

浅析基于AI的信道信息预测在6G中的应用



Application of AI-Based Channel Information Prediction in 6G

肖华华/XIAO Huahua^{1,2,3}, 鲁照华/LU Zhaohua^{2,3},
胡留军/HU Liujun^{2,3}

(1. 北京交通大学, 中国 北京 100044;
2. 中兴通讯股份有限公司, 中国 深圳 518057;
3. 移动网络和移动多媒体技术全国重点实验室, 中国 深圳 518055)
(1. Beijing Jiaotong University, Beijing 100044, China;
2. ZTE Corporation, Shenzhen 518057, China;
3. State Key Laboratory of Mobile Network and Mobile Multimedia
Technology, Shenzhen 518055, China)

DOI: 10.12142/ZTETJ.202403002

网络出版地址: <http://kns.cnki.net/kcms/detail/34.1228.TN.20240619.1517.014.html>

网络出版日期: 2024-06-20

收稿日期: 2024-04-16

摘要: 深入探讨了基于AI的信道信息预测在6G通信系统中的应用, 并从信道信息预测的信道模型、信道信息预测方案、数据收集方法、模型监控技术、仿真验证结果, 以及基于AI的信道信息预测所面临的机会与挑战这6个维度展开分析。在信道信息预测方案的分析中, 广泛探索了多种信道信息预测策略; 在数据收集方面, 详细分析了不同参考信号传输类型及数据收集范围的影响; 在模型监控方面, 讨论了3种可能的监控方式。此外, 通过仿真验证, 充分展示了基于AI的信道信息预测技术的有效性和优越性。

关键词: 多输入多输出; 信道信息预测; 人工智能; 模型监控; 模型训练

Abstract: The application of AI-based channel information prediction in the 6G communication system is deeply discussed from the following six dimensions: the channel model of channel information prediction, the channel information prediction scheme, the data collection method, the model monitoring technology, validation results, and opportunities and challenges of AI-based channel information prediction. In the analysis of channel information prediction schemes, various channel information prediction strategies are widely explored; in the data collection section, the influence of different reference signal transmission types and data collection ranges is analyzed in detail; in the model monitoring, three possible monitoring methods are discussed. In addition, the effectiveness and superiority of AI-based channel information prediction technology are presented through simulation verification.

Keywords: multi-input multi-output; channel information prediction; artificial intelligence; model monitoring; model training

引用格式: 肖华华, 鲁照华, 胡留军. 浅析基于AI的信道信息预测在6G中的应用 [J]. 中兴通讯技术, 2024, 30(3): 3-9. DOI: 10.12142/ZTETJ.202403002

Citation: XIAO H H, LU Z H, HU L J. Application of AI-based channel information prediction in 6G [J]. ZTE technology journal, 2024, 30(3): 3-9. DOI: 10.12142/ZTETJ.202403002

随着无线通信技术的飞速发展, 特别是6G时代的来临, 业界对通信速率和传输网络可靠性的要求日益提高^[1]。与此同时, 人工智能 (AI) 技术也在不断进步, 其影响力已渗透至各个领域, 包括智能家居、自动驾驶汽车、医疗诊断、金融投资等。在通信领域, AI同样展现出了巨大的潜力和价值。在未来的无线通信技术中, AI技术的应用得到了业界广泛的关注和研究^[2-5]。AI技术与无线通信技术相互融合、相互促进将是一种趋势。

多天线技术^[6]是提升无线通信系统传输速率的关键技术之一。但要充分发挥多天线技术的优势, 需要在发送端获得

准确的信道信息, 其中信道信息包括信道状态信息 (CSI)、信道矩阵、特征向量等。特别是在基于频分复用的系统中, 获取准确的信道信息成为了多天线技术的核心要点。然而, 无线通信中的信道常常受到多径效应、阴影衰落、多普勒频移等多种因素的影响, 是一种时变的信道。这给无线通信系统的调度带来了挑战。为了应对这一挑战, 一种有效的方法是利用历史信道信息预测未来的信道信息。通过信道信息预测, 人们可以了解未来信道信息变化趋势, 并且通信系统可以根据预测的信道信息提前进行调度, 以便在数据传输前做出相应的调整和优化, 从而确保数据传输的可靠性和效率,

提高了网络性能、优化资源分配并确保服务质量。

传统的信道信息预测方法主要依赖于复杂的数学模型和信号处理算法，但在面对高速移动、高密度部署和复杂多变的通信环境时，这些信道信息预测方法的预测性能和鲁棒性常受到限制。随着6G时代的到来，网络密度的增加、数据速率的提升和传输时延的降低都对信道信息预测提出了更高的要求。传统的信道信息预测方法在性能上难以满足要求，而基于AI的信道信息预测技术^[2]则能够利用大数据和深度学习算法，自适应地学习和挖掘信道状态变化的内在规律，实现更为准确和高效的信道信息预测。通过基于AI的信道信息预测，6G网络可以更加精准地预测信道信息的变化，从而提前进行资源分配和传输策略调整，确保数据传输的高效性和可靠性。

本文旨在详细探讨基于AI的信道信息预测在6G通信系统中的应用，并从6个方面探讨AI在6G信道信息预测中的应用：信道模型简述、信道信息预测方案分析、信道信息预测的数据收集、信道信息预测的模型监控、信道信息预测的仿真验证，以及基于AI的信道信息预测面临的机会与挑战。

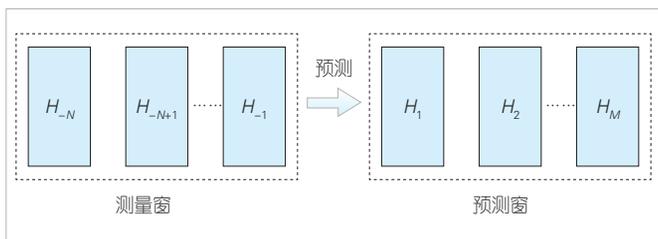
1 信道模型介绍

在一个多输入多输出的无线通信系统中，信道信息预测是关键技术之一。如图1所示，信道信息预测通常需要在测量窗口获得 N 个历史信道信息 $\{H_{-N}, H_{-N+1}, \dots, H_{-1}\}$ ，并且通过信道信息预测技术预测 M 个未来的信道信息 $\{H_1, H_2, \dots, H_M\}$ 。

这个过程可以表述为：

$$H_1, H_2, \dots, H_M = f(H_{-N}, H_{-N+1}, \dots, H_{-1}), \quad (1)$$

其中， H_i 为信道信息，是 $N_r \times N_t \times N_b$ 的复数矩阵， N_r 、 N_t 、 N_b 分别表示接收天线数目、发送天线数目、子载波数目/时域符号数。这里，当 $i=-N, \dots, -1$ 时， H_i 表示历史信道信息，一般在测量窗口中测量 M 个参考信号获得；当 $i=1, \dots, M$ 时， H_i 表示预测的信道信息，它一般根据测量窗口的 N 个历史信道信息预测获得。其中， f 表示信道信息预测过程，可以为基于人工智能的神经网络，也可以为维纳滤波或者卡尔曼滤波等。



▲图1 信道信息预测示意图

2 信道信息预测方案

2.1 信道信息预测的模型类型

信道信息预测是一项依赖于 N 个历史信道信息预测未来 M 个信道信息的任务，这些信道信息具有时间相关性，因此循环神经网络^[2]如循环神经网络（RNN）、长短期记忆网络（LSTM）、门控循环单元网络（GRU）、Transformer等可以用于信道信息预测。

模型部署位置（基站侧或终端侧）会影响反馈的信道状态信息内容、反馈开销、参考信号设计以及模型管理策略等。基于部署位置的不同，信道信息预测模型可分为3种类型：基站侧模型、终端侧模型以及双边模型。

1) 基站侧模型

此类模型部署于基站。基站发送参考信号，终端接收并测量所述参考信号，从而获取并反馈历史信道信息给基站。基站接收终端反馈的历史信道信息预测未来的信道信息。基站通常有全局视野和强大的数据处理能力，可以运行复杂模型以提高信道信息的预测精度。该模型需要量化反馈历史信道信息，从而影响模型输入精度。此外，由于需要反馈大量的历史信道信息，该模型对网络基础设施有较大的依赖，可能导致延迟和带宽限制。

2) 终端侧模型

此类模型直接在终端运行。终端通过测量获得历史信道信息后直接进行信道信息预测，无须反馈历史信道信息给基站，这减少了反馈开销且保证了输入数据的高精度。然而，终端的多样性和算力水平的差异可能导致模型复杂度和预测精度有所不同。

3) 双边模型

该模型包括两部分：一部分部署于终端，另外一部分部署于基站。终端进行低精度的信道信息预测，并将结果反馈给基站。基站接收低精度信息并进行高精度恢复。这种方法结合终端和基站的优点，但要求基站和终端均支持AI，且终端侧模型的多样性对基站侧模型的泛化能力提出了挑战。

表1总结了上述3种模型的优缺点，以便更直观地比较和选择适合的模型类型。

2.2 模型输入数据的形式分析

信道信息预测模型的输入主要包括3种形式：原始信道信息、信道信息对应的特征向量、信道信息对应的码本。

1) 原始信道信息

这种方式直接采用信道测量的原始数据进行预测，完整

▼表1 3种信道信息预测的模型优缺点总结

	基站侧模型	终端侧模型	双边模型
模型位置	基站	终端	基站和终端
算力水平	高,可以实现高性能的预测模型	低,一般实现简单低性能的预测模型	终端侧低、基站侧高
输入的信道信息精度	低	高	高
信道信息预测精度	低	高	中
反馈开销大小	高	低	低
标准影响	可实现标准透明	可能对参考信号配置和模型监控有影响	可能对参考信号配置和模型监控、CSI反馈等有影响

CSI:信道状态信息

保留了信道信息。其显著优势在于信息全面,有利于预测精度的提升。然而,原始信道信息的数据维度通常较大,可能导致模型训练的复杂度和计算成本、存储成本显著增加。考虑到反馈原始信道信息的开销巨大,这种方式更适合用于终端侧模型。

2) 信道信息对应的特征向量

此方式通过提取信道信息的特征向量,将高维的原始数据转化为低维的特征向量作为模型输入,例如,在频域上一个子带(通常包含数十个子载波)对应一个特征向量。这种方法有效降低了数据维度,减少了计算复杂度。然而,特征提取过程中可能伴随部分信道特征信息的损失,进而对信道信息预测精度产生一定影响。由于反馈特征向量的开销也不容忽视,这种方式同样更适合终端侧模型。如果要用于基站侧模型,则需要进一步研究高效反馈特征向量的方法。

3) 信道信息对应的码本

此方式将信道信息或者信道信息对应的特征向量编码为离散的码本形式,有利于信道信息的反馈。其优势在于显著降低了数据的存储和传输资源开销。然而,码本表示不可避免地会引入量化误差,对预测精度造成一定影响。由于反馈开销得到了有效降低,这种方式可以灵活应用于基站侧模型或双边模型。

表2对上述模型输入方式进行了总结。

2.3 模型输入和输出分析

模型输入和输出的大小主要基于预测需求及数据集的特性。输入的信道信息个数越多,模型便能捕获到更多有用信息,进而提高预测精度。然而,随着输入数据量的增长,模型的计算复杂度和训练时长也会相应攀升。输出信道信息的数量则受到模型预测能力、不同时隙信道间的相关性、预测时间范围及预测步长等多重因素影响。在实际操作中,需结合具体需求和数据集特性,确定合适的输入输出规模。

当预测信道信息个数 M 大于1时,通常存在两种预测方式:直接预测与迭代预测。

1) 直接预测

直接预测法通过模型一次性输出 M 个预测信道信息,比如使用 N 个历史信道信息 $\{H_{-N}, H_{-N+1}, \dots, H_{-1}\}$ 直接预测得到 M 个预测信道信息 $\{H_1, H_2, \dots, H_M\}$ 。此方法简单直观,能快速获取多个预测结果。然而,由于输出维度较大,模型的复杂度会随着 M 的增加而线性上升。

2) 迭代预测

迭代预测法则采用逐步推进的方式。首先,利用 N 个历史信道信息 $\{H_{-N}, H_{-N+1}, \dots, H_{-1}\}$ 预测第1个信道信息 H_1 ; 随后,将 H_1 加入历史信息集合,用更新后的集合 $\{H_{-N+1}, \dots, H_{-1}, H_1\}$ 预测第2个信道信息 H_2 ; 以此类推,直至完成所有 M 个信道信息的预测。这种方法的优势在于能利用先前的预测结果优化后续预测,可提高预测精度。模型的复杂度主要取决于输入大小,与输出信道信息个数 M 无关。然而,迭代过程可能导致误差累积,尤其在长期预测中,误差可能逐渐放大。

因此,在选择预测方案时,需综合考虑具体需求、数据特性及模型复杂度等因素。对于短期预测或高精度要求的场景,直接预测法可能更为合适;而对于长期预测或精度要求相对较低的情况,迭代预测法则不失为一个可考虑的选择。

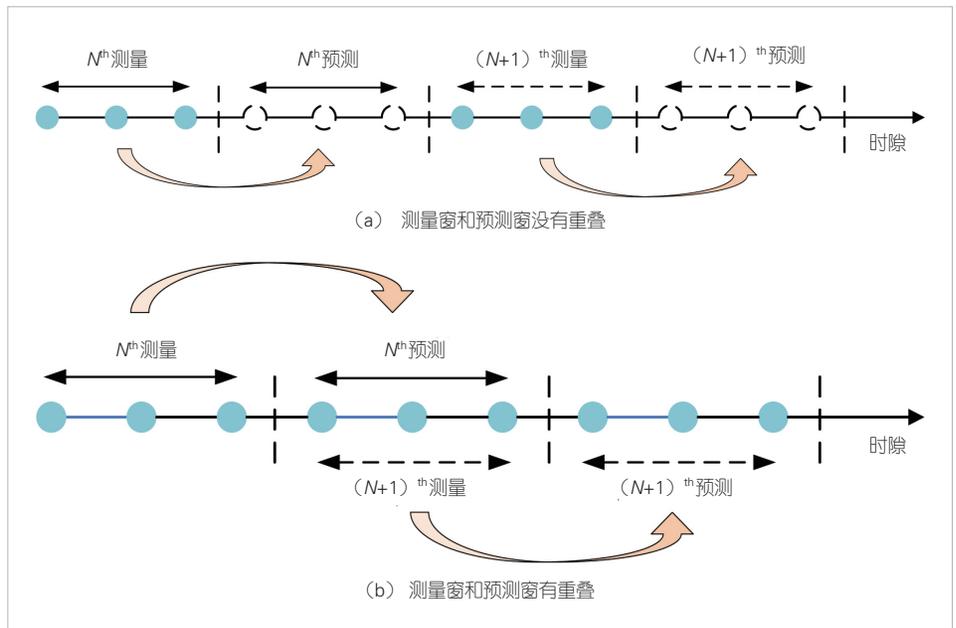
3 信道信息预测的数据收集

数据收集在模型训练过程中扮演着至关重要的角色,对模型的性能、泛化能力产生重要影响。在机器学习和人工智能领域,高质量的数据集是训练出高效、可靠模型的

▼表2 3种输入数据形式的优缺点总结

输入形式	原始信道信息 H H 对应的特征向量		H 对应的码本
适用的模型类型	终端侧模型	终端侧模型	基站侧模型和双边模型
模型复杂度	高	中	中
模型输入的数据精度	高	中	低
数据存储开销	大	中	小
信道信息预测精度	高	中	低
反馈开销	极高	高	低

基石。数据收集的数量和质量直接决定模型训练的效果。更多的数据可以提供更多的特征和模式信息，这使得模型能够更好地学习数据的内在规律和关联。同时，数据的多样性也是至关重要的，它能够增强模型的泛化能力，使其在面对新数据时能够做出更准确的预测。数据收集的精准性对于模型训练同样具有重要意义。精准的数据集可确保模型学习到的是与目标任务紧密相关的特征，从而避免引入无关噪声或偏差。这有助于提升模型的性能，使其在特定任务上达到更高的准确率。



▲图2 两种参考信号的传输方式示意图

3.1 参考信号的设计

为了积累足够多且质量高的信道信息预测数据集，基站需要在特定时间段内发送参考信号。通常，根据时域特性的不同，参考信号被划分为3类：周期参考信号、半持续参考信号以及非周期参考信号。其中，周期参考信号每隔固定时隙 T 发送一次；半持续参考信号同样每隔 T 时隙发送，但仅限于激活和去激活期间；非周期参考信号则通过物理层信令触发后进行发送，可以是单次触发单次发送，也可以是按照标准规定次数发送。

为获得丰富多样的样本，我们需要在一段足够长的时间里，收集不同时间和位置的信道信息。设定一个起始时隙，每 $N+M$ 个连续周期上的参考信号组成一组数据。其中，前 N 个参考信号位于测量窗口，用于捕获历史信道信息；随后的 M 个参考信号位于预测窗口，在训练数据中用于获取标签，而在模型推理时，这部分预测窗口的参考信号无须传输。

参考信号的传输方式有两种可能的模式^[7]。第一种如图2 (a) 所示，第 N 组参考信号的测量窗口与预测窗口完全不重叠。这种方式在收集模型推理所需数据时，能有效减少导频的开销，但在收集训练数据时，由于需要收集标签数据，因此并不能节省参考信号的开销。第2种方式如图2 (b) 所示，第 $N+1$ 组参考信号的测量窗口与第 N 组参考信号的预测窗口存在部分重叠。由于这种方式的参考信号会持续发送，因此无法在收集模型推理数据时节省导频开销。然而，在收集训练数据时，这种重叠方式能够有效减少参考信号的开销。

在选择传输方式时，需根据实际应用场景和需求进行权

衡，以达到最佳的数据收集效率和模型性能。

3.2 数据收集的范围

基于AI的信道信息预测，用于信道信息预测的模型存在不同的应用范围，包括适用于整个小区范围的通用模型和特定于单一小区的专用模型。这两类模型有各自的优势与不足。通用模型因其良好的泛化能力，可以广泛用于不同小区的用户。为训练此类模型，数据收集者需收集涵盖多个小区的数据集，因此通常需要较大的数据集，模型构建也相对复杂。然而，其显著优势在于，当用户在不同小区切换时，无须切换模型，这极大提升了模型使用的便捷性，比较适合终端侧模型。相对地，小区专用模型则专为特定小区用户设计。在训练此类模型时，数据收集者仅需收集该小区的数据集，因此所需数据量较小，模型构建也更为简单。然而，当用户在小区切换时，必须同时切换模型，这在一定程度上增加了小区切换的复杂性。如果模型推理在终端侧，则在用户进行小区切换时，需要从基站下载模型。我们将通用模型和专用模型特点在表3中做了总结。

综上所述，选择使用通用模型还是专用模型，需根据实际应用场景和需求进行权衡。

4 信道信息预测的模型监控

4.1 模型监控的意义

由于用户在移动过程中可能存在的阴影衰落、阻挡物体改变、离基站的距离改变等因素，无线信道会随时间发送而

▼表3 通用模型和专用模型的特点比较

模型作用域	泛化能力	使用范围	数据集范围	模型复杂度	模型类型
小区通用模型	强	不同小区用户	不同小区的数据集	一般较高	终端侧模型
小区专用模型	弱	单一小区用户	单一小区的数据集	一般较低	基站侧模型

变化。这种变化可能导致先前性能良好的模型在适应新的信道环境时性能下降。也就是说，一个模型在某一时刻可能表现优异，但随着时间推移和无线信道的改变，其推理性能有可能逐渐减弱。因此，我们需要设计一套机制来实时监控模型的性能。一旦发现模型性能下滑，我们可以迅速采取行动，切换到更合适的模型或传统的信道信息预测方法。这样的性能监控流程与模型监控方法对于确保通信质量和效率至关重要。通过监控，我们能够及时发现模型存在的问题以及性能下降的趋势，从而采取相应的措施进行调整和优化，避免通信故障和性能下降对用户体验造成不利影响。

4.2 模型监控的方法

一般来说，基站侧的模型监控比较简单，只需要终端反馈一些模型性能参数就可以实现。而终端侧的模型则稍微复杂一些，主要包括3种可能的监控方法。

1) 基站侧进行监控

在该方法中，终端将预测的信道信息和预测窗测量的标签信道信息发送给基站。基站利用这些信道信息计算模型性能参数，并据此判定现有模型是否有效。随后，基站将判决结果发送给终端，用于终端的模型选择/切换等。此方法的优点在于基站具有全局视野，能够更准确地评估模型性能；缺点是需要消耗额外的通信资源来传输信道信息和判决结果。

2) 终端侧进行监控

在此方法中，终端获取预测的信道信息和预测窗测量的标签信道信息，并计算网络性能特征以判定模型的有效性。这种方法无须与基站通信，减少了通信资源开销。然而，终端可能受限于其计算能力和存储空间，对模型性能的评估可能不够准确。一般来说，在主流的无线通信协议中，一般都是基站具有主导权，以避免一些恶意终端的恶意操作行为。这种监控方法容易造成终端不受基站控制的情况。

3) 终端和基站共同监控

在该方法中，终端同样计算模型性能参数，但自己不决定模型的性能好坏，而是将模型性能参数反馈给基站。基站根据接收的模型性能参数判定模型的有效性，并将判决结果发送给终端。这种方式结合了前两种方法的优点，既利用了基站的全局视野，又减少了不必要的通信资源开销。

综上所述，每种监控方法都有其独特的优缺点。终端厂

商比较倾向于终端侧监控方法，而基站厂商则更倾向于基站自主可控的方案。在6G的研究中，需要根据标准影响、产业链等因素全盘研究和充分讨论。

5 信道信息预测的仿真

在前面的章节中，我们详细探讨了基于AI的信道信息预测所涉及的模型类型、用于模型训练或监控的数据收集、模型监控方案等关键环节。在本节中，我们将从仿真的视角出发，验证基于AI的信道信息预测的性能优势。

在众多模型中，LSTM^[2]作为一种特殊的RNN，因其引入了门控机制和记忆单元，成功解决了传统RNN在处理长序列时遇到的梯度消失和爆炸问题。在信道信息预测中，LSTM模型能够精准捕捉信道信息的时序依赖关系，进而实现对未来信道状态的预测。与此同时，Transformer模型在捕捉全局依赖关系和并行计算方面展现出显著优势。它通过自注意力机制学习信道信息之间的关联，从而实现对未来信道信息的预测。然而，相对于LSTM模型，基于Transformer的模型在参数数量和计算复杂度上较高，因此要求基站或终端具备更强的计算能力。

鉴于此，本仿真实验主要聚焦于LSTM网络，并采用了简单的两层网络结构。作为对比基线，我们采用了大多数公司在3GPP RAN1中使用的方案^[3-4,8-11]，即仅使用最近一个历史时隙的信道信息作为预测的信道信息。通过仿真对比，我们可以更直观地展示基于AI的信道信息预测的性能优势，并为实际应用提供有力支持。

5.1 仿真条件介绍

我们进行了一系列仿真，从不同的角度来验证基于AI的信道信息预测的性能。在仿真中，我们收集了3GPP 38.901^[11]中密级城区宏基站的信道数据。发送天线配置为32天线(8,8,2,1,1,2,8)，接收天线为4根(1,2,2,1,1,1,2)。带宽为10 MHz(52个物理资源块)，载波间距为15 kHz，100%室外用户，且移动速度为30 km/h，参考信号的周期为5 ms。AI模型相关的参数见表5所示。

5.2 仿真结果

在表6中，我们用4个历史信道信息预测未来1个预测

信道信息。其中，预测的信道信息距离最后一个历史信道信息的时间为 P ，模型的输入为原始信道信息矩阵 \mathbf{H} ，模型的输出为预测的信道信息矩阵 \mathbf{H}' 。

在表7中，我们用10个历史信道信息预测1个预测信道信息。其中，预测信道信息距离最后一个历史信道信息的时间为 P ，模型的输入为原始信道信息矩阵 \mathbf{H} ，模型的输出为预测信道信息矩阵 \mathbf{H}' 。

在表8中，我们用10个历史信道信息预测1个预测信道信息。其中，预测信道信息距离最后一个历史信道信息的时间为 P ，模型的输入为原始信道信息对应的特征向量 \mathbf{V} ，模型的输出为预测信道信息对应的特征向量 \mathbf{V}' 。

▼表5 信道信息预测模型的训练相关参数

参数	取值
模型	LSTM
参数类型	实数
模型输入数据形式	原始信道信息或特征向量
模型输入大小	$T_1 \times 2 \times N_i \times N_r \times N_b$ 其中, T_1 为测量窗大小
模型输出大小	$T_2 \times 2 \times N_i \times N_r \times N_b$ 其中, $T_2=1$ 为预测窗大小
训练数据集	80 000
验证数据集	5 000
测试数据集	5 000
Batch大小	200
优化器	Adam
损失函数	MSE
性能指标	SGCS和NMSE ^[8]

LSTM: 长短期记忆网络
MSE: 均方误差
NMSE: 归一化均方差
SGCS: 平方余弦相似度

▼表6 测量窗口为4且输入和输出为信道矩阵的仿真结果

SGCS	$P=5$ ms	$P=10$ ms	$P=15$ ms	$P=20$ ms
AI(SGCS)	0.956 9	0.814 9	0.774 8	0.748 1
Legacy(SGCS)	0.799 9	0.749	0.728 8	0.718 2
AI(NMSE)	-9.080	-3.891	-3.086	-2.715
Legacy(NMSE)	-3.726	-2.752	-2.489	-2.343

AI: 人工智能
NMSE: 归一化均方差
SGCS: 平方余弦相似度

▼表7 测量窗口为10且输入和输出为信道矩阵的仿真结果

SGCS	$P=5$ ms	$P=10$ ms	$P=15$ ms	$P=20$ ms
AI(SGCS)	0.991 5	0.918 4	0.820 0	0.792 7
Legacy(SGCS)	0.799 2	0.749 4	0.731 0	0.720 4
AI(NMSE)	-14.76	-7.017	-3.935	-3.516
Legacy(NMSE)	-3.512	-2.769	-2.579	-2.386

AI: 人工智能
NMSE: 归一化均方差
SGCS: 平方余弦相似度

5.3 仿真结果总结

从表6和表7可以看出，测量窗口为10的信道信息预测性能远好于测量窗口为4的信道信息预测性能，即更多的历史信道信息的输入，有利于提高信道信息预测的性能。

从表7和表8可以看出，对于都是测量窗口为10的信道信息预测，输入数据为原始信道信息矩阵的性能远好于输入数据为特征向量的性能。这主要是因为，对原始信道矩阵做特征值分解可能会丢失一部分信道特征，这可能导致不同时隙的信道信息的相关性会相应减小。

6 机会和挑战

基于人工智能的信道信息预测技术为无线通信领域带来了前所未有的机会。

首先，AI技术具有强大的学习和分析能力，能够深入挖掘信道信息的内在规律和变化趋势。通过对历史数据的训练和学习，AI模型能够提高信道信息预测精度，实现对未来信道信息的准确预判。这有助于通信系统提前做出适应性调度，优化资源配置，提高传输效率。

其次，基于AI的信道信息预测技术可以实现个性化服务。不同用户、不同场景下的信道特性可能存在差异，AI模型可以通过学习不同用户的通信习惯和环境特点，为不同用户提供更加精准的信道预测服务。这有助于提升用户体验，满足多样化的通信需求。

最后，随着5G、6G等新一代通信技术的不断发展，信道信息预测技术将成为实现高速、低时延、大连接等目标的关键技术之一。基于AI的信道信息预测技术可以与其他通信技术相结合，比如基于AI的信道信息压缩和信道信息预测相融合的技术、基于AI的历史位置预测用户的位置信息，并将位置信息生成信道信息的技术等，共同推动无线通信系统的性能提升和创新应用。

然而，基于人工智能的信道信息预测技术也面临着一些挑战。

首先，数据的质量和数量对AI模型的性能至关重要。在实际应用中，获取大量高质量的信道信息数据往往是一项

▼表8 测量窗口为10且输入和输出为特征向量的仿真结果

SGCS	$P=5$ ms	$P=10$ ms	$P=15$ ms	$P=20$ ms
AI(SGCS)	0.844 4	0.767 6	0.746 0	0.732 9
Legacy(SGCS)	0.799 3	0.749 4	0.731 0	0.720 4
AI(NMSE)	-5.088	-3.833	-3.536	-3.355
Legacy(NMSE)	-3.521	-2.773	-2.581	-2.387

AI: 人工智能
NMSE: 归一化均方差
SGCS: 平方余弦相似度

艰巨的任务。数据的缺失、噪声和不平衡等问题都可能影响模型的训练效果和预测精度。

其次，模型的复杂度和计算量也需要考虑。为了获得更好的预测性能，AI模型通常有较高的复杂度，这可能导致计算资源的消耗增加。如何在保证预测精度的同时降低模型的复杂度和计算量，是一个需要解决的技术难题。

最后，无线信道环境的复杂性和动态性也给信道信息预测带来了挑战。信道环境可能受到多种因素的影响，如多径效应、干扰、移动性等。这些因素可能导致信道信息的快速变化，使得预测变得更加困难。因此，如何设计能够适应复杂多变环境的AI预测模型，是另一个需要面对的挑战。

综上所述，基于AI的信道信息预测技术既带来了不错的技术机会，也面临着诸多挑战。通过不断的研究和创新，我们可以克服这些困难，充分发挥AI在信道信息预测中的潜力，为无线通信系统的性能提升和创新应用做出贡献。

7 结束语

本文中，我们深入剖析了基于AI的信道预测在6G中的应用，并从信道模型、预测方案、数据收集、模型监控、仿真验证等多个维度进行了全面探讨。我们探索了多种预测策略，分析了不同数据收集方法的影响，并讨论了多种模型监控方式。通过仿真验证，我们充分展示了AI在信道信息预测中的优势。这一系列研究为6G中信道信息预测的应用奠定了坚实基础。

致谢

感谢中兴通讯股份有限公司算法部魏兴光、李伦、李永、刘文丰对本研究的大力支持！

参考文献

- [1] IMT-2030(6G)推进组. 6G总体愿景与潜在关键技术白皮书 [R]. 2021
- [2] IMT-2030(6G)推进组. 无线AI技术研究报告(第2版) [R]. 2022
- [3] 3GPP. New WID on artificial intelligence (AI)/machine learning (ML) for NR air interface, qualcomm (moderator): RP-234039 [S]. 2023

- [4] 3GPP. Study on artificial intelligence (AI)/machine learning (ML) for NR air interface (Release 18): TR 38.843 V1.3.0 [S]. 2023
- [5] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback [J]. IEEE wireless communications letters, 2018, 7(5): 748-751. DOI: 10.1109/lwc.2018.2818160
- [6] XU B K, WANG Z, XIAO H H, et al. Low-complexity precoding for extremely large-scale MIMO over non-stationary channels [C]// Proceedings of ICC 2023-IEEE International Conference on Communications. IEEE, 2023: 6516-6522. DOI: 10.1109/icc45041.2023.10279327
- [7] ZTE. Discussion on specification support for AI/ML beam management [R]. 2024
- [8] Huawei. Summary#5 of [109-e-R18-AI/ML-03] [R]. 2022
- [9] ZTE. Evaluation on AI CSI feedback enhancement [R]. 2023
- [10] ZTE. Discussion on study for AI/ML CSI prediction [R]. 2024
- [11] 3GPP. Technical specification group radio access network; study on channel model for frequencies from 0.5 to 100 GHz (Release 16): TR 38.901 [S]. 2019

作者简介



肖华华，北京交通大学在读博士研究生，中兴通讯股份有限公司技术预研无线资深专家；主要研究领域包括多天技术、人工智能和定位技术等；发表论文10余篇。



鲁照华，中兴通讯股份有限公司资深预研工程师；主要从事移动通信物理层关键技术研究；发表论文10余篇。



胡留军，中兴通讯股份有限公司算法部副部长，正高级工程师；曾获信息产业重大技术发明奖、深圳市科技进步奖一等奖、广东省科学技术奖二等奖及专利金奖、广东省技术发明奖二等奖等奖项；主持或参与多项国家级项目，发表论文15篇。