面向语义的数字孪生用于基于 AI 的信道状态信息获取

Jiajia Guo, *Member, IEEE*, Yiming Cui, *Graduate Student Member, IEEE*, and Shi Jin, *Fellow, IEEE*

arxiv:2506.21126v1 中译本

摘要—人工智能（AI）显著提升了信道状态信息（CSI）获取的性能，但受限于其对单一模态信息的依赖和部署挑战，特别是在数据集收集方面。本文研究了使用语义感知数字孪生（DT）来增强基于 AI 的 CSI 获取的应用。我们首先简要介绍了驱动 CSI 获取和语义感知 DT 在空中接口中应用的动力及近期进展。然后，我们深入探讨了如何通过语义感知 DT 强化基于 AI 的 CSI 获取。我们将用于基于 AI 的 CSI 获取的语义感知 DT 分为两类：通过与数字孪生集成来增强基于 AI 的 CSI 获取，以及使用数字孪生来辅助基于 AI 的 CSI 部署。详细介绍了潜在的整合框架。最后，我们总结了在语义感知 DT 辅助下的基于 AI 的 CSI 获取领域内的潜在研究方向。

I. 介绍

大规模多输入多输出（MIMO）技术通过在基站（BS）上配备大量天线，成为 5G 的关键使能技术。为了满足 6G 的大幅提高的要求 [1]，大规模 MIMO 技术将进一步增强和演进 [2]。天线数量将显著增加到数百或数千（定义为极端 MIMO 在 [2] 中），大大提升频谱和能源效率、网络覆盖等，同时像全息 MIMO 这样的创新变体也在出现。大规模 MIMO 及其变体的潜力取决于基于信道状态信息（CSI）的高质量优化（如预编码设计）。然而，由于大规模 MIMO 的高天线维度，获取高质量 CSI 导致了显著的开销和高的计算复杂度，这些对于实际系统是不可接受的。因此，开发一种高效的 CSI 获取技术对在 6G 中充分发挥大规模 MIMO 的潜力至关重要。

人工智能（AI），能够自动从大规模数据集中学习知识，已被引入无线通信领域。AI 原生特性已获认可为 6G 空中接口 [2] 的重要特征，并且也被采用在信道状态信息（CSI）获取任务中，如信道估计 [3]、反馈 [4] 和预测 [5]。将 AI 集成到 CSI 获取中提供了两个主要优势，即性能改进（包括准确性和开销）以及复杂性降低。然而，在大多数现有研究中普遍存在两大主要缺点。首先，现有研究倾向于通过部署更先进的 AI 技术来提高 CSI 获取性能，而忽视了其他领域/模态中的有价值知识。此外，将 AI 集成到 CSI 获取中带来了实际部署相关的新型挑战，这些挑战往往被忽略。

数字孪生（DT）[6]，将物理世界复制到一个数字虚拟世界中，有望成为 6G 中的关键应用和服务，在 [1] 中突出，并称为*无线通信对于 DT*。同时，DT 也有可能增强无线通信，被称作*无线的 DT*。无线电接入网络（RAN）部署和优化的迭代试错方法是资源密集型的。DT 技术可以通过提供一个完整的 RAN 虚拟模型进行测试和优化来大幅减少这些费用。许多制造商已经在实际系统中实现了基于 DT 的 RAN 部署和优化，包括华为的 IntelligentRAN 和英伟达的 Omniverse [7]。此外，还有一些努力将 DT 融入空中接口，例如波束预测 [8]。尽管如此，CSI 获取方面缺乏广泛的研究，只有少数研究，如 [9], [10]，解决了这一精细任务。然而，正如之前讨论的那样，在 CSI 获取中的高开销和有限精度对实现大规模 MIMO 的巨大潜力构成了重大挑战。此外，现有工作旨在构建一个紧密反映现实环境的 DT 复制品，利用所有可用信息来实现这一点，并将其用于辅助 CSI 获取。然而，这种方法导致了相当大的低效。鉴于这些挑战，将高效的 DT 集成到基于 AI 的 CSI 获取中至关重要。

在此，我们主要关注利用语义感知 DT 进行基于 AI 的 CSI 获取。具体来说，我们首先简要介绍 AI 在 CSI 获取和 DT 在空中接口方面的动机和最近进展。随后，我们深入研究如何利用语义感知 DT 来提升基于 AI 的 CSI 获取。我们将方法分为两类：*AI 与语义感知 DT 在 CSI 获取中的集成和利用语义感知的 DT 来促进基于 AI 的 CSI 采集的部署*。最后，我们强调了一些在基于 AI 的 CSI 获取中与语义感知 DT 相关的潜在研究方向。

II. 动机与近期进展

本节分别介绍了 AI 在信道状态信息获取和 DT 在空中接口方面的动机及最新进展。

A. 人工智能用于信道状态信息采集

传统 CSI 获取的主要挑战涉及获取性能（准确性和开销）和计算复杂度。为此，AI 已彻底融入 CSI 获取框架，涵盖了导频设计、信道估计和反馈 [4]。

与传统算法通常首先假设某种信道分布并严重依赖手动设计的特征不同，人工智能中的神经网络（NN）可以根据从训练数据集中学到的环境知识（即信道分布）自动提取特征 [11]。因此，使用大量 CSI 样本训练的 CSI 获取神经网络可以在具有相同信道分布的 CSI 数据集上表现出色，从而提高 CSI 获取精度并减少 CSI 获取开销。与传统的迭代算法相比，在图形处理单元（GPU）的帮助下，基于 AI 的 CSI 获取推理过程可以大大加快。

如前所述，基于 AI 的 CSI 获取面临两个主要挑战：**1). 多模态信息的集成与利用：** CSI 是传播环境的指标，也可以通过其他模态中的信息来表征，例如视觉和点云数据。整合并利用这些新信息可以提高基于 AI 的 CSI 获取性能，值得深入研究和探索。**2). 基于 AI 的信道状态信息获取的实际部署挑战：** AI 驱动的 CSI 获取在预训练和在线学习阶段都依赖于大量的数据。这带来了显著的挑战，为实际系统引入了相当大的开销——这一因素并未被传统的空中接口研究所考虑。

B. DT 用于空中接口

无线中的 DT 通常被视为物理传播环境的复制品。在真实无线系统中（例如波束管理 [8]）的决策可以根据从数字虚拟世界获得的知识来进行。因此，空气接口的 DT 包括两个主要组成部分：创建传播环境的复制品（即数字虚拟世界）及其相应的利用策略以支持现实系统的决策。

如何高效地构建物理传播环境的复制品？随着三维（3D）测绘技术的快速发展，包括数据采集和处理设备，现在可以生成详细的 3D 地图，例如 NVIDIA 的 Omniverse [7]。这些地图包括精确的位置、材料以及传播环境内通信设备和周围物体（如树木和道路）的其他相关细节 [13]。另一种广泛用于复制构建的工具是光线追踪模拟器，以商业软件 Wireless InSite 和开源平台 Sionna 为例 [14]。光线追踪模拟器可以根据 3D 计算机图形软件工具（例如 Blender）生成的传播环境，在给定的通信设置下，生成相应的信道响应（包括每个路径信息）。由于 Sionna 的开源可访问性，光线追踪模拟器已成为无线通信领域一种流行的研究工具，有效地连接了数字世界和复杂信道。然而，使用所有可用信息构建一个完全镜像现实世界环境的 DT 复制品是高度低效且往往不切实际的。相反，只有影响信道分布的组件才是必要的。例如，在 [12] 中，使用场景图来创建一个能够高效捕获传输环境的 DT。我们将这种简洁高效的 DT 称为语义感知 DT，它捕捉到对信道特性至关重要的环境语义的同时保持高效率。

例如，图 1 展示了一个由语义感知的 DT 在 [12] 中启用的基于 AI 的 CSI 反馈框架，其创建过程显示在左下角部分。在一个简化的室内场景中，主要影响传播的环境特征——如墙壁位置、尺寸和房间布局——被选中。这些特征被离散化为一个矩阵，在这个矩阵中，墙壁和开放空间由不同的值表示。这种离散化的矩阵可以被视为语义感知的 DT，并显著提高了 CSI 反馈的准确性。

如何通过副本增强实际系统中的决策制定？一些通信任务，如波束选择，高度依赖于用户周围的环境。如果可以通过全球导航卫星系统（GNSS）或摄像头获得用户位置，则可以利用精确的 3D 地图来评估周围环境，从而选出最佳的波束以实现有效的通信。同时，射线追踪模拟器可以通过实时仿真提供有价值的信道路径信息，有助于设计和优化通信系统。然而，目前针对通过数字孪生（DT）增强或支持基于 AI 的 CSI 获取的研究有限。[9], [10]

III. 语义感知的 DT 用于基于 AI 的 CSI 获取

CSI 采集不仅是基本方面，也是无线通信背后的核心模块。人工智能在提升 CSI 采集性能方面展示了巨大的潜力。本节将全面探讨利用语义感知 DT 进行基于 AI 的 CSI 采集的应用，这可以分为两类：一类是通过整合 AI 和语义感知 DT 来增强 CSI 采集性能；另一类则是使用语义感知 DT 部署基于 AI 的 CSI 采集以解决相关挑战。前者专注于通过集成 AI 来提升性能优势，而后者则旨在利用语义感知 DT 解决部署基于 AI 的 CSI 采集所面临的挑战。

A. AI 与语义感知 DT 的集成以增强 CSI 获取

作为一种数据驱动的技术，人工智能经常被用作工具来部分或完全替代传统算法，从而在准确性和效率上

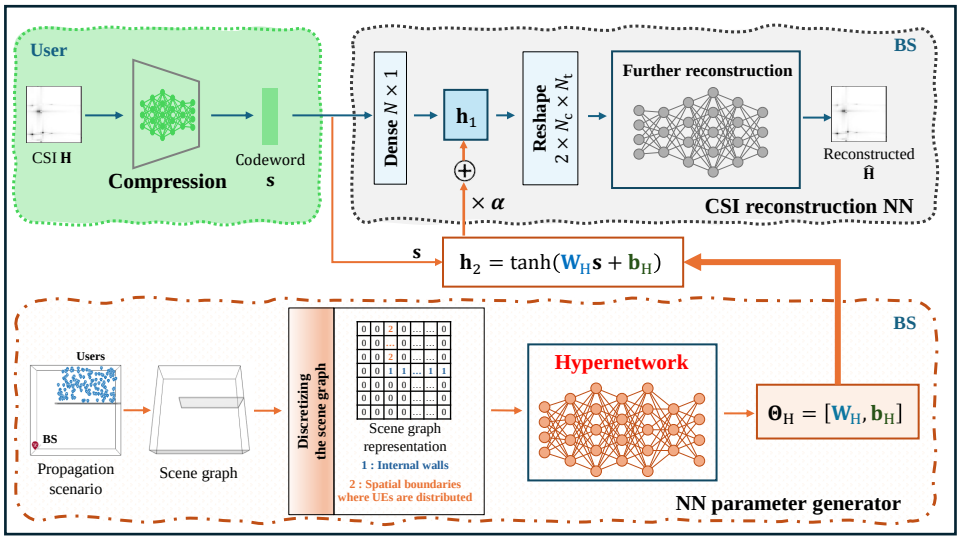

图 1. 一种基于 AI 的 CSI 反馈的半黑盒方法，如 [12] 中所提出的。超网络处理离散化场景图以生成个性化稠密层的权重和偏差，然后该层处理反馈编码词以实现特定场景的 CSI 重建。

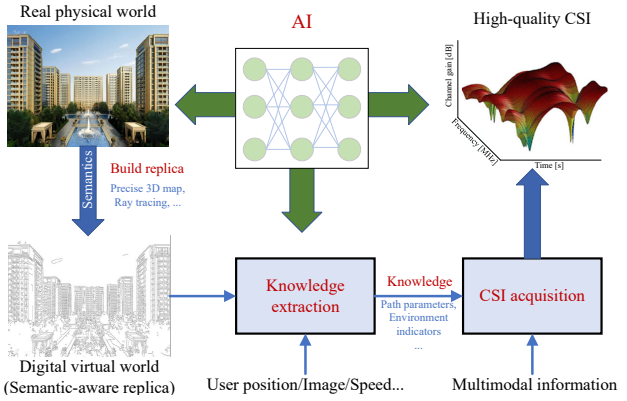

图 2. 人工智能与语义感知 DT 集成以增强 CSI 获取的示例。语义感知 DT 作为新的知识/信息来源，而 AI 整合到各个模块中，促进从 DT 的知识提取和 CSI 的获取。

实现改进。相比之下，DT 不是一种工具，而是一个提供额外信息的新维度，并且之前未被研究过。在这部分内容中，我们将首先阐明 AI 和语义感知 DT 集成的整体架构以增强 CSI 的获取，然后再详细介绍所涉及的关键模块。

1) 总体框架： 图 2 提供了集成 AI 和语义感知 DT 以增强 CSI 获取的示意图。语义感知 DT 作为知识/信息的新来源，而 AI 整合到各个模块中，促进从 DT 的知识提取（KE）和 CSI 的获取。更具体地说，由语义感知 DT 辅助的 CSI 获取包括三个主要阶段，在这些阶段中，AI 被紧密地编织在一起。详细阶段如下：

- 第一阶段，与第 II-B 节中提到的第一个问题相同，是构建一个语义感知的现实物理世界的复制品。
- 在第二阶段，称为“知识提取”，模块提取相关知识和信息以获取 CSI。此提取基于初始阶段构建的语义感知数字副本，并结合现实世界中的用户数据。
- 在最后阶段，CSI 是利用第二阶段提取的知识以及一些真实世界的多模态数据进行估计或重构的，如信道估计中的接收到的导频信号、信道预测中的历史 CSI 和用户位置及视觉信息。

总结而言，初始阶段侧重于构建物理传播环境的精确数字复制品；而最后一个阶段则专注于基于多模态数据的 AI 驱动 CSI 获取，其中包括来自真实传播世界的数据输入以及 KE 提供的知识。由于本文重点在于探讨 DT 在提升 AI 驱动 CSI 获取中的作用，因此初始和最终阶段不是此次讨论的主要内容。有兴趣了解这两个阶段的读者可以参考 [13] 获取关于复制品创建的详细信息，并参考 [5] 深入探索应用于 CSI 获取的多模态学习。接下来的部分将对第二阶段实施的 KE 模块进行详细介绍。

2) DT 辅助的知识提取用于 CSI 获取： 第二阶段，即 KE 模块，提出了两个主要问题：传输到 KE 模块的信息是什么，以及该模块可以生成什么输出。这里的关键点在于 *DT* 函数在提升 *CSI* 获取性能方面的作用。

KE 模块的输入： KE 模块的输入设计旨在促进用户周围传播环境的理解，这种环境影响信号传输，在复制品世界中丰富了信道状态信息采集的信息池。信道状态信息采集分为两类：瞬时类，捕捉当前信道状况；预测类，预测未来信道状态。每一类都需要为 KE 模块提供不同的输入。

瞬时信道状态信息获取：在稳定环境中，用户的 CSI 特征受其位置影响。通过使用诸如射线追踪等技

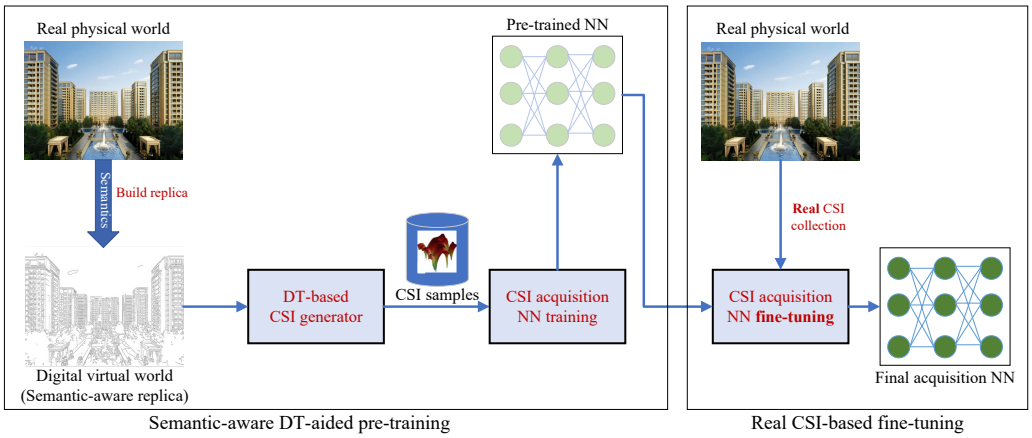

图 3. 通过语义感知 DT 部署基于 AI 的 CSI 获取的示例：基于语义感知 DT 的白盒训练数据生成。训练过程被设计为两阶段方法，其中初始阶段使用由语义感知 DT 生成的 CSI 数据进行初步神经网络预训练，随后阶段利用实际系统收集的 CSI 数据对神经网络进行微调。

术，在具有准确位置数据的情况下，我们可以在复制品环境中模拟信号传播，从而获得高质量的 CSI 特征。因此，挑战在于如何在现实世界中精确确定用户的位置。一种简单的方法是使用内置定位系统，如 GNSS。然而，GNSS 可能并非总是可用，并且即使有 GNSS，定位精度也可能无法满足要求。必须采用其他技术，例如基于视觉的定位，以确保高精度和稳定的定位。

未来 CSI 获取：考虑到信道老化以及消除 CSI 获取开销的潜力，基于历史信息预测未来 CSI 的 CSI 预测方法脱颖而出。因此，KE 模块的输入应该有助于捕捉传播环境中的趋势变化。用户的历位位置、移动方向和速度可以通过多种传感器（如惯性测量单元）和技术（如 GNSS）获得，并作为输入来帮助预测用户趋势。

KE 模块的输出： KE 模块的输出展示了语义感知 DT 可以提供哪些信息来辅助基于 AI 的 CSI 获取。我们将这些信息归类为以下两个主要类别。

与 CSI 直接相关的数据信息：信道状态信息矩阵描述了特定传播环境中的信号传输，考虑到了多径效应，即信号通过各种路径传播。在模拟复制品中，某些路径参数（例如路径损耗、到达角和离开角）可以准确确定。然而，随机因素，如系统噪声和收发器的非理想特性，避免了精确测量，并且可能根本无法检测到这些因素。不过，从语义感知复制品中获得的路径信息可以显著提高信道状态信息获取性能。例如，在这样的信息的帮助下，可以设计更有效的导频信号，并且可以通过使用此附加/侧边信息来改进信道估计和反馈过程。

与 CSI 间接相关的资讯：对 CSI 获取协议设计有用的信息也需要被提取。获取 CSI 是一个复杂的程序，需要的不仅仅是详细的获取算法的精心设计。语义感知 DT 副本可以在多个部分提供帮助，而不仅仅是在详细

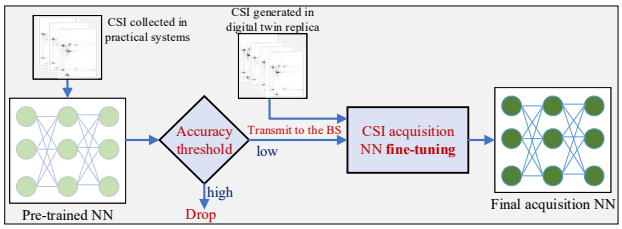

图 4. 使用 [10] 所提议的细化数据选择示例。展示低采集性能的 CSI 样本应该与 DT 数据一起被选中，以进一步微调神经网络。

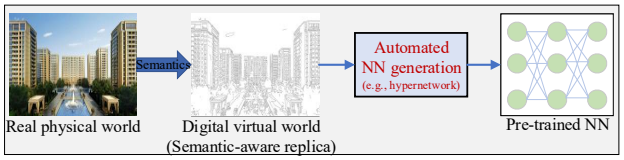

图 5. 基于语义感知 DT 的黑盒训练数据生成示意图。

算法方面。获取 CSI 依赖于一个全面协议的支持，包括指定导频信号的密度、结构和类型，执行估计和反馈的时间间隔等。从 DT 副本中提取相关信息并将其纳入协议设计是非常有益的。例如，如果在语义感知 DT 副本中观察到稳定传播环境中的缓慢信道变化，则可以采用较大的信道估计和反馈间隔，从而大大减轻 CSI 获取开销。

B. 基于 AI 的 CSI 获取的部署使用 DT

虽然 AI 集成显著提升了 CSI 的获取，但在部署时也带来了新的挑战。基于 AI 的 CSI 获取完全依赖于数据，在部署时首先需要解决数据问题。在基于 AI 的 CSI 获取中，数据对于两个关键阶段是必需的：部署前的神经网络训练和在线神经网络训练以应对泛化问题。无论是部署前还是部署过程中，收集训练数据都面临重大挑战，包括数据收集的开销和时间限制。在这个小节中，我们讨论两种语义感知的 DT 方法——白盒方法，生成

显式的训练数据；黑盒方法，直接产生神经网络参数，以应对这些挑战。

1) 基于语义感知 DT 的白盒训练数据生成: 采用语义感知的 DT 来辅助生成 CSI 训练样本是一种逻辑方法，从而减少数据收集带来的开销。图 3 展示了基于语义感知 DT 的白盒训练数据生成方法增强的 CSI 获取 NN 的训练框架。NN 的训练分为两个不同的阶段:

利用语义感知 DT 生成的数据进行预训练: 在基于 AI 的 CSI 获取中的 NN 训练涉及学习信道分布，然后根据这些学到的分布设计自动算法来执行信道估计、反馈和其他操作。由物理环境决定的信道分布在从该数据集中学习的信道数据中有所体现，NN 从中推断并调整其参数以实现准确建模。鉴于语义感知的 DT 镜像现实世界的 CSI 分布，在语义感知 DT 复制品中的 CSI 信道分布与真实传播环境中紧密相似。因此，利用 DT 复制品内生成（收集）的 CSI 样本作为训练 CSI 获取 NN 的数据集是一个自然的想法。[10]

一旦建立了高效的语义感知 DT 副本，可以使用诸如射线追踪的方法来获取 CSI 样本，并随机分配用户位置。然而，该方法存在以下两个主要问题，

- *未知用户位置分布*: 为了简化，大多数现有的研究通常假设用户位于规则形状的服务区域内，例如矩形或圆形。例如，[10] 在一个 $200m \times 230m$ 矩形区域中随机分配用户位置。然而，在实际系统中，用户的分布往往不规则。用户的位置分布极大地影响了特定小区内的信道分布，因此确定潜在的用户位置至关重要。在户外环境中，大多数用户携带带有 GNSS 功能的设备，便于获取用户位置数据。相反，室内用户的位置分布难以确定，并需要先进的方法。
- *高语义感知 DT 基础 CSI 生成的复杂性*: 信道状态信息（CSI）的生成过程需要大量的计算资源。尽管 GPU 可以加速这一过程，但 CSI 的生成仍然是一个漫长的过程。存在两种可能的解决方案来解决这个问题。第一种是简化参与传播参数。例如，限制信号路径的数量可能会显著降低 CSI 生成过程的复杂性。另一种解决方案是减少需要生成的 CSI 数量。只要生成的 CSI 样本能够准确表示信道分布，就没有必要再产生额外的 CSI 样本。在训练阶段，可以利用数据增强技术来提高神经网络（NN）性能。

使用实际系统中收集的数据进行微调: 现实世界与简化的语义感知 DT 复制品之间的不可避免的不匹配导致了信道分布的差异。首先，DT 复制品无法完全捕捉到现实世界的 [10]，因为不可预测的因素可能会影响信号传播，并且准确描述现实世界的语义具有挑战性。因此，语义感知 DT 优先考虑效率而牺牲准确性。其次，如前所述，精确确定影响信道分布的关键因素——用户位置分布，在实际系统中是一个重大挑战。因此，微调预先使用语义感知 DT 数据训练的 CSI 获取神经网络是减轻这些差异并提高性能的关键。

然而，CSI 采集神经网络的额外微调需要从实际系统中收集 CSI 样本，这导致了相当大的数据收集负担。为减轻这一负担，并不需要收集所有 CSI 样本。相反，可以专注于仅收集那些对微调过程有益且不在语义感知 DT 副本生成的数据集中出现的样本。例如，[10] 中的 DT 副本假设与现实世界相同的几何布局，但省略了树木等物体，并且相应地，[10] 提出了一个基于数据选择的微调框架，如图 4 所示，以减轻这一负担。具体来说，只应选择使用 DT 数据预训练的神经网络采集性能低下的 CSI 样本进行进一步微调。虽然这可以在实际系统中显著提高 CSI 采集精度并减轻数据收集负担，但仍有一个问题是，那些与预训练神经网络表现不佳的 CSI 样本是否确实缺失于 DT 数据中。如 [4, Figure 34] 所示，尽管部分样本被包含在训练数据集中，但其采集精度仍然较低。因此，需要一个更优的数据收集算法。

2) 基于语义感知 DT 的黑盒训练数据生成: 所讨论的白盒方法遵循数据驱动神经网络训练的传统框架。DT 复制品通过提供与实际系统分布相似的训练数据，有助于部署信道状态信息采集神经网络。然而，该方法仍需占用大量计算资源来预训练信道状态信息采集神经网络。探索使用语义感知 DT 以完全消除预训练过程是值得的。

CSI 获取 NN 训练的本质是从训练样本中学习信道分布。因此，在白盒方法中，使用 DT 复制品生成的数据来帮助 NN 学习信道分布。这种分布由传播环境和用户位置的分布决定。换句话说，信道分布与传播环境和用户位置分布都存在映射关系。给定一个预定义的 NN 架构，NN 参数由传播环境和用户位置分布共同决定，在本文中假定这些信息被整合在语义感知 DT 世界内。因此，直接从语义感知 DT 世界生成 CSI 获取 NN 参数是有逻辑意义的。我们认为这种方法是基于语义感知 DT 的黑盒训练数据生成，它隐式地生成数据。

图 5 展示了基于语义感知 DT 的黑盒训练数据生成

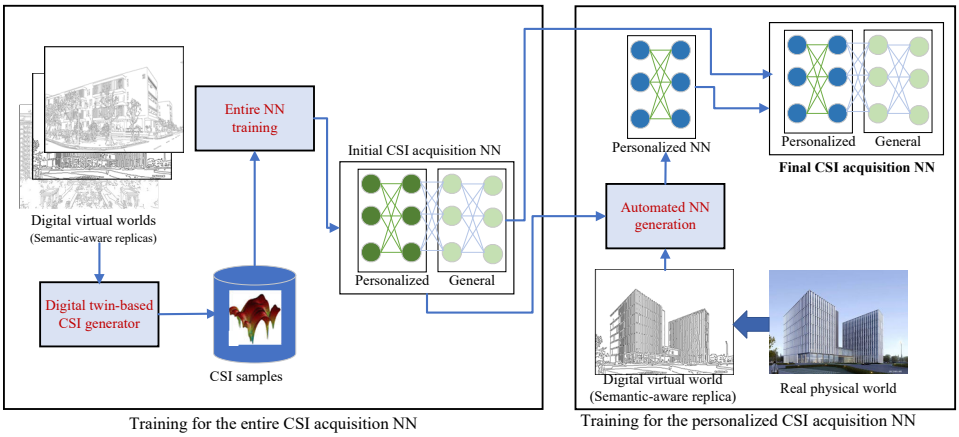

图 6. 基于语义感知 DT 的半黑盒训练数据生成，这涉及将整个 CSI 获取神经网络分割为两个部分：一个通用神经网络和一个个性化神经网络。通用神经网络使用来自多种语义感知 DT 世界的样本进行训练，而个性化神经网络则通过特定语义感知 DT 世界的数据进行微调。

框架，用于预训练 CSI 获取 NN 的参数生成。最初，构建了一个反映真实传播世界的语义感知 DT 世界，并包含了诸如传播环境和用户位置分布等详细信息。DT 不需要完全捕捉现实世界的所有信息，但应该包括影响信号传输的关键语义，如建筑物及其材料。随后，将这样的语义感知 DT 世界输入到 NN 参数生成模块中以产生预训练的 NN 参数。主要挑战在于基于语义感知 DT 世界的 NN 参数生成模块。该模块包含三个主要问题：

- 输入形式：复杂的 DT 世界可以用各种模态来表示，例如精确的 3D 地图和 Blender 中的 OBJ 文件。假设生成模块是基于神经网络的，其输入必须以矩阵或张量的形式存在。因此，如何将 DT 世界转换为矩阵或张量格式。在新格式中，输入应有选择地保留影响信道分布的特征，简化数据的同时确保准确的信道分布。
- 模块设计：本模块的目的是生成神经网络参数，通常在超网络的帮助下完成这一任务 [15]。超网络的基本概念是根据其输入生成神经网络参数。例如，为了增强基于神经网络的信道估计对不同信噪比（SNR）的鲁棒性，超网络使用 SNR 作为输入变量来生成用于信道估计神经网络的参数。同样地，表示为新格式的 DT 世界可以被输入到超网络中，进而生成用于 CSI 获取神经网络的参数。
- 模块复杂度：信道状态信息采集神经网络的参数数量通常非常庞大，这不可避免地导致了神经网络参数生成模块内的显著复杂性。在为提高泛化能力而在线更新神经网络参数的过程中，这一缺点可能会成为其部署的障碍。因此，减少神经网络参数生成模块的负担至关重要。

考虑到提到的挑战，采用具有相当复杂性的纯黑盒方法存在严重障碍，并且在实际系统中可能是不可行的。半黑盒策略可能更具可行性。图 6 展示了用于信道状态信息（CSI）获取的半黑盒方法的核心结构。该方法将 CSI 获取神经网络分为两个部分：一个通用神经网络和一个个性化神经网络。通用神经网络使用来自不同设备类型世界的样本进行训练，而个性化神经网络则通过特定设备类型世界的数据进行微调。因此，培训过程涉及两个关键阶段。最初，整个包括通用和个性化组件的 CSI 获取神经网络是使用来自各种设备类型环境的 CSI 样本进行训练的。随后，将一个具体的语义感知设备类型世界输入到自动神经网络生成模块中，以产生个性化神经网络的参数，从而实现针对目标环境的定制化适应。

图 1 展示了一种基于 AI 的 CSI 反馈的半黑盒方法，如 [12] 所提出的。接收到反馈编码字后，基站通过两个阶段使用 NNs 重构下行链路 CSI：首先通过密集层进行初步重建，然后使用复杂数 NN 进行进一步优化。在第一训练阶段，一个包含密集层和复杂数 NN 的通用重构 NN 是用从各种语义感知 DT 世界中获得的 CSI 样本进行训练的，这些世界表示为场景图。随后，超网络通过输入特定环境的场景图生成额外的密集层，作为个性化 NN。具体而言，超网络处理离散化的场景图以产生个性化密集层的权重和偏置，该层接着处理反馈编码字以实现特定场景下的 CSI 重构。鉴于自动化神经网络生成模块无需生成所有神经网络参数，并且整个神经网络已经过预训练，这在很大程度上降低了该模块的复杂性和工作量。此外，尽管第一阶段的预训练神经网络可能无法达到为特定场景定制的神经网络性能，但它仍可能表现令人满意。

IV. 结论与潜在研究方向

本文探讨了通过利用语义感知的 DT（决策树）在 6G 系统中实现高效 CSI 获取的方法，为大规模 MIMO 未来的发展奠定了基础。基于 AI 的 CSI 获取涉及将 AI 与语义感知 DT 集成以进行 CSI 获取，并使用语义感知 DT 来促进基于 AI 的 CSI 获取的部署。详细介绍了潜在框架。然而，该领域仍存在一些重要的挑战和进一步研究的方向：

- *语义感知的 DT 世界（复制品）创建*：上述讨论假设了精确创建一个语义感知的数字孪生世界（复制品），而一个不精确的复制品将显著削弱所提出的数字孪生辅助策略。准确复制现实世界的无线语义和用户位置数据存在重大挑战，有时甚至可能不可行。因此，现在可以初步在更简单、更可控的环境中研究和应用语义感知的数字孪生辅助策略，比如智能工厂。
- *多模态信息利用*：在基于语义感知 DT 辅助的 AI 获取 CSI 的基本属性中，涉及利用多模态信息。然而，整合这些多模态数据的方法仍然不清楚，并需要进一步的研究。AI 被认为是可以解决这一复杂挑战的有前景的解决方案。
- *用户位置分布建模*：信道分布不仅受传播环境的影响，还受到用户位置分布的影响。据我们所知，关于学习用户位置分布的研究很少。这一问题超越了传统的无线通信挑战，需要跨学科研究。
- *多个 DT 的合作*：在无蜂窝网络等场景中，需要从多个接入点获取用户的信道状态信息（CSI）。这需要多个 DT 世界之间的协作以确保高质量地获取 CSI。
- *标准化*：与收发器设计不同，信道状态信息获取需要严格的标准化。DT 世界的引入带来了显著的挑战。为了确保性能的同时，标准化需求要求基站和用户具有尽可能大的灵活性。
- *隐私保护*：为了高效获取信道状态信息，DT 世界需要收集用户行为数据，包括但不限于位置和速度，这存在隐私泄露的风险。因此，有必要开发专门的隐私保护机制，仅收集无线环境语义。

参考文献

[1] ITU-R WP5D, "Framework and overall objectives of the future development of IMT for 2030 and beyond," Tech. Rep., Jun. 2023, Accessed on Mar. 20, 2025. [Online]. Available: https://www.itu.int/md/R19-WP5D-230612-TD-0905/en

[2] ITU-R M.2516-0, "Future technology trends of terrestrial international mobile telecommunications systems towards 2030 and beyond," Tech. Rep., Nov. 2022, Accessed on Mar. 20, 2025. [Online]. Available: https://www.itu.int/dms_pub/itu-r/opb/rep/R-REP-M.2516-2022-PDF-E.pdf

[3] M. Soltani, V. Pourahmadi, A. Mirzaei, and H. Sheikhzadeh, "Deep learning-based channel estimation," *IEEE Commun. Lett.*, vol. 23, no. 4, pp. 652–655, Apr. 2019.

[4] J. Guo, C.-K. Wen, S. Jin, and G. Y. Li, "Overview of deep learning-based CSI feedback in massive MIMO systems," *IEEE Trans. Commun.*, vol. 70, no. 12, pp. 8017–8045, Dec. 2022.

[5] Y. Yang, F. Gao, C. Xing, J. An, and A. Alkhateeb, "Deep multimodal learning: Merging sensory data for massive MIMO channel prediction," *IEEE J. Sel. Areas Commun.*, vol. 39, no. 7, pp. 1885–1898, Jul. 2021.

[6] L. U. Khan, Z. Han, W. Saad, E. Hossain, M. Guizani, and C. S. Hong, "Digital twin of wireless systems: Overview, taxonomy, challenges, and opportunities," *IEEE Commun. Surveys Tuts.*, vol. 24, no. 4, pp. 2230–2254, 4th Quart. 2022.

[7] X. Lin, L. Kundu, C. Dick, E. Obiodu, T. Mostak, and M. Flaxman, "6G digital twin networks: From theory to practice," *IEEE Commun. Mag.*, vol. 61, no. 11, pp. 72–78, Nov. 2023.

[8] S. Jiang and A. Alkhateeb, "Digital twin based beam prediction: Can we train in the digital world and deploy in reality?" in *Proc. IEEE Int. Conf. Commun. Workshops (ICC Workshops)*, 2023, pp. 36–41.

[9] B. Vilas Boas, W. Zirwas, and M. Haardt, "Machine learning for CSI recreation in the digital twin based on prior knowledge," *IEEE Open J. Commun. Soc.*, vol. 3, pp. 1578–1591, 2022.

[10] S. Jiang and A. Alkhateeb, "Digital twin aided massive MIMO: CSI compression and feedback," in *Proc. IEEE Int. Conf. Commun. (ICC)*, 2024, pp. 1–6.

[11] J. Guo, Y. Cui, C.-K. Wen, and S. Jin, "Prompt-enabled large AI models for CSI feedback," *arXiv preprint arXiv:2501.10629*, 2025.

[12] J. Liu, J. Guo, Y. Cui, C.-K. Wen, and S. Jin, "AdapCsiNet: Environment-adaptive CSI feedback via scene graph-aided deep learning," *arXiv preprint arXiv:2504.10798*, 2025.

[13] A. Alkhateeb, S. Jiang, and G. Charan, "Real-time digital twins: Vision and research directions for 6G and beyond," *IEEE Commun. Mag.*, vol. 61, no. 11, pp. 128–134, Nov. 2023.

[14] F. A. Aoudia, J. Hoydis, M. Nimier-David, S. Cammerer, and A. Keller, "Sionna RT: Technical report," *arXiv preprint arXiv:2504.21719*, 2025.

[15] D. Ha, A. M. Dai, and Q. V. Le, "Hypernetworks," in *Proc. 5th Int. Conf. Learn. Representations (ICLR)*, 2017, pp. 1–18.