

DOI:10.16356/j.1005-2615.2025.05.003

大语言模型驱动的通信制式识别的挑战、机遇与应用前景

陈 思, 胡力凡, 章伟杰, 唐甜甜, 桂 冠

(南京邮电大学通信与信息工程学院, 南京 210003)

摘要: 随着无线通信技术的快速演进, 5G、Wi-Fi 和窄带物联网 (Narrowband internet of things, NB-IoT) 等多种通信制式并存, 网络结构与信道环境的复杂性显著提升, 使通信制式识别在频谱管理、干扰抑制与安全监测中的作用愈加重要。传统依赖人工特征与规则的方法在动态复杂场景及未知协议下适应性有限, 而深度学习通过端到端建模与自动特征提取显著提升了识别精度与鲁棒性, 但其在跨制式泛化、数据稀缺与计算开销方面仍面临瓶颈。以大语言模型与多模态模型为代表的大规模预训练模型凭借强泛化、跨任务迁移和少样本学习能力, 展现出在复杂通信制式识别中的巨大潜力。本文系统梳理了通信制式识别技术的发展脉络, 重点探讨了大语言模型驱动方法的最新进展, 剖析了其在泛化能力、可解释性与高效部署等方面所面临的挑战, 挖掘了其在智能频谱管理与安全监测中的应用机遇, 并展望了其在 5G/6G 智能网络管理中的发展前景。

关键词: 信号与信息处理; 机器学习; 深度学习; 通信制式识别; 大语言模型

中图分类号: TN911.71

文献标志码: A

文章编号: 1005-2615(2025)05-0822-09

Challenges, Opportunities, and Future Directions of Large Language Model Empowered Wireless Technology Recognition

CHEN Si, HU Lifan, ZHANG Weijie, TANG Tiantian, GUI Guan

(School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications,
Nanjing 210003, China)

Abstract: With the rapid evolution of wireless communication technologies, multiple standards such as 5G, Wi-Fi, and narrowband internet of things (NB-IoT) coexist, which lead to significantly increased complexity in network architectures and channel environments. This makes wireless technology recognition increasingly vital for spectrum management, interference mitigation, and security monitoring. Traditional methods relying on handcrafted features and rule-based approaches exhibit limited adaptability in dynamic and complex scenarios, particularly when facing unknown protocols. Deep learning has substantially improved recognition accuracy and robustness through end-to-end modeling and automatic feature extraction. However, it still encounters bottlenecks in cross-standard generalization, data scarcity, and computational overhead. In recent years, large-scale pre-trained models, represented by large language models and multimodal models, have demonstrated remarkable potential in complex wireless technology recognition owing to their strong generalization, cross-task transfer, and few-shot learning capabilities. This paper provides a systematic review of the development of wireless technology recognition, with a focus on the latest advances driven by large language models. We analyze the challenges related to generalization ability, interpretability, and efficient deployment, explore the opportunities in intelligent spectrum management and security monitoring,

收稿日期: 2025-06-25; 修订日期: 2025-08-26

通信作者: 桂冠, 男, 教授, 博士生导师, E-mail: guiguan@njupt.edu.cn。

引用格式: 陈思, 胡力凡, 章伟杰, 等. 大语言模型驱动的通信制式识别的挑战、机遇与应用前景[J]. 南京航空航天大学学报(自然科学版), 2025, 57(5): 822-830. CHEN Si, HU Lifan, ZHANG Weijie, et al. Challenges, opportunities, and future directions of large language model empowered wireless technology recognition[J]. Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition), 2025, 57(5): 822-830.

and finally present a forward-looking perspective on their potential applications in intelligent network management for 5G/6G.

Key words: signal and information processing; machine learning; deep learning; wireless technology recognition; large language models

随着信息技术的不断发展和应用,全球通信行业经历了前所未有的变革。从2G到5G,乃至展望中的6G,无线通信技术不仅在传输速率和覆盖范围上不断突破,更在网络容量、连接密度和频谱效率等关键指标上实现了数量级提升^[1-2]。同时,无线接入技术呈现出前所未有的多样化趋势,除了传统的蜂窝网络外,Wi-Fi、蓝牙、ZigBee、窄带物联网(Narrowband Internet of things, NB-IoT)和LoRa等多种通信制式在各垂直行业广泛应用,构成了支撑智慧城市、工业互联网和智能交通等场景的复杂异构网络^[3-4]。这种多制式共存的局面使得网络架构与电磁环境日益复杂。不同制式在非授权频谱下的共存与互干扰问题如图1所示。设备在不同网络间无缝切换的需求,对通信制式的识别提出了极高要求^[5]。



图1 不同通信制式干扰示意图

Fig.1 Interference diagram between different wireless technologies

准确、实时的通信制式识别是频谱资源动态分配、网络干扰协同管理、无线安全监测及用户体验保障的基础^[6]。在智能城市中,设备需要自动识别并切换至最佳的通信协议,这对于实现低功耗、低延迟和高效数据传输至关重要。如果识别不准确,可能会导致设备间的通信中断、响应延迟增加,影响整体系统的运行效率^[7-8]。在军事通信领域,战场上充满了来自敌方、友军和无人系统的无线信号,及时识别敌方通信协议或加密方式,并迅速做出反应,对于确保通信系统的安全性和有效性至关重要^[9-10]。

为应对这一挑战,通信制式识别技术在不断演进。早期的传统通信制式识别方法,往往依赖于基于规则的静态特征提取技术,如时域和频域特征分析、决策树以及支持向量机(Support vector machine, SVM)等^[11-12]。这些方法通常需要手工设计特征,依赖大量标注数据进行训练,并且在面对未

知协议、低信噪比或动态变化的环境时,其泛化能力和鲁棒性显著下降^[13]。随着人工智能技术的兴起,深度学习方法为通信制式识别带来了革命性的进步。基于卷积神经网络(Convolutional neural network, CNN)和长短期记忆网络(Long short-term memory, LSTM)的模型能够直接从原始同相和正交分量(In-phase and quadrature-phase, IQ)数据或时频图中进行端到端的特征学习与分类,避免了繁琐的人工特征工程,并在许多公开数据集上取得了接近完美的识别精度^[14-15]。然而,深度学习训练和测试都是在预先定义好的、固定的制式类别集合上进行,一旦应用于真实开放环境,面对训练时未曾见过的全新或未知通信制式,深度学习模型往往会误判,甚至可能会造成严重的后果。

大语言模型在自然语言处理、多模态理解与推理方面展现出很强的能力,其核心优势在于强大的泛化性、深层的语义理解能力和上下文学习机制^[16-17]。将大语言模型引入通信制式识别,为解决传统方法面临的诸多瓶颈提供了新的技术路径。传统通信制式识别方法通常依赖单一输入,基于底层信号特征进行分类,严重依赖信噪比,抗干扰能力有限。同时,常规分类器难以主动利用通信协议本身的结构性先验信息,在区分调制方式相近的制式时易产生混淆^[18-19]。大语言模型能够融合多源信息,不仅可处理原始IQ信号或时频谱,还可嵌入循环谱、高阶统计量、带宽标签和同步信号检测结果等多类特征,并将其统一表示为Token序列,输入Transformer或多模态架构进行联合建模。大语言模型还能够嵌入通信协议的结构性先验知识,例如5G信号的帧结构等,将“协议语法”以Token形式与信号特征共同处理,从而实现对通信信号的深层语义理解与推理^[20-23]。

本文在系统回顾传统方法与深度学习方法发展的基础上,重点分析了大模型驱动的通信制式识别的核心优势与关键挑战,探讨了其在智能频谱管理、安全监测等场景中的应用机遇,并展望了其在5G/6G智能网络管理中的前景。本文的贡献在于从“挑战-机遇-应用前景”的视角,为未来通信制式识别研究提供参考路径。

1 现有通信制式识别方法

1.1 基于传统机器学习的通信制式识别方法

在深度学习兴起之前,通信制式识别主要依赖

于传统机器学习方法。研究者首先利用信号处理领域的先验知识,从原始 IQ 信号中手工设计和提取能够区分不同制式的特征向量,然后将这些特征向量输入到分类器中进行判决。

分类器主要有 SVM、决策树、K 近邻以及隐马尔可夫模型 (Hidden Markov model, HMM) 等。Petrova 等^[24]利用高斯核 SVM 构建 7 类信号的多类分类器,在 1 024~4 096 样本段、0~30 dB 信噪比的多径信道条件下取得 85%~98% 的识别准确率。Hu 等^[25]将谱相关分析抽取的四维特征输入非线性 SVM,在 4 dB 信噪比、1 000 样本条件下整体正确率超过 92.8%。为了进一步降低特征维度与计算复杂度,He 等^[26]提出将谱相关特征嵌入 HMM 先验概率估计,再以 SVM 进行二阶精细判别,构建 HMM/SVM 双层架构,在信噪比从 -5~15 dB 范围内对 5 类信号实现 80%~100% 的识别率。后续研究通过特征工程进一步降低网络复杂度,文献[27]利用瞬时包络、高阶累积量及谱峰系数构造九维特征,结合二叉树结构的多个 SVM 分类器,在 10 dB 以上实现对 10 类信号 95% 以上的识别率。

尽管传统机器学习方法在通信制式识别中展现出一定的应用潜力,但其性能高度依赖于手工特征的质量,特征设计需要深厚的领域专业知识,不仅繁琐而且主观性强,所获特征往往难以达到最优表征效果^[28]。同时这些为特定制式和环境设计的特征,在面对未知协议、复杂多径衰落或动态变化的干扰时,其区分度会急剧下降,导致泛化能力严

重不足。整个系统缺乏自适应能力,任何新制式的出现都意味着需要重新进行特征工程和模型训练,难以满足开放动态环境的应用需求。

1.2 基于深度学习的通信制式识别方法

随着无线通信环境日益复杂,传统机器学习方法被深度学习方法取代,成为通信制式识别领域的研究热点。通过构建深层神经网络,模型可以直接从原始信号或简单的变换域数据中自动学习具有高度区分性的层次化特征,从而避免了繁琐且主观的人工特征工程。

基于深度学习的通信制式识别方法如表 1 所示。Girmay 等^[14]提出了一个基于 CNN 的通信制式识别与流量特征提取系统,在 5.9 GHz 智能交通系统 (Intelligent transportation system, ITS) 频段实现了对 LTE、第 5 代新空口技术 (5th generation new radio, 5G NR)、Wi-Fi、蜂窝车联网 (Cellular vehicle-to-everything PC5 interface, C-V2X PC5) 和 ITS-G5 等 5 种技术的识别,在低信噪比的条件下,高采样率的 CNN 模型可达到 96% 以上的分类准确率。Bitar 等^[15]设计了一种 5 层 CNN 架构,针对 2.4 GHz 的 Wi-Fi、ZigBee 和蓝牙信号进行识别,在 30 dB 信噪比条件下实现了 93% 的分类准确率。常见的 CNN 结构示意图如图 2 所示,输入是一个代表功率-频率特性的二维矩阵,表示为

$$\mathbf{X}_s = [x_{i,j}]_{N \times M} \quad i = 1, 2, \dots, N; j = 1, 2, \dots, M \quad (1)$$

式中: N 为频率点数, M 为时间点数, $x_{i,j}$ 表示第 i 个频率点在第 j 个时间点的功率值。

表 1 基于深度学习的通信制式识别方法

Table 1 Deep learning-based methods for wireless technology identification

模型	识别制式	分类准确度/%
CNN ^[14]	LTE, 5G NR, Wi-Fi, C-V2X PC5, ITS-G5	97.50
CNN (5-layer) ^[15]	Wi-Fi, Zigbee, Bluetooth	93.00
WiST-ID (CNN+ST) ^[29]	29 种无线标准 (AM/FM/TV/蜂窝/WLAN/WPAN 等)	98.91
DeepSpectrum ^[30]	Wi-Fi, Zigbee, LoRa, Bluetooth	99.00
Spike CNN (SNN) ^[31]	ITS-G5, C-V2X, Wi-Fi, LTE, 5G NR, Noise	92.40




图 2 神经网络示意图

Fig.2 Neural network architecture

经过卷积-池化层组进行特征提取,最后连接一个全连接层。网络的最终输出通过 Softmax 函数转换为类别概率分布,即

$$\psi_i(\mathbf{y}') = \frac{e^{y_i}}{\sum_k e^{y_k}} \quad (2)$$

式中: $\psi_i(\mathbf{y}')$ 表示样本属于第 i 类的概率; $\mathbf{y}_i$ 为全连接层的输出向量; k 为总类别数。

对于具有显著时序特征的通信信号,循环神经网络及其变体 LSTM 能够捕捉信号的长期依赖关

系。Rajendran等^[32]提出了一种基于LSTM的调制分类模型,直接利用信号的时域幅度与相位信息作为输入,无需人工设计特征。在RadioML 2016.10a数据集上,该模型在0~20 dB信噪比范围内实现了90%的平均分类准确率。深度学习模型的性能高度依赖于输入数据的质量与表征形式。S变换因其高时频分辨率和相位保持能力,被Behura等^[29]用于构建WiST-ID系统,实现了对29种无线标准技术的盲识别。实验表明,S变换预处理的CNN模型在10 dB信噪比下对大尺度数据集的分类准确率达98.91%,优于短时傅里叶变换和连续小波变换。Su等^[30]提出DeepSpectrum系统进一步将信号识别问题转化为频谱图上的目标检测任务,通过YOLO架构实现了对Wi-Fi、ZigBee、LoRa和蓝牙的多信号重叠识别。

尽管深度学习模型在精度上表现优异,但其高计算复杂度限制了在资源受限设备上的部署。为此,研究者提出了多种轻量化方案。Rajendran等^[32]通过量化将LSTM模型的计算量减少至原来的1/32,在ARM处理器上实现了接近80%的分类准确率。Hu等^[31]提出的脉冲神经网络(Spiking neural network, SNN)利用漏电积分放电模型神经元和替代梯度方法,在保持92.4%识别准确率的同时,功耗仅为传统CNN的1/10。

深度学习方法在特定数据集上实现了近乎完美的识别精度,并大幅减轻了对专家知识的依赖。但基于深度学习的通信制式识别方法依旧存在弊端,深度学习模型本质上是在一个预先定义好的、固定的制式类别集合上进行训练和测试。一旦在真实环境中遇到训练时未曾见过的全新或未知制式,模型会将其归类为某个已知类别,导致置信度很高的错误判决。且深度模型的优异性能建立在海量标注数据的基础上,获取大量尤其是未知新制式的标注信号数据在现实中极其困难且成本高昂。

1.3 现有方法的潜在不足

通信制式识别技术虽已从依赖手工特征的传统机器学习,演进到能够自动提取特征的深度学习阶段,但其核心范式仍未突破“模式匹配”的范畴。无论是传统方法还是深度方法,都难以解决开放环境下的未知制式识别这一核心挑战。前者受限于特征工程的泛化能力,后者则受限于“封闭集”假设和数据依赖。

真实世界的电磁频谱是开放、动态且持续演进的。因此下一代通信制式识别技术迫切需要一种能够理解通信“语义”、具备知识推理能力和少样本学习能力的新范式。为有效应对上述挑战,研究者开始探索新一代智能通信识别技术体系。近年来在自然语言处理等领域取得突破性进展的大语言模型,

因其恰好具备强大的泛化、推理和上下文学习能力,为破解这一困境带来了曙光。因此,下文将系统阐述基于大语言模型的通信制式识别的研究现状。

2 大语言模型在通信制式识别中的研究现状

2.1 基于大语言模型的通信制式识别

大语言模型是一类基于深度学习的统计语言模型,通常采用以Transformer为核心的编码器-解码器架构,通过在大规模文本语料上进行自监督预训练,获得对自然语言的深度理解与生成能力^[33],结构图如图3所示。将大语言模型应用于通信制式识别,能够有效克服传统方法的局限性。大语言模型凭借其强大的多信息融合能力,可以整合IQ序列、时频谱、循环谱特征以及高阶统计特征等多种信息,突破了传统方法依赖单一底层信号特征的瓶颈。大语言模型能够嵌入通信协议的先验知识,还具备可解释性和泛化能力,不仅能够准确识别通信制式,还能解释识别过程,并能通过少量样本的微调适应新的识别需求。




图3 大语言模型结构示意图

Fig.3 Architecture of large language model

将大语言模型应用到通信制式识别中,其核心思想在于:将通信系统视为一种特殊的“语言”。其中,协议规范、标准文本是这种语言的“语法书”,而空中传播的信号则是这种语言的“语句”或“对话”。将信号与协议知识一同嵌入到高维语义空间,大语言模型通过理解信号的“语义”及其与先验知识的上下文关联,进行推理和判断,尝试回答的是“这个信号是什么,以及它为何如此”的问题。这种转变使得大语言模型能够利用在海量文本语料中预训练获得的强大知识表征、逻辑推理和上下文学习能力来处理通信识别问题,为实现通用化、智能化的频谱感知提供了全新的技术路径。

2.2 大语言模型在通信制式识别中的研究进展

基于上述框架,研究者们已提出了一系列创新性方案,展现了大语言模型在该领域的巨大潜力。

基于大语言模型的通信制式识别方式如表2所示。Lotfi等^[34]在2025年提出的提示词增强的多智能体强化学习框架首次将领域专用大语言模型ORANSight引入开放式无线接入网(Open radio access network, O-RAN)切片场景,通过可学习提

表 2 基于大语言模型的通信制式识别方法对比

Table 2 Comparison of large language model-based methods for wireless technology recognition

模型/框架	创新点	作用
Prompt-Augmented MARL ^[34]	可学习提示生成“制式-频谱-负载”描述	语义描述生成器、智能体先验
RadioLMM ^[35]	混合提示与 Token 重编程	推理引擎、分类器
KG-WTR ^[36]	通信协议知识图谱增强	知识感知的推理引擎
TF-Transformer ^[37]	文本-频谱图跨模态注意力	多模态信息融合器

示动态生成“制式-频谱-负载”三元组语义描述,显著提升了未知协议出现时的零样本识别能力。同样,Chen 等^[35]提出的 RadioLMM 采用混合提示与词元重编程,将 Wi-Fi 信标帧解析为“802.11ax、160 MHz、OFDMA”等关键词序列,通过语义匹配实现协议软对齐,有效地提升了少样本场景下的识别率。

研究人员也在尝试将通信协议规范编码为结构化知识图谱,注入大语言模型推理链。Li 等^[36]的 KG-WTR 模型构建了通信协议知识图谱,并利用人工智能大型语言模型家族(Large language model family of AI, LLaMA-2)的大上下文窗口实现长程规范检索。当检测到未知信号时,模型能通过推理“协议-频段-调制”三元组关系做出判断,显著提升了在未知波形出现时的鲁棒性。同样,Liu 等^[37]提出的 TF-Transformer 将大语言模型的文本编码器与频谱图 CNN 通过交叉注意力机制融合,将协议描述文本作为查询(Query),频谱图的时-频 patch 作为键-值(Key-Value),实现语义引导的局部频谱聚焦。在 OFDM2024 数据集上,该模型对 5G 非授权频谱与授权辅助接入的 LTE 的区分准确率达 89.19%,相比于 CNN 提升 37.98%。Chen 等^[38]的 ResNet-Transformer 混合架构通过残差路径将大语言模型的全局协议语义与 CNN 的局部正交信号特征耦合,在 -6 dB 信噪比下对扩频因子 12 的 LoRa 调制的识别率仍保持 82%。

2.3 大语言模型在通信制式识别中的优势与挑战

2.3.1 核心优势

在开放、动态且协议栈持续演进的 6G 频谱环境中,传统深度学习方法往往受限于“封闭集”假设,即训练阶段需要穷举所有可能出现的制式类别。因此,新出现的私有协议、定制化物联网波形以及应急通信制式常常超出既有标签空间,会导致模型在推理阶段直接失效。大语言模型凭借以下 4 项核心能力,为未知制式识别提供了前所未有的解决方案。

(1) 零样本/少样本的语义泛化

大语言模型在海量文本语料上习得的“通信语言”先验,使其能够利用自然语言描述即可对齐未知制式的关键特征。具体而言,当接收端捕获到一段未知信号时,系统仅需通过文本提示给出该制式

的规范摘要或频谱特征描述,大语言模型即可在嵌入空间内将文本语义与信号表征进行跨模态匹配,实现零样本分类^[39]。

(2) 知识图谱注入的规范推理

大语言模型可与通信协议知识图谱无缝集成,通过检索“协议-频段-调制-帧结构”四元组,对未知波形进行结构化推理。例如,当检测到中心频点 902 MHz、带宽 125 kHz 的信号时,大语言模型通过知识图谱链路推断其极大概率属于远距离广域网(Long range wide area network, LoRaWAN) US902-928 子带,从而在未显式训练该子带的情况下完成制式归属判断。该机制显著降低了对大规模标注数据的依赖,并提升了系统对新规范的响应速度^[40]。

(3) 上下文自适应与持续学习

大语言模型的上下文窗口允许在推理阶段动态引入最新标准文档或设备厂商白皮书,实现“即时知识更新”。当监管频段新增 60 GHz 车联网时,运维人员只需将协议文本嵌入提示,大语言模型即可在无需重训模型的条件识别该制式。实验表明,在持续学习框架下,大语言模型对新增协议的适应仅需 3~5 条文本描述即可收敛,而传统深度网络需完整重训并重新采集数千条射频样本^[41-42]。

(4) 高精度的信号识别

大语言模型具有强大的上下文理解能力,可以捕捉到通信信号中的细微变化和长时间的依赖关系。通信信号通常具有复杂的时序结构,传统的识别方法往往难以处理这些长时间依赖,而大语言模型利用其自注意力机制,能够有效分析长时序数据,捕捉信号之间的细微差异,从而提高识别的准确性^[43]。

采用大语言模型后,通信制式识别系统在零样本与少样本场景下对未知制式的识别准确率将大幅提高,能够显著降低对大规模标注数据的依赖。同时借助动态知识注入与上下文学习机制,模型更新与协议适应速度将显著加快,实现近乎实时的知识集成与推理响应。模型在低信噪比、多制式共存等复杂信道条件下的鲁棒性也将得到进一步增强,从而为开放频谱环境下的可靠感知提供坚实支撑。

2.3.2 主要挑战

(1) 高计算资源需求

大语言模型虽然在各个领域都取得了显著的成果,但其巨大的计算资源需求也是不可忽视的挑战。尤其是在处理大规模通信信号数据时,大语言模型通常需要进行大规模的计算,涉及大量的参数和复杂的模型结构,会消耗大量的计算资源和存储空间^[44]。对于基于大语言模型的通信制式识别来说,低延迟和高效的计算能力是必不可少的。在针对特定的通信协议识别任务中,模型的推理过程也可能面临较大的计算压力,导致无法实时响应。因此,针对设备资源有限的场景,如何减少计算负担,使得大语言模型能够在边缘计算或移动设备上高效运行,将是技术发展的一个重要方向。

(2) 实时性与动态适应性

通信环境中的信号特征是高度动态变化的,尤其在复杂的无线网络中,设备的移动、网络负载的变化、环境干扰等因素都会导致信号特征的波动,因此需要保证基于大语言模型的通信制式识别系统能够实时识别并适应这些动态变化^[45]。当前,虽然大语言模型具有较强的自适应性和学习能力,但仍然面临着如何在高速变化的网络环境中保持实时识别的问题。特别是在一些应用场景中,通信信号的快速变化可能会导致系统反应不及时,从而影响整体性能和安全性。为了保证模型的实时性和稳定性,需要平衡模型的复杂性与计算效率,并有效处理动态变化的信号环境。

(3) 安全性与隐私问题

在大语言模型的应用中,安全性和隐私是不可忽视的问题。通信信号中可能涉及到大量的敏感数据,如用户的身份信息、设备通信内容等,因此需要在保护用户隐私的同时高效地识别通信制式,尤其是在军事通信、医疗通信等领域,对数据的保密性和安全性要求极高^[46-47]。

3 基于大语言模型的通信制式识别未来发展方向

3.1 多模态学习与跨领域协同

随着通信技术的不断演进,未来的通信制式识别不能再仅依赖单一的信号数据。单一模态往往难以全面刻画复杂环境下的通信行为,特别是在多径衰落、异构网络共存以及协议栈快速迭代时,传统方法依赖有限的手工特征,在动态变化场景下容易失效,难以满足实际应用中对鲁棒性与泛化能力的要求。

大语言模型为通信制式识别提供了新的思路,能够融合多源异构信息。(1) 可以融合物理层IQ信号、时频谱特征和循环谱特征等低层特征,与网络拓扑、设备行为日志和业务流量模式等高层信息联合建模,实现跨模态特征对齐^[48]。(2) 跨领域协

同可以将大语言模型与频谱感知平台、网络管理系统和交通监测系统等其他智能系统深度集成,借助外部知识提升识别的准确性与鲁棒性。通过多模态学习与跨领域协同,未来的通信制式识别将突破“信号孤立识别”的局限,形成覆盖“信号-语义-场景”的全栈式智能感知框架。这不仅能够显著提升未知制式识别与跨场景泛化能力,还将为智能频谱管理、跨域干扰治理和6G网络的自适应优化提供重要支撑。

3.2 边缘计算与轻量化模型

大语言模型在通信制式识别中展现出显著优势,但其庞大的参数规模和高计算开销限制了其在低延迟、低功耗场景中的落地应用。特别是在无人机、车联网终端和物联网节点等算力有限的设备上,传统依赖云计算的模式会带来过高的通信开销和响应延迟,难以满足实时识别和快速响应的需求。

为应对算力瓶颈,可以将边缘计算与轻量化大语言模型结合。(1) 通过模型压缩、剪枝、量化和知识蒸馏等方法,构建保留大语言模型核心能力但参数量大幅减少的轻量级模型。(2) 采用云-边-端协同的分布式架构,将复杂推理任务交由云端处理,而边缘和终端设备则承担快速识别和低复杂度计算,从而在保证准确率的同时降低系统延迟。基于边缘计算的轻量化模型部署方案将推动通信制式识别向高效、低延迟方向发展,特别适合车联网、无人机编队和应急通信等需要毫秒级响应的场景。

3.3 联邦学习与隐私保护

在通信制式识别过程中,信号中往往包含敏感信息,如用户身份、通信内容和设备指令。随着数据隐私保护需求不断提升,传统集中式模型训练方式因需要将数据上传至中心服务器而面临隐私泄露风险。且分布式网络中数据分散、场景多样,也使得传统训练方式难以高效覆盖所有应用环境。

联邦学习为解决隐私与分布式数据利用问题提供了新思路。在联邦学习框架下,通信数据始终保留在本地,设备通过更新模型参数而非上传原始数据的方式参与全局模型训练,从而在不泄露隐私的前提下提升模型性能。将联邦学习与大语言模型结合,有望实现兼顾隐私保护和性能优化的通信制式识别框架。通过在用户设备或边缘计算节点上进行训练和推理,模型能够在不接触敏感数据的情况下,进行有效的通信协议识别。这种方式不仅可以保护用户隐私,还能在多设备协作的情况下提高识别精度和系统性能^[49]。

3.4 可解释性与知识增强

虽然大语言模型在通信制式识别中表现出强大的泛化与推理能力,但其“黑箱”特性使得输出结果难以被直观解释。在安全敏感场景中,仅给出识

别结果而缺乏可验证的理由,会导致运维人员难以信任模型^[50]。且单纯依赖数据驱动的大语言模型在面对快速演进的新标准时,缺乏对规范知识的及时吸收与利用能力。(1) 可以引入可解释性 AI 方法,为制式识别结果提供决策依据,使识别过程更透明。(2) 可以通过知识增强手段,将通信协议知识库、标准文档与大语言模型深度融合,构建“知识驱动+数据驱动”的混合模型。

可解释性与知识增强的引入,有望显著提升大语言在通信制式识别中的透明度与可控性。未来的识别系统不仅能够“给出答案”,还能够“解释原因”,并且能够快速吸收新标准和领域知识,这将增强系统在关键任务中的可信度,推动其在高安全需求的 5G/6G 智能网络中广泛应用。

3.5 鲁棒性与对抗安全

在复杂的无线电环境中,通信信号易受噪声、干扰及非理想硬件的影响,导致识别性能下降。且随着大模型的广泛应用,其也可能成为对抗攻击的目标,通过恶意构造的频谱样本来干扰识别结果^[51]。这些问题直接关系到通信系统的可靠性和安全性。(1) 可以研究鲁棒特征提取与抗干扰建模方法,增强大语言模型在低信噪比、多径衰落和频率偏移等非理想条件下的稳定性。(2) 可以探索对抗训练、输入扰动检测和置信度评估等机制,提高模型抵御对抗攻击的能力。

面向鲁棒性与对抗安全的研究将使大语言模型驱动的制式识别具备更强的工程可用性。在未来的应用中,无论是干扰密集的战术通信,还是对可靠性要求极高的医疗通信,模型都能保持稳定输出并抵御恶意攻击,从而提升整体系统的安全性与可信性。

3.6 标准化与可复现

当前基于大语言模型的通信制式识别研究多集中在实验验证阶段,缺乏统一的数据集、评测指标和实验规范,不利于不同研究间的横向对比和成果积累。同时,部分研究没有提供明确的实验配置,导致结果难以复现,不利于推动产业落地与标准化发展。(1) 可以推动构建跨场景、多协议、多信噪比条件的开放数据集,涵盖典型应用场景,为学术界和工业界提供统一的验证平台。(2) 应制定可复现实验规范,例如明确 Token 长度、频谱 Patch 大小、信噪比区间划分、延迟预算以及硬件算力约束等设置。

随着标准化与可复现研究的推进,通信制式识别领域将逐渐形成统一的评测体系,促进学术界和产业界的深度合作。未来的研究成果将更易于对比和复用,加速大语言模型在无线通信领域的工程落地与产业化推广。

4 结 论

通信制式识别作为无线通信领域中的一项关键技术,随着通信技术的迅速发展,面临着越来越复杂和多样化的挑战。无线通信制式不仅限于蜂窝通信,还包括 Wi-Fi、蓝牙、ZigBee 和 NB-IoT 等新兴通信技术。网络环境呈现出制式多样化、协议私有化与场景动态化的开放复杂特性,使得依赖“封闭集”假设和数据的传统机器学习与深度学习方法面临泛化能力不足、对未知制式识别失效。基于大语言模型的通信制式识别应运而生,为解决这一问题提供了新的技术方案。大语言模型凭借其强大的自适应能力、深度学习特性和少样本学习能力,能够从复杂的信号数据中自动提取有价值的特征,并进行准确的识别。与传统的基于特征提取的方法相比,大语言模型的应用不仅减少了对人工特征设计的依赖,还能够更好地适应动态变化的通信环境,并快速响应未知或新兴的通信协议。

本文系统梳理了从传统机器学习、深度学习到大语言模型驱动的识别技术发展脉络,探讨了大语言模型驱动方法的最新进展,深入探讨了其在泛化能力、可解释性与高效部署等方面面临的核心挑战,进一步挖掘了该方法在智能频谱管理和安全监测等领域的具体应用机遇,并对其在 5G/6G 智能网络治理中的未来发展前景进行了展望。尽管大语言模型在通信制式识别中展示了巨大的潜力,但大语言模型在通信信号处理中的应用仍处于早期阶段,面临计算效率、实时响应、隐私保护与对抗安全等多重挑战。未来研究需聚焦轻量化建模、跨模态对齐、联邦学习与可解释性增强等方向。大语言模型驱动的通信制式识别有望成为 6G 智能网络管理与频谱共生演进的核心支柱,为构建高效、可靠、安全的下一代无线通信系统奠定坚实基础。

参考文献:

- [1] GAUR S. Evaluation of mobile communication technology from scratch[J]. International Journal of Emerging Technologies and Innovative Research, 2018, 5(11): 232-238.
- [2] RAPPAPORT T S, XING Y, KANHERE O, et al. Wireless communications and applications above 100 GHz: Opportunities and challenges for 6G and beyond[J]. IEEE Access, 2019, 7: 78729-78757.
- [3] CITONI B, ANSARI S, ABBASI Q H, et al. Comparative analysis of an urban LoRaWAN deployment: Real world versus simulation[J]. IEEE Sensors Journal, 2022, 22(17): 17216-17223.
- [4] SINHA R S, WEI Y, HWANG S H. A survey on LPWA technology: LoRa and NB-IoT[J]. ICT Express, 2017, 3(1): 14-21.

- [5] CHEN M, MIAO Y, HAO Y, et al. Narrow band internet of things[J]. *IEEE Access*, 2017, 5: 20557-20577.
- [6] SONG L, HU X, ZHANG G, et al. Networking systems of AI: On the convergence of computing and communications[J]. *IEEE Internet of Things Journal*, 2022, 9(20): 20352-20381.
- [7] KUMAR K, PUNIA M. Network traffic classification techniques: A survey[C]//*Proceedings of 2023 Seventh International Conference on Image Information Processing (ICIIP)*. Solan, India: IEEE, 2023: 205-211.
- [8] SYED A S, SIERRA-SOSA D, KUMAR A, et al. IoT in smart cities: A survey of technologies, practices and challenges[J]. *Smart Cities*, 2021, 4(2): 429-475.
- [9] CLANCY T C, GOERGEN N. Security in cognitive radio networks: Threats and mitigation[C]//*Proceedings of the 3rd International Conference on Cognitive Radio Oriented Wireless Networks and Communications (CrownCom 2008)*. Singapore: IEEE, 2008: 1-8.
- [10] PASDAR A, KORONOTIS N, KESHK M, et al. Cybersecurity solutions and techniques for Internet of things integration in combat systems[J]. *IEEE Transactions on Sustainable Computing*, 2024, 10: 345-365.
- [11] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//*Proceedings of International Conference on Engineering Applications of Neural Networks*. Cham: Springer International Publishing, 2016: 213-226.
- [12] HUYNH-THE T, PHAM Q V, NGUYEN T V, et al. Automatic modulation classification: A deep architecture survey[J]. *IEEE Access*, 2021, 9: 142950-142971.
- [13] ZHOU R, LIU F, GRAVELLE C W. Deep learning for modulation recognition: A survey with a demonstration[J]. *IEEE Access*, 2020, 8: 67366-67376.
- [14] GIRMAY M, MAGLOGIANNIS V, NAUDTS D, et al. Technology recognition and traffic characterization for wireless technologies in ITS band[J]. *Vehicle Communications*, 2023, 39: 100563.
- [15] BITAR N, MUHAMMAD S, REFAI H H. Wireless technology identification using deep convolutional neural networks[C]//*Proceedings of 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*. Montreal, QC, Canada: IEEE, 2017: 1-6.
- [16] SHI Y, DAVASLIOGLU K, SAGDUYU Y E, et al. Deep learning for RF signal classification in unknown and dynamic spectrum environments[C]//*Proceedings of 2019 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*. Newark, NJ, USA: IEEE, 2019: 1-10.
- [17] 战权海,张雄伟,宋磊,等.基于改进Transformer的自动调制识别方法[J].*数据采集与处理*,2024,39(6): 1410-1419.
- ZHAN Quanhai, ZHANG Xiongwei, SONG Lei, et al. An automatic modulation recognition method based on improved transformer[J]. *Journal of Data Acquisition and Processing*, 2024, 39(6): 1410-1419.
- [18] RADFORD A, KIM J W, HALLACY C, et al. Learning transferable visual models from natural language supervision[C]//*Proceedings of International Conference on Machine Learning*. [S.l.]: PMLR, 2021: 8748-8763.
- [19] 孙姝君,彭盛亮,姚育东,等.基于深度学习的调制识别综述[J].*电信科学*,2024,37(5): 82-90.
SUN Shujun, PENG Shengliang, YAO Yudong, et al. A survey on modulation recognition based on deep learning[J]. *Telecommunications Science*, 2024, 37(5): 82-90.
- [20] ZHANG W, HUANG D, ZHOU M, et al. Open-set signal recognition based on transformer and wasserstein distance[J]. *Applied Sciences*, 2023, 13(4): 2151.
- [21] BROWN T, MANN B, RYDER N, et al. Language models are few-shot learners[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 1877-1901.
- [22] 李振星,赵晓蕾,刘伟承,等.基于Transformer的通信信号调制识别方法[J].*太赫兹科学与电子信息学报*,2022,20(12): 1311-1317.
LI Zhenxing, ZHAO Xiaolei, LIU Weicheng, et al. A communication signal modulation recognition method based on transformer[J]. *Journal of Terahertz Science and Electronic Information Technology*, 2022, 20(12): 1311-1317.
- [23] AKYILDIZ I F, KAK A, NIE S. 6G and beyond: The future of wireless communications systems[J]. *IEEE Access*, 2020, 8: 133995-134030.
- [24] PETROVA M, MÄHÖNEN P, OSUNA A. Multi-class classification of analog and digital signals in cognitive radios using support vector machines[C]//*Proceedings of 2010 7th International Symposium on Wireless Communication Systems*. York, UK: IEEE, 2010: 986-990.
- [25] HU H, WANG Y, SONG J. Signal classification based on spectral correlation analysis and SVM in cognitive radio[C]//*Proceedings of the 22nd International Conference on Advanced Information Networking and Applications (AINA 2008)*. Ginowan, Japan: IEEE, 2008: 883-887.
- [26] HE X, ZENG Z, GUO C. Signal classification based on cyclostationary spectral analysis and HMM/SVM in cognitive radio[C]//*Proceedings of 2009 International Conference on Measuring Technology and Mechatronics Automation*. Zhangjiajie, China: IEEE, 2009, 3: 309-312.
- [27] 周敏.数字通信信号制式自动识别与参数估计算法研究与实现[D].成都:西南交通大学,2013.
ZHOU Min. Research and implementation of automatic recognition and parameter estimation algorithms for digital communication signal formats[D]. Chengdu:

- Southwest Jiaotong University, 2013.
- [28] BKASSINY M, LI Y, JAYAWEERA S K. A survey on machine-learning techniques in cognitive radios [J]. *IEEE Communications Surveys & Tutorials*, 2012, 15(3): 1136-1159.
- [29] BEHURA S, KEDIA S, HIREMATH S M, et al. WiST ID—Deep learning-based large scale wireless standard technology identification[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(4): 1365-1377.
- [30] SU J, YAO J, XIE R, et al. DeepSpectrum: A deep-learning-based spectrum identification for wireless signals[C]//*Proceedings of 2023 19th International Conference on Mobility, Sensing and Networking (MSN)*. Nanjing, China: IEEE, 2023: 636-643.
- [31] HU L, WANG Y, FU X, et al. Enhanced wireless technology recognition method using energy-efficient spiking neural networks[C]//*Proceedings of 2024 Sixth International Conference on Next Generation Data-driven Networks (NGDN)*. Shenyang, China: IEEE, 2024: 183-187.
- [32] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, 4(3): 433-445.
- [33] SHAO M, BASIT A, KARRI R, et al. Survey of different large language model architectures: Trends, benchmarks, and challenges[J]. *IEEE Access*, 2024, 12: 188664-188706.
- [34] LOTFI F, RAJOLI H, AFGHAH F. LLM-Augmented deep reinforcement learning for dynamic O-RAN Network slicing[C]//*Proceedings of 2025 IEEE International Conference on Communications (ICC)*. Montreal, QC, Canada: IEEE, 2025: 3827-3832.
- [35] CHEN S, ZU Y, FENG Z, et al. RadioLLM: Introducing large language model into cognitive radio via hybrid prompt and token reprogrammings[EB/OL]. (2025-05-13) [2025-10-01]. <https://arxiv.org/abs/2501.17888>.
- [36] LI Y, YUAN L, ZHOU F, et al. KGAMC: A novel knowledge graph driven automatic modulation classification scheme[C]//*Proceedings of ICC 2024 IEEE International Conference on Communications*. Denver, CO, USA: IEEE, 2024: 4857-4862.
- [37] LIU J, LI Z. TF-Transformer: Temporal-frequency transformer for OFDM signal recognition[C]//*Proceedings of 2025 IEEE Wireless Communications and Networking Conference (WCNC)*. Milan, Italy: IEEE, 2025: 1-6.
- [38] CHEN J, ZHAO R, YANG C, et al. Wireless signal recognition based on ResNet-Transformer[C]//*Proceedings of the 11th International Conference on Intelligent Computing and Wireless Optical Communications (ICWOC)*. Chongqing, China: IEEE, 2023: 1-6.
- [39] ALAYRAC J B, DONAHUE J, LUC P, et al. Flamingo: A visual language model for few-shot learning [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 23716-23736.
- [40] WANG Y, HAN H, FENG Y, et al. Semantic communication empowered 6G networks: Techniques, applications, and challenges[J]. *IEEE Access*, 2025, 13: 28293-28314.
- [41] WAN X, SUN R, DAI H, et al. Better zero-shot reasoning with self-adaptive prompting[EB/OL]. (2023-05-23) [2025-10-01]. <https://arxiv.org/abs/2305.14106>.
- [42] ZHOU H, DENG Y, LIU X, et al. Goal-oriented semantic communications for 6G networks[J]. *IEEE Internet of Things Magazine*, 2024, 7(5): 104-110.
- [43] JIANG Y, CHEN Y, LI X, et al. FSTLLM: Spatio-temporal LLM for few shot time series forecasting[C]//*Proceedings of Forty-second International Conference on Machine Learning*. Vancouver, Canada: [s.n.], 2025.
- [44] AVELLANEDA D, MENDEZ D, FORTINO G. A tinyml deep learning approach for indoor tracking of assets[J]. *Sensors*, 2023, 23(3): 1542.
- [45] ZHOU F, LIU C, ZHANG H, et al. SpectrumFM: A foundation model for intelligent spectrum management[EB/OL]. (2025-05-02) [2025-10-01]. <https://arxiv.org/abs/2505.06256>.
- [46] SUN Y, LIU J, WANG J, et al. When machine learning meets privacy in 6G: A survey[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(4): 2694-2724.
- [47] NGUYEN V L, LIN P C, CHENG B C, et al. Security and privacy for 6G: A survey on prospective technologies and challenges[J]. *IEEE Communications Surveys & Tutorials*, 2021, 23(4): 2384-2428.
- [48] GREGORI A, AMICI F, BRILMAYER I, et al. A roadmap for technological innovation in multimodal communication research[C]//*Proceedings of International Conference on Human-Computer Interaction*. Cham: Springer Nature Switzerland, 2023: 402-438.
- [49] BAI J, CHEN D, QIAN B, et al. Federated fine-tuning of large language models under heterogeneous tasks and client resources[J]. *Advances in Neural Information Processing Systems*, 2024, 37: 14457-14483.
- [50] GUO W. Explainable artificial intelligence for 6G: Improving trust between human and machine[J]. *IEEE Communications Magazine*, 2020, 58(6): 39-45.
- [51] YUAN X, HE P, ZHU Q, et al. Adversarial examples: Attacks and defenses for deep learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(9): 2805-2824.