

# 6G 内生智能与信道基础模型



## 6G Native AI and Channel Foundation Models

徐树公/Xu Shugong<sup>1</sup>, 蒋骏/Jiang Jun<sup>2</sup>

(1. 西交利物浦大学, 中国 苏州 215123;

2. 上海大学, 中国 上海 200444)

(1. Xi'an Jiaotong-Liverpool University, Suzhou 215123, China;

2. Shanghai University, Shanghai 200444, China)

DOI: 10.12142/ZTETJ.202601008

网络出版地址: <https://link.cnki.net/urlid/34.1228.TN.20260225.0923.002>

网络出版日期: 2026-02-25

收稿日期: 2025-12-27

**摘要:** 人工智能 (AI) 与通信系统的深度融合已成为 6G 的关键目标与核心标志之一, 内生智能 (Native AI) 被普遍视为 6G 系统的重要特征。阐述了 6G 内生智能的内涵与需求, 在此基础上系统梳理了无线通信领域 AI 研究范式的演进历程, 揭示了基于监督学习的传统 AI 模型在支撑 6G 内生智能方面存在的固有局限。针对上述挑战, 提出了信道基础模型 (CFM) 的概念框架, 系统介绍了其预训练方法体系及面向各类信道相关任务的任务适配机制。认为 6G 内生智能需具备强大的任务适应性与场景泛化能力, 而信道基础模型凭借其核心技术特征, 有望成为未来 6G 内生智能的关键技术选项之一。

**关键词:** 6G 内生智能; 信道基础模型; 掩码信道重建; 对比学习; 通感一体化; 自监督学习

**Abstract:** The deep integration of artificial intelligence (AI) and communication systems has emerged as a key objective and core hallmark of 6G, with native AI being widely recognized as an essential characteristic of 6G networks. An understanding of the connotation and requirements of 6G native intelligence is first elaborated. Based on this, the evolution of AI research paradigms in wireless communications is systematically reviewed, revealing the inherent limitations of traditional supervised learning-based AI models in supporting 6G native intelligence. In response to the above challenges, a conceptual framework of channel foundation model (CFM) is proposed, and its pre-training methodology as well as task adaptation mechanisms for various channel-related tasks are systematically introduced. It is envisioned that 6G native intelligence requires strong task adaptability and cross-scenario generalization capabilities, and channel foundation models, by virtue of their core technical features, are expected to become one of the key technological enablers for future 6G native intelligence.

**Keywords:** 6G native AI; channel foundation model; masked channel modeling; contrastive learning; integrated sensing and communication; self-supervised learning

**引用格式:** 徐树公, 蒋骏. 6G 内生智能与信道基础模型 [J]. 中兴通讯技术, 2026, 32(1): 46-52. DOI: 10.12142/ZTETJ.202601008

**Citation:** Xu S G, Jiang J. 6G native AI and channel foundation models [J]. ZTE technology journal, 2026, 32(1): 46-52. DOI: 10.12142/ZTETJ.202601008

将人工智能 (AI) 技术融入移动通信系统的各个环节, 已成为学术界和产业界广泛关注的研究方向。随着国际电信联盟 (ITU) 将 AI 定义为 6G 网络的一项基础能力, “内生智能” (Native AI) 被普遍视为 6G 系统的核心特征之一, 标志着 AI 与通信系统的深度融合正成为 6G 发展的关键目标。然而, 关于内生智能的确切内涵, 以及 6G 系统究竟需要具备何种 AI 能力, 目前仍缺乏广泛共识。本文旨在围绕上述问题, 分享我们的理解与思考。

我们认为, 内生智能指的是系统原生具备的 AI 能力。在 6G 设计中, 这种能力应从系统架构的初始阶段即被纳入规划、设计、优化与交付流程, 成为系统不可分割的基础组成部分。类比于汽车制造, 内生智能可视为“前装组件”, 即在出厂前已完成集成并随整车交付, 而非用户购车后到

4S 店加装的“后装配件”。正因为内生智能难以通过后期“打补丁”方式实现, 我们有必要深入探讨: 究竟何种 AI 能力能够满足 6G 系统的长远需求, 才有可能成为其核心组件, 内嵌于系统底层。

当前, 6G 研究方兴未艾, 关于 AI 的相关标准化工作也已启动。从应用场景角度看, 6G 需要支持地面、空基、卫星等多域融合通信, 信道环境具有动态时变、异构干扰交织等复杂特征, 涵盖信道估计、波束赋形、通感一体化等多种任务。若仅采用面向单一任务或特定场景的专用 AI 技术, 将难以支撑系统在全域部署和功能扩展上的需求。缺乏任务适应性的内生智能, 可能导致网络架构因专用模型种类繁多而变得臃肿; 而缺乏跨场景泛化能力, 则难以应对不同信道环境下性能的剧烈波动。这显然与“内生智能作为系统核心

组件”的定位相悖。

为此，本文将在梳理无线通信领域AI研究范式演进历程的基础上，系统分析传统AI模型在6G环境下面临的局限，进而提出一种面向信道的专用基础模型（FM）概念，探讨其面向多类下游任务的适配能力，并评估其作为6G内生智能核心支撑技术的可行性。

## 1 AI赋能无线通信的范式演进

回顾将人工智能技术应用于无线通信领域的研究<sup>[1-2]</sup>，其发展脉络与人工智能研究范式的演进基本一致，呈现出一条从早期单任务监督学习，到多任务协同建模，再到预训练基础模型驱动范式变革的清晰路径。在这一演进过程中，传统AI模型在支撑6G内生智能需求方面逐渐暴露出诸多难以克服的固有局限，使其难以成为未来6G内生智能的核心组成部分。

人工智能研究范式的演进大致可分为3个阶段，如图1所示。第1阶段为单任务监督学习阶段，研究聚焦于“一个任务、一个数据集、一个模型”的模式，模型主要采用端到端方式针对特定任务进行训练。这类模型的性能高度依赖于带标签数据的质量与数量，在数据集不足时易面临过拟合问题，且其跨任务迁移能力天然受限。随着应用场景复杂度的不断提升，研究者提出了包含共享参数的多任务学习框架，通过联合训练利用任务间的共性实现知识迁移<sup>[3-4]</sup>。然而，多任务学习仍然要求任务之间存在统计相似性，且依赖于任务专用的架构设计。FM的出现标志着深度学习范式的根本性变革，其“预训练+微调”的两阶段方法彻底革新了该领域的发展模式：首先基于大规模无监督数据集进行预训练，构建具备泛化能力的FM；随后通过下游任务的轻量级微调，高效适配多样化的任务需求与应用场景。在这一演进历程中，传统AI模型依赖大量带标签数据、泛化能力不足等固有局限愈发凸显。

传统基于监督学习的AI模型存在三大核心局限，严重制约了其在6G内生智能中的应用。

首先是数据依赖性困境。多数传统AI模型要实现可靠性能，必须依托海量带标签数据集作为支撑。然而在动态变化的无线环境中，传输模式与干扰状态时刻变化，稳定采集符合要求的数据集难度极高。更为关键的是，人工标注过程不仅耗时费力，还难以避免标注错误，进一步加剧了资源消耗。

其次是泛化能力不足。6G需要融合地面、海上、空中等多场景通信，对模型的跨场景适配能力提出了严苛要求。传统AI模型在训练过程中极易对训练数据产生过拟合，在

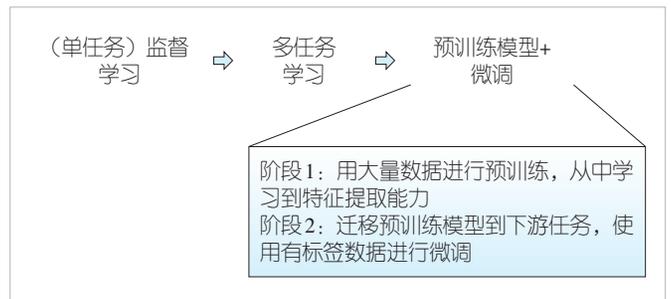


图1 AI研究范式的发展路线

训练场景中能够表现出良好性能，但一旦迁移至新场景，性能便会显著下降。

再次是任务专用化困境。6G中的每个应用场景都需为传统AI模型进行定制化设计，导致任务专用模型数量激增。这不仅大幅增加了系统链路的复杂度与资源消耗，也与6G内生智能所追求的高效统一框架理念相悖。

此外，传统AI模型还存在实时自适应能力薄弱的问题。无线通信环境动态多变，实时自适应能力是维持模型性能的关键。然而，在静态条件下训练的传统模型难以快速适应现实场景中的动态变化，对于自动驾驶、远程医疗等需要近实时响应的6G关键应用将产生不利影响。上述局限共同凸显了开发先进AI解决方案以满足下一代无线网络多维需求的必要性，也为信道基础模型（CFM）的提出奠定了研究基础。

## 2 从FM到CFM

受大语言模型与计算机视觉领域成功案例的启发，基础模型依托大规模数据集构建，仅需少量额外数据即可适配特定任务。如图2所示，与通用大语言模型的方法不同，无线通信领域的基础模型通过无线专用数据集进行预训练，显著提升了其在无线通信场景下的相关性与适配效率。

借鉴基础模型在相关领域的成功经验，本文面向无线通信场景提出CFM的概念。与信道外推、用户定位等需从零开始设计与训练的传统任务专用模型不同，CFM遵循“预训练-微调”的范式：首先，在涵盖多传播场景、多频段、多环境条件的大规模信道测量数据集上进行预训练，使模型能够提取通用信道特征并学习无线信道的内在统计规律；随后，针对特定的无线通信任务，利用小规模任务导向数据集对预训练CFM进行微调。该范式不仅加速了任务专用模型的开发进程，还提升了模型在不同无线环境下的泛化能力，为应对多样化动态信道条件下的模型适配挑战提供了有效解决方案。

凭借上述能力，CFM标志着“AI+无线”技术路线的范

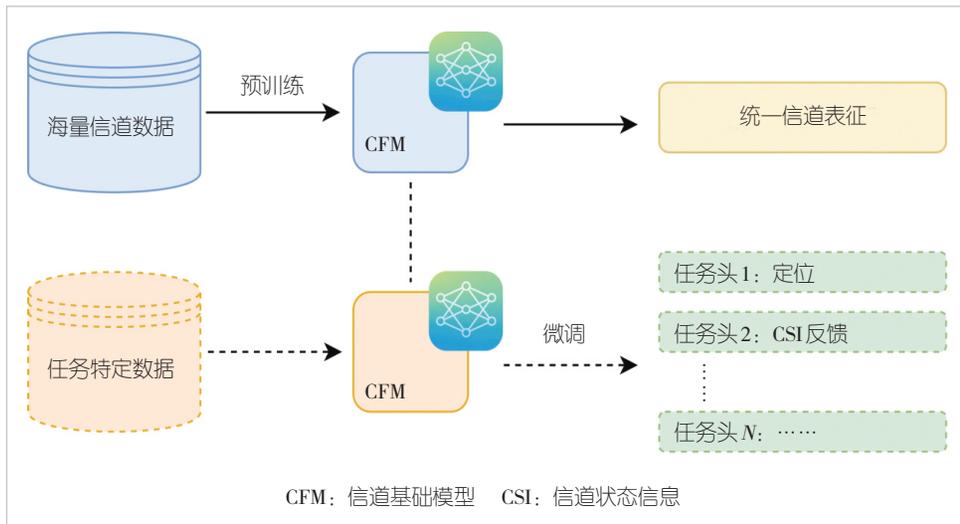


图2 CFM的整体框架图

式转变，为应对6G内生智能的多维度挑战提供了一种兼具高效性与灵活性的可行解决方案。

### 2.1 CFM的定义

斯坦福大学Wiggins等人将FM定义为一种在大量原始数据基础上通过无监督学习训练而成的人工智能神经网络，具备适应多样化任务的能力<sup>[5]</sup>。CFM则是面向无线通信领域设计的专用基础模型，其核心聚焦于信道相关特征的挖掘与任务适配。需要明确的是，CFM与无线大模型存在本质差异：后者以“大语言模型、大参数量”为核心支撑，而CFM采用中等参数规模设计，旨在实现信道类任务的精准优化，在模型性能与工程部署效率之间取得平衡。从技术范式角度看，预训练模型体现了“预训练-微调”的通用方法论，CFM则是基于该范式、针对无线信道物理特性定制开发的具体模型实例，并非所有采用预训练范式的模型均可归入CFM范畴，例如通用视觉基础模型即不属此类。值得注意的是，尽管早期已有研究在无线信道领域尝试应用自监督表征学习方法<sup>[6-7]</sup>，但这些工作多聚焦于单一任务，忽视了对信道通用特征的系统挖掘与跨任务迁移能力的构建，因而仍未突破传统任务专用模型的固局限。

具体而言，CFM以无线信道为专属核心研究对象，基于大规模异构信道数据开展离线预训练构建而成，其输入输出空间及任务集合均围绕信道特性实现精准界定。在输入空间方面，模型明确以信道状态信息（CSI）和同相正交（IQ）信号为主要数据形态，涵盖多场景、多频段、多环境条件下的异构信道数据；输出空间则聚焦于通用信道特征，通过模型学习实现对信道底层物理规律的精准表征。任务集合严格

限定为各类信道相关任务，主要涵盖两大维度：一是生成任务，包括信道外推、信道估计、信道压缩与反馈、预编码等；二是感知任务，包括场景分类、用户定位、波束管理等。CFM采用神经网络架构，其核心目标在于学习信道内在物理规律与跨场景通用特征，为上述多样化任务提供统一的特征支撑。这一设计理念与基于通用知识预训练的大语言模型以及传统有监督任务专用模型形成本质区别。

### 2.2 CFM与其他范式差异

AI赋能无线通信的主流范式主要包括任务专用模型、大语言模型（LLM）及CFM，三者核心特征对比见表1。通过指标差异可清晰印证CFM作为信道专用范式的必要性与优势。

在泛化能力与预训练需求方面，LLM的预训练并非必选项，其以通用知识为核心，未融入信道物理特性，跨场景泛化能力仅达到中等水平；CFM则将预训练作为必需环节，基于大规模异构信道数据学习信道底层规律，展现出优异的泛化能力。

在参数规模、存储与时延协同优化方面，LLM参数规模极大、推理时延较长，难以适配边缘部署与实时处理需求；CFM采用中等参数规模设计，存储开销与推理时延均控制在中等水平，通过轻量化微调即可适配具体任务，在模型性能与部署效率之间实现了有效平衡。

在任务适应性方面，LLM面对多样化信道任务需频繁进行微调，灵活性受限；CFM依托预训练阶段积累的信道专用特征，仅需微调少量参数即可高效适配多类信道任务，任务适应性显著更优。

表1 AI赋能无线通信的不同范式对比

内容	任务专用监督模型	LLM	CFM
泛化能力	较差	中等	优异
存储开销	低	高	中等
参数规模	小	极大	中等
预训练需求	无	可选	必须
推理时延	低	高	中等
任务适应性	低	中等	高

CFM: 信道基础模型 LLM: 大语言模型

综上所述，传统任务专用监督模型与LLM均难以均衡满足信道任务的多维度需求；CFM通过针对性的信道预训练与中等参数规模设计，构建了更契合信道特性的专用技术范式，有望成为支撑6G内生智能的重要技术选项之一。

## 2.3 CFM的核心特征

### 2.3.1 跨场景与配置的泛化性

传统AI模型在无线通信中的核心局限之一在于泛化能力薄弱，即模型在与训练环境不同的场景中部署时，性能显著下降。传统模型通常基于窄范围场景专用数据集训练，并针对单一任务优化，在面对未见过的场景时性能会出现“灾难性退化”。

在需覆盖地面、空中、卫星通信等多域异构场景的6G系统中，泛化挑战尤为严峻。不同传播域具有独特的信号传播特性，多样化的环境条件要求模型能够适配差异化的应用场景与天线配置。

CFM通过高效的跨场景泛化能力有效应对这一挑战。与传统模型不同，CFM的预训练数据集具有大规模异构特性，整合了多源信道数据：既包括基于信道模型生成的合成数据，也涵盖从不同场景采集的真实测量数据，以及模拟暴雨、高速移动等极端条件的仿真数据。这种多源数据融合使CFM能够学习无线信道的通用统计规律与跨场景共性特征，从而在多样化场景中保持稳定的性能表现。

### 2.3.2 对多下游任务的适应性

CFM作为通用信道特征提取器，具备多下游任务适配能力——通过轻量化微调即可无缝适配各类信道相关下游任务。这种适应性是基础模型设计的固有属性：通过在大规模多样化数据集上进行预训练，CFM学习到全面的通用特征，仅需少量数据即可高效迁移至特定任务。CFM的“少样本、低参数”适配机制对实际无线系统具有重要意义。与传统监督模型不同，CFM仅需少量带标签样本与局部参数调整，即可实现具有竞争力的性能，同时大幅降低计算开销。这一机制有效缓解了部署中的两大核心挑战：

1) 数据依赖问题：无线通信领域带标签数据的采集过程耗时且资源消耗巨大，CFM所具备的少样本适配能力恰好契合了这一关键实际需求。

2) 计算复杂度问题：低参数微调机制无须在部署阶段投入大量计算资源，使得CFM能够在处理能力受限的边缘设备上实现高效应用。

CFM凭借其卓越的任务适配能力，有望成为6G通信系统的核心组件，能够在无须构建多个专用模型的前提下，高

效部署于各类信道相关任务中，为无线通信领域的技术演进提供重要支撑。

### 2.3.3 可扩展性

可扩展性是指模型性能随模型参数与训练数据集规模增加而稳定提升的特性，这一特性是CFM的核心特征，也是其与传统模型的关键区别所在。

CFM的可扩展性源于基础研究领域中已被实证的缩放定律：随着模型容量与训练数据规模的扩大，模型的表征能力与泛化性能呈现可预测的提升趋势。传统模型的性能通常在模型规模或数据量达到某一阈值后趋于饱和，而CFM则遵循完全不同的演进规律，其可扩展性主要体现在模型规模和训练数据两个维度：

1) 模型规模可扩展性：增加CFM的参数数量可显著提升其捕捉细粒度信道动态的能力。大规模CFM擅长建模多干扰信号间的非线性交互，凭借更高的表征精度，能够为信道估计、预编码等关键任务提供更精准的输出。

2) 训练数据可扩展性：当CFM在涵盖多运营场景、多设备类型、多环境条件的大规模异构数据集上进行训练时，能够学习到更全面的信道特征。这种全方位、多视角的数据使CFM得以掌握信道动态的底层物理规律，从而在所有下游任务中实现更优的泛化性能。

## 3 CFM预训练方法

尽管CFM的概念相对较新且仍处于早期发展阶段，但已有部分研究在方法设计和应用目标上与CFM的定义及目标高度契合，值得进行系统性梳理与总结。

为便于分析与对比，本文根据自监督预训练策略的差异，将CFM的预训练方法划分为以下3类：生成式方法、判别式方法，以及生成-判别混合方法。

### 3.1 生成式

生成式预训练方法的核心思想在于通过建模输入数据的底层分布，学习具备泛化能力的特征表示。这类方法通常以重构任务为训练目标，能够有效捕捉信道数据中的局部与全局特征，兼具较强的泛化能力与多模态适配性，是一种高效的预训练策略。其中最具有代表性的是掩码重建方法，典型的流程如图3所示，以WiFo<sup>[8]</sup>和WirelessGPT<sup>[9]</sup>为例，该方法通过随机掩码部分CSI块，迫使模型学习从残缺输入中重建完整信道特征的能力。掩码策略的设计确保了模型能够捕捉信道的全局结构与局部依赖关系，而编码器-解码器架构的采用则实现了从特征提取到信号重建的端到端优化。

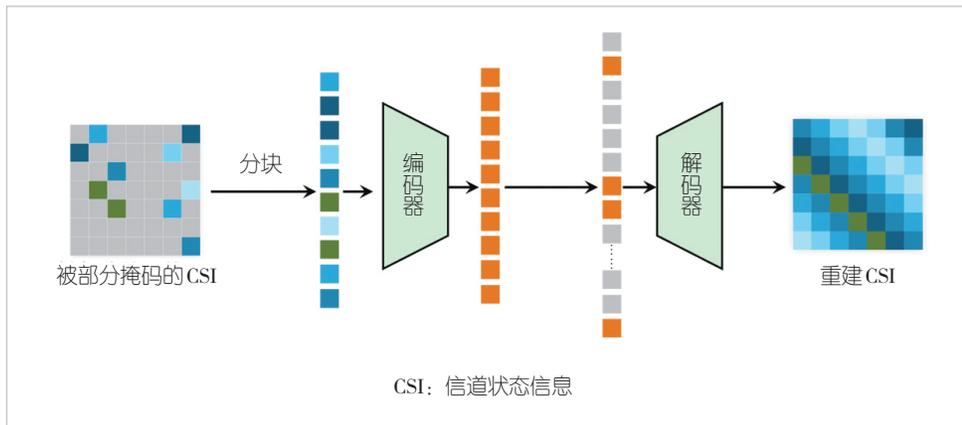


图3 生成式(掩码重建)的基本流程

优势互补。融合两种范式优势的混合方法，能够同时从数据中学习结构信息与判别性特征，从而有效提升模型的表达能力与泛化能力。该类方法综合了生成式与判别式预训练策略的各自优势，使模型能够在同一框架下同时学习丰富的结构特征与具有判别力的特征表示。混合方法在提升模型泛化能力方面展现出显著潜力。已有研究工作<sup>[11-12]</sup>表明，混合方法相比单一范式方法具有更

强的性能表现。该方向有望成为CFM研究的重要演进路径。

### 3.2 判别式

判别式预训练方法的核心在于通过区分不同样本或构建正负样本对来学习判别性特征表示。与生成式方法不同，这类方法不依赖数据重构，而是通过衡量样本间的相似性实现训练目标，因此在部分下游任务中展现出更强的泛化能力与迁移性能。

对比学习作为判别式方法在CFM构建中的核心自监督手段，通过构造正负样本对，引导模型精准捕捉并区分不同样本，进而学习到更具表征能力的高维信道特征，典型的流程如图4所示。在现有研究中，CSI-CLIP<sup>[10]</sup>等模型创新性地利用信道数据的时域-频域对偶特性构建正样本对，以最大化同类样本相似度、最小化异类样本距离为优化目标，使模型能够自动捕捉信道的内在物理特性，从而在下游任务中实现优异的性能表现。

### 3.3 生成-判别混合

生成式方法与判别式方法并非互斥关系，反而能够形成

## 4 CFM的可能应用及6G内生智能

CFM 凭借其优异的泛化性、适应性与可扩展性，已确立为6G内生智能的重要技术路径及AI赋能的核心载体，正在物理层、无线接入网及通感一体化三大关键场景中，全面驱动6G系统的智能化升级。

### 4.1 CFM赋能物理层

在无线通信物理层的研究与实际部署中，CFM 凭借其强大的通用特征提取与迁移能力，已成为突破传统技术瓶颈的核心工具之一，在信道估计、信道反馈、波束赋形优化等诸多应用场景中展现出显著优势。

传统方法通常依赖特定场景下的大量带标签数据进行模型训练。然而，当面临信道环境突变或样本数据稀缺时，这类模型的估计精度会大幅下降，甚至出现失效情况。相比之下，CFM 作为6G内生智能的一种实现路径，通过在涵盖多

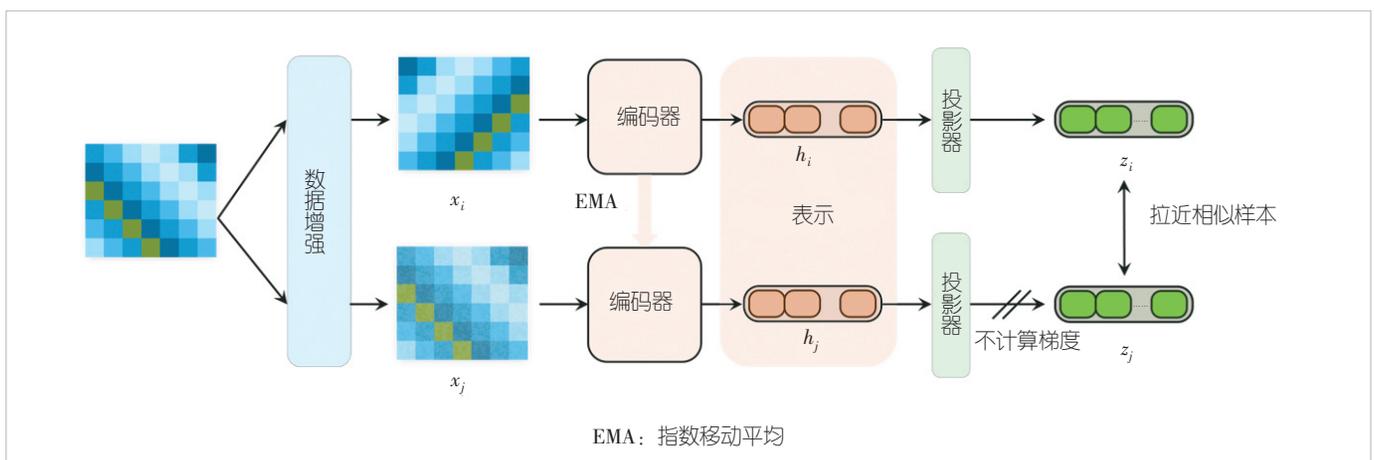


图4 判别式(对比学习)的基本流程

频段、多地形、多干扰条件的大规模多样化信道场景中进行预训练，能够学习到具有泛化能力的信道底层特征。将这些通用特征迁移至特定信道估计任务后，可有效降低模型对目标场景带标签数据的依赖，即便在数据有限或环境动态变化的情况下，仍能保持稳定的估计性能。

#### 4.2 CFM赋能无线接入网

无线接入网（RAN）作为用户终端与核心网之间的关键接口，其资源调度效率与干扰控制能力直接决定了用户体验质量。CFM 凭借其复杂网络环境的建模与分析能力，正推动 RAN 核心任务的智能化升级，助力 RAN 从“被动优化”向“主动自适应”的范式转型。以波束管理为例，现有 5G 网络在人口密集城区部署时面临诸多挑战：用户密度高、建筑物遮挡严重、信道条件动态变化快。传统波束选择方法多依赖固定信道模型或简单信号强度检测，易因波束重叠引发小区间干扰，从而限制网络整体容量的提升。而 CFM 所支持的动态波束选择机制，则能够实现更精细化的优化调控。总体而言，CFM 为 6G 内生智能的实现提供了核心技术支撑，推动无线接入网向具备自组织、自优化、自修复能力的高阶智能形态持续演进。

#### 4.3 CFM赋能通感一体化

在通感一体化领域，通信与感知在信号处理目标与特征需求上存在本质差异：通信系统以降低误码率为核心目标，重点关注信号的调制解调特性；感知系统则以提升定位精度为核心诉求，高度依赖目标散射特性。二者在目标导向与特征侧重上的根本性差异，为技术融合带来了严峻挑战。

在此背景下，CFM 凭借其多模态信道特征的统一建模与协同优化能力，成为破解这一难题的变革性方案。以智能交通场景为例，基于 CFM 的融合处理框架能够同时提升车辆定位与通信性能。该框架通过挖掘多模态信道特征的内在关联性，构建统一的特征表示空间，有效打破了通信与感知技术之间的壁垒，为 6G 通感一体化网络的实际部署提供了可行的技术路径。

#### 4.4 CFM有效性验证

为验证 CFM 的有效性、泛化能力及任务适应性，本文基于 CSI-CLIP 框架，选用 Vision Transformer (ViT) 作为编码器开展实验验证。同时，引入无预训练的 ViT 模型作为基线模型，以进行对比分析。

预训练数据基于 DeepMIMO 数据集构建，共包含超过 70 万条样本，覆盖 35 个典型通信场景。该数据集涵盖室内外

多种环境类型，工作频段从 Sub-6 GHz、毫米波延伸至太赫兹，全面覆盖了无线通信的关键频谱资源，为模型泛化能力的验证提供了充足的场景支撑。

据场景下的核心价值，为 CFM 适配无线通信数据稀缺场景提供了实证支撑。

如表 2 所示，在定位任务中，当面对有限的新场景微调数据时，CFM 无须从零开始学习任务特征，仅通过轻量化微调即可将预训练阶段习得的通用特征有效迁移至定位任务。这一机制不仅大幅降低了对带标签数据的依赖，还有效抑制了小样本条件下易出现的过拟合问题。

反观无预训练的基线模型，在少量数据微调时极易陷入过拟合，导致定位误差显著偏高。随着微调数据量的增加，基线模型的过拟合现象虽有所缓解，但 CFM 仍展现出持续且明显的性能增益。这一结果进一步印证了预训练特征在数据稀缺场景下的核心价值，为 CFM 适配无线通信中普遍存在的数据样本受限问题提供了有力的实证支撑。

表 3 所示的数据清晰呈现了 CFM（以 CSI-CLIP 为代表）与基线模型在波束预测任务中的性能差异，进一步印证了 CFM 在信道相关任务中的适配优势。整体而言，CSI-CLIP 在所有 6 个测试场景中均取得了优于基线的表现，性能提升

表 2 城市场景下 CSI-CLIP 对比基线的定位误差与性能提升(误差:m)

场景	微调数据	验证数据	基线/%	CSI-CLIP/%	性能提升/%
Philadelphia	503	126	34.10	19.91	41.61
Los Angeles	592	148	49.03	34.18	30.29
New York	1 026	257	41.19	36.15	12.24
Columbus	1 148	288	17.60	14.48	17.73
San Francisco	1 326	332	19.78	14.17	28.36
Austin	1 482	371	14.16	8.95	36.79
Phoenix	2 163	541	10.65	9.34	12.30
Oklahoma	2 764	691	18.87	16.74	11.29
Indianapolis	2 720	439	48.08	46.39	3.51
平均	—	—	—	—	21.57

表 3 不同城市场景下 CSI-CLIP 对比基线的波束预测准确率对比

场景	基线/%	CSI-CLIP/%	性能提升/%
Los Angeles	75.68	78.38	2.70
Chicago	87.72	89.47	1.75
Fort Worth	82.94	84.78	1.84
Columbus	62.85	65.63	2.78
Charlotte	77.53	80.18	2.08
Indianapolis	77.53	80.18	2.65

幅度介于 1.75%~2.78%，平均提升约 2.3%，充分体现了通过预训练积累的信道特征对波束预测任务的有效增益。

值得指出的是，尽管波束预测任务的整体性能提升幅度相对有限，但 CFM 在保持模型参数规模与推理时延不变的前提下，仍能实现稳定的性能增益。这一结果进一步验证了其“泛化能力-部署效率”的均衡优势，为 CFM 作为 6G 内生智能的可行技术路径之一提供了有力的实证支撑。

## 5 结束语

本文首先阐述了对 6G 内生智能内涵与需求的理解，指出未来 6G 内生智能需具备强大的任务适应性与场景泛化能力。在对 AI 模型演进范式进行系统分析的基础上，揭示了传统 AI 模型难以满足上述需求的固有局限。进而，本文系统介绍了 CFM 的构建方法、核心技术特征及其潜在应用场景。随着 6G 内生智能技术的持续演进，我们认为 CFM 有望成为支撑 6G 内生智能的关键技术选项之一，并在 6G 通感一体化网络等新兴场景中发挥更为重要的作用。

## 参考文献

- [1] Gao Y, Lu Z C, Wu X Y, et al. AI-driven channel state information (CSI) extrapolation for 6G: current situations, challenges, and future research [J]. IEEE communications surveys & tutorials, 2026, 28: 4485-4518. DOI: 10.1109/COMST.2026.3652799
- [2] Pan G J, Gao Y, Gao Y L, et al. AI-driven wireless positioning: fundamentals, standards, state-of-the-art, and challenges [J]. IEEE communications surveys & tutorials, 2026, 28: 4394-4428. DOI: 10.1109/COMST.2025.3648577
- [3] Wang X P, Guan K, He D P, et al. Super-resolution of wireless channel characteristics: a multitask learning model [J]. IEEE transactions on antennas and propagation, 2023, 71(10): 8197-8209. DOI: 10.1109/TAP.2023.3305096
- [4] Jiang J, Yu W J, Gao Y, et al. MTCA: multi-task channel analysis for wireless communication [C]//Proceedings of IEEE 102nd Vehicular Technology Conference (VTC2025-Fall). IEEE, 2025: 1-6. DOI: 10.1109/VTC2025-Fall65116.2025.11310525
- [5] Wiggins W F, Tejani A S. On the opportunities and risks of foundation models for natural language processing in radiology [J]. Radiology: artificial intelligence, 2022, 4(4): e220119. DOI: 10.1148/ryai.220119
- [6] Davaslioglu K, Boztaş S, Ertem M C, et al. Self-supervised RF signal representation learning for NextG signal classification with

- deep learning [J]. IEEE wireless communications letters, 2023, 12(1): 65-69. DOI: 10.1109/LWC.2022.3217292
- [7] Chafaa I, Negrel R, Belmega E V, et al. Self-supervised deep learning for mmWave beam steering exploiting sub-6 GHz channels [J]. IEEE transactions on wireless communications, 2022, 21(10): 8803-8816. DOI: 10.1109/TWC.2022.3170104
- [8] Liu B X, Gao S J, Liu X Y, et al. WiFo: wireless foundation model for channel prediction [J]. Science China information sciences, 2025, 68(6): 162302. DOI: 10.1007/s11432-025-4349-0
- [9] Yang T T, Zhang P, Zheng M F, et al. WirelessGPT: a generative pre-trained multi-task learning framework for wireless communication [J]. IEEE network, 2025, 39(5): 58-65. DOI: 10.1109/MNET.2025.3579496
- [10] Jiang J, Yu W J, Li Y F, et al. A MIMO wireless channel foundation model via CIR-CSI consistency [C]//Proceedings of IEEE International Conference on Machine Learning for Communication and Networking (ICMLCN). IEEE, 2025: 1-6. DOI: 10.1109/ICMLCN64995.2025.11140262
- [11] Pan G J, Huang K X, Chen H, et al. Large wireless localization model (LWLM): a foundation model for positioning in 6G networks [PP/OL]. arXiv[2026-01-05]. <https://arxiv.org/abs/2505.10134>
- [12] Guler B, Giovanni G, Hamid J. Robust channel representation for wireless: a multi-task masked contrastive approach [EB/OL]. [2026-01-05]. <https://openreview.net/pdf?id=KXNDs9ZGb9>

## 作者简介



徐树公，西交利物浦大学教授、IEEE Fellow；主要研究领域包括基础模型、无线 AI、多模态感知等；带领学生团队连续 5 年获得全国无线 AI 类算法竞赛前 3 名；已发表论文 200 余篇，获授权专利 80 余项。



蒋骏，上海大学在读博士研究生；主要研究领域包括基础模型、无线 AI；已发表论文 5 篇。