通信会议研讨会（ICC研讨会）。IEEE，2024年，第1146–1151页。[219] X. Meng, C. Lin, Y. Wang, 和 Y. Zhang, 《Netgpt：用于网络流量的生成式预训练Transformer》，arXiv预印本 arXiv:2304.09513，2023年。[220] Y. Chen, R. Li, Z. Zhao, C. Peng, J. Wu, E. Hossain, 和 H. Zhang, 《NetGPT：超越个性化生成式服务供给的原生人工智能网络架构》，arXiv预印本 arXiv:2307.06148，2023年。[221] Y. Liu, Y.-H. Wu, G. Sun, L. Zhang, A. Chhatkuli, 和 L. Van Gool, 《具有分层注意力的视觉变换器》，《机器智能研究》，第21卷，第4期，第670–683页，2024年。[222] W. Fedus, B. Zoph, 和 N. Shazeer, 《Switch Transformers：通过简单高效的稀疏性扩展至万亿参数模型》，《机器学习研究期刊》，第23卷，第120期，第1–39页，2022年。[223] D. Lepikhin, H. Lee, Y. Xu, D. Chen, O. Firat, Y. Huang, M. Krikun, N. Shazeer, 和 Z. Chen, 《GShard：通过条件计算与自动分片扩展巨型模型》，arXiv预印本 arXiv:2006.16668，2020。[224] J. Moon, K. A. Ngo, B. Lee, 和 B. Shim, 《面向 6G 毫米波大规模天线系统的多模态感知辅助信道预测》，IEEE认知通信与网络汇刊，第1–1页，2025年6月。[225] Z. Xin, Y. Liu, J. Xing, J. Huang, J. Bian, 和 Y. Zhang, 《一种面向无人机通信的新型多模态融合感知信道预测方法》，IEEE物联网期刊，第12卷，第4期，第3948–3960页，2024年10月。[226] Z. Ren, L. Qiu, J. Xu, 和 D. W. K. Ng, 《大规模天线系统的感知辅助稀疏信道恢复》，IEEE车辆技术汇刊，第73卷，第11期，第17 824–17 829页，2024年7月。[227] J. He, Z. Ren, J. Yao, H. Hu, T. X. Han, 和 J. Xu, 《复杂无线环境中的感知辅助信道预测：一种基于大语言模型的方法》，arXiv预印本 arXiv:2505.09141，第1–1页，2025年8月。[228] Y. Jin, P. Qi, Y. Gao, 和 S. Liu, 《用于提高RIS辅助通信系统信道估计效率的双路径残差注意力网络》，《物理通信》，第68卷，文章编号102577，2025年。[229] T. Baltrušaitis, C. Ahuja, 和 L.-P. Morency, 《多模态机器学习：综述与分类体系》，IEEE模式分析与机器智能汇刊，第41卷，第2期，第423–443页，2018年。[230] Y. Han, S. Jin, M. Matthaiou, T. Q. Quek, 和 C.-K. Wen, 《迈向超大规模多输入多输出：新的信道特性与低成本设计》，IEEE物联网期刊，第10卷，14 594，2023年16，14 569 no. pp. – 。[231] G. Sun, R. He, B. Ai, Z. Ma, P. Li, Y. Niu, J. Ding, D. Fei, 和 Z. Zhong, 《可重构智能表面辅助多输入多输出通信的三维宽带信道模型》，IEEE车辆技术汇刊，第71卷，第8期，第8016–8029页，2022年。[232] K.-K. Wong, A. Shojaeifard, K.-F. Tong, 和 Y. Zhang, 《流体天线系统》，IEEE无线通信汇刊，第20卷，第3期，第1950–1962页，2020年。[233] E. Basar, M. Di Renzo, J. De Rosny, M. Debbah, M.-S. Alouini, 和 R. Zhang, 《通过可重构智能表面实现无线通信》，IEEE Access，第7卷，第116 753–116 773页，2019年。[234] Y. Gao, Y. Zhang, Y. Jin, D.-K. Wu, 和 W. Yang, 《星上处理多网关卫星通信中稀疏码多址的和速率最大化》，《物理通信》，第69卷，文章编号102613，2025年。[235] W. U. Khan, M. A. Jamshed, E. Lagunas, S. Chatzinotas, X. Li, 和 B. Ottersten, 《不完美信道状态信息下反向散射增强的NOMA协作式车联网通信能效优化》，IEEE智能交通系统汇刊，第24卷，第11期，第12 961–12 972页，2022年。

[236] Y. Xu、M. Wang、H. Zhang、Q. Xue、J. Kang、Q. Chen 和 C. Yuen，《不完美 SIC 和信道状态信息下基于 RSMA 的共生无线电系统资源分配》，*IEEE*车辆技术汇刊，2024年。[237] B. Hu、Y. Gao、M. L´opez-Ben´ıtez、J. Du、J. Zhang 和 X. Chu，《无人机辅助卫星网络系统中的计算卸载与资源分配》，载于*2024*年*IEEE/CIC*中国国际通信大会（*ICCC*）。IEEE，2024年，第382–387页。[238] Z. Wu、S. Pan、F. Chen、G. Long、C. Zhang 和 P. S. Yu，《图神经网络综合综述》，*IEEE*神经网络与学习系统汇刊，第32卷，第24期，2020年，第1、4页。[239] L. Bai、Q. Xu、Z. Huang、S. Wu、S. Ventouras、G. Goussetis 和 X. Cheng，《一种结合特征选择的大气数据驱动Q波段卫星信道模型》，*IEEE*天线与传播汇刊，第70卷，第6期，第4002–4013页，2021年。